Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Doktorski studij Management

Marija Ileš Kaplan

EKONOMSKI PREDIKTORI NAMJERE RAĐANJA U REPUBLICI HRVATSKOJ

Doktorski rad

Osijek, 2025.

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Doktorski studij Management

Marija Ileš Kaplan

EKONOMSKI PREDIKTORI NAMJERE RAĐANJA U REPUBLICI HRVATSKOJ

Doktorski rad

Matični broj studenta: 419
E-mail: marija.iles@efos.hr
Mentor: izv. prof. dr. sc. Domagoj Karačić
Komentor: izv. prof. dr. sc. Marin Strmota

Osijek, 2025.

Josip Juraj Strossmayer University of Osijek
Faculty of Economics and Business in Osijek
Doctoral study Management

Marija Ileš Kaplan

ECONOMIC PREDICTORS OF FERTILITY INTENTIONS IN THE REPUBLIC OF CROATIA

Doctoral thesis

Osijek, 2025.

IZJAVA
O AKADEMSKOJ ČESTITOSTI,
PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA,
SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA
I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem kako je doktorski rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska.*
3. Kojom izjavljujem da sam suglasan/suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o visokom obrazovanju i znanstvenoj djelatnosti, (NN 119/2022).
4. Izjavljujem da sam autorica predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan s dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studenta: Marija Ileš Kaplan

JMBAG: 419

OIB: 82417460947

e-mail za kontakt: marija.iles@efos.hr

Naziv studija: Doktorski studij Management

Naslov rada: Ekonomski prediktori namjere rađanja u Republici Hrvatskoj

Mentor rada: izv. prof. dr. sc. Domagoj Karačić

Komentor: izv. prof. dr. sc. Marin Strmota

U Osijeku, kolovoz 2025. godine

Marija Ileš Kaplan

_____

Marija Ileš Kaplan

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Doktorski rad**
Ekonomski fakultet u Osijeku

Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija

EKONOMSKI PREDIKTORI NAMJERE RAĐANJA U REPUBLICI HRVATSKOJ

Marija Ileš Kaplan

Doktorski rad je izrađen u: Osijeku
Mentor: izv. prof. dr. sc. Domagoj Karačić
Komentor: izv. prof. dr. sc. Marin Strmota

Kratki sažetak doktorskog rada:
Doktorski rad istražuje prediktore namjere rađanja u sljedeće dvije godine primjenom proširenog konceptualnog modela konstruktima ekonomske sigurnosti, fiskalnih instrumenata javnih politika te regionalne razvijenosti. Poseban naglasak stavljen je na analizu ekonomskih ograničenja koja su doprinijela nastanku fertilnog jaza. Rezultati istraživanja ukazuju da je ekonomska sigurnost djelomično pozitivno povezana s namjerom rađanja u sljedeće dvije godine, međutim ekonomska sigurnost nije povezana s fertilnim jazom. Regije prema indeksu razvijenosti nisu značajan prediktor namjere rađanja kada se promatraju kao samostalna varijabla, iako u interakciji s drugim varijablama regionalni kontekst postaje statistički značajan prediktor. Rezultati primarnog istraživanja pokazuju pozitivnu povezanost fiskalnih instrumenata javnih politika i namjere rađanja. Zaključci empirijskog istraživanja ukazuju na potrebu za ciljanim demografskim strategijama i mjerama za smanjenje fertilnog jaza i stvaranje poticajnog okruženja za donošenje fertilitetnih odluka.

Broj stranica: 337
Broj slika: 11
Broj tablica: 42
Broj grafikona: 13
Broj literaturnih navoda: 438
Jezik izvornika: hrvatski
Ključne riječi: ekonomska sigurnost; fertilni jaz; fiskalni instrumenti; namjera rađanja; regionalna razvijenost

Datum obrane:
Stručno povjerenstvo za obranu:
1.
2.
3.
4. (zamjena)
5. (zamjena)

Doktorski rad je pohranjen u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek

BASIC DOCUMENTATION CARD
Josip Juraj Strossmayer University of Osijek **PHD thesis**
Faculty of Economics and Business in Osijek

Scientific Area: Social sciences
Scientific Field: Economics

ECONOMIC PREDICTORS OF FERTILITY INTENTIONS IN THE REPUBLIC OF CROATIA

Marija Ileš Kaplan

Thesis performed at: Osijek
Supervisor: Domagoj Karačić, Associate Professor
Consultative supervisor: Marin Strmota, Associate Professor

Short abstract:
The doctoral thesis analyses the predictors of fertility intentions over the next two years using an extended conceptual model that incorporates constructs of economic security, fiscal instruments of public policy and regional development. Particular attention is paid to analysing the financial constraints that have contributed to the emergence of the fertility gap. The research results show that economic security is partially positively related to fertility intentions over the next two years, but not to the fertility gap. The regions, when considered independently based on the development index, are not a significant predictor of fertility intentions, although the regional context becomes a statistically significant predictor when combined with other variables. The results of the primary research show a positive correlation between public fiscal instruments and fertility intentions. The conclusions of the empirical research underline the need for targeted demographic strategies and measures aimed at reducing the fertility gap and creating a favourable environment for fertility-related decisions.

Number of pages: 337
Number of figures: 11
Number of tables: 42
Number of graphs: 13
Number of references: 438
Original in: Croatian
Keywords: economic security; fertility gap; fiscal instruments; fertility intention; regional development

Date of the thesis defense:

Reviewers:
1.
2.
3.
4.
5.

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library of Osijek, Europska avenija 24, Osijek; Josip

Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics and Business in Osijek, Trg Lj. Gaja 7, Osijek

Ekonomski prediktori namjere rađanja u Republici Hrvatskoj

SAŽETAK

Republika Hrvatska jedna je od zemalja koje prolaze brojne socio-ekonomske promjene, pri čemu su mnogobrojne negativne promjene zabilježene u području demografije. Republika Hrvatska je u posttranzicijskoj etapi demografskog razvoja (odnosno drugoj demografskoj tranziciji), pri čemu je evidentan prijelaz ukupne stope fertiliteta s niske pozitivne stope na razinu koja više ne osigurava generacijsku obnovu. Osim navedenog, brojni kulturološki trendovi prema postmodernim stavovima i normama, kao što su individualnost i samoostvarenje imaju izniman utjecaj na smanjenje stope fertiliteta te se mogu pripisati trenutnim demografskim tranzicijskim procesima. Zbog činjenice da javne politike, kroz različite instrumente, mogu utjecati na promjene ka pozitivnim demografskim trendovima, u ovom doktorskom radu im je posvećena posebna pozornost. Negativni demografski trendovi s kojima se suočava Republika Hrvatska iziskuju daljnje napore u kreiranju novih mjera javnih politika, ali i prilagodbi postojećih, kojima će se ciljano djelovati na povećanje fertiliteta kroz pomoć u financiranju izravnih i neizravnih troškova odgoja djece te smanjenje jaza između željenog i ostvarenog broja djece. Kako bi se to postiglo, nužno je razmotriti koji ekonomski prediktori utječu na namjeru rađanja.

Prethodna su istraživanja identificirala različite utjecajne čimbenike na namjeru rađanja, no i dalje postoji neistražen prostor, posebice ekonomskih prediktora koji utječu na namjeru rađanja, ali i prediktora koji utječu na fertilni jaz kod žena u Republici Hrvatskoj. Slijedom navedenog proizlaze svrha i cilj doktorskog rada. Cilj ovog doktorskog rada je analizirati povezanost ekonomskih prediktora i reproduktivnih namjera u Republici Hrvatskoj. Identificirani ekonomski prediktori, na temelju dosadašnjih istraživačkih spoznaja, odnose se na: ekonomsku sigurnost (sigurnost posla, financijska sigurnost, vlasništvo nad nekretninom), fiskalne instrumente javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi) i regionalnu razvijenost. Poseban naglasak stavlja se na identificiranje i evaluaciju ekonomskih ograničenja s kojima se suočavaju žene koje već imaju djecu, a koja su pridonijela razlici između željenog i stvarno ostvarenog broja djece.

Koristeći prošireni model Teorije planiranog ponašanja, ovo istraživanje donosi sveobuhvatan konceptualni okvir te analizira povezanost ekonomske sigurnosti, fiskalnih instrumenata javnih politika, regionalne razvijenosti i namjere rađanja u sljedeće dvije godine.

Za prikupljanje podataka je korišten visokostrukturirani istraživački instrument temeljen na postojećim mjernim ljestvicama i prethodnim istraživačkim spoznajama. Konačan uzorak obuhvatio je 1036 žena, starosti 22 do 49 godina, prostorno obuhvaćajući jedinice područne (regionalne) samouprave podijeljene u četiri skupine sukladno indeksu razvijenosti. Za testiranje hipoteza istraživanja korištena je logistička regresija, Kruskall-Wallisov test te Spearmanov koeficijent korelacije ranga.

Rezultatima istraživanja ukazuju se na djelomičnu pozitivnu povezanost ekonomske sigurnosti i namjere rađanja. Naime, s aspekta ekonomske sigurnosti, varijable sigurnost posla i financijska sigurnost su se pokazale statistički značajnima i pozitivno povezanima s namjerom rađanja u sljedeće dvije godine. Ispitujući potpuno vlasništvo nad nekretninom, u ovom istraživanju rezultati ukazuju na negativnu povezanost s namjerom rađanja u sljedeće dvije godine. Istraživanjem su se nastojali utvrditi i čimbenici koji su doprinijeli fertilnom jazu kod žena koje već imaju dijete/djecu te je utvrđeno da ekonomska sigurnost nije povezana s fertilnim jazom, već su se značajnijim pokazali čimbenici koji se odnose na druge životne okolnosti. U Republici Hrvatskoj, regije prema indeksu razvijenosti nisu se pokazale značajnim prediktorom namjere rađanja kada se promatraju samostalno, no regionalni kontekst postaje statistički značajan u interakciji s drugim varijablama. Fiskalni instrumenti javnih politika (izravni novčani transferi, neizravni novčani transferi i naknade u naravi i subvencije) statistički su značajan prediktor namjere rađanja u sljedeće dvije godine.

Iz navedenog su proizašle smjernice usmjerene na sustavno unaprjeđenje ekonomskih i socijalnih uvjeta s ciljem poticanja rađanja, smanjenja jaza između željenog i ostvarenog broja djece te dugoročnog povećanja stope fertiliteta. Njihova provedba temelji se na integriranom pristupu koji obuhvaća primjenu fiskalnih instrumenata, učinkovitih javnih politika te mjera za poticanje usklađenosti profesionalnog i obiteljskog života. Takav strateški okvir omogućuje ciljano djelovanje na demografske izazove i doprinosi stvaranju poticajnijeg okruženja za donošenje reproduktivnih odluka.

Ključne riječi: ekonomska sigurnost; fertilni jaz; fiskalni instrumenti; namjera rađanja; regionalna razvijenost

Economic Predictors of Fertility Intentions in the Republic of Croatia

ABSTRACT

The Republic of Croatia is one of the countries undergoing numerous socio-economic changes, many of which have led to negative demographic trends. Croatia is currently in the post-transition phase of demographic development, also known as the second demographic transition, characterised by a decline in the total fertility rate from a slightly positive level to a level insufficient for generational change. In addition, postmodern cultural trends emphasising individualism and self-fulfilment have a significant impact on declining fertility rates and are closely linked to the current demographic transition processes.

Since public policies can influence positive demographic changes with various instruments, their role is given special attention in this doctoral thesis. The negative demographic trends Croatia is facing require the further development of new policies as well as the adaptation of existing policies to directly address fertility challenges. These measures should aim to reduce the gap between the desired and actual number of children and reduce the financial burden of raising children through targeted support for direct and indirect costs. To achieve this, it is important to identify the economic predictors that influence fertility intentions.

Previous research has identified various factors influencing fertility intentions; however, there is still a knowledge gap, particularly with regard to the economic predictors of fertility intentions and the fertility gap among women in Croatia. Against this background, the purpose and aim of this doctoral thesis emerge. The main objective is to analyse the relationship between economic predictors and reproductive intentions in the Republic of Croatia. Based on existing research, the following economic predictors were identified: economic security (job security, financial stability, home ownership), fiscal instruments of public policy (direct cash transfers, indirect cash transfers and benefits in kind) and regional development. A particular focus is on identifying and assessing the economic constraints faced by women who already have children, which has contributed to the discrepancy between desired and actual family size.

Using an extended model of the theory of planned behaviour, this research provides a comprehensive conceptual framework to examine the relationship between economic security, fiscal instruments, regional development and fertility intentions over a two-year period. Data

collection was conducted using a highly structured research instrument based on validated measurement scales and previous empirical findings. The final sample comprised 1,036 women aged 22 to 49 years from administrative units, who were categorised into four categories according to their development index. The hypotheses were tested using logistic regression, the Kruskal-Wallis test and the Spearman rank correlation coefficient.

The results indicate a partial positive correlation between economic security and fertility intentions. In particular, job security and financial stability were statistically significant and positively associated with the intention to have a child within the next two years. Complete home ownership, however, showed a negative correlation with fertility intentions. The study also looked at factors contributing to the fertility gap among women who already have children and found that economic security was not significantly associated with the gap; instead, other life circumstances played a greater role. Region was not a significant predictor of fertility intentions in an independent analysis by development index, although regional context became statistically significant when considered in interaction with other variables. Fiscal instruments of public policy including direct and indirect cash transfers as well as benefits in kind and subsidies were found to be significant predictors of fertility intentions.

Based on these results, strategic guidelines were formulated that aim to systematically improve economic and social conditions to promote childbearing, reduce the gap between desired and actual fertility and increase fertility rates in the long term. The implementation of these guidelines is based on an integrated approach that combines fiscal instruments, effective public policies and measures to promote the reconciliation of work and family life. This strategic framework enables targeted responses to demographic challenges and contributes to creating a more favourable environment for reproductive choices.

Keywords: economic security; fertility gap; fiscal instruments; fertility intention; regional development

Za Noemi

Tvoje rođenje dalo je dublji smisao životu i nadam se da ćeš jednog dana u ovim stranicama prepoznati koliko je tvoja prisutnost bila važna u ostvarenju ovog sna.

Mojem suprugu i roditeljima

Vaša bezuvjetna ljubav, podrška i vjera u mene bile su snaga u svim izazovima ovog puta.

SADRŽAJ

1. UVOD 1

1.1. Problem istraživanja 2

1.2. Svrha i ciljevi istraživanja 6

1.3. Hipoteze istraživanja 8

1.4. Metode znanstvenog istraživanja 15

1.5. Očekivani znanstveni doprinos 15

1.6. Struktura doktorskog rada 17

2. DEMOGRAFSKI TRANZICIJSKI PROCESI I TRENDOVI U REPUBLICI HRVATSKOJ 19

2.1. Predtranzicijska etapa 22

2.2. Etapa demografske tranzicije 23

2.2.1. Rana tranzicijska podetapa 24

2.2.2. Središnja (centralna) tranzicijska podetapa 24

2.2.3. Kasna tranzicijska podetapa 25

2.3. Posttranzicijska etapa - Druga demografska tranzicija 25

2.4. Demografski trendovi i izazovi u Republici Hrvatskoj 30

3. EKONOMSKE TEORIJE FERTILITETA 39

3.1. Teorija averzije prema riziku 40

3.2. Teorija smanjenja neizvjesnosti 41

3.3. Teorija konjunkturnog djelovanja 42

4. ULOGA I ZNAČAJ JAVNIH POLITIKA U FUNKCIJI POVEĆANJA FERTILITETA 45

4.1. Populacijska i obiteljska politika 46

4.2. Eksplicitna i implicitna pronatalitetna politika u Republici Hrvatskoj 52

4.3. Namjera rađanja kod žena 67

4.3.1. Čimbenici namjere rađanja s ekonomskog aspekta 70

4.3.1.1. Ekonomska nesigurnost 71

4.3.1.2. Fiskalni instrumenti javnih politika 77

4.3.1.3. Pozadinski čimbenici 89

4.3.2. Usklađivanje obiteljskog i poslovnog života žena 92

4.3.3. Odgađanje rađanja i fertilni jaz 100

4.4. Fiskalni instrumenti u domeni socijalne politike u Republici Hrvatskoj i zemljama članicama Europske unije 105

5. EMPIRIJSKO ISTRAŽIVANJE EKONOMSKIH PREDIKTORA NAMJERE RAĐANJA U REPUBLICI HRVATSKOJ 131

5.1. Metodologija istraživanja 131

5.2. Dizajn istraživanja 133

5.3. Okvir izbora uzorka 138

5.4. Metode i proces prikupljanja podataka 141

5.4.1. Arhivsko istraživanje 142

5.4.2. Anketno istraživanje 142

5.5. Metode ocjenjivanja pouzdanosti i valjanosti mjerenja 146

5.6. Statističke metode analize 157

5.6.1. Deskriptivna analiza 158

5.6.2. Kruskal - Wallisov test i Mann – Whitney U test nezavisnih uzoraka 158

5.6.3. Probit i logit regresijski model 160

5.6.4. Korelacijska analiza 169

5.7. Rezultati istraživanja 170

5.7.1. Rezultati deskriptivne analize 171

5.7.2. Istraživanje povezanosti ekonomske sigurnosti, fertilnog jaza i namjere rađanja 190

5.7.3. Istraživanje povezanosti fiskalnih instrumenata javnih politika i namjere rađanja 207

5.7.4. Istraživanje razlike u namjeri rađanja ovisno o indeksu razvijenosti jedinica područne (regionalne) samouprave 223

6. RASPRAVA O REZULTATIMA ISTRAŽIVANJA I USPOREDBA S PRETHODNIM ISTRAŽIVANJIMA 225

7. ZAKLJUČAK 238

7.1. Ograničenja provedenog istraživanja i preporuke za buduća istraživanja 242

7.2. Preporuke koje proizlaze iz rezultata istraživanja 244

8. LITERATURA 248

Popis tablica 289

Popis slika 291

Popis grafikona 292

Prilozi 293

Prilog 1: Upitnik 293

Prilog 2: Povezanost sigurnosti posla i namjere rađanja u sljedeće dvije godine 324

Hipoteza H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja, mjerenje namjere rađanja M1 324

Opcija 2 324

Hipoteza H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja, mjerenje namjere rađanja M3 326

Prilog 3: Povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine ...328

Prilog 4: Povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine 329

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M1 329

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M2 329

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M2 330

Prilog 5: Povezanost izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine 331

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M1 331

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M2 331

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M3 332

Prilog 6: Povezanost neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine 333

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M1 333

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M2 333

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M3 334

Prilog 7: Povezanost transfera u naravi i namjere rađanja u sljedeće dvije godine 335

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M1 335

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M2 335

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M3 336

Popis objavljenih radova 337

1. UVOD

Republika Hrvatska već se dugi niz godina suočava s demografskim izazovima, prvenstveno s povećanjem starije populacije uz istovremeno smanjenje reproduktivne baze i broja mladih. Kao i većina europskih zemalja, nalazi se u posttranzicijskoj etapi demografskog razvoja, odnosno, prolazi kroz drugu demografsku tranziciju.

U toj fazi posebno je važno praćenje fertiliteta – demografskog procesa koji, uz mortalitet i migracije, može promijeniti broj stanovnika nekog područja. Fertilitet se mjeri stopom totalnog fertiliteta koja pokazuje prosječni očekivani broj živorođenih koje bi žena rodila tijekom fertilne dobi (15 do 49 godina). Stopa totalnog fertiliteta od 2,1 djeteta često se u literaturi i javnosti spominje kao prihvatljiva brojčana razina generacijske zamjene, dok Republika Hrvatska već desetljećima bilježi stope ispod te razine. Posljednja zabilježena stopa totalnog fertiliteta iz 2023. godine iznosi 1,47. Usporedbe radi, 2012. godine ista ta stopa iznosila je 1,51 (Eurostat, 2025c). Popis stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine ukazuje na nastavak negativnog trenda u ukupnom broju obitelji, ali i u broju obitelji s djecom. Ukupan broj obitelji u 2021. godini iznosio je 1 104 395, što predstavlja pad od 8,21 % u odnosu na 1971. godinu. Popisom je, također, zabilježen porast broja obitelji bez djece (za 38 497 obitelji u odnosu na 1971. godinu). Još jedna važna značajka posttranzicijske faze je rastući trend odgođenog rađanja pri čemu se povećava dobna granica ulaska u brak, a s time i spremnost na prvo dijete. Prema podatcima Eurostata (2023a), prosječna dob majke pri rođenju prvog djeteta u Republici Hrvatskoj povećala se s 23,5 godina (1960.) na 29,2 godina (2021.), što predstavlja značajno skraćivanje reproduktivnog razdoblja žene.

Kao posljedicu smanjenja fertiliteta u Europi, Letablier i sur. (2009) navode dramatično smanjenje prosječne veličine obitelji. Naime, sve je manje obitelji s dvoje ili više djece, dok su obitelji s jednim djetetom uobičajene u srednjoj, istočnoj i južnoj Europi, pri čemu je prisutan trend porasta broja žena mlađe životne dobi bez djece. Važno je naglasiti da među ženama mlađe životne dobi bez djece prevladava visoka obrazovna razina, što je povezano s dinamikom tržišta rada i izazovima usklađivanja privatnog i poslovnog života. Nadalje, smanjenje reproduktivne motivacije među mlađom populacijom u Republici Hrvatskoj očituje se u ekonomskim čimbenicima poput egzistencijalnih problema kao što su nezaposlenost, loši

stambeni uvjeti, prekarni rad, atipično radno vrijeme i financijski trošak podizanja djece (Čipin i Međimurec, 2017; Akrap, 2005). Druga kontinuirana premisa dosadašnjih istraživanja fertiliteta zasnovana je na dinamičnijoj evoluciji kulture i ideja u modernim civilizacijama te nestajanje tradicionalnih civilizacijskih vrijednosti, posebice u 21. stoljeću (Lesthaeghe, 2020; Zaidi i Morgan, 2017; Wertheimer – Baletić, 2016). Stoga je izbor o rađanju djece uključen u promjenjivi društveni kontekst koji naglašava rastuću ravnopravnost spolova, rastuću osobnu autonomiju u odnosu na institucionalne i normativne regulative te povećane težnje za samoizražavanjem i samoostvarenjem, što je u skladu s idejnim pristupom koji se obično naziva drugom demografskom tranzicijom. Jedna od ključnih karakteristika druge demografske tranzicije jest trend odgađanja rađanja, kao i rastuća učestalost dobrovoljnog izbora života bez djece. Također, ona je nastavak promjena i trendova nastalih u prvoj demografskoj tranziciji koja se očituje kroz troetapni model razvoja stanovništva: 1) predtranzicijska etapa, 2) etapa demografske tranzicije (rana, središnja i kasna tranzicijska podetapa) te 3) posttranzicijska etapa. Wertheimer-Baletić (2016: 49) ističe da je "u razdoblju druge demografske tranzicije, odnosno posttranzicijske etape u odnosu na prvu demografsku tranziciju došlo do brojnih promjena u demografskim i socio-demografskim pokazateljima, među kojima dominira slabljenje utjecaja braka uz dominaciju utjecaja pojedinca i pluraliteta životnih zajednica (kohabitacija i druge „partnerske zajednice")". Ove promjene imale su zamjetan utjecaj na daljnje smanjenje nataliteta i fertiliteta, što se primarno očitovalo u smanjenju broja djece po obitelji te istodobnom porastu broja zajednica bez djece.

Razumijevanje uzroka pada fertiliteta kompleksno je i zahtijeva interdisciplinarni pristup različitih znanstvenih područja. Stoga se u ovome radu nastoji utvrditi koji sve čimbenici utječu na fertilitet (Čipin i Međimurec, 2017), ali i buduće fertilitetne namjere, koje se u znanstvenoj literaturi navode kao pouzdan prediktor stvarnog reproduktivnog ponašanja (Westoff i Ryder, 1977; Schoen i sur., 1999).

1.1. Problem istraživanja

Uslijed negativnih demografskih trendova, nužno je utvrditi prediktore koji utječu na fertilitet. S ekonomskog aspekta, postoji istraživački jaz u ovome području te je potreban širi pristup analizi i istraživanju ovog problema. Naime, prema trenutno dostupnim informacijama kojima doktorandica raspolaže, u Republici Hrvatskoj nije provedeno sveobuhvatno istraživanje (osobito ne primarno istraživanje) ekonomskih prediktora namjere rađanja,

uključujući i prediktore koji utječu na jaz između željenog i ostvarenog broja djece. Nizak natalitet ne predstavlja samo demografski, već i problem javnih financija i uloge države jer utječe na starenje populacije i održivost mirovinskog sustava, funkcioniranje obrazovnog sustava, tržišta rada i kvalitete života radno aktivnog stanovništva te uređenosti po pitanju zdravstvene i socijalne skrbi. Stoga je nužna financijska prilagodba na svim razinama vlasti i socijalnim programima kako bi se odgovorilo na demografske promjene i osigurala dugoročna fiskalna održivost države.

Pod realističnom premisom da je imati dijete posljedica izbora, proučavanje namjere rađanja zauzelo je središnje mjesto u demografskim istraživanjima i važan je čimbenik demografske politike. Na odluku o rađanju utječu različite životne okolnosti i čimbenici. Dosadašnja istraživanja pokazala su da se čimbenici koji utječu na fertilitet mogu podijeliti u sljedeće skupine: društvene, ekonomske, demografske i kulturološke (Čipin i Međimurec, 2017).

Ovo se istraživanje temelji na Teoriji planiranog ponašanja (Ajzen, 1991) prema kojoj se upravo namjera za poduzimanjem određenog ponašanja smatra najboljim prediktorom stvarnog ponašanja, a u ovom slučaju na primjeru istraživanja namjere rađanja i ekonomskih prediktora koji čine obrasce ponašanja i planiranja kod žena te utječu na kvalitetu života obitelji s djecom i bez djece.

Društvene promjene u srednjoj i istočnoj Europi tijekom 1990-ih i 2000-ih dovele su do ubrzanih demografskih transformacija, osobito u obrascima rađanja djece (Basten i Frejka, 2015). Došlo je do značajnog odgađanja stupanja u brak i rađanja, a posljedično i do smanjenja stopa fertiliteta. Nije moguće jednoznačno utvrditi koji su razlozi smanjenja fertiliteta, ali npr. Letablier i sur. (2009) razloge smanjenja fertiliteta pripisuju odgađanju rađanja, no ne može se sa sigurnošću tvrditi je li odgađanje rađanja dovelo do kvantitativnog učinka broja rođene djece ili je dovelo do temporalnog učinka[1]. Pogled na dobno-specifične stope fertiliteta sugerira da bi učinak tempa mogao biti važan u određivanju razine plodnosti. Međutim, stope fertiliteta za žene mlađe od 30 godina neprestano su se smanjivale posljednjih desetljeća i taj se trend nastavlja u većini država članica Europske unije. S druge strane, fertilitet nakon tridesete

[1] Temporalni učinak – vremenski učinak, odnosno vrijeme rađanja.

godine raste, što ukazuje na to da mnoge žene odgađaju majčinstvo. Osim odgađanja rađanja, kao dodatni problem nameće se i negativan jaz između željenog i ostvarenog broja djece.

Negativni fertilni trendovi mogu se ublažiti kontinuiranim provođenjem sveobuhvatnih javnih politika koje bi ciljano i putem različitih mjera trebale biti usmjerene na povećanje fertiliteta. U tom segmentu razlikuju se i postoje dvije vrste politika populacijska i obiteljska politika. Stropnik (1995) populacijsku politiku sagledava kao makroorijentaciju, dok obiteljsku politiku kao mikroorijentaciju. Autorica navodi da na populacijsku politiku utječu makrodeterminante nataliteta, tj. determinante koje funkcioniraju na razini cjelokupnog društva kao što su ideološka, zakonska, filozofska i ostala obilježja društva. S druge strane, mikrodeterminante, odnosno determinante nataliteta na razini obitelji poput troškova i koristi djece spadaju u obilježje obiteljske politike. Reprodukcijska funkcija glavna je veza između populacijske i obiteljske politike (Malačić, 1994 u Stropnik, 1995).

Provedena istraživanja sugeriraju da mjere u okviru obiteljske politike utječu na rađanje i pomažu u nadoknađivanju povećanih troškova koji dolaze s rađanjem djece (Zhang i sur., 2023; Laroquen i Salanié, 2004; Björklund, 2006; Milligan, 2002). Dodatno uporište navedenom daju empirijska istraživanja koja su ukazala na pozitivan, statistički značajan utjecaj mjera obiteljskih politika na rađanje (Zhang i sur., 2023; Cowan i Wyndham Douds, 2022; Bano i sur., 2021; Laroque i Salanié, 2014; Thévenon i Gauthier, 2011; Luci i Thévenon, 2013; Gauthier, 2007; Monnier, 1990; Duclos i sur., 2001; González, 2013; Cohen i sur., 2013; Blanchet i Ekert-Jaffé, 1994; Ekert, 1986; Buttner i Lutz, 1990; Björklund, 2006).

Eksperimentalno istraživanje, koje su provele Cowan i Wyndham Douds (2022) na uzorku žena starosti od 15 do 44 godine, potvrđuje da novčani transferi povećavaju kratkoročne stope plodnosti na Aljasci tijekom prve dvije godine nakon isplate, osobito među socijalno ugroženim stanovništvom. Stoga se očekuje da će mjere obiteljske politike kao što su dječji i obiteljski novčani doplatci, porezne olakšice za djecu, subvencije za skrb o djeci te potpore za rodiljni i roditeljski dopust imati pozitivan učinak na fertilitet smanjenjem izravnih ili neizravnih (oportunitetnih) troškova rađanja djece ili povećanje prihoda pojedinca. Moguće je pretpostaviti da obiteljske politike utječu na reprodukciju kroz tri odvojena kanala: njihov utjecaj na troškove vezane uz djecu (kao što su subvencije), prihod pojedinca (kao što su novčani transferi) i/ili preferencije pojedinca (Gauthier, 2007). Ovaj je ekonomski model vrlo

utjecajan u literaturi i u središtu je pretpostavljenog odnosa između javnih politika i fertilitetnog (reproduktivnog) ponašanja.

Ako ne postoje konkretne mjere populacijske politike, mjerama obiteljske politike može se samo ograničeno djelovati na povećanje fertiliteta i ne postoji konsenzus o tome odnosi li se učinak javnih politika samo na vrijeme rađanja ili na povećanje fertiliteta (Stropnik, 1995; Hoem, i sur. 2001; Gauthier, 2007; Letablier i sur., 2009; Duclos i sur., 2001; Sleebos, 2003). Međutim, odsutnost novčanih potpora u okviru obiteljskih politika vjerojatno bi dovela do još niže stope fertiliteta (Stropnik, 1995; Gauthier, 2007).

Kako je već ranije spomenuto, mjere obiteljske politike pokušavaju neutralizirati ili barem smanjiti negativan utjecaj psiholoških, socijalnih i ekonomskih ograničenja i prepreka za osnivanje obitelji, kao i jaz između željenog i ostvarenog broja djece (Goldstein i sur., 2003; Stropnik, 1995). Upravo financijska sredstva u obliku novčanih potpora pomažu neutralizirati negativan utjecaj ekonomskih ograničenja.

Na temelju iznesenih istraživačkih i znanstvenih spoznaja, problem istraživanja doktorskog rada ogleda se u nedovoljno istraženim ekonomskim i financijskim prediktorima koji potiču ili sprječavaju namjeru rađanja ili mogu dovesti do jaza između željenog i ostvarenog broja djece kod žena u Republici Hrvatskoj. Ovo je u skladu s preporukama koje naglašavaju potrebu za zajedničkim interdisciplinarnim pristupom ekonomskih i drugih znanosti u istraživanju fertiliteta kako bi se dobili cjelovitiji modeli i kvalitetnije analize. Werding (2014) naglašava da su odluke o roditeljstvu pod utjecajem različitih trendova i da ih sve treba uzeti u obzir pri izradi modela za predviđanje fertiliteta. Među nedostatcima postojećih modela posebno ističe važnost uključivanja željenog broja djece, a ne samo stvarnog te državne potpore kao važnog faktora u određivanju fertiliteta. No, prije svega, nužno je utvrditi koji prediktori utječu na namjeru rađanja kako bi se moglo ciljano djelovati. Utvrđivanjem prediktora namjere rađanja te njihovim razumijevanjem moguće je identificirati načine poticanja povećanja fertiliteta.

Na temelju proučene literature, identificirani su ključni ekonomski prediktori namjere rađanja:

- ekonomska sigurnost (sigurnost posla, financijska sigurnost, vlasništvo nad nekretninom)

- fiskalni instrumenti javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi)
- regionalna razvijenost.

Za potrebe istraživanja doktorskog rada ključno je analizirati međuovisnost pozitivnih i negativnih utjecaja ekonomskih prediktora na namjeru rađanja u Republici Hrvatskoj. U okviru doktorskog rada provedeno je istraživanje o namjeri rađanja u sljedeće dvije godine na uzorku žena 22 do 49 godina s ciljem utvrđivanja ekonomskih prediktora koji utječu na tu namjeru, odnosno koji dovode do jaza između željenog i ostvarenog broja djece.

Identificirani problemi, dostupne spoznaje o njihovu rješavanju, postavljene hipoteze i ciljevi istraživanja te dostupni podatci čine metodološki okvir za istraživanje.

1.2. Svrha i ciljevi istraživanja

Svrha i cilj doktorskog rada je istražiti utjecaj ekonomskih prediktora na namjeru rađanja u Republici Hrvatskoj. Osim toga, nužno je odrediti i utvrditi ograničavajuće ekonomske prediktore kod žena koje već imaju djecu, a koji su pridonijeli negativnom jazu između željenog i ostvarenog broja djece.

Namjera rađanja, u ovom doktorskom radu, odnosi se na planiranu odluku žena (starosti između 22 i 49 godina) da imaju dijete/još jedno dijete u određenom vremenskom razdoblju (sljedeće dvije godine). Ova namjera odnosi se na svjesnu želju i namjeru da postanu majke i/ili da prošire svoju obitelj.

Istraživačke spoznaje dobivene primarnim istraživanjem imaju za cilj i usmjerene su na oblikovanje važnih preporuka u vidu ciljanih aktivnosti usmjerenih prema smanjenju jaza između željenog i ostvarenog broja djece, odnosno povećanja fertiliteta kod žena koje nemaju djecu. Iz navedenog primarnog cilja proizlaze i ostali specifični ciljevi koji su kategorizirani prema teorijskom, metodološkom i aplikativnom dijelu.

Iz navedenog primarnog cilja proizlaze i ostali specifični ciljevi koji su kategorizirani prema teorijskom, metodološkom i aplikativnom dijelu.

Ciljevi teorijskog dijela:

- definirati i opisati ekonomsku teoriju fertiliteta
- definirati i opisati procese demografske tranzicije
- kreirati sveobuhvatni model namjere rađanja temeljen na Teoriji planiranog ponašanja (engl. *Theory of planned behavior*, *TPB*), proširen ekonomskim prediktorima (ekonomska sigurnost, fiskalni instrumenti javnih politika, regionalna razvijenost)
- prikazati i analizirati ulogu javnih politika u demografskoj revitalizaciji kroz poticanje povećanja fertiliteta
- prikazati i analizirati rezultate prethodnih istraživanja
- pridonijeti razvoju teorijskog okvira koji će ukazati na interakciju između ekonomskih prediktora i namjere rađanja te na taj način obogatiti postojeće spoznaje o ovom važnom aspektu društvenog i demografskog ponašanja.

Ciljevi metodološkog i empirijskog dijela:

- testirati povezanost odabranih ekonomskih prediktora (ekonomska sigurnost, fiskalni instrumenti javnih politika, regionalna razvijenost) i namjere rađanja
- testirati povezanost ekonomske nesigurnosti (nesigurnost posla, financijska nesigurnost, vlasništvo nad nekretninom) i jaza između željenog i ostvarenog broja djece
- usporediti dobivene empirijske rezultate s rezultatima prethodnih istraživanja.

Ciljevi aplikativnog dijela:

- povezati i argumentirati ekonomske prediktore s namjerom rađanja kao važan dio strategije demografske revitalizacije
- oblikovati zaključke rezultata istraživanja za javne politike sa stajališta ekonomskih prediktora.
- identificirati i predložiti potencijalne strategije i mjere koje mogu pozitivno utjecati na namjeru rađanja te smanjiti jaz između željenog i ostvarenog broja djece.

1.3. Hipoteze istraživanja

Na temelju postavljenih ciljeva, postojeće literature te rezultata dosadašnjih empirijskih istraživanja, postavljaju se sljedeće hipoteze:

H1: Postoji statistički značajna pozitivna povezanost između ekonomske sigurnosti i namjere rađanja.
H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja.
H1b: Postoji statistički značajna pozitivna povezanost financijske sigurnosti i namjere rađanja.
H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja.

H2: Postoji statistički značajna negativna povezanost ekonomske sigurnosti i jaza između željenog i ostvarenog broja djece.

Hipoteze H1 i H2 ispituju odnos ekonomske sigurnosti i namjere rađanja u sljedeće dvije godine te fertilnog jaza.
Hipoteza H2 pretpostavlja da viša razina ekonomske sigurnosti smanjuje razliku između željenog i ostvarenog broja djece.

Među varijablama koje negativno utječu na namjeru rađanja, ekonomska nesigurnost može igrati važnu ulogu (Novelli i sur., 2021). Ekonomska nesigurnost „proizlazi iz izloženosti pojedinaca, zajednica i zemalja nepovoljnim događajima, te iz njihove nesposobnosti da se nose sa skupim posljedicama tih događaja i da se oporave od njih“ (Ujedinjeni Narodi, 2008: vi).

Ekonomska nesigurnost i neizvjesnost u literaturi su identificirane kao ključni čimbenici koji utječu na odgađanje rađanja (Kreyenfeld, 2010) i dovode do smanjenja stopa fertiliteta (Koahler i sur., 2002). Nizak stupanj bogatstva kućanstva značajno i pozitivno utječe na odluku o odgađanju rađanja prvog djeteta (Modena i sur., 2014). Osim toga, žene koje imaju ugovor na određeno vrijeme odgađaju odluku o majčinstvu (Pieroni i sur., 2023; Alderotti i

sur., 2021; Rica i Iza, 2005; Vignoli i sur., 2012). Nepotpuna kontrola i neizvjesnost u vezi s odlukama o začeću, sklapanjem i razvodom braka, potrošnjom i štednjom, promjenama na tržištu rada i drugim promjenjivim čimbenicima utječu na odluku o tome hoće li parovi imati dijete ili ne, i kada (Norling, 2021; Heckman i Willis, 1976). Budući da ovi čimbenici mogu spriječiti ljude da savršeno predvide stvarni broj djece u odnosu na onaj broj koji kažu da namjeravaju imati, nerijetko dolazi do jaza između željenog i ostvarenog broja djece (Bachrach i Morgan, 2013). Chesnais (1999) je upotrijebio izraz „fertilni jaz" (engl. *fertility gap*) kako bi opisao veliku razliku između promatrane stope fertiliteta i željenog broja djece. Razumijevanje jaza između željene veličine obitelji i stvarnog fertiliteta važno je jer se usredotočuje na razloge koji stoje iza nemogućnosti žena da postignu željeni broj djece. Osim toga, ima implikacije na politiku i programske intervencije povezane s planiranjem obitelji. Jaz između željenog broja djece i stvarnog broja jedan je od temeljnih izazova za tvorce javnih politika koji nastoje omogućiti parovima da ostvare željeni broj djece (Philipov, 2009). Provedena su brojna istraživanja koja su nastojala utvrditi čimbenike koji utječu na odgađanje rađanja, ali i na fertilni jaz (Golub i sur., 2023; Norling, 2021; Beaujouan, i Berghammer, 2019; Adsera, 2006; Gutiérrez-Domènech, 2006; Ahn i Mira, 2001; Spéder i Kapitány, 2009). Fertilni jaz, prema spomenutim istraživanjima i brojnim čimbenicima, primarno nastaje zbog financijskih poteškoća, nezaposlenosti te neravnoteže između obiteljskog i poslovnog života. Svi navedeni osnovni i brojni ostali čimbenici dovode i do odgađanja rađanja te je važno kriterijski analizirati i oblikovati čimbenike radi jednostavnijeg razumijevanja problematike namjere rađanja.

Veliki dio novije literature o vezi između ekonomskih uvjeta i formiranja obitelji predložio je konceptualizacije sigurnosti (ili nesigurnosti) koje obuhvaćaju različite dimenzije životnih uvjeta pojedinaca (Modena i sur., 2014; Fiori i sur., 2013; Bernardi i Nazio, 2005; Bhaumik i Nugent, 2002; Kreyenfeld, 2010). Iako se njihovi pristupi razlikuju, postoji konsenzus da ekonomska sigurnost ne bi trebala biti isključivo vezana uz status zapošljavanja, već da bi trebalo uključiti i ostale čimbenike (poput financijskih resursa kućanstva, monetarnih i nemonetarnih resursa koji pomažu u prevladavanju poteškoća, stambenih uvjeta i sl.) koji tako mogu doprinijeti osobnoj ekonomskoj sigurnosti pojedinca. Ekonomska nesigurnost i neizvjesnost također su u literaturi identificirani kao ključni čimbenici koji utječu na odgađanje rađanja (Kreyenfeld, 2010) i dovode do smanjenja stopa fertiliteta (Koahler i sur., 2002).

Teorije o plodnosti (Brewster i Rindfuss, 2000; McDonald, 2002) čvrsto su ukorijenjene u ideji da ekonomska sigurnost, u smislu zaposlenja i prihoda, predstavlja važan

preduvjet za rađanje djece. Istraživanja pokazuju da je prihod pozitivno koreliran s ulaskom u majčinstvo (Vignoli i sur., 2012; Vikat, 2004; Andersson, 2000; Ermisch, 1989), dok nekolicina autora (Jones i sur., 2010; Jones i Tertilt, 2006) ukazuju na negativan odnos između prihoda i rađanja. Ekonomske poteškoće predstavljene negativnim promjenama prihoda tijekom majčina života povezane su sa smanjenjem ukupnog broja rođene djece tijekom fertilnog razdoblja (Mansour, 2018).

Nadalje, uočen je negativan odnos sudjelovanja žena u radnoj snazi i rađanja, što je dovelo do pada stopa fertiliteta (Baizan, 2007; Adsera, 2004; Mira i Ahn, 2002). Stalno zaposlenje povezano je s većim fertilitetom, dok osobe koje imaju nestabilan posao imaju i smanjen fertilitet (Golub i sur., 2023; Doepke i sur., 2022; Ciritel i sur., 2019; Modena i sur., 2014; Vignoli i sur., 2012; Santarelli, 2011). Osim toga, žene koje imaju ugovor na određeno vrijeme odgađaju ulazak u majčinstvo (Vignoli i sur., 2012; Rica i Iza, 2005).

Prethodna istraživanja pokazala su da, također, uvjeti stanovanja utječu na namjeru rađanja (Golub i sur., 2023; Hu i sur., 2022; Ciritel i sur., 2019; Simon i Tamura, 2009; Vignoli i sur., 2012; Kulu i Vikat, 2007). Osobe bez djece koje žive u velikoj kući imaju manju namjeru rađanja (Ciritel i sur., 2019). Prema Hu i sur. (2022) istraživanje provedeno u Švedskoj pokazalo je da žene koje žive u vlastitim nekretninama imaju veću vjerojatnost namjere rađanja u odnosu na žene koje žive u unajmljenim stanovima (navedeno potvrđuje i istraživanje Fiori i sur., 2013). Povećana vjerojatnost da će žene imati dijete nakon stjecanja vlasništva nad nekretninom dokazano je i u Nizozemskoj i zapadnoj Njemačkoj (Mulder i Wagner, 2001 u Hu i sur., 2022). Međutim, u europskim zemljama s najvišim razinama vlasništva nad nekretninama (osobito u južnoj Europi, u Italiji, Grčkoj i Španjolskoj, gdje je postotak vlasnika nekretnina iznad 75 %) i relativno niskim davanjem hipotekarnih zajmova uočeno je odgađanje rađanja i smanjenje stope fertiliteta (Sobotka, 2011). Postati vlasnikom nekretnine može biti zamjena za troškove rađanja dodatne djece, dok s druge strane, izostanak adekvatnog smještaja može dovesti do odgađanja rađanja ili ograničavanja veličine obitelji (Fiori i sur., 2013).

Zbog činjenice da kratkoročne namjere odražavaju percepciju održivih mogućnosti i ograničenja u odnosu na trenutnu situaciju i potencijalne buduće ishode, ekonomska situacija je značajna ne samo za financijsko blagostanje ljudi, već i za planove rađanja djece.

Prethodna istraživanja pokazala su da ekonomska nesigurnost, u smislu nesigurnosti posla, prihoda i neadekvatnih stambenih uvjeta, dovode do negativnog jaza između željenog i ostvarenog broja djece (Beaujouan, i Berghammer, 2019; Adsera, 2006; Ahn i Mira, 2001; Gutiérrez-Domènech, 2006; Abbasi-Shavazi i Khani, 2014). Ekonomska nesigurnost stoga može ograničiti sposobnost žena da planiraju imati djecu, ali i dovesti do negativnog jaza između željenog i ostvarenog broja djece (veći broj željene djece u odnosu na ostvareni broj djece).

H3: Postoji statistički značajna pozitivna povezanost između fiskalnih instrumenata javnih politika i namjere rađanja.

H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja.

H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja.

H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja.

Dva su osnovna oblika javne potrošnje i ulaganja u djecu ili kućanstva s djecom, a to su novčani i nenovčani transferi (Slesnick, 1996). Navedeni transferi imaju nekoliko ciljeva koji polaze od poticanja parova/obitelji da imaju djecu, smanjenja troškova uzdržavanja djece te smanjenja siromaštva djece. Novčani transferi mogu se promatrati kao izravni i neizravni novčani transferi, dok se nenovčani transferi najvećim dijelom odnose na transfere u naravi. Izravni novčani transferi oblici su financijske potpore koji se dodjeljuju obiteljima s djecom putem izravnih isplata novca. Novac izravno dolazi iz državnog proračuna ili drugih javnih fondova i prenosi se izravno na obitelji. U izravne novčane transfere spadaju: doplatci za djecu, jednokratne novčane potpore za novorođeno dijete, zajamčena minimalna naknada, rodiljne i roditeljske potpore. S druge strane, neizravni novčani transferi odnose se na porezne olakšice ili porezne beneficije koje su namijenjene obiteljima s djecom. Ove olakšice smanjuju iznos poreza koji obitelji moraju platiti, što im omogućuje da zadrže više dohotka. Transferi u naravi su oblici pomoći koje se ne isplaćuju u novcu, već u obliku dobara ili usluga koje obitelj može koristiti kako bi im se olakšao odgoj i skrb djece. Ove vrste transfera dodjeljuju se kao dodatni oblici podrške, uz novčane transferne programe. Uglavnom se određuju na lokalnoj razini, a obuhvaćaju: sufinanciranje udžbenika, subvencije prijevoza, sufinanciranje troškova prehrane,

sufinanciranje smještaja u učeničkim/studentskim domovima i sl. U nekim zemljama, transferi u naravi poput zdravstvene zaštite ili obrazovanja pružaju se od strane države, kao što je slučaj u Europi, financiraju se općim oporezivanjem, dok se u drugim zemljama, primjerice u SAD-u, takve usluge moraju financirati iz raspoloživog dohotka kućanstava (Pezer i sur., 2023).

Prethodna empirijska istraživanja o utjecaju novčanih transfera na makrorazini, ukazuju na pozitivnu povezanost novčanih transfera i fertiliteta (Cowan i Wyndham Douds, 2022; Bano i sur., 2021; Laroque i Salanié, 2014; Thévenon i Gauthier, 2011; Luci i Thévenon, 2013; Gauthier, 2007; Monnier, 1990; Duclos i sur., 2001; González, 2013; Cohen i sur., 2013). Na primjer, Cowan i Wyndham Douds (2022) empirijski su istraživali utjecaj novčanih transfera na rađanje žena starosti između 15 i 44 godine. Rezultati logističke regresije pokazali su da novčani transferi uzrokuju povećanje kratkoročnih stopa plodnosti jednu i dvije godine nakon isplate, osobito među populacijama u nepovoljnom položaju. Količina transfera potrebna za izazivanje učinka ovisi o veličini kućanstva. Navedeno upućuje na to da novčani transferi uklanjaju ekonomske prepreke rađanju djece za pojedince i stoga predstavljaju održiv politički mehanizam za smanjenje nejednakosti u rađanju i reproduktivnoj autonomiji. Autori također navode da novčani transferi, iako su osmišljeni za rješavanje problema siromaštva i ekonomskih nejednakosti, mogu uspješno smanjiti nejednakosti na makrorazini.

Empirijska istraživanja provedena na mikro razini upućuju na općeniti zaključak o pozitivnom utjecaju financijskih transfera i općih pokazatelja obiteljske politike na fertilitet, međutim, ne postoji jednoznačan zaključak jer utjecaj ovisi o broju djece koji parovi već imaju (Hart i Galloway, 2023; Raute, 2019; Spéder i sur., 2019; Riphahn i Wiynck, 2017; Laroque i Salanie, 2008; Milligan, 2005). Tako su na primjeru Norveške Hart i Galloway (2023) dokazali da je provedena reforma kojom se povećavaju univerzalni transferi i porezne olakšice povećala rađanje žena u ranim 20-ima (analiza je rađena na uzorku žena starosti od 20 do 39 godina). Učinak je najizraženiji kod prvog poroda, ali postoje i tendencije porasta kod drugog i trećeg poroda. Također postoji porast trećeg rođenja među ženama u dobi od 35 do 39 godina u trenutku provedbe istraživanja, što ukazuje na trajan učinak na fertilitet. Navedeno ukazuje na zaključak da su niski izravni troškovi podizanja djece doprinijeli visokom fertilitetu. Transferi u naravi kao što su obrazovne i zdravstvene usluge, stanovanje, subvencije za prijevoz ili školski obroci, imaju znatno veću vrijednost za kućanstva s niskim primanjima. No, neki rezultati istraživanja pokazuju da siromašniji roditelji, ako imaju izbora, radije biraju novčane transfere umjesto transfera u naravi zbog nedostatka svijesti (Pezer i sur., 2023). S druge strane,

subvencioniranje ustanova za skrb o djeci ima pozitivan učinak na fertilitet i stopu sudjelovanja majki na tržištu rada (Givord i Marbot, 2015; Lefebvre i sur., 2009). Navedeno je usko vezano i s istraživačkim spoznajama da transferi u naravi smanjuju siromaštvo djece (Pezer i sur., 2023; Nygård i sur., 2019).

H4: Odluke o namjeri rađanja statistički značajno se razlikuju ovisno o ekonomskoj razvijenosti lokalne i regionalne samouprave, odnosno indeksu razvijenosti.

Pozadinske čimbenike, osim osobina ličnosti, općih vrijednosnih orijentacija (poput religioznosti i tradicionalnih naspram modernih stavova prema rodnim ulogama), općih životnih vrijednosti (poput vrijednosti djece) određuju i demografske karakteristike (dob, spol, obrazovanje). Značajnu ulogu mogu imati i šire nacionalne i regionalne kulturološke vrijednosti te institucionalni kontekst, uključujući političko i ekonomsko okruženje (Fishbein, 1972; Ajzen i Klobas, 2013). S ekonomskog aspekta, u skladu s prethodnim istraživanjima (Riederer i Buber-Ennser, 2019; Ciritel i sur., 2019; Kulu, 2013; De Beer i Deerenberg, 2007; Hank, 2001), kao pozadinski čimbenik u analizu čimbenika koji utječu na namjeru rađanja uključuje se i regionalni razvojni kontekst. Naime, u istraživačkim studijama uočene su značajne varijacije u fertilitetu, ovisno o mjestu stanovanja. Ovakav obrazac uočen je u Grčkoj (Nickayin i sur., 2022), Rumunjskoj (Ciritel i sur., 2019), Velikoj Britaniji (Kulu i Washbrook, 2014), Sloveniji (Černič Istenič i Kveder, 2008), Škotskoj (Boyle i sur., 2007), nordijskim zemljama (Kulu i sur., 2007), Nizozemskoj (De Beer i Deerenberg, 2007), Austiji i Poljskoj (Kulu, 2006), Njemačkoj (Hank, 2001) i Francuskoj (Fagnani, 1991).

Nadalje, Myrskylä i sur. (2009), Fox i sur. (2018) navode da je negativna povezanost fertiliteta s gospodarskim i društvenim razvojem postala jedna od najčvršće utvrđenih i općeprihvaćenih empirijskih pravilnosti u društvenim znanostima. Utjecaj regionalnog konteksta na namjeru rađanja potvrđuju i Ciritel i sur. (2019). Autori su dokazali da se namjera rađanja drugog djeteta značajno razlikuje među razvojnim regijama Rumunjske, predstavljajući socioekonomske podjele unutar državnog teritorija (do sličnih zaključaka došao je i Jemna, 2015). Zaključno, natalitet značajno varira između urbano-ruralnih područja, odgovarajući na društvene, političke, kulturne i teritorijalne pokretače promjena. Razlike se očituju i u veličini obitelji zbog dostupnosti posla i obrazovnog sustava.

Predloženi model namjere rađanja predstavljen je slikom 1. U modelu su prikazane varijable s odnosima definiranim hipotezama istraživanja.

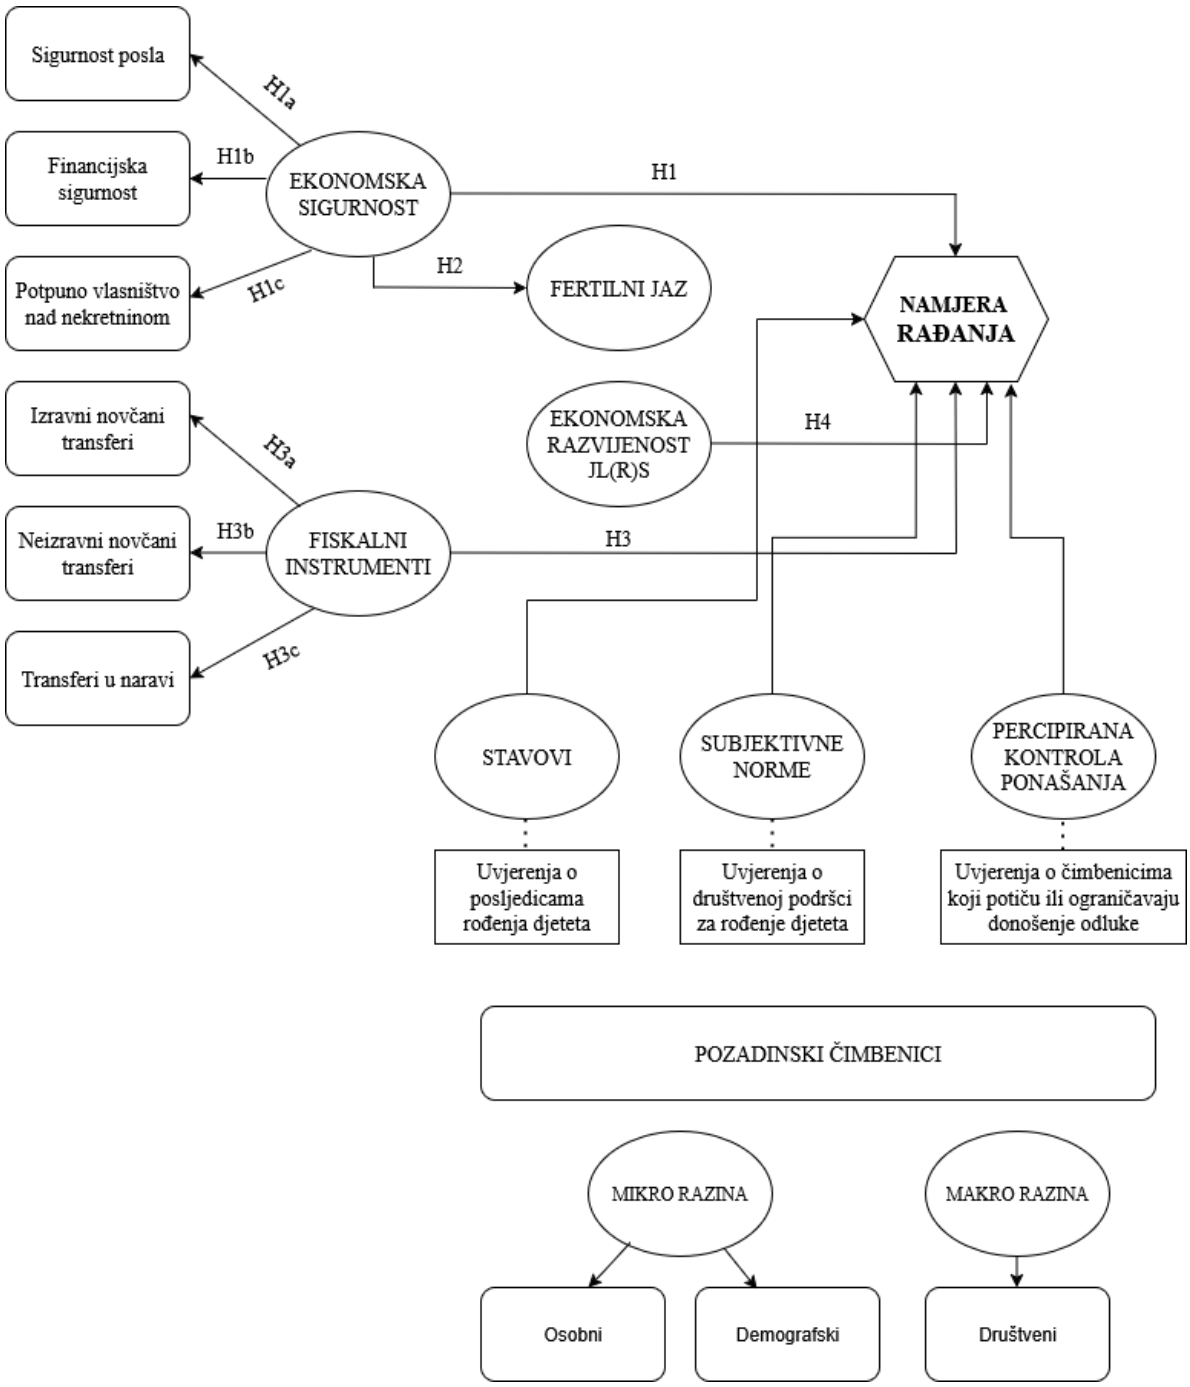

Slika 1. Pretpostavljeni model namjere rađanja u sljedeće dvije godine s postavljenim hipotezama
Izvor: izrada doktorandice

1.4. Metode znanstvenog istraživanja

Sukladno postavljenim ciljevima i istraživačkim pitanjima, u doktorskom radu su korišteni primarni podatci prikupljeni metodom upitnika te sekundarni podatci koristeći se arhivskom metodom[2] prikupljanja kvantitativnih podataka iz javno dostupnih izvora. Za testiranje hipoteza i provjeru postavljenih ciljeva primijenjena je deskriptivna statistička analiza i prikladne neparametrijske metode (detaljnije u poglavlju 5.6. Statističke metode analize) upotrebom programa za statističku obradu podataka primjenom programskog paketa Statistical Package for the Social Science (SPSS) for Windows, IBM SPSS Statistics 25.0.

1.5. Očekivani znanstveni doprinos

Očekivani znanstveni doprinos ovog istraživanja očituje se u tri aspekta: teorijskom, metodološkom i aplikativnom.

Teorijski znanstveni doprinos proizlazi iz sistematizacije postojećih znanstvenih i teorijskih saznanja o temi kroz detaljno izučavanje i sintezu recentne znanstvene literature. Sveobuhvatni pregled i analiza srodnih istraživanja, njihovih metodoloških okvira i rezultata iz područja demografije i ekonomije, uz interdisciplinarni pristup omogućit će oblikovanje primarnih i sekundarnih znanstvenih spoznaja o relevantnim ekonomskim čimbenicima koji utječu na namjeru rađanja i/ili dovode do jaza između željenog i ostvarenog broja djece. Osim toga, napravit će se opsežan uvid u implikacije koje negativni demografski trendovi imaju na financijski sustav, gospodarstvo i državu. Također, analizirat će se sustav mjera i akcija usmjerenih ka poboljšanju demografskog razvitka, odnosno demografskoj revitalizaciji. Dosadašnja istraživanja uglavnom su obuhvatila samo pojedine ekonomske prediktore koji utječu na namjeru rađanja ili su se istraživanja temeljila isključivo na elementima Teorije planiranog ponašanja (stavovi, subjektivne norme i percipirana kontrola ponašanja) ispitujući namjeru rađanja. Stoga će ovo istraživanje upotpuniti navedeni istraživački jaz kroz sveobuhvatni pristup objedinjujući elemente Teorije planiranog ponašanja i ekonomske prediktore (ekonomska sigurnost, fiskalni instrumenti javnih politika, regionalna razvijenost) kako bi se ispitala njihova povezanost s namjerom rađanja i jaz između željenog i ostvarenog broja djece kod žena u Republici Hrvatskoj.

[2] Metoda ankete i arhivska metoda detaljnije su opisane u poglavlju 5.4.

Metodološki znanstveni doprinos očituje se u testiranju povezanosti varijabli u proširenom konceptualnom modelu Teorije planiranog ponašanja. Proširenje modela odnosi se na uključivanje prediktorskih ekonomskih varijabli, a koje su u testiranju hipoteza podijeljene u tri skupine: ekonomska sigurnost (sigurnost posla, financijska sigurnost i vlasništvo nad nekretninom), fiskalni instrumenti javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi) i regionalna razvijenost. Nadalje, modelom se testira i povezanost ekonomske nesigurnosti i fertilnog jaza. Kako bi se povećala uspješnost testiranja pretpostavljenog modela neophodno je istraživanjem obuhvatiti žene različitih dobnih skupina i stupnja obrazovanja vodeći računa o reprezentativnosti uzorka sukladno i regiji prema indeksu razvijenosti. Navedenim će se osigurati relevantnost i opća primjenjivost rezultata, omogućujući dublje razumijevanje utjecaja ekonomskih čimbenika na reproduktivne odluke žena u različitim socioekonomskim i regionalnim kontekstima.

Aplikativni znanstveni doprinos ogleda se u njegovoj relevantnosti za hrvatsku znanost i nositelje javnih politika u području demografije, s naglaskom na poboljšanje kvalitete života žena, djece i obitelji.

Analiza utjecaja odabranih ekonomskih prediktora na namjeru rađanja ukazat će na potencijalne nedostatke postojećih mjera javnih politika. Rezultati istraživanja trebali bi imati sveobuhvatan utjecaj na kreiranje određenih smjernica u oblikovanju javnih politika u Republici Hrvatskoj s ciljem poboljšanja demografskih trendova, ali i inicijativa. Osnovni cilj i doprinos ovog doktorskog rada i istraživačkih aktivnosti usmjeren je na kreiranje mjera koje dovode do povećanja nataliteta te smanjenja jaza između željenog i ostvarenog broja djece. Regionalni okvir, promatran kroz prizmu konkurentnosti i razvijenosti, predstavlja ključan čimbenik u analizi kvalitete života. U tom kontekstu, namjera rađanja kao polazišna varijabla ima iznimnu važnost jer neposredno utječe na potrebu usklađivanja demografskih mjera na svim razinama teritorijalnog ustroja.

Osim toga, rezultati istraživanja ukazat će i na mogućnosti poboljšanja standarda kvalitete življenja obitelji i povećanja nataliteta u smjeru kvalitetnijih rješenja i perspektiva žena te oblikovanja demografskih i kohezivnih okvira aktivnosti države i privatnog sektora koje bi doprinijele poboljšanju demografske revitalizacije i usklađivanju obiteljskog i privatnog života.

1.6. Struktura doktorskog rada

Ovaj doktorski rad obuhvaća ukupno sedam poglavlja. U uvodnom dijelu rada istaknuti su svrha i ciljevi doktorskog rada na temelju identificiranog istraživačkog problema, odnosno jaza u dosadašnjim istraživačkim spoznajama. Također, u okviru uvodnog razmatranja postavljaju se istraživačke hipoteze, metode znanstvenog istraživanja te očekivani znanstveni doprinos s teorijskog, metodološkog i aplikativnog stajališta.

Drugi dio doktorskog rada pruža teorijski pregled demografskih tranzicijskih procesa kroz analizu etapa demografske tranzicije. Osim toga, ovo poglavlje prikazuje ključne demografske trendove u Republici Hrvatskoj

Treći dio doktorskog rada teorijski obrađuje ekonomske teorije fertiliteta kroz tri različita pristupa: teoriju averzije prema riziku, teoriju o smanjenju neizvjesnosti i teoriju konjunkturnog djelovanja.

Četvrto poglavlje počinje analizom razlika između populacijske i obiteljske politike te utvrđivanjem uloge i značaja eksplicitne i implicitne pronatalitetne politike. Drugi dio četvrtog poglavlja donosi teorijski pregled i sintezu dosadašnjih istraživanja namjere rađanja, stavljajući naglasak na ekonomske prediktore koji utječu na namjeru rađanja. U poglavlju se objašnjava ekonomska nesigurnost i fiskalni instrumenti kojima se oblikuju javne politike usmjerene na fertilitet te druge sastavnice koje utječu na ravnotežu obiteljskog i poslovnog života žena. Objašnjavaju se i pozadinski čimbenici koji utječu na namjeru rađanja kod žena. Budući da brojni čimbenici utječu na namjeru rađanja, jedno potpoglavlje posvećeno je istraživanju uzroka odgađanja rađanja i jaza između željenog i ostvarenog broja djece. Posljednji dio četvrtog poglavlja prikazuje usporedni prikaz Republike Hrvatske i zemalja članica Europske unije u segmentu financiranja obitelji i djece kroz sustav socijalne zaštite.

Peti dio doktorskog rada objašnjava metodologiju rada kroz dizajn istraživanja, kreiranje upitnika, definiranje uzorka i proces prikupljanja podataka. U istome poglavlju objašnjene su i metode istraživanja, prikazani rezultati provedenog empirijskog istraživanja te testiranje hipoteza. Testiranjem hipoteza istražuje se povezanost ekonomske sigurnosti, fiskalnih instrumenata javnih politika i regionalne razvijenosti mjesta stanovanja ispitanica na

namjeru rađanja. Osim toga, testira se povezanost ekonomske sigurnosti i jaza između željenog i ostvarenog broja djece.

Nakon testiranja hipoteza, kroz šesti dio doktorskog rada pod nazivom Rasprava o rezultatima istraživanja, objašnjavaju se implikacije rezultata istraživanja. U sedmom poglavlju slijede zaključna razmatranja kroz koja su sažeti rezultati istraživanja s naglaskom na njihove implikacije za javne politike i društvene intervencije. Spomenuta su ograničenja istraživanja, kao i preporuke za daljnja istraživanja na navedenu temu. Na samom kraju slijede popis korištene literature, popis slika, tablica, grafikona, prilozi i popis objavljenih radova doktorandice.

2. DEMOGRAFSKI TRANZICIJSKI PROCESI I TRENDOVI U REPUBLICI HRVATSKOJ

Istraživanje povijesti razvoja stanovništva otkriva nekoliko razvojnih faza koje se odlikuju određenim odnosima između ključnih elemenata prirodnog kretanja stanovništva, poput nataliteta i mortaliteta. Uz to, uočavaju se specifične tendencije u kretanju tih elemenata, kao i odgovarajuće promjene u različitim strukturama stanovništva. Prije detaljnijeg razmatranja etapa demografske tranzicije, nužno je definirati temeljne demografske pojmove. Prirodno kretanje stanovništva odnosi se na utjecaj bioloških, odnosno prirodnih čimbenika i procesa na osnovne tokove promjena u broju stanovnika. Njegove glavne sastavnice su natalitet (rodnost) i mortalitet (smrtnost), čiji međusobni odnos rezultira prirodnim prirastom (kada je broj rođenih veći od broja umrlih) ili prirodnim padom stanovništva u suprotnom slučaju. Teorija demografske tranzicije suvremena je teorija koja razvoj stanovništva prikazuje kao proces etapnog razvoja, uvjetovanog ukupnim procesom društveno-gospodarskog i kulturnog razvoja.

Prvi teoretičari koji su u prvoj polovici 20. stoljeća nastojali generalizirati nastale demografske promjene i teoriju demografske tranzicije bili su Thompson i Notestein (Wertheimer-Baletić, 2016). Promjene koje su razmatrali odnosile su se na sastavnice prirodnog kretanja stanovništva (natalitet i mortalitet) u razvijenim zapadnoeuropskim zemljama. Značajan doprinos demografskoj teoriji u segmentu povijesnog procesa demografske tranzicije dao je američki demograf Ansley J. Coale (1973, 1986) svojim empirijskim istraživanjem na primjeru zapadnoeuropskih zemalja. Ocem teorije demografske revolucije smatra se francuski demograf Adolf Landry, koji je razmatrao procese u Francuskoj početkom 20. stoljeća. Najznačajnije djelo u kojem je iznio temeljne postavke onoga što će kasnije biti poznato kao teorija demografske revolucije objavljeno je 1934. godine pod naslovom *La révolution démographique* (Demografska revolucija). U tom djelu Landry analizira specifičan slučaj Francuske, koja je među prvim zemljama ušla u fazu smanjenja fertiliteta, i time pokazala da ekonomski i društveni razlozi imaju značajan utjecaj na natalitet. Njegove ideje bile su temelj za kasniju formulaciju teorije demografske tranzicije, koja je postala dominantni okvir za objašnjenje promjena u stopama rađanja i umiranja tijekom modernizacije.

Nadalje, Notestein i Thompson su za proces promjena nastalih tijekom vremena u brojčanoj razini nataliteta, mortaliteta i prirodnog prirasta umjesto pojma „demografska revolucija“ upotrebljavali pojam „demografska tranzicija“. Pojam „demografska tranzicija“ smatra se sadržajno cjelovitijim i znanstveno prikladnijim za istraživanje procesa primjene razine vitalnih stopa. Američki demograf Frank W. Notestein predstavio je svoju cjelovitu teoriju demografske tranzicije 1945. godine. Ova teorija nastojala je opisati i objasniti proces kroz koji populacije prolaze prilikom prijelaza s visokih stopa nataliteta i mortaliteta na niske stope nataliteta i mortaliteta, što u konačnici dovodi do značajnih demografskih promjena karakterističnih za moderna društva (Micklin, 1969; Bélanger i Edmonston, 2018; Stokes, 1995). Njegovo djelo predstavilo je četveroetapni model koji integrira kako socioekonomske tako i demografske čimbenike koji utječu na trendove fertiliteta i mortaliteta. Taj okvir od tada je široko prihvaćen i primjenjivan u svjetskoj demografskoj literaturi za analizu dinamike stanovništva (Jackson, 2017; Alfonso-Sánchez i Peña, 2005).

U svojim izvornim formulacijama teorija demografske tranzicije konceptualno predstavlja detaljan opis mehanizama promjene mortaliteta i fertiliteta s razmatranjima kako će to utjecati na demografski razvoj svijeta u budućnosti (Reher, 2011). Prema Wertheimer-Baletić (2016), teorija demografske tranzicije promatra razvoj stanovništva kao etapni proces, odnosno proces koji se odvija kroz specifične razvojne faze, a koji je uvjetovan cjelokupnim društveno-ekonomskim razvojem u najširem smislu te riječi. Prema teorijskim spoznajama „temeljna pretpostavka teorije demografske tranzicije jest međuovisnost procesa modernizacije i ekonomskog razvoja s promjenom sastavnica prirodnog kretanja stanovništva“ (Wertheimer-Baletić (2016: 52). Nadalje, demografska razvojna paradigma temelji se na empirijskim istraživanjima koja dokazuju čvrstu negativnu korelaciju između brojčane razine vitalnih stopa (nataliteta i mortaliteta) s jedne strane i razine društveno-ekonomskog razvoja mjerene BDP-om po glavi stanovnika, s druge strane (Wertheimer-Baletić, 2016; Hansen i Lønstrup, 2015; Bloom i sur., 2014; Bloom i Freeman, 1988).

Notestein (1945) navodi da je rast stanovništva zavisna varijabla na koju će u velikoj mjeri u budućnosti utjecati tehnološki, društveni, ekonomski i politički razvoj. Slijedom toga, nezanemariv je utjecaj industrijalizacije i urbanizacije kao sastavnica modernizacije društva, odnosno čimbenika koji smanjuju natalitet. Ekonomsko-socijalni razvoj, unaprjeđenje zdravstvene zaštite, širenje obrazovanja i porast životnog standarda utjecali su ne samo na

smanjenje mortaliteta, već i na smanjenje nataliteta i fertiliteta. Kao ključne dinamičke sastavnice, promjene u stopama nataliteta i fertiliteta značajno obilježavaju i oblikuju proces demografske tranzicije.

Demografska tranzicija proces je koji se kao važna društvena pojavnost počela izučavati krajem 18. i 19. stoljeća u zapadnoeuropskim zemljama, dok je u drugoj polovici 20. stoljeća zahvatila i većinu ostalih dijelova svijeta. „Proces demografske tranzicije u užem poimanju obuhvaća razmatranje promjena u smjeru i brojčanoj razini sastavnica prirodnog kretanja stanovništva, konkretno nataliteta i mortaliteta te njihove uzroke“ (Wertheimer-Baletić, 2016: 53). Proces demografske tranzicije najčešće se razmatra kroz tri etape razvoja stanovništva koje bilježe značajno smanjenje brojčane razine stopa nataliteta i mortaliteta. Ovaj proces započeo je, kako je već ranije spomenuto, u većini zapadnoeuropskih zemalja zbog pada stope mortaliteta krajem 18. i u prvoj polovici 19. stoljeća, a nakon toga je došlo i do smanjenja stope nataliteta pred kraj 19. i početak 20. stoljeća. Etape demografske tranzicije prikazane su na slici 2.

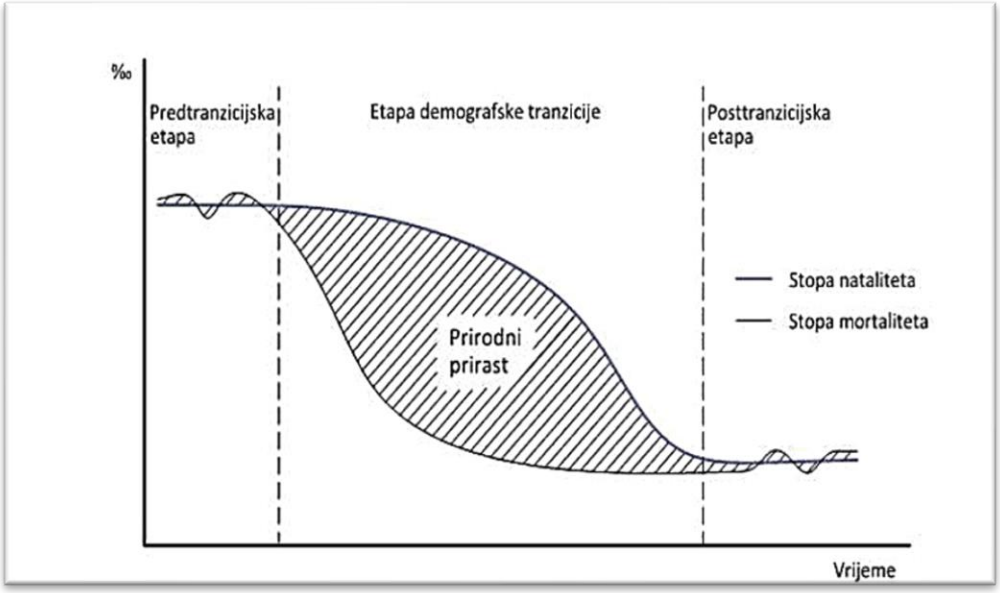

Slika 2. Etape demografske tranzicije
Izvor: Obadić, Tica (2016)

Predtranzicijska etapa, etapa demografske tranzicije i posttranzicijska etapa, uključujući i podetape demografske tranzicije (rana, središnja i kasna tranzicijska podetapa), bit će detaljno objašnjene u sljedećim potpoglavljima doktorskog rada.

2.1. Predtranzicijska etapa

Predtranzicijska etapa obuhvaća razdoblje prije industrijske revolucije u 19. stoljeću, koje je obilježeno predindustrijskim i agrarnim načinima proizvodnje, odnosno, prirodnim gospodarstvom čija su obilježja vezana uz proizvodnju, razmjenu i potrošnju. U ovoj etapi, značajnu ulogu igraju socio-biološki čimbenici koji su uzrokovali visoke stope mortaliteta i nataliteta (prosječno više od 40 živorođenih i umrlih na 1000 stanovnika). Reprodukcija stanovništva u ovim uvjetima najvećim je dijelom spontana i neregulirana, pod snažnim utjecajem socio-bioloških i predindustrijskih ekonomskih čimbenika. Ovo razdoblje obilježavaju objektivne nemogućnosti pružanja hrane stanovništvu, primjena tradicionalnih sredstava kontrole rađanja te ograničene mogućnosti produljenja životnog vijeka zbog slabe zdravstvene zaštite i niskog obrazovanja stanovništva.

Empirijski dokazana činjenica koja sugerira da visoki mortalitet prati i visoki natalitet potvrđuje se u skladu s teorijom Notesteina (1945: 39), koja tvrdi da društva suočena s visokim mortalitetom moraju imati visok natalitet kako bi opstala. U tim uvjetima, većina civilizacijskih društava organizirana su s ciljem postizanja visokih stopa nataliteta. „Religiozne doktrine i vjerovanja, moralne norme, zakoni, obrazovanje, lokalni običaji, ženidbeni običaji, organizacija obitelji i podjela rada unutar obitelji – svi su usmjereni, u uvjetima visokog mortaliteta, na poticanje visokog nataliteta“ (Wertheimer-Baletić, 2016 prema Notestein, 1945).

Radi lakšeg razumijevanja dobno-spolne strukture nužno je pojasniti pojam demografske piramide i njezine oblike. Naime, demografska piramida je „grafikon koji prikazuje broj ili postotak stanovnika prema dobi i spolu, s muškarcima obično na lijevoj strani i ženama na desnoj strani X-osi te dobnim skupinama na Y-osi, pri čemu su najmlađi na dnu; u tradicionalnim društvima s visokom stopom nataliteta demografska piramida ima široku bazu s velikim brojem djece i mladih, dok su starije dobne skupine malobrojne; međutim, u razvijenim zemljama, gdje je stopa nataliteta u posljednjim desetljećima pala i ostala ispod stope mortaliteta, oblik piramide mijenja se i poprima oblik urne s manjim brojem djece i mladih u bazi te širokim srednjim slojem, ali i sve većim brojem starijih“ (Čipin i Međimurec, 2024:13). Postoje četiri modela dobno-spolne strukture (Proleksis enciklopedija, 2012):

1. oblik piramide – ekspanzivni tip u kojemu je široka osnovica, odnosno prevladava udio mladog stanovništva i visoke stope rasta stanovništva; broj stanovnika raste
2. oblik zvona/košnice – stacionarni tip u kojemu se stope nataliteta i mortaliteta poklapaju, tj. nema prirodnog prirasta, broj stanovnika stagnira
3. oblik urne i viseće kapi – konstriktivni i regresivni tip u kojemu prevladava malen udio mladog, a velik udio staroga stanovništva koji vodi u depopulaciju. Kod oblika urne broj stanovnika opada, a kod viseće kapi stanovništvo odumire.

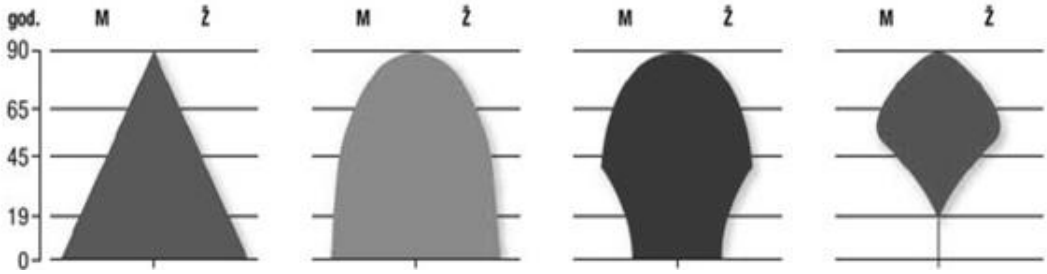

Slika 3. Oblici dobno – spolne strukture
Izvor: Loomen (2021:n.p.)

Predtranzicijsku etapu karakteriziraju visoke stope nataliteta i mortaliteta što dovodi do dominacije mladog stanovništva. Nadalje, široka dječja baza dobne strukture ima oblik piramide.

2.2. Etapa demografske tranzicije

Druga etapa demografske tranzicije središnja je etapa u kojoj se događa proces demografske tranzicije, ali i prijelaz s visokih stopa mortaliteta i nataliteta iz predtranzicijske etape na niske stope nataliteta i mortaliteta – ispod 14 promila, a kasnije i ispod 10 promila (Wertheimer-Baletić, 2016). Druga etapa demografske tranzicije podijeljena je na tri podetape: i) ranu tranzicijsku podetapu, ii) središnju (centralnu) tranzicijsku podetapu i iii) kasnu tranzicijsku podetapu (Bowen, 1955 u Wertheimer-Baletić, 2016) koje su u nastavku detaljnije objašnjene.

2.2.1. Rana tranzicijska podetapa

Ranu tranzicijsku podetapu karakterizira povećanje prirodnog prirasta stanovništva, odnosno demografska ekspanzija. Uvjetuje ju nagli pad stopa mortaliteta, uz nepromijenjene visoke stope nataliteta. Dobna struktura ima oblik piramide s brojčano većom bazom djece. Navedeno je rezultat naglog pada stopa smrtnosti, što je prvenstveno posljedica značajnog poboljšanja higijenskih i sanitarnih uvjeta života, veće dostupnosti hrane, poboljšane zdravstvene skrbi, medicinskih otkrića te napretka u obrazovanju i drugim aspektima razvoja i civilizacijskog napretka.

U isto vrijeme, u početku, dok smrtnost opada, stopa rađanja ostaje nepromijenjena ili ostaje visoka. Kao rezultat toga, porast stanovništva proizlazi iz pada smrtnosti. Međutim, važno je napomenuti da i stabilno visoka stopa rađanja također doprinosi ovom povećanju prirodnog prirasta. Smanjenje stope rađanja događa se tek kasnije, što je Notestein (1945: 41) objasnio riječima da smanjenje stope rađanja zahtijeva promjenu socijalnih ciljeva, od onih koji su usmjereni na preživljavanje grupe prema onima koji su usmjereni na blagostanje i razvoj pojedinca.

2.2.2. Središnja (centralna) tranzicijska podetapa

Središnja (centralna) etapa započela je već početkom 19. stoljeća u nekim zapadnoeuropskim zemljama, dok je u većini zemalja nastupila krajem 19. i početkom 20. stoljeća. Obilježilo ju je smanjenje nataliteta uz istodobno smanjivanje mortaliteta. Važno je napomenuti da je pad mortaliteta bio nešto sporiji od pada nataliteta. Posljedica toga je smanjenje prirodnog prirasta stanovništva. Tada dobna struktura doživljava radikalne demografsko-tranzicijske promjene, u njoj se usporava porast udjela mladih, dok udjel stanovništva u radno sposobnoj dobi raste, a prisutan je trend porasta udjela starog stanovništva (Wertheimer-Baletić, 2009). Notestein je proces smanjivanja nataliteta smatrao „izravnom posljedicom procesa modernizacije društva, koji obuhvaća ekonomske i društvene promjene uvjetovane brojnim posljedicama industrijske revolucije i društvenih procesa koji su je pratili“ (Notestein, 1953: 54).

2.2.3. Kasna tranzicijska podetapa

Treća etapu u okviru etape demografske tranzicije jest kasna tranzicijska podetapa u kojoj se nastavlja smanjenje nataliteta, koje je brže od smanjenja mortaliteta. Karakterizira ju starenje stanovništva i povećanje udjela staračkog stanovništva u ukupnom stanovništvu, ali se još uvijek povećava broj radno sposobnog stanovništva. „Prirodni prirast se je počeo smanjivati i sve je više dolazila do izražaja tendencija stabilizacije i uravnoteženja stope nataliteta i mortaliteta na relativno istoj brojčanoj razini vodeći prema nultoj razini stope prirodnog prirasta“ (Wertheimer-Baletić, 2016: 57). Tijekom procesa demografske tranzicije došlo je i do promjene dobne strukture stanovništva, odnosno premještanja relativne brojčane većine iz mlađih u starije dobne grupe. Wertheimer-Baletić (2009) navodi da se dobna struktura stanovništva, usporedno s ukupnim razvojem zemlje, transformira iz oblika piramide, koja prezentira velik i rastući broj mladih (0-14 godina), prema obliku košnice, u kojem se broj mladih smanjuje, pa prema obliku urne, koju karakterizira pretežno starije stanovništvo.

2.3. Posttranzicijska etapa – Druga demografska tranzicija

Na makrorazini postoji nekoliko teorija koje mogu pomoći u objašnjavanju niskih stopa fertiliteta u razvijenim zemljama. Među njima je najpoznatija teorija druge demografske tranzicije. Ova teorija nudi uvjerljivo objašnjenje za dugoročan pad fertiliteta u proteklih pedeset godina. Osim promjena u broju rođenja i vremenu rađanja, druga demografska tranzicija naglašava i ključne promjene u sklapanju braka, partnerstva i stope razvoda, koje su karakteristične za moderna društva.

Temeljno obilježje posttranzicijske etape u odnosu na etapu demografske tranzicije odnosi se na smanjenje nataliteta uslijed jačeg intenziteta djelovanja socio-psiholoških i socio-kulturnih čimbenika, dok su u etapi demografske tranzicije primarni utjecaj na smanjenje nataliteta imali socio-ekonomski čimbenici, odnosno industrijalizacija gospodarstva, urbanizacija naselja te širenje obrazovanja. Već u središnjoj i kasnoj tranzicijskoj podetapi počinje dominacija socio-ekonomskih, socio-psiholoških i socio-kulturnih čimbenika na trend smanjenja fertiliteta i promjenu u strukturi obitelji. 1949. godine Blacker je pretpostavio dvije podetape posttranzicijske etape. Prva podetapa posttranzicijske etape ili niskostacionarna faza demografskog ciklusa obilježena je niskim stopama nataliteta i mortaliteta. Druga podetapa

posttranzicijske etape obilježena je stvarnim viškom broja umrlih nad rođenima i, osim ako se ne kompenzira imigracijom, padom broja stanovnika (Blacker, 1949).

Wertheimer-Baletić (2016: 49) ističe da je "u razdoblju druge demografske tranzicije, odnosno posttranzicijske etape u odnosu na prvu demografsku tranziciju došlo do brojnih promjena u demografskim i socio-demografskim pokazateljima, među kojima dominira slabljenje utjecaja braka uz dominaciju utjecaja pojedinca i pluraliteta životnih zajednica (kohabitacija i druge „partnerske zajednice"), koji su imali zamjetan utjecaj na daljnje smanjivanje nataliteta/fertiliteta što se primarno odrazilo na smanjivanje broja djece u obitelji uz istovremeni porast broja zajednica bez djece tj. neimanja djece".

Demografska tranzicija, odnosno prijelaz s visokih na niske stope mortaliteta i nataliteta, tijekom dužeg razdoblja drugog dijela dvadesetog stoljeća privukla je pozornost brojnih demografa. Ova pozornost rezultirala je značajnim teorijskim i empirijskim spoznajama koje su dale objašnjenje za smanjenje vitalnih stopa stanovništva (Bongaarts i Watkins, 1996; Casterline, 2003). Okvir druge demografske tranzicije postao je ključni koncept i teorijski okvir za proučavanje promjena u obitelji i plodnosti u suvremenoj Europi (McLanahan, 2004; Sobotka, 2008; Bianchi, 2014), kao i u širem svjetskom kontekstu (Atoh i sur., 2004; McDonald, 2009; Esteve i sur., 2012).

Prva demografska tranzicija odnosi se na smanjenje plodnosti i smrtnosti s visokih na niske razine, s posrednim razdobljem brzog rasta stanovništva uzrokovanog ranijim i bržim padom mortaliteta u odnosu na natalitet. Pokretač ovih demografskih promjena bila je industrijalizacija, kao i povezani društveni i gospodarski razvoj (tj. modernizacija) koji je povećao izglede djece za preživljavanje, ali je ujedno i povećao troškove roditeljima. Te promjene su, zauzvrat, povećale motivaciju za smanjenje veličine obitelji, ali nisu narušile univerzalno očekivanje braka i roditeljstva. Demografi su tvrdili da je ta demografska tranzicija neizbježna, unilinearna i nepovratna (Casterline, 2003).

Lesthaeghe (1977) je tvrdio je da su novi načini razmišljanja bili ključni za brzinu i vremenski tijek smanjenja plodnosti. Ti novi načini razmišljanja uključivali su razvoj svijesti, društvenu prihvatljivost i razvoj zdravstva (kontrola plodnosti). Naknadna smanjenja plodnosti u zemljama u razvoju u razdoblju nakon Drugog svjetskog rata imala su sličan karakter

(Cleland, Wilson, 1987; Bongaarts i Watkins, 1996). Uloga novih ideja koje legitimiziraju manje obitelji i planiranje obitelji postale su ključne za demografsku tranziciju.

Prema van de Kaa (1987), početak druge tranzicije može proizvoljno biti postavljen u 1965. godinu. Glavna demografska značajka druge tranzicije je smanjenje plodnosti s nešto više od „zamjenske“ razine od 2,1 rođenja po ženi, što osigurava ravnotežu između rođenja i smrti te stacionarnost stanovništva na dugi rok, na razinu znatno ispod zamjenske razine.

Druga demografska tranzicija podrazumijeva „trajnu supstitucijsku plodnost, mnoge druge organizacije života osim braka, odvajanje braka i rađanja te nepromjenjivo stanovništvo“ (Lesthaeghe, 2010: 211) čiji su okvir 1986. godine prvotno predložila dva europska demografa – Ron Lesthaeghe i Dirk van de Kaa. Glavni pokretač ovih trendova je kulturološki pomak prema postmodernim stavovima i normama koji naglašavaju individualnost i samoostvarivanje (van de Kaa, 2001). Prema Zaidi i Philip Morgan (2017) na makrorazini, druga demografska tranzicija pruža pogled na to kako se društva razvijaju tijekom vremena, naglašavajući ulogu idejnih promjena u stvaranju skupa demografskih i obiteljskih ponašanja. Na individualnoj razini, okvir druge demografske tranzicije nudi orijentacije vrijednosti pojedinaca kao glavne nositelje odrednica plodnosti i obiteljskog ponašanja osoba.

Međutim, postavlja se pitanje zašto druga demografska tranzicija nije nastavak prve demografske tranzicije. Zagovornici druge demografske tranzicije tvrde da se središnji fenomen promijenio u smjeru odgađanja rađanja i povećanja dobrovoljnog odsustva djece (van de Kaa 2001, 2002; Lesthaeghe 2010). Prema Lesthaeghe (1995, 2014) i van de Kaa (1987) razliku između prve i druge demografske tranzicije predstavlja pomak u normama, od altruističkih do individualističkih skupova vrijednosti. Nove motivacije na kojima se temelji ponašanje pri stvaranju obitelji razlikovale su drugu tranziciju od prve. Veća emancipacija žena i individualna autonomija središte su druge demografske tranzicije (Lesthaeghe, 1995). Nadalje, prva tranzicija prema niskoj plodnosti bila je dominirana brigom za obitelj i potomstvo, dok druga tranzicija naglašava prava i ostvarenje pojedinaca (van de Kaa, 1987).

Tablica 1. Ključne značajke i etape druge demografske tranzicije

Osnovne značajke druge demografske tranzicije	Etape druge demografske tranzicije
▪ slabljenje braka kao jedine vrste obiteljske strukture, što je posljedica visoke stope razvoda i porasta kohabitacije ▪ promjena u obiteljskim odnosima od „kralj-dijete“ s roditeljima na „kralj-par“ s djetetom ▪ prijelaz s preventivne kontracepcije na samoispunjavajuću kontracepciju ▪ jedinstvena obitelj (bračna obitelj) počinje ustupati mjesto pluralističkijim oblicima obitelji.	▪ Etapa I (1955. – 1970.): povećanje razvoda, pad nataliteta, kontracepcijska revolucija, zaustavljanje smanjenja dobi pri sklapanju braka. ▪ Etapa II (1970. – 1985.): porast suživota prije braka, porast izvanbračnog nataliteta. ▪ Etapa III (1980. – nadalje): stabilizacija stopa razvoda; pad broja ponovnih brakova; oporavak nataliteta kod osoba starijih od 30 godina, što dovodi do porasta ukupnih stopa rađanja u tom razdoblju.

Izvor: prilagodba doktorandice (Zaidi i Philip Morgan, 2017)

Zaidi i Philip Morgan (2017) navode da je van de Kaa (1987) tvrdio kako je glavna demografska značajka ove druge tranzicije pad fertiliteta s razine nešto iznad zamjenske od 2,1 rođenja po ženi na razinu znatno ispod zamjenske. Pokretačka snaga ove tranzicije bila je promjena u idejama, odnosno dramatičan pomak s altruističkih prema individualističkim normama i stavovima. Druga demografska tranzicija započela je u Europi nakon Drugog svjetskog rata. Van de Kaa (1987) je tvrdio da je rat doveo do porasta predbračnih spolnih odnosa te da je dob prvog spolnog odnosa pala u poslijeratnom razdoblju. Međutim, društveni stavovi su se sporije mijenjali, a brak je i dalje bio nužan za legitimnost i prihvatljivost spolnih odnosa. Kao rezultat toga, dob sklapanja braka pala je tijekom ovog razdoblja. Poboljšanje

socioekonomskih uvjeta nakon rata učinilo je odgajanje djece financijski pristupačnijima pa su stope fertiliteta rasle sve do 1960-ih. Van de Kaa (1987) je tvrdio da su rani brakovi oslabili povezanost između braka i rađanja djece jer su mladi bračni parovi čekali s rađanjem dok ne postanu financijski spremni. Napredak u zdravstvu, prvenstveno u mogućnosti regulacije i ograničavanja trudnoće dodatno je oslabio vezu između braka i rađanja. Povećanje broja razvoda i razdvajanja doveli su do pada stope brakova i porasta kohabitacije. Nakon što je u početku opstao, pritisak na brak prije rođenja djeteta također je popustio (tj. izvanbračni fertilitet je porastao). Brak (i izvanbračne zajednice) više nisu prvenstveno odražavali želju za djecom, a stope fertiliteta pale su znatno ispod razina potrebnih za zamjenu generacija. Van de Kaa (1987) je tvrdio da će sve zemlje doživjeti četiri osnovne značajke tranzicije prema fertilitetu ispod razine zamjene i mogu se grupirati prema fazi u kojoj se nalaze. Tri od četiriju značajki odnose se na promjene u obiteljskom formiranju i strukturi, a jedna se odnosi na promjenu u korištenju kontracepcije (s preventivne na samoispunjavajuću).

Lesthaeghe (1991) je izgradilo slijed Druge demografske tranzicije (tablica 1.) u tri faze na van de Kaaovom opisu značajki. Tijekom početne faze, otprilike između 1955. i 1970., postojale su tri glavne komponente. Prvo, došlo je do značajnog ubrzanja već prisutnog trenda rasta razvoda. Drugo, završio je *baby boom*. Stope fertiliteta istovremeno su opale u svim dobnim skupinama što se podudaralo s kontracepcijskom revolucijom. Treće, smanjenje dobi pri sklapanju braka, koje je započelo između 1880. i 1920. u većini zapadnih zemalja, zaustavilo se. Umjesto toga, udio onih koji su stupali u brak prije 25. godine značajno je opao. Pred kraj 1960-ih, nekoliko zemalja također je doživjelo privremeni porast prisilnih brakova: predbračni spolni odnosi bili su u porastu tijekom 1960-ih, a kontracepcijska zaštita u takvim odnosima još uvijek nije bila dovoljno učinkovita. U većini zemalja ova je pojava nestala tijekom ranih 1970-ih, no u određenom broju zemalja problem trudnoća kod tinejdžerica i dalje je postojao.

Tijekom druge faze, otprilike između 1970. i 1985. godine, predbračna kohabitacija širi se iz nordijskih zemalja u mnoge druge. U Europi, udio onih koji žive u kohabitaciji uvelike kompenzira pad udjela onih koji stupaju u brak. To nije slučaj u SAD-u, Kanadi ili Australiji, gdje dolazi do neto smanjenja osoba u zajednicama prije 25. godine života. Nakon toga, prokreacija također počinje unutar izvanbračnih zajednica, a te zajednice sve više postaju „brak bez papira“. Prokreacija unutar izvanbračnih zajednica, naravno, rezultira većim udjelom izvanbračnih rođenja u ukupnom broju rođenih.

Treća faza započinje sredinom 1980-ih i obilježena je stabilizacijom stopa razvoda u zemljama koje su dosegle visoke razine. Međutim, važno je naglasiti da su se vjerojatnosti ponovnog braka, kako za razvedene, tako i za udovce, smanjivale tijekom cijelog razdoblja od 1960-ih. Postbračna kohabitacija i odnosi „živjeti odvojeno, ali zajedno" pojavljuju se kao nove značajke i djelomično zamjenjuju ponovne brakove. Osim toga, dolazi do efekta oporavka fertiliteta nakon 30. godine života. U nekim zemljama pad fertiliteta u mlađoj dobi prestaje, uglavnom zato što je dosegnuo vrlo niske razine ili zbog upornih problema s tinejdžerskom trudnoćom. Kao posljedica toga, oporavak fertiliteta nakon 30. godine dovodi do blagog porasta periodnih stopa fertiliteta.

Jedna od posljedica ovih promjena bio je porast jednoroditeljskih obitelji, većinom s majkama kao glavama kućanstva. To je pridonijelo feminizaciji siromaštva[3]. Međutim, te društvene posljedice uvelike variraju između zemalja, uglavnom ovisno o odredbama sustava socijalne sigurnosti. Još jedna posljedica je porast broja samačkih kućanstava, ali i obrasci napuštanja doma među mladim odraslim osobama također su se promijenili. Valja istaknuti da se većina prethodno navedenih istraživanja odnosi na kontekste naprednih ekonomija te europskih zemalja u razvoju. Stoga je važno imati na umu da se uvjeti i demografski obrasci u najmnogoljudnijim državama svijeta mogu značajno razlikovati zbog specifičnih ekonomskih, kulturnih i institucionalnih okolnosti.

2.4. Demografski trendovi i izazovi u Republici Hrvatskoj

Republika Hrvatska se prema formalnim demografsko-statističkim kriterijima koje uzima teorija demografske tranzicije i s obzirom na brojčanu razinu sastavnica reprodukcije stanovništva (natalitet i mortalitet), nalazi u posttranzicijskoj etapi razvoja stanovništva, čije su temeljne karakteristike navedene u prethodnim poglavljima doktorskog rada. Sukladno navedenim karakteristikama, u nastavku su prikazani demografski trendovi u Republici Hrvatskoj (tablica 2).

Tablica 2. Demografski trendovi u Republici Hrvatskoj

[3] Feminizacija siromaštva se odnosi na fenomen prema kojem su žene i djeca nerazmjerno zastupljeni među siromašnima u svijetu u usporedbi s muškarcima (Christensen, 2019).

	1971.	2001.	2011.	2021.	% promjene (2021./1971.)
Ukupan broj stanovnika	**4 426 221**	**4 437 460**	**4 284 889**	**3 871 833**	**-12,53**
Obitelji - ukupno	1 203 240	1 252 025	1 215 865	1 104 395	-8,21
Parovi bez djece	298 492	338 023	348 185	336 989	12,90
Parovi s djecom	904 748	914 002	867 680	767 406	-15,18
Sklopljeni brakovi	37 701	22 076	20 211	18 203	-51,72
Razvedeni brakovi	5427	4670	5662	5100	-6,13
Broj rođenih	64 891	40 993	41 197	36 508	-43,74
Broj umrlih	44 878	49 552	51 019	62 712	39,74
Stopa totalnog	n/a	1,46	1,48	1,63	n/a
Prosječna starost majke pri prvom porodu	22,6	25,7	27,6	29,2	+ 6,6 godina

Izvor: DZS, Eurostat (2023a, b), Akrap (2003), interni podatci DZS

Demografski trendovi u Republici Hrvatskoj od 1971. do 2021. godine ukazuju na značajan pad broja stanovnika, koji je smanjen za 12,53 %. Smanjenje broja stanovnika prati i pad broja obitelji od 8,21 %, što sugerira promjene u strukturi kućanstava, poput manjeg broja članova po obitelji. Istovremeno, broj parova bez djece porastao je za 12,90 %, dok je broj parova s djecom opao za 15,18 %, što ukazuje na smanjenje nataliteta i sve češći trend parova koji nemaju djecu. Broj sklopljenih brakova drastično je pao za više od polovice (51,72 %), dok broj razvedenih brakova bilježi pad od 6,13 %, što upućuje na promjene u društvenim normama i sve manju sklonost sklapanju braka. Zanimljivo je promotriti omjere sklopljenih i razvedenih brakova koji ukazuju da je 1971. godine svaki sedmi brak vodio ka razvodu, dok u 2021. taj omjer ukazuje na svaki četvrti brak. Broj rođenih smanjio se za 43,74 %, dok se broj umrlih povećao za 39,74 %, čime je starenje populacije i negativan prirodni prirast postao demografski trend u Republici Hrvatskoj. Stopa totalnog fertiliteta od 1,58 u 2021. godini ostaje ispod razine potrebne za reprodukciju stanovništva, dok je prosječna starost majke pri prvom porodu porasla za 6,6 godina, što ukazuje na promjene u reproduktivnim navikama i na kasnije rađanje djece. Ovi podatci jasno pokazuju ozbiljne demografske izazove s kojima se Hrvatska suočava, uključujući starenje populacije, smanjenje broja novorođenih i iseljavanje.

Popis stanovništva iz 2021. godine pokazuje da je broj žena u dobi od 15 do 49 godina smanjen za 30 % u odnosu na popis iz 1991. godine, a predviđa se nastavak tog trenda do idućeg popisa. „U narednim godinama broj živorođene djece u Republici Hrvatskoj bit će pod

utjecajem dva važna demografska čimbenika: porasta prosječne dobi majki pri prvom porodu i smanjenja broja žena reproduktivne dobi“ (NN 36/2024). Ključno pitanje za demografsku obnovu u ovim uvjetima jest koliko će odgođenih rođenja, uzrokovanih kasnijim planiranjem roditeljstva, biti ostvareno u kasnijoj životnoj dobi.

Odgađanje rađanja predstavlja značajan demografski problem u Republici Hrvatskoj i može se pratiti analizom kohortne stope fertiliteta, koja mjeri konačan broj djece rođene po ženi na kraju reproduktivnog razdoblja. Podaci popisa stanovništva iz 2011. pokazuju da su žene rođene krajem 1960-ih i početkom 1970-ih, koje su tada bile blizu kraja svojih reproduktivnih godina (u dobi od 40 do 44 godine), prosječno imale 1,9 djece. Prema popisu iz 2021., za žene rođene u 1970-ima stopa fertiliteta opala je ispod 1,9, a za generaciju žena rođenih početkom 1980-ih zabilježen je daljnji pad na prosječno oko 1,7 djece (NN 36/2024.).

Usporedba međupopisnih podataka iz 2001. i 2021. godine za Republiku Hrvatsku pokazuje znatne razlike u razini totalne stope fertiliteta među gradovima i općinama. Prema podacima iz 2021., gradovi imaju nižu stopu fertiliteta (1,58 djece) u odnosu na općine (1,75 djece). U četiri najveća grada (Zagreb, Split, Rijeka i Osijek), stopa fertiliteta iznosi 1,51, što je manje od prosjeka drugih velikih gradova s populacijom većom od 35 000 stanovnika, gdje stopa iznosi 1,58. Uz to, primijećeno je da se stopa fertiliteta povećava kako se smanjuje veličina grada. Tako je u srednjim gradovima (10 000 do 34 999 stanovnika) stopa fertiliteta 1,65, dok mali gradovi (s manje od 10 000 stanovnika) bilježe stopu od 1,66. S druge strane, u općinama se bilježi suprotan trend: totalna stopa fertiliteta opada s veličinom općine. U velikim općinama (više od 3000 stanovnika) stopa iznosi 1,77, u srednje velikim općinama (1500 do 2999 stanovnika) iznosi 1,74, dok male općine (s manje od 1500 stanovnika) imaju stopu fertiliteta od 1,65.

Demografski trend koji obilježava Republiku Hrvatsku jest i promjena u obiteljskim strukturama koja se prije svega očituje kroz odgađanje sklapanja braka i povećani broj razvoda. Prosječna dob ulaska u prvi brak 2001. godine bila je 28,5 godina za muškarce i 25,4 godine za žene. Do 2020. godine ta dob se povećala na 31,3 godine za muškarce i 28,8 godina za žene. Totalna stopa sklapanja prvog braka važan je pokazatelj preferencija stanovništva prema braku. Nedavni podatci pokazuju da će se u Republici Hrvatskoj oko 67 % muškaraca i 72 % žena vjenčati tijekom života. S druge strane, totalna stopa razvoda pokazuje udio brakova koji se razvedu u određenoj godini. Totalna stopa razvoda u Hrvatskoj dosegnula je vrhunac 2016.

godine, iznosivši 0,29, što znači da se očekuje da će se 29 % brakova sklopljenih te godine razvesti do 35. godišnjice. Od 2002. do 2016. godine stopa razvoda se udvostručila, a nakon 2016. godine počela je padati te je 2020. iznosila 0,22. Sve više djece u Hrvatskoj rađa se izvan braka, posebno prvorođena djeca. Udio živorođene djece izvan braka 2022. godine bio je 24,8 %, dok je udio prvorođene djece izvan braka iznosio 32,9 %. To su najviše vrijednosti od 1950. godine. Iako udio živorođenih izvan braka kontinuirano raste od 2000-ih, Hrvatska i dalje ima jedan od najnižih udjela u Europskoj uniji; manji udio imaju samo Grčka i Cipar. U prosjeku, u državama članicama Europske unije oko 43 % djece rađa se izvan braka.

Prema Popisu stanovništva iz 2021. godine, 67,3 % muškaraca u dobi od 25 do 34 godine bilo je neoženjeno, dok je u istoj dobnoj skupini neudano bilo nešto više od polovice žena (50,6 %). U starijim dobnim skupinama, muškarci su u svim popisnim godinama najčešće bili oženjeni, pri čemu je udio udovaca i razvedenih bio razmjerno nizak. Suprotno tomu, zbog dužeg očekivanog životnog vijeka, kod žena se u najstarijim dobnim skupinama bilježi znatno veći broj udovica u odnosu na broj udanih, razvedenih i neudanih žena.

Prirodno kretanje u vidu rodnosti i smrtnosti te nataliteta i mortaliteta stanovništva predstavlja dominantnu odrednicu ukupnog kretanja stanovništva u većini zemalja svijeta. U užem smislu, pod prirodnim kretanjem stanovništva podrazumijevaju se rodnost i smrtnost u određenoj ljudskoj populaciji. U širem smislu, „prirodno kretanje obuhvaća i kretanje sklopljenih i rastavljenih brakova, zasebno iskazivanje i analizu živorođenih u i izvan braka, obiteljsku strukturu, red rođenja i učestalost rađanja u obitelji i pripadajućoj populaciji, višestruke porode, starost majke u trenutku rađanja, kretanje broja i udjela mrtvorođenih, pobačaja, umrle dojenčadi, umrle po dobi i spolu te uzroku smrti“ (Gelo i sur., 2005: 35).

U populacijama u kojima je proces demografske tranzicije završen, kao što je slučaj Republike Hrvatske, bitnu dinamičku komponentu prirodnog kretanja stanovništva čini natalitet/fertilitet, dok mortalitet u tim uvjetima predstavlja relativno stabilnu veličinu. Od 1950. godine pa sve do 2021. godine bilježi se trend smanjivanja broja živorođenih i prirodnog prirasta stanovništva, koji je od 1991. godine poprimio negativan saldo (više umrlih nego rođenih). Broj živorođene djece u razdoblju od 1950. godine[4] do 2021. godine[5] smanjen je za

[4]1950: broj živorođenih 95 500, broj umrlih: 47 292 (Wertheimer-Baletić, 1992: 277)
[5]2020: broj živorođenih 36 508, broj umrlih: 62 712 (Državni zavod za statistiku, 2022)

61,77 %. Istovremeno je broj umrlih porastao za 32,61 %. Gledajući ukupan broj stanovnika Republike Hrvatske, u drugoj polovici 20. stoljeća došlo je do znatnog usporavanja stope porasta stanovništva. Porast broja stanovnika bilježi se sve do 1991. godine kada započinje trend negativne stope porasta stanovništva. Tako je na primjer, Republika Hrvatska 1991. godine imala 4 784 265 stanovnika (Wertheimer-Baletić, 1992: 291, prema Popis stanovništva 1991.), dok je prema podatcima Državnog zavoda za statistiku 2021. godine ukupan broj stanovnika iznosio 3 871 833, što predstavlja smanjenje za 19,07 %. Posljedice prirodnog smanjenja stanovništva očituju se djelomično i u ratnim gubitcima stanovništva te iseljavanjem tijekom domovinskog rata u prvoj polovici 1990-ih godina, uz istovremeno nepovoljnu gospodarsku situaciju.

Promjene nastale u ukupnom broju žena u fertilnoj dobi slijedile su smjer promjena u ukupnom broju stanovništva kako je to prikazano tablicom 3.

Tablica 3. Broj žena u fertilnoj dobi u popisima od 1971. do 2021.

Godina	Ukupan broj ženskog stanovništva	Žene u fertilnoj dobi	Udio fertilnog kontigenta (%)
1971.	2 287 173	1 174 488	51,4
1981.	2 374 579	1 152 704	48,5
1991.	2 465 642	1 149 407	46,6
2001.	2 301 560	1 080 121	46,9
2011.	2 218 554	972 948	43,9
2021.	2 013 963	807 308	40,1

Izvor: Wertheimer-Baletić (2003), Državni zavod za statistiku (2021a)

Tablica 3. prikazuje povećanje ukupnog broja žena u razdoblju od 1971. godine do 1991. godine za 178 469 (7,80 %). Od 1991. godine do 2021. godine broj ženskog stanovništva smanjen je za 18,32 %. Navedene trendove prati i broj žena u fertilnoj dobi. Od 1971. godine do 2021. godine bilježi se smanjenje broja žena u fertilnoj dobi (tablica 3.). Prema podatcima iz 2021. godine, broj žena u fertilnoj dobi iznosio je 807 308 što predstavlja smanjenje za 367 180 žena u fertilnoj dobi u odnosu na 1971. godinu. Nadalje, udio fertilnog kontingenta opao je za 11,3 % u 2021. godini u odnosu na 1971. godinu. Navedeno se može objasniti starenjem stanovništva i emigracijama.

Tablica 4. prikazuje pregled strukture žena prema godinama starosti od 1971. godine do 2021. godine prema dosadašnjim evidentiranim popisima stanovništva koji se rade svakih 10 godina.

Tablica 4. Žene u fertilnoj dobi prema godinama starosti (popisi stanovništva od 1971. do 2021.)

Godina	Žene u fertilnoj dobi	Godine starosti				
		15-19	**20-24**	**25-29**	**30-34**	**35-49**
1971.	1 174 488	192 318	176 308	134 871	162 043	508 948
1981.	1 152 704	165 133	178 791	181 347	167 840	459 593
1991.	1 149 407	159 381	157 609	169 648	180 658	482 111
2001.	1 080 121	145 930	149 892	145 831	147 511	490 957
2011.	972 948	119 259	128 203	141 650	144 621	439 215
2021.	807 308	92 215	103 607	105 816	113 408	392 262

Izvor: izrada doktorandice (Wertheimer-Baletić, 2003; Državni zavod za statistiku, 2021a)

Iz Tablice 4. vidljiva su dva važna kretanja koja posljedično ukazuju na problematiku fertiliteta žena u Republici Hrvatskoj. Nevezano za promjenu metodologije popisa stanovništva iz 2001. godine vidljivo je da je došlo do pada broja žena, na što ukazuje usporedba između 1971. godine i 2021. godine i pad od 31,26 % broja žena u fertilnoj dobi. Gledano prema određenim kategorijama godina starosti žena u fertilnoj dobi prisutan je pad u svim kategorijama, pri čemu su najveće stope pada vidljive u kategorijama od 15 do 19 godina (-52,06 %) i od 20 do 24 godine (-41,24 %) prema popisu stanovništva iz 2021. godine u odnosu na popis stanovništva iz 1971. godine.

U tablici 5. prikazana je analitika žena u fertilnoj dobi od 1971. godine do 2021. godine temeljem čega se mogu izvući zaključci vezani uz specifičnosti svakog razdoblja koji su utjecali na prikazan omjer dobne strukture žena u fertilnoj dobi.

Tablica 5. Dobna struktura žena u fertilnoj dobi (popisi stanovništva od 1971. do 2021.)

Godina/starost	15-19	20-24	25-29	30-34	35-49
1971.	16,4 %	15,0 %	11,5 %	13,8 %	43,3 %
1981.	14,3 %	15,5 %	15,7 %	14,6 %	39,9 %

1991.	13,9 %	13,7 %	14,8 %	15,7 %	41,9 %
2001.	13,5 %	13,9 %	13,5 %	13,7 %	45,5 %
2011.	12,3 %	13,2 %	14,6 %	14,9 %	45,1 %
2021.	11,4 %	12,8 %	13,1 %	14,0 %	48,6 %

Izvor: izrada doktorandice (Savezni zavod za statistiku, 1994; Državni zavod za statistiku 2001, 2011 i 2021)

Prikaz dobne strukture žena u fertilnoj dobi iz tablice 5. daje važan uvid u kategorizaciju žena prema dobnoj strukturi i za svako vremensko razdoblje te se na temelju ovih podataka može napraviti prikaz i analiza svakog desetogodišnjeg razdoblja po pitanju demografskih politika, učinaka i mjera vezanih uz problematiku fertiliteta. U svim promatranim godinama popisa stanovništva najveći udio imale su žene u fertilnoj dobi starosti između 35 i 49 godina. Promatrajući udjele žena prema godinama starosti između popisa stanovništva, vidljivo je da je došlo do smanjenja udjela žena mlađe dobne skupine (od 15 do 34 godine) dok je istovremeno povećan udio žena starije dobne skupine (od 35 do 49 godina) tijekom 2021. godine u odnosu na 1971. godinu.

Specifična stopa fertiliteta označava omjer broja živorođene djece koju su rodile žene određene dobi i procijenjenog broja žena iste dobne skupine u promatranom razdoblju. Ove stope pod utjecajem su društvenih čimbenika, pa čine društvenu odrednicu reprodukcije stanovništva. Na njih utječu različiti međusobno povezani društveni uvjeti i čimbenici – gospodarski, socijalni, kulturni, politički i tradicionalni.

Tablica 6. daje prikaz specifičnih stopa fertiliteta prema starosti majke (na 1000) od 1970. godine do 2021. godine temeljem kojih se mogu oblikovati određeni zaključci vezani uz reproduktivne demografske trendove prema određenim kategorijama godina starosti.

Tablica 6. Specifične stope fertiliteta prema starosti majke (na 1000)

Starost majke	1970.	1980.	1990.	2000.	2010.	2020.	2021.
15-19	46,9	45,4	29,0	15,8	11,9	7,6	6,9
20-24	133,6	159,3	131,0	83,3	55,1	39,5	41,8
25-29	96,9	107,3	114,0	92,9	98,7	88,0	96,9
30-34	53,1	50,8	48,2	57,8	84,8	99,5	109,1
35-39	22,5	17,2	15,5	24,2	35,9	50,7	57,8
40-44	5,9	4,2	2,8	5,3	6,0	10,9	11,9

45-49	0,6	0,3	0,2	0,3	0,2	0,5	0,5

Izvor: Wertheimer-Baletić (1985: 268), Wertheimer-Baletić (2003: 40), Državni zavod za statistiku (n.d. b)

Kako je prikazano u tablici 6., specifične stope fertiliteta prema dobi su u petogodišnjim dobnim grupama od 30 do 34, od 35 do 39 i od 40 do 44 godina značajno porasle tijekom promatranog razdoblja od 1970. godine do 2021. godine. Brojčanu razinu specifičnih stopa fertiliteta iznad razine 100,00 nalazimo do 1990. godine, nakon toga, tijekom 2021. godine u starosnoj skupini žena 30 do 34 godine ova stopa ponovno doseže razinu iznad 100,00. Brojčane razine specifičnih stopa fertiliteta iznad 100,00 vidljive su samo u dobnim grupama od 20 do 24 godine i od 25 do 29 godina do 1990. godine, pri čemu veći udio u ukupnom broju živorođene djece ima dobna grupa od 20 do 24 godine starosti majke. Porast specifične stope fertiliteta u dobi od 15 do 19 godina u razdoblju do 1980. godine može se objasniti ranim ulaskom u brak, niskom starosnom dobi žene prilikom rođenja prvog djeteta te porastom broja sklopljenih brakova u mlađim dobnim grupama. Nakon 1990. godine pojačava se tendencija smanjivanja ukupnog broja žena u fertilnoj dobi, nastavlja se proces starenja fertilnog kontingenta te dolazi do smanjivanja specifičnih stopa fertiliteta u mlađim dobnim grupama majke. Navedeno se može djelomično objasniti ratnom agresijom na Hrvatsku početkom 1990-ih godina koja je zasigurno imala utjecaj na nepovoljne demografske trendove. Osim toga, Wertheimer-Baletić (2003) navodi da je u tom razdoblju došlo i do izražaja posttranzicijskog obilježje reprodukcije stanovništva te djelovanje društvenih odrednica na daljnje smanjivanje specifičnih stopa fertiliteta prema dobi i pomicanja težišta fertiliteta na starije dobne grupe.

Konačno, na temelju prethodnih analiza demografskih trendova u Republici Hrvatskoj može se zaključiti da se smanjuje ukupni fertilni kontingent te dolazi do starenja fertilnog kontingenta odnosno povećanja broja žena niske plodnosti.

Zaključno, nizak fertilitet nije samo demografski problem, već i ekonomski problem cijele države. Povećanja stope ovisnosti, odnosno udjela uzdržavanih osoba (osobe starije od 65 godina) u odnosu na aktivno stanovništvo, koje je radno sposobne dobi (15 do 64 godine) zasigurno je bitan problem. U Republici Hrvatskoj ovaj omjer iznosi 35,6 % (Eurostat, 2022). Europa se također suočava s procesom starenja stanovništva, što će do 2100. godine rezultirati povećanjem omjera ovisnosti s trenutnih 33 % na značajnih 60 %. Ovaj demografski trend nosi

rizik smanjenja radno sposobnog stanovništva Europske unije za 57,4 milijuna osoba do kraja stoljeća, uz istovremeno starenje tog stanovništva (Europska komisija, 2023). U sljedećim godinama očekuje se nastavak opadanja populacije Europske unije, što bi moglo imati negativne posljedice na gospodarstvo, društvo i položaj Europske unije u svjetskim okvirima. Navedeno može negativno utjecati na konkurentnost Europske unije na globalnoj razini. Ako se demografske promjene ne riješe na adekvatan način, mogu dovesti do dodatnog pogoršanja nedostatka radne snage te daljnjeg povećavanja pritiska na javne proračune država. Nadalje, depopulacija i „odljev mozgova“ mogu rezultirati značajnim disparitetima među regijama, što u konačnici ugrožava socijalnu koheziju EU-a. Očekivane posljedice zahtijevaju dodatne napore privatnog i javnog sektora uvođenjem mjera za suočavanje i upravljanje demografskim promjenama.

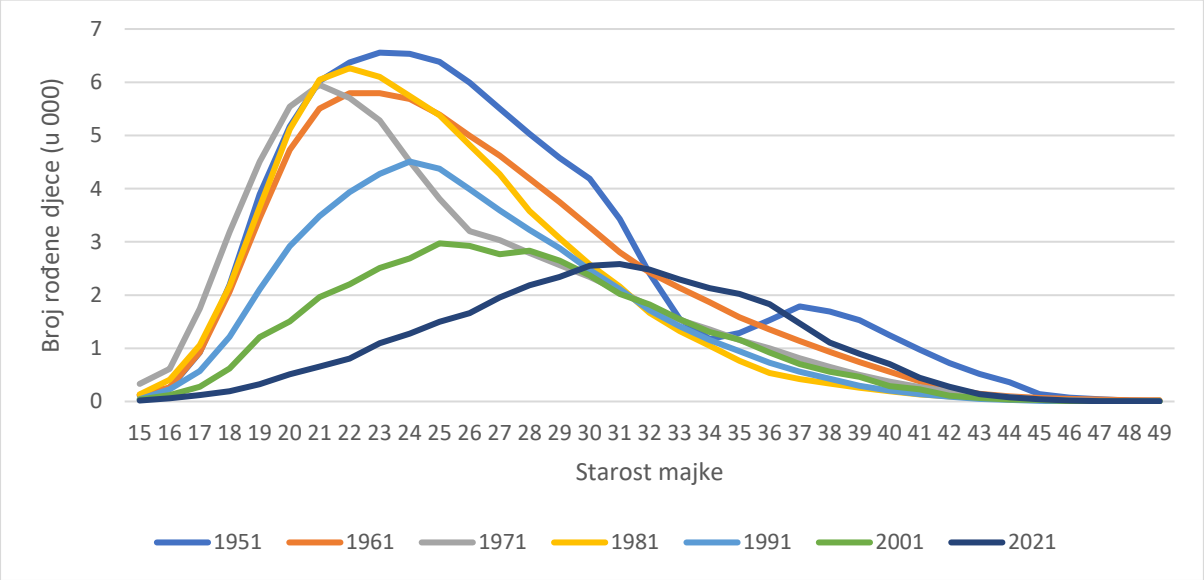

Grafikon 1. Distribucija rađanja prema dobi majke, Republika Hrvatska
Izvor: Ujedinjeni narodi (2024)

Grafikon 1. prikazuje smanjenje broja rođene djece u apsolutnom broju prema dobi majke, kao i značajan pomak distribucije u desno. Naime, s vremenskim pomakom došlo je i do smanjenja broja rođene djece u ranim dvadesetim godinama te povećanja rađanja u kasnijim dvadesetim i ranim tridesetim godinama majke.

3. EKONOMSKE TEORIJE FERTILITETA

Ovo poglavlje bavi se teorijama fertiliteta koje utječu na odluke o rađanju. Većina istraživanja odnosi se na dvije glavne alternativne teorije: teoriju averzije prema riziku (s posebnim naglaskom na odlučivanje obitelji (McDonald, 2002)) i teoriju smanjenja neizvjesnosti (Friedman i sur., 1994). Obje teorije imaju neke zajedničke točke, no obje teorije postuliraju dvije suprotne strategije koje pojedinci mogu koristiti kako bi učinili svoje buduće izglede manje nesigurnima. Naposljetku, objašnjena je i teorija konjunkturnog djelovanja.
No, prije objašnjenja samih teorija, nužno je pojasniti određene demografske pojmove.

Prema Wertheimer-Baletić (1999: 208, 209), natalitet (tj. fertilitet) predstavlja pozitivan čimbenik u prirodnom kretanju stanovništva, koji uz ostale iste uvjete doprinosi povećanju broja stanovnika na određenom području. Na temelju šireg tumačenja, pojmovi nataliteta i fertiliteta su u biti jednaki jer se odnose na istu pojavu – broj rođenja u određenoj populaciji tijekom određenog razdoblja. Stoga, u općem smislu, izražavaju kvantitativne aspekte vezane uz rađanje djece u cijelom stanovništvu nekog područja ili unutar njegovog određenog segmenta. Međutim, kada se usredotočimo na uže značenje tih pojmova, posebno u kontekstu mjerenja (izračunavanja stope nataliteta i stope fertiliteta), razlikuju se. Natalitet se odnosi na broj živorođene djece u odnosu na ukupno stanovništvo tog područja, dok fertilitet označava broj živorođene djece u odnosu na žensko stanovništvo u fertilnoj dobi, obično između 15 i 49 godina (Središnji državni ured za demografiju i mlade, 2024).

Totalna stopa fertiliteta označava prosječan broj rođene djece tijekom fertilne dobi žene i najčešće je upotrebljavana mjera plodnosti prilikom usporedbe među različitim zemljama. Ujedno, totalna stopa fertiliteta od prosječno 2,1 djeteta često se u literaturi i javnosti navodi kao zamjenska stopa fertiliteta. Kao očekivana posljedica demografske tranzicije u većini razvijenih zemalja navodi se niska stopa plodnosti tijekom dužeg vremenskog razdoblja, uz izostanak zamjenske stope fertiliteta od 2,1 djeteta (Werding, 2014; Nargund, 2009; Bloom i sur., 2001). Međutim, McDonald (2006) navodi da društva ne moraju nužno težiti postizanju zamjenske razine plodnosti jer postoji „sigurnosna zona“ za nižu zamjensku plodnost koja ima donju granicu iznad 1,5 rođenih po ženi. U ovoj sigurnosnoj zoni, učinci niske plodnosti na buduću ponudu radne snage mogu se nadoknaditi migracijom ili, alternativno, može se dopustiti da buduća ponuda radne snage opada sporo i kontrolirano. Zemlje sa stopama

plodnosti ispod 1,5 rođenih po ženi moraju ispitati smjernice politike koje bi njihovu plodnost podigle u sigurnosnu zonu.

3.1. Teorija averzije prema riziku

Ekonomska teorija plodnosti koju je uveo Becker (1960) ukazuje da roditelji izvlače zadovoljstvo kako iz kvalitete djece, tako i iz kvantitete djece, tj. broja djece. Ako se djeca smatraju normalnim dobrima i ako je elastičnost prihoda potražnje za kvalitetom veća od elastičnosti prihoda potražnje za brojem djece, porast prihoda povećao bi i željenu kvalitetu i kvantitetu djece, pri čemu bi povećanje kvalitete bilo veće od povećanja kvantitete (Hu i sur 2022). Nadalje, Becker (1992) povezuje potražnju za djecom s prihodima roditelja i troškovima odgoja djece, posebno s vrijednošću vremena provedenog na brigu o djeci, ali i s javnim politikama koje mijenjaju i utječu na troškove djece. Sukladno navedenom, trošak rađanja djece smatra se važnim čimbenikom namjere rađanja.

Teorija averzije prema riziku dodaje još jednu dimenziju teoriji racionalnog izbora. Pretpostavka teorije racionalnog izbora jest da ljudi dobro poznaju ili razumiju troškove i koristi koje proizlaze iz odluke o imanju sljedećeg djeteta. Teorija averzije prema riziku koja proizlazi iz teorije racionalnog izbora i nove ekonomske teorije (Becker, 1993) sugerira da se odluka o tome hoće li par imati dijete donosi usporedbom koristi i troškova od rađanja dodatnog djeteta. Odlučujući se za dijete, ljudi donose odluku o promjeni svog budućeg životnog puta, pa stoga njihova odluka ovisi o njihovoj orijentaciji prema budućnosti (McDonald, 1996). Pri razmatranju budućih odluka, pojedinci imaju samo oskudno razumijevanje prilika, koristi i troškova povezanih s njihovim razmatranjem namjere rađanja. Međutim, kada se ekonomske, društvene ili osobne posljedice doživljavaju kao nesigurne, pojedinci su skloni djelovati na način da izbjegavaju rizik i pri tome biraju sigurnost. U vremenima kada je ugrožena sigurnost sustava socijalne skrbi, sklonost averziji prema riziku dobiva na značaju (McDonald, 2002). Dodatno uporište negativnog utjecaja nesigurnosti na odluke o rađanju i odgađanje rađanja potvrđuju i brojna druga istraživanja (Norling, 2021; Kreyenfeld, 2010; Koahler i sur., 2002; Heckman i Willis, 1976).[6] U situaciji ekonomske nesigurnosti, teorija averzije prema riziku

[6] Detaljnije objašnjenje o utjecaju nesigurnosti i neizvjesnosti na namjeru rađanja prikazano je u poglavlju 4.2.1.1. ovog doktorskog rada.

implicira ulaganje u ekonomsku sigurnost (npr. obrazovanje, štednju i sl.) umjesto u nesigurnost koja je povezana s namjerom rađanja i imanja djece (Fiori i sur., 2013).

Osim u uvjetima ekonomske nesigurnosti, averzija prema riziku može se primijeniti na društvene, intimne i osobne dimenzije života (McDonald, 2000). Naime, prema McDonald (2002), postoji rizik da će djeca narušiti odnos roditelja, da će slijediti puteve koji uzrokuju roditeljima tjeskobu, da će neka opasnost zadesiti dijete, da će imati još više poteškoća u prevladavanju teških trenutaka, da će javna podrška obiteljima s djecom biti smanjena itd. Rješenje navedenih problema i strahova autor pronalazi u ograničavanju broja djece, tj. smanjenju broja djece koje će roditelji imati. Osim toga, averzija prema riziku može utjecati i na sklapanje braka i rađanje djece izvan bračne zajednice.

3.2. Teorija smanjenja neizvjesnosti

Teorija smanjenja neizvjesnosti (Fiori i sur., 2013) proizlazi iz spoznaje da, čak i u uvjetima velike neizvjesnosti, ne izostaje namjera i realizacija rađanja. Promatrajući širu sliku, pojedinci se odlučuju za izbore koji će im pomoći smanjiti neizvjesnost. U tom kontekstu, roditeljstvo se može promatrati kao snaga koja neutralizira neizvjesnost koju stvaraju nesigurni radni uvjeti, potičući parove da se približe relativnoj sigurnosti koja proizlazi iz imanja doživotnih prava i obveza u vezi sa svojom djecom. Imati djecu stoga se može smatrati alternativnim životnim ciljem za one koji su najviše pogođeni neizvjesnošću koju donosi proces globalizacije. Ideja da pojedinci mogu tražiti smanjenje ukupne neizvjesnosti imajući djecu predložena je u nizu istraživanja koja proučavaju odnos između ekonomske nesigurnosti i plodnosti (Begall, 2011; Klesment i Puur 2010; Bernardi i sur., 2008).

Friedman i sur. (1994) koriste nestandardnu vrijednosnu pretpostavku - smanjenje neizvjesnosti - za objašnjenje racionalnog izbora suvremenog ponašanja nataliteta u razvijenim društvima. Autori nastoje objasniti zašto neki ljudi u naprednim društvima nemaju djece, dok drugi imaju barem jedno dijete, tvrdeći da smanjenje neizvjesnosti predstavlja univerzalnu unutarnju vrijednost. Međutim, tvrdnja o vrijednosti djece u svrhu smanjenja neizvjesnosti primjenjuje se samo na razvijena društva, gdje djeca predstavljaju neto ekonomske troškove svojim roditeljima. Nasuprot tomu, Cain (1978 u Friedman i sur., 1994) zaključuje da kućanstva i žene koje se suočavaju s iznenadnim razvodom ili iznenada postaju udovice, bez ikakve ekonomske sigurnosti rađaju djecu kako bi smanjile neizvjesnost. Implikacije ovog

nalaza za ponašanje žena jest da je poželjno imati što više sinova, međutim, teško je razdvojiti motivaciju za smanjenje neizvjesnosti od ekonomske motivacije, jer djeca povećavaju kapacitet proizvodnje kućanstva.

Da bi se postupalo racionalno, pojedinac treba biti sposoban procijeniti rizik. Iz tog razloga, racionalni sudionici radije biraju situacije s rizikom nego situacije pod neizvjesnošću (Ellsberg, 1961). Pretpostavka o smanjenju neizvjesnosti ogleda se u moći pojedinca da promijeni nesigurno stanje u određeno manje rizično stanje. Uz dodatnu pretpostavku povećanja bračne solidarnosti, smanjenje neizvjesnosti omogućava razvoj teorije vrijednosti djece. Naime, u tradicionalnim uvjetima, djeca su bila važna za smanjenje neizvjesnosti, i to zbog njihove sposobnosti da pruže bogatstvo i osiguranje svojim starijim roditeljima te zbog doprinosa društvenoj integraciji. Prvi skup doprinosa, ali ne i drugi, izgubio je vrijednost tijekom vremena. Ovaj vremenski pomak u vrijednosti djece sugerira, kao i ekonomska teorija smanjenja plodnosti, da bi se traženi broj djece trebao smanjiti, ali ne na nulu (Friedman i sur. (1994).

Fiori i sur. (2013) navode da se glavna neizvjesnost javlja pri namjeri rađanja prvog djeteta, međutim teorija smanjenja neizvjesnosti ne bi trebala biti odbačena niti prilikom proučavanja namjere rađanja bilo kojeg sljedećeg djeteta, neovisno o redoslijedu.

3.3. Teorija konjunkturnog djelovanja

Teorija konjunkturnog djelovanja (engl. *Theory of Conjunctural Action*, TCA), prema Kertzer (2013), polazi od dvostrukog strukturnog modela koji je razvio sociolog William Sewell. Ova novorazvijena teorijska konstrukcija u socijalnoj demografiji pruža vrijednu teorijsku orijentaciju. Autor navodi da je „stari pogled na demografske događaje kao proizvod neovisnog, individualnog racionalnog izbora dramatično oslabljen istraživanjima u disciplinama od psihologije do antropologije i biologije“ (Kertzer, 2013: 130). Teorija konjunkturnog djelovanja stavlja veliki naglasak na važnost razumijevanja utjecaja društvenih struktura koje su oblikovane međudjelovanjem shematskih i materijalnih elemenata. Prvi elementi, koji su već desetljećima predmet pažnje u kognitivnoj psihologiji, odnose se na mentalne konstrukte kojima ljudi razumiju svoj svijet i koji motiviraju njihovo ponašanje. Materijalni elementi sastoje se od objekata (ne moraju biti fizički adekvatni) koji sakupljaju sheme u opažanom svijetu. Ostali važni dijelovi ove teorije su koncepti „konjunkture“ i

„interpretacije“. Konjunkture su povijesni trenutci promjene ili potencijalne promjene kada se običan tijek događaja dovodi u pitanje. Interpretacija se odnosi na način na koji pojedinac tumači određenu situaciju.

Prema Johnson-Hanks i sur. (2011) teorija konjunkturnog djelovanja počinje od pretpostavke da bi vitalni događaji koji čine predmet socijalne demografije trebali biti tretirani kao proizvodi društvenog djelovanja i da razumijevanje društvenog djelovanja zahtijeva koncept društvenih struktura. Izraz „društvene strukture“ akumulirao je višestruka značenja u različitim tradicijama društvenih znanosti, obuhvaćajući skup odnosa među različitim klasama, rasnim ili rodno određenim grupama pa sve do konkretnog niza zakona, politika i institucija koje oblikuju društveno djelovanje. Izraz „struktura“ koristi se kako bi se odnosio na trajne oblike organizacije, obrasce ponašanja ili sustave društvenih odnosa. U nekim granama antropologije, „struktura“ se koristi kao sinonim ili zamjena za „kulturu“, posebno u posljednjih nekoliko desetljeća. Dvojno razumijevanje strukture (Sewell, 1992) skreće pozornost na činjenicu da oblici obitelji i druge strukture nastaju i održavaju se putem međudjelovanja shematskih i materijalnih elemenata. Shematski elementi, poput ideja, vrijednosti i navika uma te materijalni elementi, kao što su objekti i izvedbe, potiču, podržavaju, ograničavaju i transformiraju jedni druge na konkretan način tijekom vremena. Teorija konjunkturnog djelovanja objašnjava promjene u obitelji putem interakcije strukture (shematske i materijalne) i slučajnosti, kroz analizu konjunktura, odnosno povijesno specifičnih prekretnica, putem kojih se strukture preoblikuju ili potvrđuju. Tako opisana teorija postavlja razumijevanje promjena i varijacija u obitelji unutar osnovne koncepcije kako ljudsko djelovanje nastaje u svijetu i mijenja ga.

Usvajanje ponašanja koje odbojno reagira na rizik ili na smanjenje neizvjesnosti može ovisiti, između ostalog, o mjeri i vrsti te neizvjesnosti, socijalnim karakteristikama pojedinaca te društvenim i institucionalnim odgovorima na neizvjesnost. Fiori i sur. (2013) navode da je dokazano da su odluke o plodnosti u vremenima ekonomske nesigurnosti diferencirane prema individualnim karakteristikama, kao što su spol, dob, trenutačan broj djece te članstvo u određenoj društvenoj skupini. Nadalje, ekonomska nesigurnost ima različite učinke na želje i/ili namjere o plodnosti, njihovo planirano vrijeme ostvarivanja, ili samu realizaciju o snažnijem utjecaju na želje za rađanjem nego na stvarne rezultate ili o različitim učincima na dugoročne ili kratkoročne namjere o plodnosti. Osim toga, promatrani učinci snažno ovise o kontekstu. Kako su predložili Mills i Blossfeld (2005), individualne reakcije na izazove i

prijetnje koje nameće globalizirajuće gospodarstvo i povećana neizvjesnost o ekonomskim i društvenim događanjima usmjeravaju se posredničkim faktorima kao što su tržište rada, obrazovni sustav te institucionalna i obiteljska skrb. Unutar istog konteksta, važan posrednički faktor između individualnog odgovora na nesigurnost i društvenih čimbenika je dostupnost podrške iz društvene mreže pojedinca. Racionalno donošenje odluka pojedinaca pod uvjetima povećane nesigurnosti može se stoga znatno razlikovati između zemalja, ovisno o institucionalnom okruženju, i unutar iste zemlje, ovisno o društvenoj strukturi jer čimbenici određuju mjeru u kojoj povećana nesigurnost utječe na individualne živote.

4. ULOGA I ZNAČAJ JAVNIH POLITIKA U FUNKCIJI POVEĆANJA FERTILITETA

Uzroci nepovoljnih demografskih trendova u Republici Hrvatskoj ne leže samo u internim društvenim i gospodarskim procesima, nego ih je nužno razmatrati i u širem europskom te globalnom kontekstu. Demografska revitalizacija postaje prioritetno nacionalno pitanje za budući razvoj države te zahtijeva promišljanje i provođenje brojnih mjera, aktivnosti i intervencija. Koordinirana suradnja između različitih razina vlasti, uključujući državne, lokalne i regionalne jedinice nužna je za poboljšanje demografske slike Republike Hrvatske, unaprjeđenje kvalitete življenja obitelji i stvaranje poticajnog okruženja za osnivanje obitelji. Također, potrebno je osigurati učinkovitu koordinaciju između populacijske politike i ostalih javnih politika. Budući da populacijska politika obuhvaća različite sfere intervencije, za njezinu uspješnu provedbu ključna je suradnja među državnim, regionalnim i lokalnim vlastima, poslodavcima, sindikatima, nevladinim organizacijama i ostalim relevantnim organizacijama. Kako bi se osigurao održiv demografski razvoj Republike Hrvatske, važno je provoditi mjere u različitim područjima javne politike – uključujući socijalnu, obrazovnu i zdravstvenu – koje trebaju djelovati sinergijski i omogućiti optimalno korištenje resursa radi postizanja željenih ciljeva, među kojima su i demografski ciljevi.

Dugoročno zadržavanje totalne stope fertiliteta ispod zamjenske razine (prosječno 2,1 djece po ženi) dovodi do pada broja stanovnika, a u budućnosti i do izumiranja stanovništva. Osim toga, problem predstavlja i pad kvalificirane radne snage koja u budućnosti može dovesti do još većeg nedostatka radne snage. Rješenje za suzbijanje starenja stanovništva i smanjenja ponude radne snage već sada se u Republici Hrvatskoj pronalazi u imigracijskim procesima. Povećanje stvarne razine sudjelovanja na tržištu rada (McDonald, 2000) moguće je postići povećanjem stope aktivnosti žena i/ili općim odgađanjem dobi za umirovljenje. Republika Hrvatska uspjela je povećati stopu aktivnosti žena (tablica 9.) dok su napori donositelja zakona usmjereni i na povećanje dobne granice odlaska u mirovinu sa 67 godina nakon 2030. godine. Politika fertiliteta je, dakle, nužna i opravdana jer bi povećanje nataliteta dugoročno moglo djelomično ponovno uravnotežiti stopu ovisnosti, ublažiti financijski teret mirovinskog i zdravstvenog sustava te zajamčiti reprodukciju ponude kvalificirane radne snage (Bernardi, 2005).

Nadalje, bitan aspekt promatranju su i izdatci koji su povezani s imanjem djece. Naime, državni i lokalni proračuni opterećeni su izdatcima kojima se pokušavaju neutralizirati ili barem smanjiti utjecaji ekonomskih ograničenja i prepreka za osnivanje obitelji, kao i jaz između željenog i ostvarenog broja djece. Nije zanemariv niti negativan utjecaj na dugoročnu održivost mirovinskih sustava. Niski natalitet može dovesti do problema održivosti mirovinskih sustava jer će manje radno aktivnih osoba doprinositi u mirovinski fond, dok će više umirovljenika očekivati mirovine. To može dovesti do potrebe za restrukturiranjem mirovinskih sustava kako bi se osigurala dugoročna financijska održivost.

Oslanjajući se na Beckerov pristup potražnje za djecom, Pritchett (1994) navodi da su izbori u vezi s plodnošću muškaraca i žena, koji su uvjetovani i ograničeni društvenim, obrazovnim, kulturnim i ekonomskim uvjetima s kojima se suočavaju, glavni pokretači stvarne plodnosti. Nadalje, politike koje poboljšavaju objektivne uvjete za žene – povećanje njihovih prihoda, poboljšanje obrazovanja i poticanje osnaživanja samo su neki od čimbenika koji utječu na smanjenje broja djece i usporavanje rasta stanovništva.

Uzimajući u obzir prethodno opisane demografske trendove i izazove, kao i negativne implikacije na gospodarstvo u cjelini, nužno je stvoriti poticajno okruženje za djecu i mlade sinergijskim djelovanjem javnih politika. Trenutne i predvidive demografske promjene zahtijevaju prilagodbu javnih politika novonastalim demografskim izazovima, osobito u područjima obiteljske i mirovinske politike, obrazovanja i zdravstva. Istodobno je nužno poticati visoku razinu zaposlenosti uz osiguranje fleksibilnih radnih uvjeta te unapređenje zdravstvenog stanja stanovništva. U cjelini, niski natalitet može imati značajan utjecaj na javne financije, stvarajući potrebu za prilagodbama u proračunu i socijalnim programima kako bi se odgovorilo na demografske promjene i osigurala financijska održivost države.

4.1. Populacijska i obiteljska politika

Zemlje središnje i istočne Europe (engl. *Central and Eastern Europe*, CEE), doživjele su pad fertiliteta tijekom 1990-ih. Prethodio mu je pad fertiliteta tijekom kasnih 1960-ih i 1970-ih u regijama sjeverne i zapadne Europe, u regiji njemačkog govornog područja te u regiji južne Europe, koja je doživjela pad fertiliteta u 1980-ima (Basten i Frejka, 2015).

Brojni su razlozi koji su doveli do smanjenja stope fertiliteta ispod zamjenske stope, no većina autora u literaturi kao uzrok pada stopa fertiliteta pronalazi u drugoj demografskoj tranziciji, koja je već prethodno opisana (vidi potpoglavlje 2.3.).

Kao posljedicu smanjenja fertiliteta u Europi Letablier i sur. (2009) navode dramatično smanjenje prosječne veličine obitelji. Naime, obitelji s dvoje ili više djece postale su sve manje prisutne, dok su obitelji s jednim djetetom uobičajene u srednjoj, istočnoj i južnoj Europi, uz istodoban trend porasta broja žena mlađe životne dobi bez djece. Kod žena mlađe životne dobi bez djece prisutna je karakteristika visokog obrazovanja, što dovodi do poteškoća u usklađivanju privatnog i poslovnog života te posljedično i utjecaja na rađanje.

Smanjenje reproduktivne motivacije među mlađom populacijom u Republici Hrvatskoj očituje se u ekonomskim čimbenicima poput egzistencijalnih problema: nezaposlenost, loši stambeni uvjeti, prekarni rad, atipično radno vrijeme i financijski trošak podizanja djece (Čipin i Međimurec, 2017; Akrap, 2005). Više o ekonomskim čimbenicima fertiliteta prikazano je u potpoglavlju 4.3.1.

Negativni demografski trendovi mogu se ublažiti provođenjem sveobuhvatnih javnih politika koje će ciljano, kroz različite mjere, biti usmjerene na demografsku revitalizaciju. U tom segmentu razlikujemo populacijsku i obiteljsku politiku. Puljiz (1999) navodi da je „populacijska politika usmjerena na postizanje određenih demografskih ciljeva. U pravilu se radi o povećanju ili smanjenju stanovništva. Povećanje stanovništva nastoje postići razvijenije zemlje s niskim stopama fertiliteta, a smanjenje stanovništva nerazvijene zemlje s visokim stopama demografskog rasta. Populacijska se politika ostvaruje na razini cijelog društva, a obiteljska na razini obitelji kao osnovne ćelije društva. Prva utječe na promjene u ukupnoj populaciji, a drugom se, prvenstveno, nastoje postići promjene u kvaliteti života obitelji, odnosno pojedinca. Ipak, i populacijska i obiteljska politika su međusobno tijesno povezane“ (Puljiz, 1999: n.p.). Stropnik (1995) populacijsku politiku sagledava kao makroorijentaciju, dok obiteljsku politiku sagledava kao mikroorijentaciju. Autorica navodi da na populacijsku politiku utječu makrodeterminante nataliteta, tj. determinante koje funkcioniraju na razini cjelokupnog društva – ideološka, zakonska, filozofska i dr. obilježja društva. S druge strane, mikrodeterminante, odnosno determinante nataliteta na razini obitelji – troškovi i koristi djece obilježje su obiteljske politike. Reprodukcijska funkcija glavna je veza između populacijske i obiteljske politike (Malačić, 1994 u Stropnik 1995).

„Prema uskoj definiciji, moglo bi se reći da obiteljska politika uključuje beneficije i usluge koje su isključivo usmjerene na parove s djecom i/ili samohrane roditelje. Takva definicija obuhvaća novčane naknade i naknade u naravi kao što su izravni novčani transferi obiteljima, porezne olakšice za obitelji s djecom, porodiljni i roditeljski dopust, vrtiće i subvencije, kao i obiteljsko pravo. Prema širokoj definiciji, obiteljska politika može se proširiti na sve javne politike koje potencijalno mogu utjecati na dobrobit obitelji uključujući politike i usluge povezane s javnim prijevozom, imigracijom, sigurnošću hrane itd.“ (Gauthier, 2000: 1).

Tablica 7. prikazuje komponente obiteljske politike prema uskoj i širokoj definiciji.

Tablica 7. Komponente obiteljske politike

Uska definicija	**Osnovne tradicionalne komponente** • izravni novčani transferi (obiteljske naknade, stambene naknade, stipendije) • neizravni novčani transfer (porezne olakšice, subvencije) • rodiljni i roditeljski dopust i naknade • ustanove za brigu o djeci.
Široka definicija	**Netradicionalne komponente** • naknade za njegu starijih osoba • mirovinski doprinos za osobe s obiteljskim obvezama • politike radnog mjesta (fleksibilno radno vrijeme, rad na daljinu itd.).
	Obiteljsko pravo • Obiteljski zakon • Zakon o zaštiti od nasilja u obitelji • Zakon o pravobranitelju za djecu • Zakon o suzbijanju diskriminacije • Zakon o privremenom uzdržavanju • Zakon o udomiteljstvu.
	Usluge • obrazovanje • zdravlje • prihvatilište za zlostavljane supružnike i djecu • službe za skrb o djeci.

	Ostale javne politike • javni prijevoz • imigracijski zakoni • potpore i naknade za nezaposlene • trening.

Izvor: prilagodba doktorandice (Gauthier, 2000: 17)

Tri široka skupa mjera općenito se smatraju jezgrom obiteljske politike (Letablier i sur., 2009: 10):

- „novčane potpore obiteljima (putem naknada i/ili poreznih olakšica)
- potpore u naravi ili usluge u obliku obrazovanja, skrbi i nadzora za malu i stariju djecu
- naknade za obiteljski dopust i naknade za odgoj djeteta roditeljima koji skrbe o djeci (rodiljni dopust, očinski dopust, roditeljski dopust, dopust radi njege bolesnog ili hendikepiranog djeteta)“.

Novčani transferi, olakšice i različite potpore osnovni su sadržaj obiteljske politike. No, širi raspon drugih instrumenata politika (Letablier i sur., 2009: 11) također se može uključiti u paket mjera obiteljskih politika: odredbe socijalne skrbi koje nisu one za obitelj/djecu, tj. koje se ne usmjeravaju isključivo na obitelji s djecom, već imaju jasan učinak na njih. Takve odredbe uključuju:

- doplatak za djecu u stambenim naknadama i naknadama socijalne pomoći
- zdravstveno osiguranje za djecu
- dodatci na mirovine
- porezne olakšice koje nisu usmjerene isključivo na obitelji s djecom, poput zajedničkog oporezivanja bračnih parova
- izdatci za obrazovanje koji također mogu biti važni
- također treba uzeti u obzir uvjete rada i zapošljavanja osim dopusta, bilo da su određeni zakonom ili kolektivnim ugovorom.

Politike potpore obitelji obično uključuju šest glavnih ciljeva, s različitim prioritetima ovisno o naciji (Letablier i sur., 2009: 9):

- „naknada za brigu o djeci, kako bi se smanjila razlika u životnom standardu između kućanstava s i bez djece

- smanjenje siromaštva obitelji s djecom i djece
- potpora fertilitetu pomaganjem odraslima da imaju onoliko djece koliko žele, odnosno kako bi se smanjio jaz između željenog i ostvarenog broja djece
- promicanje dobrobiti djece i njihovog kognitivnog i socijalnog razvoja
- povećanje postotka zaposlenih žena i bolja ravnoteža između poslovnog i obiteljskog života. Potpora obiteljima u ovoj situaciji ima za cilj pomoći roditeljima da usklade posao i brigu o djeci kao i „kompenzirati“ troškove odgoja djece
- promicanje ravnopravnosti spolova, osobito u pogledu skrbi o djeci i ishoda zapošljavanja“.

Uzimajući u obzir činjenicu da se demografski procesi odvijaju tijekom vrlo dugog razdoblja, ključni kontekst za oblikovanje populacijske politike jest dugoročna strategija društveno-gospodarskog razvoja. Kratkoročni i srednjoročni planovi obično ne pružaju dovoljno vremena za usklađivanje demografskih promjena s ekonomskim i društvenim procesima. Međutim, važno je napomenuti da kratkoročne i srednjoročne mjere u okviru populacijske i obiteljske politike mogu imati dugoročne posljedice na demografska kretanja i promjene. Na primjer, smanjenje rodiljskih naknada, skraćenje porodiljnog dopusta ili smanjenje dječjih doplataka kao kratkoročne mjere uslijed nedostatka financijskih sredstava tijekom ekonomske recesije može rezultirati smanjenjem broja rođenja u sadašnjosti, a također, i u budućnosti. Razlog tomu je što će se tek nakon dvadeset godina početi rađati manji broj djece koja su rođena u okolnostima smanjenih potpora (Wertheimer-Baletić, 2003).

Mjerama obiteljske politike, bez prisustva populacijske politike može se samo ograničeno djelovati na povećanje fertiliteta i ne postoji konsenzus o tome odnosi li se učinak javnih politika samo na vrijeme rađanja ili na povećanje fertiliteta (Stropnik, 1995; Hoem, i sur. 2001; Gauthier, 2007; Letablier i sur., 2009; Duclos i sur., 2001; Sleebos, 2003). Međutim, odsutnost novčanih potpora u okviru obiteljskih politika vjerojatno bi dovela do još niže stope fertiliteta (Stropnik, 1995; Gauthier, 2007).

Milinković (1996: 103-104) navodi da „pod populacijskom ili politikom stanovništva razumijevamo skup mjera ili akcija pomoću kojih se djeluje na demografske procese, posebno na prirodno i mehaničko kretanje stanovništva, radi postizanja određenog (po smjeru, intenzitetu i strukturi) specifičnog kretanja stanovništva, usklađenog s postojećim

ekonomskim, socijalnim, političkim i drugim ciljevima“. Populacijska politika, prema svom teorijskom i etimološkom značenju, odnosi se na svjesno usmjeravanje razvoja ljudske populacije kroz ciljeve koji su povezani s njezinom veličinom ili strukturom. Ti ciljevi mogu biti izravno ili neizravno vezani uz kvantitetu ili kvalitetu populacije, a ostvaruju se putem odabranih društvenih mjera.

U kvantitativnom smislu, prema populacijska politika usmjerena je na povećanje nataliteta kao osnovne komponente „prirodnog prirasta stanovništva, dok je u kvalitativnom smislu usmjerena na izmjenu određenih struktura stanovništva (poboljšanje karakteristika populacije relevantnih za opći, društveni i gospodarski razvoj)“ (Milinković, 1996:104).

Obiteljske politike mogu imati višestruke ciljeve. Tradicionalno se smatra da su usmjerene na smanjenje dječjeg siromaštva te ublažavanje nepovoljnog dohodovnog položaja obitelji s djecom. U novije vrijeme sve veći naglasak stavlja se na poticanje sudjelovanja žena na tržištu rada te na uspostavljanje uravnoteženije podjele obiteljskih obveza između spolova. Shodno tomu, važan je cilj obiteljskih politika u Europi promicanje porasta stope fertiliteta žena boljom ravnotežom obiteljskog i poslovnog života. Ova ravnoteža nije odgovarajuće riješena u Republici Hrvatskoj, bez obzira na to što hrvatski obiteljski sustav nudi određene pronatalitetne mjere u području fiskalnih mjera, politike dopusta i ranog i predškolskog odgoja i obrazovanja. Naime, javna ulaganja u obitelji i dalje su razmjerno niska, a osim toga, sustav ne potiče ravnomjernu raspodjelu obiteljskih obveza između žena i muškaraca, kao niti ravnotežu poslovnog i obiteljskog života. Nadalje, u Republici Hrvatskoj još uvijek su troškovi povezani s imanjem djece daleko veći u odnosu na plaćeni rad.

Promatrajući europske zemlje, postoje različiti modeli obiteljskih politika. Prema podatcima Svjetske banke (2019), zemlje sjeverne Europe pružaju najopsežniju potporu zaposlenim roditeljima, kombinirajući izdašne roditeljske naknade s obiteljskim politikama koje uključuju široko dostupne usluge ranog i predškolskog odgoja i obrazovanja. Ovi sustavi utemeljeni su na načelima društvene i rodne ravnopravnosti. Nasuprot tomu, zemlje engleskog govornog područja pružaju znatno manju nenovčanu potporu, dok su novčane potpore uglavnom usmjerene na obitelji s nižim prihodima. Zemlje kontinentalne Europe zauzimaju međupoziciju između ove dvije skupine. Južnoeuropske zemlje pružaju vrlo ograničenu javnu potporu obiteljima, oslanjajući se pretežno na obiteljsku mrežu, dok se u zemljama istočne Europe modeli obiteljske politike značajno razlikuju ovisno o državi. Među europskim

zemljama koje su odgovarajućim kombinacijama obiteljskih politika uspješno pokrenule trendove fertiliteta izdvajaju se Švedska i Francuska. Iako ove zemlje imaju drugačije modele obiteljskih politika, obje zemlje kao prioritet ističu zadržavanje žena na tržištu rada.

Ključni uvjet za provedbu mjera populacijske politike je suradnja i aktivno sudjelovanje svih relevantnih sektora, uzimajući u obzir područja djelovanja, nadležnosti institucija i ministarstava, kao i aktivnosti usmjerene na poticanje demografske obnove Republike Hrvatske. Uzimajući u obzir negativne trendove, sveobuhvatan pristup obiteljskih politika istodobno bi trebao obuhvatiti financijske učinke rađanja djece, skrb o djeci u ranoj dobi, obrazovanje u ranom djetinjstvu te uređenje radnog vremena. Ovisno o zemlji, može se uključiti i pomoć u stambenom zbrinjavanju mladih parova, kao i promjene u vrijednostima u vezi s vremenom prvog rađanja (McDonald, 2006). Obiteljske politike sastoje se od kombinacija politika koje se međusobno nadopunjuju i međusobno djeluju. Stoga se prilikom evaluacije treba uzeti u obzir cijeli paket mjera zajedno (Letablier i sur., 2009).

Zaključno, politike usmjerene na demografske procese i strukture trebale bi se temeljiti na načelima demografske održivosti i dugoročnog planiranja, uz istodobno uvažavanje ograničenja koja proizlaze iz prethodnih i već oblikovanih demografskih kretanja. Za postizanje održivog demografskog razvoja Republike Hrvatske nužno je provoditi mjere u različitim područjima javne politike – poput stambene, obrazovne, zdravstvene i drugih – koje bi trebale djelovati međusobno usklađeno i sinergijski. Takav pristup omogućuje optimalno korištenje dostupnih resursa s ciljem ostvarenja strateških, uključujući i demografskih, ciljeva.

4.2. Eksplicitna i implicitna pronatalitetna politika u Republici Hrvatskoj

Eksplicitna pronatalitetna politika odnosi se na državne mjere koje izravno potiču fertilitet. Ove politike dizajnirane su s jasnim ciljem povećanja fertiliteta i uključuju konkretne, direktne mjere poput financijskih poticaja za rađanje djece, subvencioniranih troškova za roditeljstvo ili poreznih olakšica za roditelje. Nasuprot tomu, implicitna pronatalitetna politika djeluje neizravno i ova politika nema primarni cilj poticanja fertiliteta, ali je usmjerena na mjere i uvjete koji mogu olakšati odluku o rađanju djece. Ovdje se radi o široj podršci obiteljima kroz politiku rada, obrazovanje, zdravstvenu zaštitu ili opću socijalnu politiku.

U nastavku je prikazan konceptualni okvir odrednica fertiliteta (slika 4.).

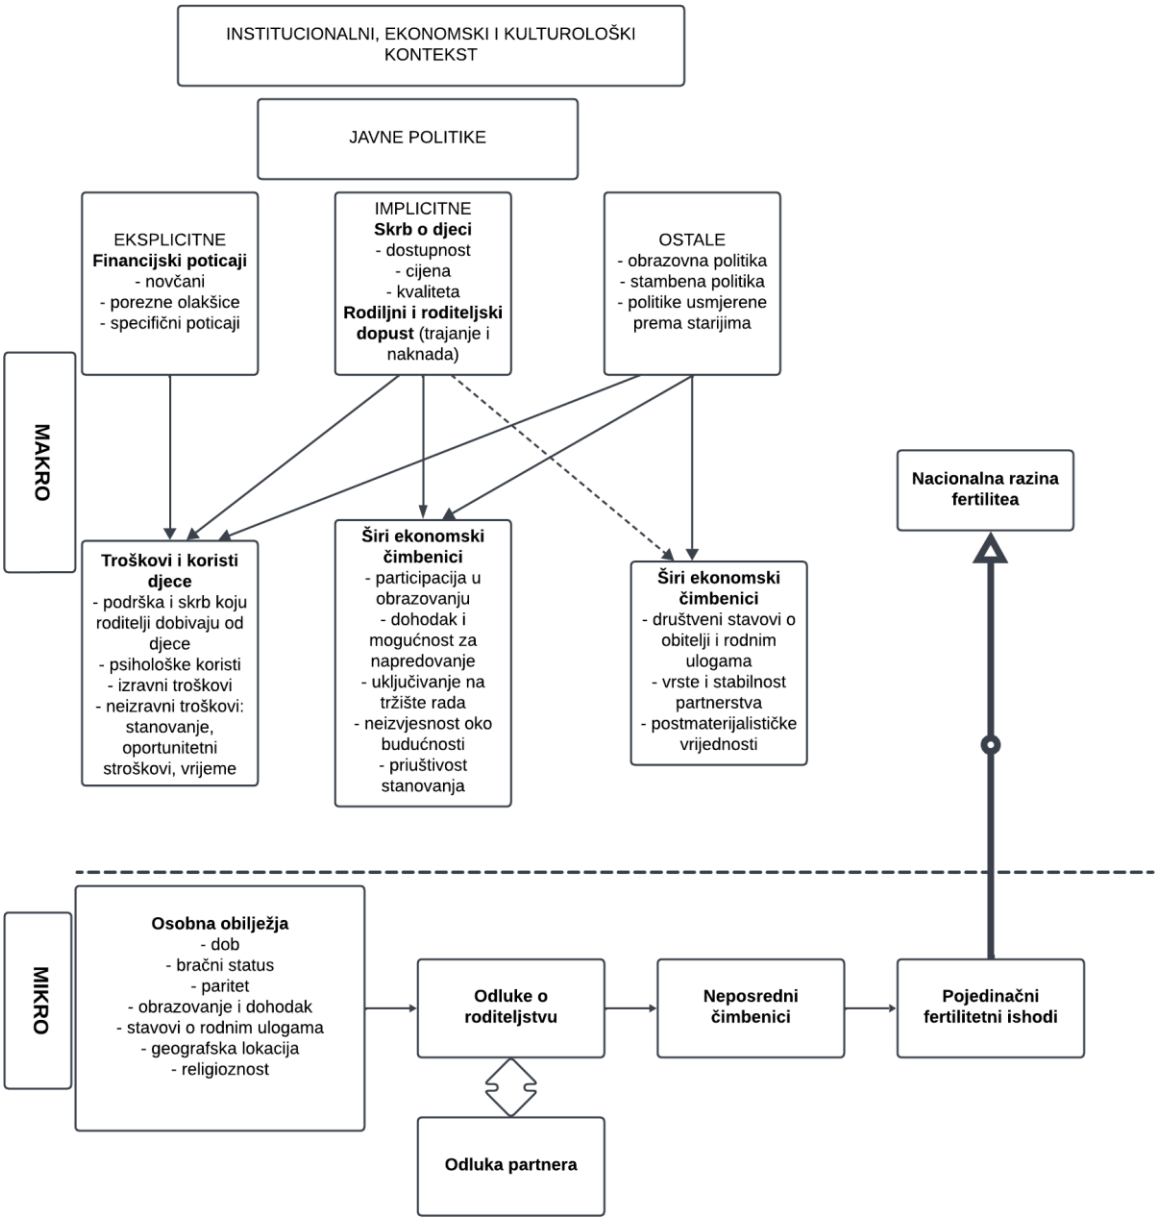

Slika 4. Konceptualni okvir odrednica fertiliteta
Izvor: prilagodba doktorandice (Grey i sur., 2022: 27)

Slika 4. prikazuje konceptualni okvir odrednica fertiliteta prilagođen hrvatskom kontekstu na temelju konceptualnog modela koji su kreirali Grey i sur. (2022). Autori su prikazali da na makrorazini, institucionalni, ekonomski i kulturni kontekst Australije predstavljaju važne čimbenike u donošenju odluka o rađanju djece. Taj kontekst uključuje

troškove i koristi roditeljstva te društvene norme povezane s roditeljstvom i načinom života. Na makrorazini su čimbenici pod utjecajem politika, uključujući skrb o djeci i roditeljski dopust. Dok na individualnoj razini, čimbenici poput dobi, bračnog statusa i razine obrazovanja djeluju u kombinaciji s čimbenicima na makrorazini te utječu na odluke ljudi o rađanju djece. Sve te odluke zajedno određuju ukupnu stopu fertiliteta u Australiji.

Alderotti i sur. (2021) ističu da ekonomska, radna i opća nesigurnost mogu biti značajno povezane s niskim stopama fertiliteta. Gospodarsko stanje i uvjeti na tržištu rada mogu utjecati na odluke parova o tome hoće li imati djecu. Posebno je izražen utjecaj ekonomske nesigurnosti na odluku o dobivanju prvog djeteta. Stabilno zaposlenje smatra se ključnim preduvjetom za osnivanje obitelji, a nesigurnost na poslu djeluje kao ograničavajući faktor, osobito kod muškaraca. Fertilitet je, stoga, rezultat individualnih odluka koje su uvjetovane širim društvenim kontekstom.

Fertilitet oblikuju brojni društveni čimbenici, poput troškova i koristi rađanja za potencijalne roditelje, šireg ekonomskog okruženja koje uključuje obrazovnu ekspanziju, nesigurnost na tržištu rada i stambene uvjete, ali i društvenih normi i stavova, osobito onih povezanih s rodnim ulogama i poželjnim životnim stilom. Konceptualizacija odluka o rađanju unutar šireg društvenog konteksta pomaže u razumijevanju brojnih čimbenika koji utječu na fertilitet, kao i načina na koji se ti čimbenici isprepliću te kako javne politike mogu utjecati na fertilitetne odluke. Važno je imati na umu da čimbenici na mikro i makrorazini nisu statični, već se međusobno mijenjaju kroz svoje interakcije. Želje pojedinaca za djecom variraju ovisno o osobnosti, stavovima prema rodnim ulogama, religioznosti, životnim vrijednostima, obiteljskom i etničkom podrijetlu, kao i o demografskim karakteristikama poput dobi, spola, bračnog statusa, broja djece, obrazovanja i prihoda. Međutim, fertilitetne želje često se ne ostvaruju, a razlozi mogu biti razni, uključujući zdravstvene probleme, nesuglasice s partnerom, raskide veza ili nesigurnost na poslu. Beaujouan i Berghammer (2019) navode da je fertilni jaz vrlo često prisutan, s tim da je najveći u onim zemljama gdje je teško uskladiti posao i obiteljske obaveze. Ova razlika sugerira da postoje mogućnosti za djelovanje kroz obiteljske i druge politike kako bi se uklonile prepreke s kojima se suočavaju roditelji pri ostvarivanju svojih fertilitetnih planova.

Prema Gauthieru (2007) postoji prostor za intervenciju politika kako bi se poboljšali uvjeti za povećanje fertiliteta. Javne politike značajno utječu na odluke o rađanju djece,

oblikujući kontekst u kojem pojedinci donose svoje reproduktivne odluke (Sleebos, 2003). Te politike mogu poticati povećanje fertiliteta na različite načine, poput smanjenja troškova odgoja djece putem novčanih transfera ili omogućavanjem roditeljskog dopusta koji nadoknađuje izgubljeni prihod te kroz pružanje usluga skrbi o djeci koje olakšavaju zaposlenim roditeljima usklađivanje obiteljskih i poslovnih obveza. Eksplicitne politike izravno su usmjerene na poticanje fertiliteta, primjerice, kroz financijske poticaje ili porezne olakšice. Neizravne politike, s druge strane, djeluju na okruženje u kojem se donose odluke o rađanju, iako njihov primarni cilj možda nije povećanje fertiliteta. One utječu na šire ekonomske uvjete i društvene norme koje oblikuju percepciju troškova i koristi imanja djece, često s naglaskom na povećanje sudjelovanja žena na tržištu rada. Politike koje poboljšavaju dostupnost i kvalitetu institucionalne skrbi za djecu mogu značajno smanjiti troškove odgoja djece, uključujući i one indirektne. Nedostatak dječjih vrtića i jaslica može dovesti roditelje, posebno žene, u situaciju u kojoj moraju birati između zaposlenja i roditeljstva, što utječe na rodnu ravnopravnost (Baizan, 2009).

Osim skrbi o djeci, kao dio implicitnih politika važnu ulogu igraju i rodiljni, očinski i roditeljski dopusti koji mogu pomoći ženama da zadrže zaposlenje nakon rođenja djeteta, smanjujući oportunitetne troškove povezane s odsustvom s tržišta rada, dok istovremeno olakšavaju povratak na radno mjesto. Sve zemlje članice Europske unije imaju politike dopusta, iako se one poprilično razlikuju. Sjevernoeuropske zemlje koje imaju veća javna socijalna ulaganja obično imaju i izdašnije potpore za vrijeme trajanja dopusta, ali i dulje trajanje dopusta. Zemlje zapadnog Balkana također nude osobito duge dopuste. Za razliku od njih, južnoeuropske zemlje imaju najkraće i najmanje izdašne naknade za dopuste. Prema podatcima Svjetske banke (2019) prosječno trajanja rodiljnog dopusta u Europskoj uniji iznosi 21,8 tjedana, što je iznad propisanog minimuma od 14 tjedana. Prosječno trajanje očinskog dopusta je 1,4 tjedana, a u većini zemalja je to od 10 do 20 dana. Roditeljski dopust je dostupan majkama u prosjeku 43,8 tjedana, a očevima 4,9 tjedana. U Republici Hrvatskoj očinski dopust je u trajanju od 20 dana, dok majke koriste obvezni rodiljni dopust u trajanju od 98 dana. U Republici Hrvatskoj roditeljski dopust traje 180 dana (obvezni i dodatni).

Bez obzira na dulje trajanje dopusta, naknade za vrijeme korištenja dopusta u istočnoeuropskim zemljama nisu izdašne i ne pokrivaju sve troškove adekvatne skrbi o djeci. Ograničenje korištenja ovih dopusta u Europskoj uniji očituje se u ostvarenju prava i fleksibilnosti. Naime, naknade za dopuste povezane su sa socijalnim doprinosima pa su iste

ograničene na žene koje su u trenutku poroda bile zaposlene. U većini zemalja Europske unije ne postoji velika fleksibilnost u korištenju rodiljnog dopusta zbog obveznog korištenja cijelog ili dijela dopusta, ali postoji fleksibilnost politika za očinski i roditeljski dopust koji su vezani za razdoblje u kojem se navedeni dopusti mogu koristiti (npr. fleksibilno radno vrijeme ili smanjenje radnog vremena). Unatoč postojećim razlikama, na razini Europske unije teži se ravnopravnosti muškaraca i žena u segmentu podjele obiteljskih obveza. Stoga su plaćeni očinski i roditeljski dopusti jedan od mehanizama kojima se nastoje uskladiti ciljevi zaštite djeteta i sudjelovanja žena na tržištu rada. „Očevi se najviše koriste očinskim dopustom kada je pravo na taj dopust neprenosivo, kada je on dobro plaćen i praćen drugim politikama namijenjenima obiteljima, kao što je fleksibilnost radnog vremena“ (Svjetska banka, 2019).

Očekivanja da mjere koje podupiru usklađivanje obiteljskog i profesionalnog života – poput institucionalne skrbi za djecu i plaćenog roditeljskog dopusta – mogu pozitivno utjecati na stopu fertiliteta temelje se na pretpostavci kako je model obitelji s jednim nositeljem prihoda sve manje održiv i poželjan s financijskog aspekta. Poteškoće koje žene doživljavaju u nastojanju da usklade radne i obiteljske obveze mogu imati negativan učinak na odluke o rađanju (Billingsley i Ferrarini, 2014). Takve politike ne samo da odražavaju postojeće društvene norme, već ih i aktivno oblikuju. Konačan učinak ovih politika ovisi o tome u kojoj mjeri su prihvaćene i korištene od strane obitelji te koliko su usklađene s njihovim očekivanjima.

Gledano po funkcijskoj klasifikaciji, na razini Republike Hrvatske (Eurostat, 2024a) tijekom 2021. godine izdvojeno je samo 1,67 % ukupnih socijalnih naknada za funkciju socijalne isključenosti, dok je na razini EU27 izdvojeno 2,60 %. Značajno manja izdvajanja su za funkcije stanovanja pa je tako za ovu funkciju u Republici Hrvatskoj izdvojeno samo 0,02 % ukupnih naknada, a na razini Europske unije 1,27 %. Međutim, s 9,14 % ukupnih naknada hrvatsko ulaganje u funkciju obitelj/djeca je nešto iznad europskog prosjeka (8,27 %). Republika Hrvatska, također, ima veća izdvajanja za zdravstvenu zaštitu (35,49 %) u odnosnu na Europsku uniju (29,73 %), kao i na osnovno obrazovanje (RH: 1,73 % BDP-a, EU: 1,09 %). U rano obrazovanje djece (djeca od 0 do 3 godine i djeca od 3 godine pa do dobi za početak osnovnog obrazovanja) Republika Hrvatska je tijekom 2021. godine izdvojila 0,58 % BDP-a, što je ispod prosjeka Europske unije od 0,71 % (Eurostat, 2024b).

Slijedom navedenog, među ostalim javnim politikama usmjerenim ka fertilitetnim odlukama izdvajaju se: obrazovna, zdravstvena i stambena politika te su iste detaljnije opisane u nastavku stavljajući naglasak na problematiku u Republici Hrvatskoj.

Obrazovna politika

Cilj Europskog jamstva za djecu (engl. *European Child Guarantee, ECG*) je spriječiti i boriti se protiv socijalne isključenosti osiguravanjem djelotvornog pristupa djece u potrebi nizu ključnih usluga:

a) „djelotvoran i besplatan pristup visokokvalitetnom ranom i predškolskom odgoju i obrazovanju, obrazovanju i školskim aktivnostima, najmanje jednom zdravom obroku svakog školskog dana te zdravstvenoj skrbi
(b) djelotvoran pristup zdravoj prehrani i odgovarajućem smještaju“ (Vijeće EU, 2021: n.p.).

Postizanje ciljeva Europske unije, poput prekida začaranog kruga siromaštva, suzbijanja korijena nejednakosti i doprinošenja izgradnji pravednog, uključivog i otpornog društva ovisi o nizu čimbenika. Jedna od glavnih prepreka društvenoj uključenosti djece jest neravnopravan pristup osnovnim uslugama koje imaju presudnu ulogu u njihovoj dobrobiti te razvoju socijalnih, kognitivnih i emocionalnih vještina. Djeca koja žive u siromaštvu ili u nepovoljnim uvjetima češće se susreću s preprekama u pristupu osnovnim uslugama kao što su rana predškolska skrb i obrazovanje, inkluzivno obrazovanje, zdravstvena zaštita, zdrava prehrana i adekvatan smještaj. Društvena isključenost koja se prenosi s generacije na generaciju ugrožava socijalnu koheziju i stvara dugoročne troškove za socijalnu državu, što slabi gospodarsku i socijalnu otpornost. Povećanje ravnopravnog pristupa ključnim uslugama za djecu kojoj je potrebna podrška ključan je korak u sprječavanju društvene isključenosti i smanjenju siromaštva.

U nastavku se analizira pet područja koja su identificirana ključnima unutar ECG-a: (1) rani i predškolski odgoj i obrazovanje, (2) obrazovanje (uključujući izvannastavne aktivnosti), (3) zdravstvo, (4) zdrava prehrana i (5) primjereno stanovanje. Navedene usluge trebaju biti djelotvorne i besplatne te se ciljanim aktivnostima javnih politika treba promicati njihovo ostvarenje.

Rani i predškolski odgoj i obrazovanje

Rano obrazovanje ključno je za razvoj vještina, zdravlje i dobrobit djece te se smatra temeljem obrazovnog sustava, kao i cjeloživotnog učenja. Posebno je korisno za djecu u nepovoljnom položaju jer sprječava nedostatak vještina i smanjuje nejednakosti. Rani i predškolski odgoj i obrazovanje važni su u borbi protiv socijalne isključenosti i siromaštva, doprinoseći ispunjenju obveza iz europskih preporuka o ulaganju u djecu i integraciji Roma. Sudjelovanje u ovim programima donosi brojne prednosti, od boljih obrazovnih postignuća do veće društvene kohezije. Rano obrazovanje također igra ključnu ulogu u društvenoj koheziji i razvoju jezičnih kompetencija, što potiče toleranciju i razumijevanje različitosti. Ulaganje u rani odgoj posebno je važno za djecu u nepovoljnom položaju jer donosi najveći povrat.

S druge strane, dostupnost i pristupačnost kvalitetnih ustanova za skrb o djeci omogućuju roditeljima sudjelovanje na tržištu rada, što doprinosi poboljšanju socioekonomske situacije i gospodarskom rastu. Međutim, samo visokokvalitetne usluge mogu donijeti stvarne koristi, stoga daljnji napori nositelja javnih politika trebaju biti usmjereni ka povećanju kvalitete i dostupnosti ustanova ranog i predškolskog odgoja i obrazovanja.

Sukladno Preporukama Vijeća o visokokvalitetnim sustavima ranog i predškolskog odgoja i obrazovanja (2019/C 189/02) sva djeca trebaju imati pravo na financijski prihvatljiv, dostupan i kvalitetan rani i predškolski odgoj i obrazovanje.

Postoje dva pristupa dostupnosti i osiguravanju prava na rani i predškolski odgoj i obrazovanje u Europi (Europska komisija, 2019). U nekim zemljama postoji zakonsko pravo na program ranog i predškolskog odgoja i obrazovanja, dok je u drugima pohađanje obvezno. Zakonsko pravo znači da svako dijete ima pravo na rani i predškolski odgoj i obrazovanje, ali pohađanje nije nužno obvezno. U zemljama gdje je rani i predškolski odgoj i obrazovanje obvezan, nadležne vlasti moraju osigurati dovoljan broj mjesta za svu djecu u propisanoj dobnoj skupini.

Značajne su razlike među europskim zemljama u pogledu dobi u kojoj je djeci zajamčeno mjesto u ranom i predškolskom odgoju i obrazovanja. U sedam zemalja EU-a (Danska, Njemačka, Estonija, Latvija, Slovenija, Finska i Švedska) te u Norveškoj, mjesto ranog i predškolskog odgoja i obrazovanja osigurano je za svako dijete već od rane dobi

(između šest i 18 mjeseci), često odmah nakon roditeljskog dopusta. U Belgiji, Češkoj, Španjolskoj, Francuskoj, Luksemburgu, Mađarskoj, Poljskoj i Portugalu, djeci je zajamčeno mjesto u dobi od tri godine ili ranije u javno subvencioniranom ranom i predškolskom odgoju i obrazovanju. Otprilike trećina europskih sustava osigurava mjesto za djecu u dobi od četiri do šest godina, često kao pripremu za osnovnu školu, gdje je pohađanje često obvezno. Nekoliko europskih zemalja nema zakonski okvir koji osigurava mjesto u ranom i predškolskom odgoju i obrazova. Samo tri države članice EU-a (Irska, Italija i Malta) formalno nisu uspostavile zakonsko pravo ili obvezno sudjelovanje u programu. U praksi, mjesta su dostupna u tim zemljama od otprilike treće godine. Na Islandu potražnja za mjestom u ranom i predškolskom odgoju i obrazovanju zadovoljava ponudu od ranije dobi. Pravo na rani i predškolski odgoj i obrazovanje široko je opisano u zakonima i propisima bez navođenja specifične dobi ili broja sati. Nasuprot tomu, odsutnost zakonskog jamstva za mjesto odražava se u manjoj dostupnosti programa u Albaniji, Crnoj Gori, Sjevernoj Makedoniji i Turskoj.

Posljednjih godina mnoge europske zemlje proširile su pravo na program ranog i predškolskog odgoja i obrazovanja. Pohađanje posljednje godine ranog i predškolskog odgoja i obrazovanja postalo je obvezno u Belgiji (od rujna 2020.), Češkoj (2017.), Hrvatskoj (2014.), Litvi (2016.), Rumunjskoj (2020.), Slovačkoj (2021.), Finskoj (2015.) i Švedskoj (2018.). Pravo zajamčeno zakonom na pohađanje ranog i predškolskog odgoja i obrazovanja ne znači da je usluga u potpunosti besplatna, već da je subvencionirana i financijski dostupna, dok se obvezni programi provode bez naknade u javnim ustanovama.

Slika 5. prikazuje razliku između kraja maksimalnog roditeljskog dopusta i najranijeg početka univerzalnog jamstva mjesta u ranom i predškolskom odgoju i obrazovanju (u nastavku RPOO) za razdoblje 2022/2023.

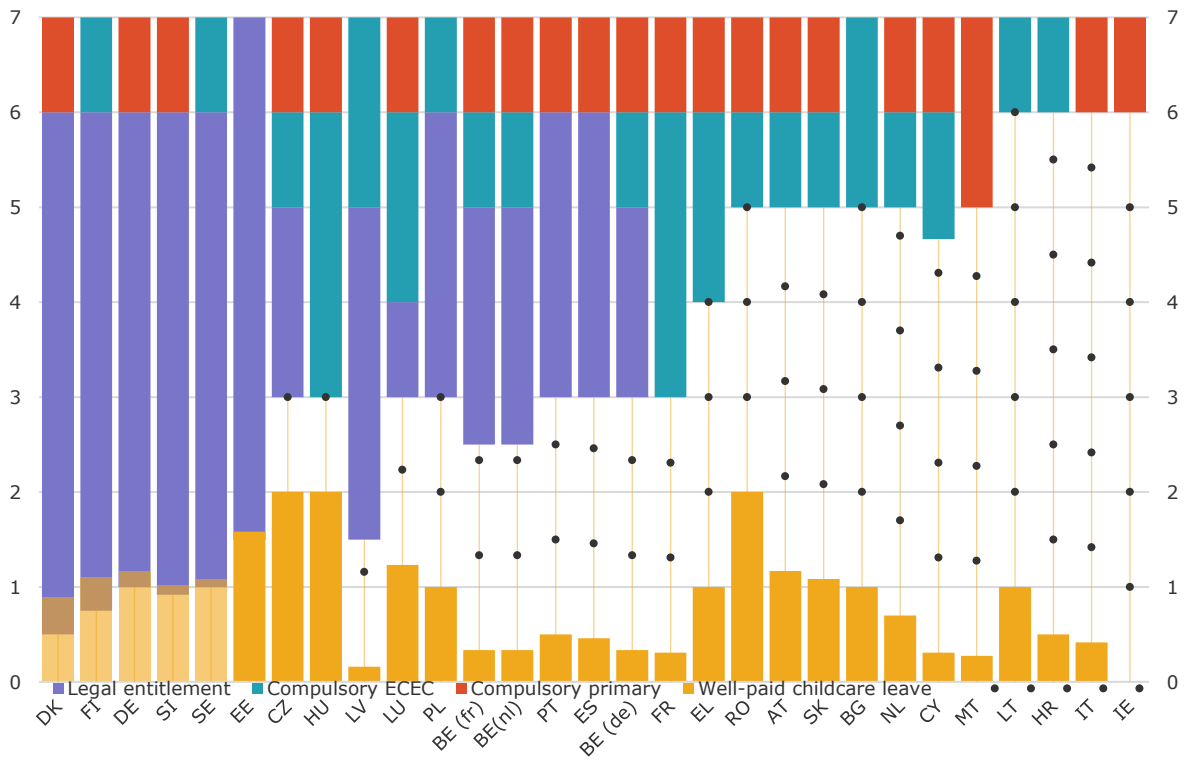

Slika 5. Vremenski jaz između roditeljskog dopusta i zajamčenog mjesta u RPOO, 2022/2023
Izvor: Eurydice, 2023.

Napomene: RPOO jaz: razmak između dvije oznake jednak je 1 godini. RPOO jaz predstavlja razliku između maksimalne duljine dobro plaćenog dopusta i najranijeg početka univerzalnog jamstva mjesta u RPOO-u (zakonsko pravo ili obvezni RPOO). Kada nema zajamčenog mjesta u RPOO-u, jaz se računa do početka obveznog osnovnog obrazovanja. Podatci o dopustima dolaze iz Međunarodne mreže za politike i istraživanja o dopustima i odnose se na travanj 2022. godine. Uključuju rodiljne, očinske i roditeljske dopuste. Dobro plaćeni znači plaćanje povezano s primanjima od 66 % ili više od zarade. Ukupna količina „dobro plaćenog" dopusta dostupnog roditeljima izražena u djetetovoj dobi u mjesecima pretvorena je u godine dijeljenjem broja s 12.

S lijeve strane na slici 5., gdje nije označen jaz, nalaze se zemlje s dobro usklađenim politikama roditeljskog dopusta i RPOO. Samo šest država članica EU-a (Danska, Njemačka, Estonija, Slovenija, Finska i Švedska), zajedno s Norveškom, nemaju RPOO jaz. U tim zemljama čak postoji određeno preklapanje, gdje roditelji još uvijek imaju pravo na roditeljski dopust, ali je već zajamčeno mjesto u javno subvencioniranim ustanovama RPOO-a. Ovo preklapanje omogućuje obiteljima fleksibilnost tijekom prijelaza na RPOO. Zemlje bez RPOO

jaza odobravaju dugi roditeljski dopust (u prosjeku 13 mjeseci) i imaju jedinstvene RPOO sustave koji pružaju zakonsko pravo na subvencionirano, ali ne besplatno mjesto. Kada postoji RPOO jaz, on traje najmanje jednu godinu, a najviše šest godina. Razlika između dobro plaćenog roditeljskog dopusta i početka zakonskog prava na RPOO iznosi između jedne i dvije godine u Češkoj, Latviji, Luksemburgu, Mađarskoj i Poljskoj. Većina tih zemalja nudi dug, dobro plaćen roditeljski dopust (1-2 godine) i jamstvo za mjesto u RPOO-u od treće godine života. Latvija je iznimka. U Latviji, univerzalno zakonsko pravo na javno subvencionirani RPOO započinje s 1,5 godina. Roditeljski dopust s naknadom od 80 % prethodnih primanja odobrava se na 16 tjedana. Nakon toga, dostupan je roditeljski doplatak s dvije opcije: do djetetove 1. godine sa 60 % prethodne plaće; ili do djetetove 1,5 godine s 44 % prethodne plaće. Osim toga, osoba koja brine o djetetu do 1,5 godine dobiva doplatak za njegu djece (171 EUR mjesečno) (Eurydice, 2023).

RPOO jaz iznosi između dvije i tri godine u Belgiji, Španjolskoj, Francuskoj i Portugalu. Ove zemlje nude relativno kratak period roditeljskog dopusta (4-6 mjeseci), ali jamče mjesto u RPOO-u od oko tri godine ili ranije.

U preostalim zemljama, razdoblje bez roditeljskog dopusta i bez prava na RPOO traje tri godine ili duže. S pravnog stajališta, 10 europskih zemalja ima RPOO jaz od pet do šest godina: Irska, Hrvatska, Italija, Litva, Albanija, Bosna i Hercegovina, Island, Crna Gora, Sjeverna Makedonija i Turska. Većina zemalja s dugim RPOO jazom nema jamstvo za mjesto u RPOO-u ili ima samo 1-2 godine obveznog RPOO-a prije početka osnovnog obrazovanja. Međutim, kao što je već raspravljeno, RPOO jaz može biti kraći budući da je javno subvencionirani RPOO gotovo univerzalno dostupan od oko 3-4 godine bez zakonskog prava.

Kako bi se osigurao pristup programu ranog i predškolskog odgoja i obrazovanja svoj djeci u Republici Hrvatskoj, isti treba biti besplatan (ili barem financijski prihvatljiv) te treba postojati jamstvo mjesta. Osim toga, treba se riješiti problem deficita visokokvalificiranog odgojno-obrazovnog osoblja kako bi se osigurala primjerena kvaliteta. Slijedom navedenog, sustavno treba pristupiti rješavanju navedenih problema na svim razinama vlasti.

Obrazovanje i školske aktivnosti

Pristup obrazovanju smatra se osnovnim pravom svakog djeteta u svim zemljama Europske unije, uključujući i Republiku Hrvatsku. Međutim, potrebno je poduzeti dodatne korake kako bi se osigurao inkluzivan obrazovni sustav i uklonile (ne)financijske prepreke pri pristupu obrazovanju, poput financiranja školskih izleta, izvannastavnih aktivnosti, školskog pribora ili računala. Ove prepreke posebno pogađaju djecu koja odrastaju u siromaštvu, a njihovo uklanjanje smatra se ključnim mehanizmom za osiguravanje jednakih prilika i sprječavanje ranog napuštanja školovanja (UNICEF, 2021).

Obvezno obrazovanje u Republici Hrvatskoj bi trebalo biti svima dostupno pod jednakim uvjetima te besplatno sukladno Ustavu Republike Hrvatske (NN 85/2010, članak 66). Međutim, istraživanja pokazuju da djeca u riziku od siromaštva, primatelji zajamčene minimalne naknade, jednokratnih novčanih pomoći i djeca romske nacionalne manjine imaju otežan pristup osnovnoškolskom obrazovanju (Pučka pravobraniteljica, 2024; Družić Ljubotina i sur., 2017; Kletečki Radović i sur., 2017).

Jedan od ključnih problema s kojima se suočavaju djeca iz siromašnih obitelji uključuje visoke troškove obrazovnih materijala, računalne opreme i internetskih usluga, kao i nedostupnost željenih srednjoškolskih programa. Nacionalna strategija prava djece u Republici Hrvatskoj za razdoblje od 2014. do 2020. godine predviđala je subvencioniranje usluga za djecu iz siromašnih obitelji, kao što su podrška u učenju i aktivnosti u slobodno vrijeme, kako bi se izjednačile mogućnosti. Međutim, provedba tih programa često se oslanjala na inicijative pojedinih udruga i financiranje putem projekata. Slična situacija postoji i s uslugom pomoćnika u nastavi koja je djeci s teškoćama u razvoju dostupna nejednako, ovisno o regiji u kojoj žive i obrazuju se te o sredstvima koja su dostupna lokalnim zajednicama ili iz EU fondova.

Visoki troškovi obrazovanja, nedostupnost potrebnih resursa i nerazmjernost u pristupu obrazovnim uslugama stavljaju pomoćnike u nastavi u nepovoljan položaj. Iako su strategije i planovi usmjereni na poboljšanje situacije postavljeni, njihova provedba često ostaje nedovoljna i ovisi o vanjskim inicijativama. Uloga pomoćnika u nastavi, koja je od iznimne važnosti za djecu s teškoćama u razvoju, dodatno naglašava potrebu za stabilnijim i dostupnijim sustavima podrške unutar obrazovnog okruženja. Na taj način ukazuje se na

važnost jačanja institucionalnih mehanizama i ulaganja u resurse koji će omogućiti svoj djeci da ostvare svoj puni potencijal.

Podatci Eurostata za 2016. godinu (Eurostat, 2023h) pokazuju kako 89 % kućanstava u riziku od siromaštva s ovisnom djecom ima poteškoće s podmirivanjem financijskih obveza koje su povezane s formalnim obrazovanjem. Veće poteškoće izraženije su u kućanstvima u velikim gradovima (96,5 %), dok u ruralnim sredinama 92,9 % kućanstava ima poteškoće s podmirivanjem obveza formalnog obrazovanja. U manjim gradovima i predgrađima 75,2 % kućanstva ima prethodno spomenute poteškoće. Budući da su udžbenici za sve učenike osnovnih škola besplatni, odnosno financirani iz državnog proračuna, roditelji djece se najčešće susreću s problemima financiranja popratnih obrazovnih materijala nužnih za rad (radne bilježnice, oprema za likovni i tjelesni odgoj, materijal za tehničku kulturu), izleta, izvannastavnih aktivnosti, računala, pristupa internetskoj mreži itd.

Kako bi se osigurala dostupnosti obrazovanja i jednake mogućnosti sudjelovanja u formalnom obrazovanju bez diskriminacije, nužno je smanjenje financijskog opterećenja roditelja, rad na inkluziji djece smanjenog socio-ekonomskog statusa te poboljšanje kvalitete i uvjeta u sustavu obrazovanja.

Zdravstvena politika

Ciljevi Europskog jamstva za djecu usmjereni su na zaštitu i dobrobit djece u riziku na europskoj razini, kao i na smanjenje društvenih nejednakosti osiguravanjem jednakih prilika za svu djecu. Zbog toga se unutar zemalja članica Europske unije intenzivno promiču zdravstvene politike i programi koji osiguravaju svakom djetetu redovitu, besplatnu i kontinuiranu zdravstvenu skrb i liječenje (Europska komisija, 2020).

U Republici Hrvatskoj sva djeca do navršene osamnaeste godine starosti imaju pravo na besplatnu zdravstvenu skrb kroz obvezno zdravstveno osiguranje. Međutim, UNICEF u svom izvješću (2021) ukazuje na izazove u području zaštite mentalnog zdravlja djece, osobito u pogledu nedovoljno razvijenih i regionalno neravnomjerno dostupnih usluga podrške. Djeci bi trebalo osigurati sustavnu psihološku podršku unutar obrazovnog sustava. Također, važno je napomenuti da djeca s poremećajima mentalnog zdravlja ne dobivaju odgovarajuću skrb jer

dječja psihijatrija nije prepoznata kao zasebna služba, a ne postoje posebne smjernice i standardi za njihovo liječenje.

Unatoč besplatnoj zdravstvenoj zaštiti, djeca i dalje nailaze na poteškoće u pristupu zdravstvenim uslugama i osiguravanju odgovarajuće njege tijekom bolesti. Iako djeca iz siromašnih obitelji i slabije razvijenih područja imaju pravo na besplatno osiguranje do 18. godine (do kraja školovanja), njihova je skrb često lošije kvalitete zbog nedostatka pedijatara i dječjih specijalista u lokalnim zajednicama. Odlazak u zdravstvene ustanove predstavlja dodatni financijski teret zbog skupog javnog prijevoza, osobito za obitelji bez vlastitog automobila. Roditelji također teško mogu priuštiti lijekove koji nisu pokriveni zdravstvenim osiguranjem. Prema istraživanjima, otprilike 50 % djece koja odrastaju u siromaštvu nema pristup sedam ključnih zdravstvenih usluga (defektolog-rehabilitator, fizijatar, fizioterapeut, dječji psiholog, dječji psihijatar, logoped i okulist) u svojoj sredini. Ove su usluge najčešće nedostupne djeci iz ruralnih i udaljenih područja, a većina siromašne djece (65 %) živi upravo u selima i ruralnim naseljima (Šućur i sur., 2015, UNICEF, 2021). Nedostupnost primjerene zdravstvene skrbi i duge liste čekanja za specijalističke preglede osobito su izraženi kod djece s poteškoćama u razvoju. Sve navedeno ukazuje na brojne nedostatke u hrvatskom zdravstvenom sustavu te se treba pristupiti njihovom rješavanju kako bi sva djeca imala primjerenu zdravstvenu skrb.

S aspekta zdravstvene politike, osim djece, i trudnice i majke se nerijetko suočavaju s dostupnošću adekvatne zdravstvene skrbi. Prije svega, mnoge trudnice susreću se s problemima u pristupu prenatalnim i postnatalnim pregledima, posebno u ruralnim područjima gdje su zdravstvene ustanove udaljenije. Nerijetko postoje i pritužbe na kvalitetu zdravstvene skrbi koju trudnice i majke primaju, uključujući nedostatak empatije i informiranosti o pravima trudnica, postupcima poroda i postnatalnoj skrbi od strane zdravstvenih radnika. Vrlo često izostaje i psihološka podrška u situacijama postporođajne depresije, kao i manjak ustanova koje bi pružale navedene usluge. Osim navedenog, evidentan je manjak ginekologa u manje razvijenim područjima Republike Hrvatske. Svi ovi problemi ukazuju na potrebu za unaprjeđenjem zdravstvenog sustava kako bi se osigurala bolja skrb za trudnice i majke.

Stambena politika i primjereno stanovanje

Stambeni uvjeti igraju ključnu ulogu u demografskoj situaciji Republike Hrvatske. Stambena politika postaje bitan aspekt kako demografske, tako i javne politike, posebno u kontekstu mladih ljudi. Pristupačnost stanovanja za mlade i obitelji s djecom izravno utječe na percepciju kvalitete života u zemlji. Ovi uvjeti stambenog tržišta ne samo da oblikuju odluke o preseljenju, već i utječu na planiranje obitelji i odluke o proširenju obitelji, što dodatno potiče iseljavanje mladih iz Hrvatske.

Prema Akrap i Čipin (2008: 415) „stanovanje je jedna od osnovnih čovjekovih potreba i odgovornost države za stambeno zbrinjavanje svojih građana ulazi u krug nužnih socijalnih prava“. Autori ističu da je stambeno zbrinjavanje jedan od najvećih i najvažnijih problema za mlade parove koji žele osnovati obitelj, a nemaju riješeno i nisu u mogućnosti kvalitetno riješiti stambeno pitanje kako bi započeli samostalni život i imali djecu. Ukratko, stambena politika je ključna za demografski razvoj i kvalitetu života s naglaskom na unaprjeđenje uvjeta stanovanja za mlade. Nedostatak financijskih sredstava, nezaposlenost i nepovoljni kreditni uvjeti samo su neki od problema s kojima se susreću mladi u Republici Hrvatskoj. Osim toga, kontinuiran porast cijena nekretnina uzrokovao je kasnije odseljavanje od roditelja, odgađanje rađanja, stupanje u brak te konačno i smanjenje stopa fertiliteta. Kako je već prethodno navedeno, ekonomska sigurnost važan je prediktor fertilitetne namjere, stoga je nužna podrška države u segmentu većih mogućnosti stambenog zbrinjavanja, posebno za mlade obitelji i obitelji s djecom.

Kako se navodi u Strategiji demografske revitalizacije Republike Hrvatske do 2030. godine (NN 36/2024) uzrok pada broja brakova, odgađanje sklapanja brakova, kao i niskih stopa fertiliteta pronalazi se upravo u financijskim poteškoćama pri stjecanju stambenog prostora i stvaranja adekvatnih uvjeta za obiteljski život. Nacionalnim programom za mlade za razdoblje 2023. do 2025. (Središnji državni ured za demografiju i mlade, 2023) kroz mjeru 3.5.3. Osiguravanje boljih uvjeta stanovanja mladim osobama, u cilju unapređenja životnih uvjeta i povećanja dostupnosti stanovanja, predviđa se sufinanciranje i/ili subvencioniranje troškova stanovanja mladih osoba putem jedinica lokalne i/ili područne (regionalne) samouprave.

Tijekom posljednja dva desetljeća Vlada Republike Hrvatske je provodila nekoliko programa stambenog zbrinjavanja, među kojima se ističu Program društveno poticajne stanogradnje (POS) i Subvencioniranje stambenih kredita (APN). „Od početka provedbe programa POS-a diljem Hrvatske izgrađena su 9072 stana u 290 objekata u 83 jedinice lokalne samouprave“ (Ministarstvo prostornog uređenja, graditeljstva i državne imovine, 2024: n.p.). Dok je mjerom APN vlastiti dom osiguralo oko 34 000 mladih obitelji u kojima je rođeno više od 8 300 djece (Vlada Republike Hrvatske, 2023). Dosadašnji program APN-a ograničavao je korisnike na dugoročno prebivanje na istom mjestu i time ograničio unutarnju migraciju hrvatskog stanovništva. Zbog navedenog problema hrvatska stambena politika bi u budućnosti trebala biti usmjerena na povećanje priuštivosti stanovanja, ali i povećanje unutarnje mobilnosti građana.

Današnja situacija, posebno za mlade obitelji, nije stabilna jer su mnogi najmodavci i najmoprimci nezaštićeni, a velik dio najma nije formaliziran. Problem je posebno izražen u obalnim gradovima gdje turistički najam smanjuje dostupnost dugoročnih najmova, što mladim obiteljima otežava pronalazak stabilnog stambenog rješenja i negativno utječe na njihove životne planove, uključujući odluke o osnivanju obitelji. Također, trebalo bi postojati aktivnije ulaganje u gradnju stanova za najam i subvencioniranje najamnina, što bi omogućilo mladima sigurniji smještaj bez nužnosti zadovoljavanja kreditne sposobnosti. Jedan od načina rješavanja ovog problema jest javno-privatno partnerstvo, gdje bi država mogla aktivirati neiskorištene državne nekretnine kako bi se smanjili troškovi najma i povećala ponuda stanova. Ova strategija usklađena je s Nacionalnom razvojnom strategijom Hrvatske do 2030. (NN 13/2021), koja vidi državnu imovinu kao ključan resurs za razvojne i demografske politike. U ruralnim područjima također se razmatraju mjere kao što su besplatno dodjeljivanje građevinskog zemljišta i građevinskog materijala za gradnju obiteljskih kuća. Cilj je demografski revitalizirati Hrvatsku zadržavanjem mladih u zemlji te stvaranjem povoljnih uvjeta za život. Aktivacija državne imovine kroz prodaju i dugoročni najam može pridonijeti pozitivnoj migracijskoj bilanci i osigurati bolje materijalne uvjete za obitelji, osobito u kontekstu regionalnih specifičnosti.

Zaključno, važnost državnog angažmana u stambenoj politici trebao bi se očitovati kroz kreiranje i provođenje mjera za olakšanje pristupa nekretninama, posebno u područjima suočenima s visokim cijenama stanovanja i poteškoćama mladih u kupnji ili najmu stana. Europske zemlje rješavaju te izazove kroz najam i kupnju stanova u državnom vlasništvu, čime

omogućuju pristupačnije stambene opcije za mlade. U tom kontekstu, Republika Hrvatska također treba aktivno razvijati i prilagođavati stambenu politiku prema svojim specifičnim uvjetima, uzimajući u obzir različitosti među regijama kako bi odgovorila na potrebe građana.

S aspekta dugoročnog djelovanja na natalitet, statistički podatci pokazuju da eksplicitna pronatalitetna politika, kao politika koja je izravno usmjerena na porast nataliteta/fertiliteta, ima „povoljniji i stabilniji učinak u odnosu na implicitnu politiku. Pokazuje se, naime, da su stope nataliteta i fertiliteta, prema brojčanoj razini nešto veće, a oscilacije u njihovom kretanju pod utjecajem drugih nedemografskih čimbenika manje, što govori o većoj stabilnosti učinka mjera eksplicitne politike“ (Wertheimer-Baletić, 2006: 19).

4.3. Namjera rađanja kod žena

Najjači prediktor budućeg ponašanja žena u vezi s rađanjem je namjera rađanja (Westoff i Ryder, 1977; Schoen i sur. 1999). Demografska istraživanja u velikoj mjeri su usmjerena prema objašnjenju ili predviđanju namjere da se ima dijete u odnosu na namjeru da se nema dijete (Billari i sur. 2009; Jaccard i Davidson, 1975; Jorgensen i Adams, 1988), uzimajući u obzir i vremensku dimenziju – namjere s kraćim i dužim vremenskim okvirom (Dommermut i sur., 2011; Schoen i sur., 1999), no često zanemarujući cijeli put koji vodi ka realizaciji namjera u stvarno ponašanje. Manski (1990) navodi da je glavni cilj izraženih namjera tijekom provođenja istraživanja predviđanje stvarnog ponašanja. Nadalje, namjera rađanja „može biti korisna za kratkoročno predviđanje stanovništva za završeni fertilitet: njihova je dosljednost na agregatnoj i pojedinačnoj razini značajna, u usporedbi s drugim indeksima fertiliteta“ (Symeonidou, 2000: 351).

Svaka namjera zahtijeva od ljudi da ispitaju i procijene alternativne smjerove djelovanja prije donošenja odluke (Carmichael i Whittaker, 2007). Proučavanje namjere rađanja pomaže u predviđanju stopa fertiliteta u određenoj populaciji. Prema provedenim istraživanjima, ta su predviđanja u prošlosti bila prilično točna na makrorazini (Bumpass i Westoff, 1969; Hagewen i Morgan, 2005; Schoen i sur., 1999; Westoff i sur., 1957). Gauthier (2007: 325) utvrđuje pretpostavku da je rađanje djece racionalna odluka (kao i Norling, 2021) te da roditelji važu troškove i koristi od rađanja djece u odnosu na svoje prihode, očekivanja u karijeri, vlastite standarde u pogledu kvalitete skrbi za djecu itd.

Vodeći se time da je odluka o rađanju djeteta rezultat osobnog izbora, analiziranje namjera vezanih uz rađanje postalo je ključno pitanje u diskusijama o stopama fertiliteta diljem svijeta i predstavlja važan aspekt demografske politike. Kratkoročne namjere točnije su od dugoročnih namjera jer se od pojedinca očekuje da predvidi svoju životnu situaciju u sljedeće dvije do tri godine točnije nego u dužem vremenskom razdoblju (Philipov, 2009: 358). Uzimajući u obzir navedeno, u ovom doktorskom radu namjera rađanja ispituje se u sljedeće dvije godine kako bi se dobila što jasnija slika budućeg reproduktivnog ponašanja žena koje su obuhvaćene istraživanjem.

Uzimajući u obzir negativne demografske trendove vezane uz stope fertiliteta, kako bi se moglo ciljano djelovati ka njihovu povećanju, potrebno je utvrditi koji čimbenici utječu na namjeru rađanja. Sukladno tomu, ovo istraživanje temelji se na široko primjenjivanoj Teoriji planiranog ponašanja (Ajzen, 1991), prema kojoj je namjera za određenim ponašanjem najsigurniji prediktor njegova stvarnog izvođenja, a u ovom slučaju na primjeru istraživanja namjere rađanja i prediktora koji čine okvire ponašanja i planiranja kod žena i stvaranja kvalitete življenja obitelji s djecom i bez djece.

Namjere rađanja povezuju društvene, ekonomske i psihološke varijable s plodnošću i stoga ovise o karakteristikama pojedinaca (dob, bračni status, paritet, razina obrazovanja, mreže odnosa i ekonomska situacija) i političkoj i gospodarskoj klimi i sustavu socijalne skrbi u zemlji (Morgan 2001; Morrissey 2017), stoga je u tablici 8. prikazan pregled literature s čimbenicima koji utječu na fertilitet.

Tablica 8. Pregled literature – kronološki pregled objavljenih radova utjecajnih čimbenika fertiliteta

	Autor (i)	**Godina**	**Prepoznati čimbenici**
1.	Riemer, R.; Whelpton, P. K.	1955.	društveni i psihološki
2.	Schultz, P.	1973.	**ekonomski**
3.	Birdsall, N.; Jamison, D. T.	1983.	socio-ekonomski, kulturološki i institucijski
4.	Borg, O.M.	1989.	**ekonomski**
5.	Barro, R.J.	1991.	**ekonomski**

6.	Hakim, A.; Mahmood, N.	1994.	socio-demografski i kulturološki
7.	Martine, G.	1996.	društveni i **ekonomski**
8.	Wertheimer-Baletić, A.	1999.	društveni i **ekonomski**
9.	Panopoulou, G.; Tsakloglou, P.	1999.	socio-ekonomski
10.	Hoem, B.	2000.	**ekonomski**
11.	De Sandre, P.	2000.	socio-ekonomski
12.	ESHRE Capri Workshop Group	2001.	društveni i **ekonomski**
13.	Wertheimer-Baletić, A.	2003.	socio-ekonomski
14.	Pinnelli, A.; Di Cesare, M.	2005.	socio-ekonomski
15.	Ghannam, A. R.	2005.	socio-ekonomski
16.	Adhikari, R.	2010.	socio-ekonomski, kulturološki i demografski
17.	Sobotka, T.; Skirbekk, V.; Philipov, D.	2011.	**ekonomski**
18.	Čipin, I.; Međimurec, P.; Vlah Jerić, S.	2016.	socio-ekonomski
19.	Nasrpour Parvin, R.	2016.	**ekonomski**
20.	Wang, Q.; Sun, X.	2016.	društveno-politički i **ekonomski**
21.	Wertheimer-Baletić, A.	2016.	socio-ekonomski, društveno-psihološki, kulturološki
22.	Awad, A.; Yussof, I.	2017.	demografski i socio-ekonomski
23.	Tropf, F.C.; Mandemakers, J. J.	2017.	društveni
24.	Čipin, I.; Međimurec, P.	2017.	**ekonomski**, kulturološki i društveni
25.	Lutfiah, U., Besral, B.; Herdayati, M.	2017.	osobni i regionalni
26.	Anderson, B.A.	2017.	regionalni i kulturološki
27.	Kurkin, R.; Sprocha, B.; Sidlo, L.; Kocourkova, J.	2018.	socio-ekonomski
28.	Akrap, A.	2019.	**ekonomski**
29.	Lim, S.	2021.	socio-ekonomski
30.	Aitken, R. J.	2022.	socio-ekonomski

Izvor: izrada doktorandice

Naglasak ovog doktorskog rada stavljen je na ekonomske čimbenike koji su se u prethodnim istraživanjima pokazali kao značajni prediktori namjere rađanja.

4.3.1. Čimbenici namjere rađanja s ekonomskog aspekta

Brojni su čimbenici koji utječu na namjeru rađanja, no sukladno problematici ovog doktorskog rada, u nastavku je veća pozornost usmjerena na čimbenike s ekonomskog aspekta.

„Glavna pretpostavka u ekonomiji plodnosti je da će smanjenje troškova rađanja povećati plodnost“ (Björklund, 2006: 10). Navedena pretpostavka počiva na Beckerovom modelu (1991), odnosno prema neoklasičnoj ekonomskoj teoriji plodnosti da imati djecu predstavlja izbor koji se može donijeti na temelju ekonomskih nagrada i troškova koji proizlaze iz toga, ali koji je podložan ograničenjima prihoda i individualnim preferencijama za rađanje djece u odnosu na druga dobra. Ovaj model predviđa da će svako smanjenje troškova djece (zbog državnih subvencija) ili povećanje dohotka (zbog transfernih plaćanja) dovesti do povećanja potražnje za djecom (Cowan i Wyndham Douds, 2022; Becker, 1993; Cigno, 1991; Cigno, 1986). Provedena istraživanja sugeriraju da mjere u okviru obiteljske politike utječu na rađanje (Laroque i Salanié, 2004; Björklund, 2006; Milligan, 2002). Dodatno uporište navedenom daju empirijska istraživanja koja su ukazala na pozitivan, statistički značajan utjecaj mjera obiteljskih politika na rađanje (Cowan i Wyndham Douds, 2022; Bano i sur., 2021; Laroque i Salanié, 2014; Thévenon i Gauthier, 2011; Luci i Thévenon, 2013; Gauthier, 2007; Monnier, 1990; Duclos i sur., 2001; González, 2013; Cohen i sur., 2013; Blanchet i Ekert-Jaffé, 1994; Ekert, 1986; Buttner i Lutz, 1990; Björklund, 2006).

Na temelju proučene literature, identificirani su ključni ekonomski prediktori namjere rađanja, koji će biti predmetom istraživanja, a oni su sljedeći:

a) ekonomska sigurnost (sigurnost posla, financijska sigurnost, vlasništvo nad nekretninom)
b) fiskalni instrumenti javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi)
c) regionalna razvijenost.

Navedeni ekonomski prediktori ujedno su i prediktorske varijable u empirijskom istraživanju namjere rađanja. Za potrebe istraživanja doktorskog rada važno je napraviti analizu međuovisnosti pozitivnih i negativnih utjecaja ekonomskih prediktora na namjeru rađanja, ali i fertilni jaz u Republici Hrvatskoj.

4.3.1.1. Ekonomska nesigurnost

Ako nesigurnost proizlazi iz ekonomske dimenzije, tada je teorija ukorijenjena u Beckerovom modelu (1991) gdje su rađanje djece i popratni oportunitetni troškovi strogo povezani s prihodima roditelja. Većina literature o plodnosti bavi se ispitivanjem učinaka resursa koji su potrebni za poduzimanje određenog ponašanja, poput onih koje se odnose na dohodak i bogatstvo, sudjelovanje u radnoj snazi, obrazovanje, stanovanje i zdravlje (Billari i sur., 2009).

Western i sur. (2012: 341) definirali su ekonomsku nesigurnost kao „rizik od ekonomskog gubitka s kojim se suočavaju radnici i kućanstva dok se susreću s nepredvidivim događajima društvenog života“.

Međutim, veliki dio novije literature o vezi između ekonomskih uvjeta i plodnosti i formiranja obitelji sugerira konceptualizaciju sigurnosti (i/ili nesigurnosti) koji obuhvaćaju nekoliko dimenzija životnih uvjeta pojedinaca (Pieroni i sur., 2023; Fiori i sur., 2013; Modena i sur., 2014; Bernardi i Nazio, 2005; Bhaumik i Nugent, 2002; Kreyenfeld, 2010). Iako se njihovi pristupi razlikuju, postoji konsenzus da ekonomska sigurnost ne bi trebala biti isključivo vezana uz status zapošljavanja, već da bi trebalo uključiti i ostale čimbenike (poput financijskih resursa kućanstva, monetarnih i nemonetarnih resursa koji pomažu u prevladavanju poteškoća, stambenih uvjeta i sl.) koji će doprinijeti osobnoj ekonomskoj sigurnosti pojedinca.

Unatoč velikoj količini empirijske literature koja izučava ekonomske nesigurnosti, ovo se pitanje često ispituje samo neizravno, a njegovo mjerenje ostaje nedovoljno razvijeno i svakako spada u buduće i potencijalne predmete istraživanja.

Teorije o plodnosti čvrsto su ukorijenjene u ideji da ekonomska sigurnost, u smislu zaposlenja i prihoda, predstavlja važan preduvjet za rađanje djece (Brewster i Rindfuss, 2000;

McDonald, 2002). Brojna istraživanja usmjerena su na negativan utjecaj ekonomske nesigurnosti na fertilitet (Mansour, 2018; Schneider, 2015; Bernardi i sur., 2008; Hondroyiannis, 2010).

Istraživanja pokazuju da je dohodak pozitivno koreliran s ulaskom u majčinstvo (Andersson, 2000; Vikat, 2004; Vignoli i sur., 2012; Ermisch, 1989), dok nekolicina autora (Jones i sur., 2010; Jones i Tertilt, 2008) ukazuje na negativan odnos između dohotka i rađanja. Ekonomske poteškoće predstavljene negativnim promjenama dohotka tijekom majčina života povezane su sa smanjenjem ukupnog broja rođene djece tijekom fertilnog razdoblja (Mansour, 2018). Nadalje, uočen je negativan odnos sudjelovanja žena u radnoj snazi i rađanja, što je dovelo do pada stopa fertiliteta (Baizan, 2007; Ahn i Mira, 2002; Adsera, 2004). Stalno zaposlenje povezano je s većim fertilitetom, dok osobe koje imaju nestabilan posao imaju i smanjen fertilitet (Alderotti i sur., 2025; Pieroni i sur., 2023; Doepke i sur., 2022; Vignoli i sur., 2012; Santarelli, 2011). Osim toga, ugovori o radu na određeno vrijeme dovode do veće ekonomske neizvjesnosti koja se identificira povećanjem volatilnosti plaća i dovodi do odgađanja rađanja (Pieroni, 2023, Alderotti i sur., 2021).

Novije istraživanje autora van Wijk, de Valk i Liefbroer (2021) pokazalo je da nizozemski radnici s ugovorom na određeno vrijeme odgađaju osnivanje obitelji, osobito žene. Postoje također, i nalazi na temelju provedenih logističkih regresijskih modela da muškarci s ugovorom o radu na određeno vrijeme odgađaju sklapanje braka i rođenje prvog djeteta. Ti su učinci djelomično objašnjeni prihodima, koji povećavaju stope sklapanja braka i rođenja prvog djeteta kod muškaraca i žena. Percepcija nesigurnosti zaposlenja uglavnom je imala mali utjecaj na formiranje obitelji, iako su zabilježene više stope sklapanja braka među ženama koje su osjećale emocionalnu nesigurnost vezanu za posao. Općenito, ovi rezultati pokazuju da su niski prihodi, a ne osjećaj nesigurnosti glede budućeg zaposlenja, razlog zbog kojeg radnici s ugovorom na određeno vrijeme odgađaju formiranje obitelji.

Golub i sur. (2023) proveli su primarno istraživanje putem upitnika na uzorku od 1000 žena reproduktivne dobi od 15 do 49 godina s područja Bosne i Hercegovine (regija Semberija). Istraživanje potvrđuje da različiti čimbenici, kao što su zaposlenje, stambeni uvjeti te financijska potpora države, značajno utječu na odluke o rađanju, ali i na odluke o željenom broju djece. Osim toga, istraživanje pokazuje da zaposlene majke imaju veći prosječni broj

djece u usporedbi s majkama koje imaju nestabilno zaposlenje, a taj broj često ostaje ispod dvoje djece po majci.

Peng i sur. (2023) empirijski su analizirali Anketu o rađanju djece u provinciji Hubei na temelju uzorka od 13 794 oženjenih mladih parova (ispod 35 godina). Namjera za rađanjem djece bila je mjerena kao idealan broj djece i planiranje rađanja u kratkom roku. Statistički rezultati pokazali su da je prosječan idealan broj djece iznosio 1,65, što je manje od razine potrebne za zamjenu stanovništva, dok je samo 16,4 % oženjenih mladih imalo kratkoročan plan za rađanje djece. Pomoću binarne logističke regresijske analize utvrđeno je da su čimbenici potaknuti pandemijom COVID-19 imali stabilniji utjecaj na namjeru rađanja djece, posebno na kratkoročno planiranje. Karakteristike percepcije roditeljstva imale su veliki utjecaj na idealan broj djece, ali relativno manji utjecaj na kratkoročno planiranje rađanja. Također, utvrđeno je da oženjeni mladi sa stabilnim poslovima i visokim obiteljskim prihodima nisu nužno pokazivali snažniju želju za rađanjem djece od onih s manje resursa. Osim toga, rezultati ukazuju na to da se relativna važnost čimbenika koji utječu na namjeru rađanja može mijenjati ovisno o tome koliko parovi već imaju djece, što ima važne implikacije glede kreiranja i oblikovanja populacijske politike.

Ciritel i sur. (2019) su primijenili četiri logistička regresijska modela specifična za paritet (i) muškarci i žene koji nemaju dijete i ii) roditelji koji imaju jedno dijete za procjenu odnosa između različitih čimbenika i namjera rađanja u sljedeće tri godine (namjera da imaju prvo dijete i namjera da imaju drugo dijete). U istraživanju je proučavanje donošenja odluka o rađanju u Rumunjskoj temeljeno na Teoriji planiranog ponašanja. Istraživanje je utemeljeno na podatcima iz Ankete o generaciji i spolu (engl. *Generation and Gender Survey,* GGS) iz 2005. godine, na uzorku od 11 986 ispitanika (muškaraca i žena) starosti od 18 do 45 godina. Ispitanici su bili podijeljeni u dvije skupine: i) muškarci i žene bez djece i ii) roditelji s jednim djetetom. Istraživanje je polučilo brojne zaključke, od kojih se izdvajaju najvažniji i djelomično su sukladni problematici i istraživačkim pitanjima ovog doktorskog rada. Radni status značajan je pokretač namjere rađanja. Međutim, to se ne odnosi na namjeru da roditelji dobiju drugo dijete. Nadalje, dohodak nije značajno povezan s namjerama rađanja nakon što se uključe u analizu kontrolne varijable stavova, vrste zaposlenja i pozadinskih čimbenika.

Azmoude i sur. (2017) su na uzorku od 241 udane žene starosti od 15 do 49 godina testirali odnos između socio-demografskih čimbenika, ponašanja u pogledu rađanja,

percipirane vrijednosti djeteta i namjere rađanja žena u istočnom Iranu. Primarno istraživanje je provedeno tijekom 2015. godine. Na temelju logističke regresije autori su došli do zaključka da zanimanje žene, godine starosti, trenutni broj djece, koristi od rađanja djece i percipirani troškovi rađanja djece imaju značajan utjecaj na namjeru rađanja. Namjera za rađanjem djece bila je značajno niža kod žena koje imaju djecu oba spola u usporedbi sa ženama koje imaju djecu samo jednog spola. Međutim, nisu utvrđene značajne razlike između budućih namjera rađanja na temelju razine obrazovanja, statusa zaposlenja para i prihoda.

Rezultati istraživanja koje su provele autorice Fahlén i Oláh (2015) pokazuju da žene bez djece (u Ujedinjenom Kraljevstvu) kao i roditelji s jednim djetetom (Španjolska, Njemačka, Nizozemska i zemlje središnje i istočne Europe) s nesigurnim zaposlenjem i prihodom pokazuju smanjenu namjeru rađanja. Zbog činjenice da kratkoročne namjere odražavaju percepciju održivih mogućnosti i ograničenja u odnosu na trenutnu situaciju i potencijalne buduće ishode, ekonomska situacija je značajna ne samo za financijsko blagostanje ljudi, nego i za potencijalne planove za rađanje djece. Kako je već prethodno navedeno, ekonomska nesigurnost i neizvjesnost utječu na odgađanje rađanja i dovode do smanjenja stopa fertiliteta, stoga ih je potrebno uključiti u istraživanje kako bi se dobio potpuni uvid u ograničavajuće čimbenike namjere rađanja.

Nestabilnost posla ne znači nužno i nesigurnost zaposlenja. Dok se nestabilnost posla odnosi na vjerojatnost raskida ugovornog odnosa između radnika i poslodavca, nesigurnost zaposlenja odnosi se na mogućnost dugotrajnog ostajanja bez posla (Stiglitz i sur., 2009.). Slično tomu, novija literatura pravi razliku između fleksibilnosti (povezane s vrstom ugovora o radu) i nesigurnosti u pogledu zaposlenja i prihoda (Origo i Pagani, 2009.). Prema Madsen, (2004) i Wilthagen i Tros (2004) fleksibilno zapošljavanje nije nužno u sukobu sa sigurnošću zaposlenja.

Uzevši u obzir nejednakosti na tržištu rada, siromaštvu i socijalnoj politici, Western i sur. (2012) predložili su četverodijelni okvir za proučavanje ekonomske nesigurnosti. Prvo, autori tvrde da bi proučavanje ekonomske nesigurnosti trebalo biti usredotočeno na kućanstva. Naime, time bi se obuhvatili ukupni rizici za ekonomsko blagostanje jer se kućanstva često sastoje od nekoliko članova koji ostvaruju dohodak. Drugo, prema navedenim autorima, koncept ekonomske nesigurnosti povezan je s promjenama u dohotku tijekom vremena, a ne samo na razine dohotka u određenom trenutku. Nadalje, gubitak prihoda povezan je s

nepovoljnim događajima, posebice gubitkom posla, raspadom obitelji ili lošim zdravljem. Naposljetku, autori tvrde da su učinci i prevalencije nepovoljnih događaja ovisni o kontekstu osiguranja koje okružuje kućanstvo. Na primjer, tržište rada, sustav socijalne skrbi ili podrška drugih ljudi iz okruženja od posebne su važnosti jer isti pružaju monetarne i nemonetarne resurse za reguliranje rizika.

Sukladno gore navedenom pristupu ekonomske nesigurnosti, Modena i sur. (2014) empirijski su istraživali kako na namjere za rađanjem djece utječu nestabilnost poslova (mjereno vrstom ugovora o radu), što može ozbiljno ugroziti stabilnost zaposlenja radnika te ekonomske poteškoće u smislu prihoda i bogatstva kućanstva (mjereno indeksom sigurnosti bogatstva/dohotka), što može implicirati nedovoljna sredstva za suočavanje s mogućim nepovoljnim budućim događajima, stvarajući time osjećaj tjeskobe i ekonomske nesigurnosti u kućanstvu. Autori su analizirali rezultate Ankete o prihodima i bogatstvu kućanstva (engl. *Survey on Household Income and Wealth*) koja je provedena na talijanskim kućanstvima između 2002. i 2008. godine, a obuhvaćala je 2085 parova (parovi u kojima je žena starosti 38 godina ili manje). Rezultati multinomne logističke regresije ukazuju na zaključak da nestabilnost radnog statusa žena (tj. zaposlenje na povremenoj i nesigurnoj osnovi) značajno smanjuje namjeru rađanja prvog djeteta. Konačno, izgledi za daljnje rađanje značajno su i negativno uvjetovani nesigurnošću prihoda kućanstva.

Ciritel i sur. (2019) istraživanjem su došli do zaključka da je radni status (nezaposlen/zaposlen) značajan pokretač namjere rađanja, ali ovisi o paritetu.

Prethodna istraživanja pokazala su da uvjeti stanovanja utječu na namjeru rađanja (Hu i sur., 2022; Ciritel i sur., 2019; Kulu i Vikat, 2007; Simon i Tamura, 2009; Vignoli i sur., 2012) zbog više razloga. Prema Hu i sur. (2022), vlasnici nekretnina imaju viši stupanj kontrole nad svojim stambenim uvjetima koji su važni za odluku o rađanju jer nerijetko parovi preferiraju osigurati stambene uvjete prije nego što dobiju dijete. Nadalje, autori navode da je istraživanje u Švedskoj pokazalo da žene koje žive u vlastitim nekretninama imaju veću vjerojatnost namjere rađanja u odnosu na žene koje žive u unajmljenim stanovima. Povećana vjerojatnost da će žene imati dijete nakon stjecanja vlasništva nad nekretninom dokazano je i u Nizozemskoj i zapadnoj Njemačkoj (Mulder i Wagner, 2001 u Hu i sur., 2022). Međutim, u europskim zemljama s najvišim razinama vlasništva nad nekretninama (osobito u južnoj Europi, u Italiji, Grčkoj i Španjolskoj, gdje je postotak vlasnika nekretnina iznad 75 %) i

relativno niskim davanjem hipotekarnih zajmova uočeno je odgađanje rađanja i smanjenje stope fertiliteta (Sobotka, 2011). Postati vlasnikom nekretnine može biti zamjena za troškove rađanja dodatne djece, dok s druge strane, izostanak adekvatnog smještaja može dovesti do odgađanja rađanja ili ograničavanja veličine obitelji (Fiori i sur., 2013). S druge strane, osobe bez djece koje žive u velikoj kući imaju manju namjeru rađanja (Ciritel i sur., 2019).

Autori Hu i sur. (2022) su na temelju podataka iz Dinamičke ankete migranata u Kini (engl. *China Migrants Dynamic Survey*) provedene tijekom 2017. godine, na uzorku od 44 423 udanih žena starosti između 15 i 50 godina koje su imale namjeru rađanja u sljedeće dvije godine istraživali kako posjedovanje nekretnina utječe na namjeru rađanja djece među migrantima u urbanoj Kini. Za istraživanje utjecaja vlasništva nad nekretninom na namjeru rađanja korištena je logistička regresija. Provedenom analizom utvrđeno je da su vlasnici nekretnina prosječno 1,12 postotnih bodova skloniji namjeri rađanja u usporedbi s osobama koje iznajmljuju nekretninu. Procijenjeni učinak posjedovanja nekretnina prosječno povećava namjeru za djecom za 7,8 %. Međutim, navedeni učinak uglavnom se odnosi na kućanstva bez djece. Sukladno navedenom, rezultati pokazuju da se odnosi između vlasništva nad nekretninom i namjera rađanja razlikuju ovisno o obliku vlasništva nad nekretninom. U pogledu namjere rađanja, ispitanici koji su imali zajedničko vlasništvo nad nekretninom ne razlikuju se značajno od ispitanika koji stanuju u iznajmljenoj nekretnini.

Uzimajući u obzir i vlasništvo nekretnine kao bitan čimbenik ekonomske sigurnosti, Fiori i sur. (2013) su u svojem istraživanju varijablu sposobnost kućanstva da se nosi s nepovoljnim događajima mjerili kroz tri dimenzije: štedni kapacitet kućanstva, posjedovanje nekretnine i potporu članova šire obitelji. Na temelju rezultata istraživanja, autori su analizirali odnos između ekonomske nesigurnosti[7] i namjere rađanja (u sljedećih tri ili više godina) kod žena u Italiji. Konačni uzorak sastojao se je od 5358 žena koje su nedavno dobile prvo dijete, a koje su još uvijek bile u braku s (ili su živjele s) ocem djeteta u vrijeme intervjua. Autori su došli do nezanemarive povezanosti između ekonomske nesigurnosti i namjere rađanja upotrebom *probit logit* modela. Rezultati ukazuju na to da se žene koje namjeravaju imati samo još jedno dijete i žene koje namjeravaju imati dvoje ili više djece razlikuju, s obzirom na to da su reproduktivni planovi žena s namjerom za rađanje većeg broja djece manje ovisni o

[7] Autori su ekonomsku nesigurnost mjerili uzimajući u obzir i nesigurnost potencijalno povezanu s radnim statusom i karakteristikama zanimanja para i druge monetarne i nemonetarne resurse dostupne kućanstvu da prevlada ekonomske poteškoće.

ekonomskim uvjetima. S druge strane, uočeni učinci sociodemografskih varijabli su vrlo slični, no izraženiji su prema namjeri za rađanjem dvoje ili više dodatne djece. Dob je nedvojbeno pokretački čimbenik, osobito među ženama koje imaju namjeru roditi još dvoje ili više djece. Nadalje, stupanj sigurnosti povezan s resursima dostupnim za suočavanje s nepredvidivim događajima ima snažan i pozitivan utjecaj na definiranje dugoročnih namjera vezanih za broj djece koji parovi namjeravaju imati (osobito kod žena koje žele dvoje djece); kratkoročni planovi su, s druge strane, gotovo isključivo povezani s trenutačnim statusom zaposlenja para. Namjera da parovi imaju točno još jedno dijete opada s povećanjem udjela mjesečnih prihoda koji se troše i manji je za žene koje unajmljuju stan. Također, namjera za rađanjem većeg broja djece opada kada kućanstvo nema sposobnost štednje.

Prethodno prikazana istraživanja u okviru recentne literature predstavljaju temelj za kreiranje varijable ekonomske sigurnosti prilikom ispitivanja namjere rađanja u Republici Hrvatskoj.

4.3.1.2. Fiskalni instrumenti javnih politika

Za daljnje razumijevanje problematike niskog fertiliteta nužno je razmotriti ekonomsku teoriju fertiliteta. Becker (1960) je prvi istraživač koji je primijenio ekonomsku analizu na fertilitet (Doepke, 2014) te istražio utjecaj troškova i koristi vezanih uz imanje djece. U svom istraživanju Becker je nastojao definirati djecu kao posebnu vrstu dobra u okviru analize „potražnje djece“ te je pretpostavio da svaka obitelj vrednuje svoju djecu kao nešto više od uobičajenog zadovoljstva, uzimajući pri tome u obzir određenu razinu dohotka. U svojim istraživanjima razmatrao je i kompromis između „kvalitete“ i broja djece, definirajući „kvalitetu“ kao veću korisnost koju roditelji očekuju kroz veća ulaganja u djecu. S aspekta individualnih preferencija, ekonomski pristup fertiliteta primarno se usredotočuje na troškove i dobrobiti rađanja, posebice izravne i neizravne troškove podizanja djece (Becker, 1993; Becker i Barro, 1988). Prema Beckeru, obitelji se suočavaju s proračunskim i vremenskim ograničenjima, s obzirom na to da isto iziskuje novac i vrijeme. Sukladno tomu, roditelji moraju rasporediti svoj prihod između potrošnje i rađanja djece te raspoloživost svojeg vremena između rada, slobodnog vremena i brige za djecu. Navedeno komplicira i činjenica da roditelji ne brinu samo o količini djece, već i o njihovoj „kvaliteti“ i mogu odlučiti potrošiti novac na izdatke koje nosi manji, a ne veći broj djece. Direktni trošak podizanja djece, oportunitetni trošak vremena provedenog u podizanju djece i fekonditet (engl. *Fecundity*) predstavljaju tri

Beckerove glavne prepreke rađanja. Samo na direktni trošak podizanja djece i oportunitetni trošak vremena provedenog u podizanju djece može utjecati prihod. Postavljena teorija predviđa da će se fertilitet povećati ako izvor prihoda nije plaća, nego npr. novčani transfer jer bi novčani transfer povećao prihod obitelji bez promjene oportunitetnog troška vremena provedenog u brizi za djecu. Povećanje plaća povećava prihod kućanstva, što može povećati fertilitet, ali također povećava oportunitetne troškove vremena za brigu o djeci, što bi moglo posljedično dovesti do učinka zamjene.

Bez poznavanja preferencija svakog pojedinca, nejasno je prevladava li učinak dohotka ili učinak supstitucije (Becker, 1960, 1993; Becker i Lewis, 1973). „Ukratko, Beckerova teorija racionalnog izbora predviđa da će novčani transferi povećati plodnost povećanjem prihoda bez mijenjanja oportunitetnog troška vremena provedenog u odgoju djece“ (Cowan i Wyndham Douds, 2022: 1007). Slijedeći klasičnu ekonomsku teoriju (djeca se mogu smatrati normalnim dobrom analognim drugim dobrima i uslugama koje pružaju zadovoljstvo/korisnost obitelji), Andersen i sur. (2018) novu obiteljsku ekonomiju objašnjavaju kao utjecaj povećanja troškova rađanja djece na odluku o rađanju. Javne politike i njihove primjene imaju utjecaj na demografiju, odnosno nastoje biti usmjerene i važni nositelji aktivnosti u procesima demografske revitalizacije.

Prema Zhang i sur. (2023) nova obiteljska ekonomija, koja se počela razvijati 1950-ih godina predstavlja ekonomsku metodu za analizu troškova i koristi obiteljskih odluka, a njeni glavni predstavnici su Harvey Leibenstein i Gary Stanley Becker. Teorija uzima obitelj kao predmet istraživanja te pruža ekonomsku analizu plodnosti, braka i drugih ponašanja kako bi se maksimizirala realizacija korisnosti (utiliteta) prilikom raspodjele ograničenih resursa obitelji na racionalan način. Kada se analiziraju odluke o reprodukciji obitelji, teorija razmatra djecu kao trajna dobra obitelji i analizira promjene u potražnji obitelji za djecom kroz analizu potražnje obitelji za trajnim dobrima. Važan čimbenik u odluci obitelji o rađanju djece jest marginalni trošak rađanja, koji uključuje direktne troškove kao što su odjeća, hrana, smještaj i troškovi za čuvanje djece te indirektne troškove kao što su gubitak prihoda s posla i gubitak ljudskog kapitala zbog napuštanja radnog mjesta radi rađanja i skrbi o djeci.

Troškovi rađanja djece mogu se kontrolirati putem javnih politika na različite načine, ali su u najvećoj mjeri usmjereni na razmatranje razdiobe novčanih i nenovčanih transfera. Javne politike koje su programski usmjerene prema obiteljima mogu djelomično nadoknaditi

sve veće troškove rađanja djece, međutim svaka promjena javnih politika posljedično može izazvati i negativne utjecaje tj. rezultirati nižim ili višim troškovima odgoja djece povećavajući ili smanjujući tako i stopu fertiliteta.

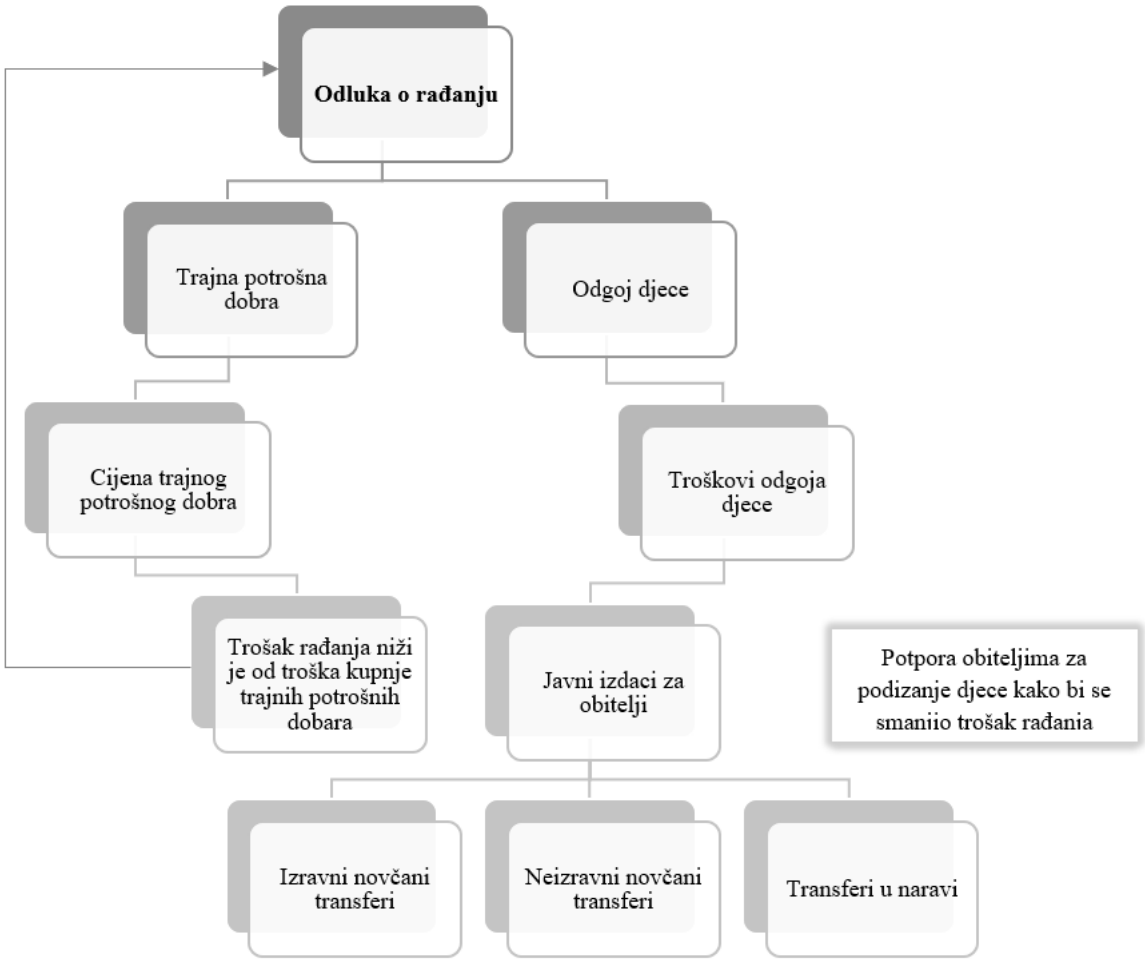

Slika 6. Shematski prikaz nove ekonomske teorije
Izvor: prilagodba doktorandice (Zhang i sur., 2023)

Za proučavanje odnosa između javnih politika i rađanja, znanstvenici najčešće polaze od teorije racionalnog izbora. Naime, prema neoklasičnoj ekonomskoj teoriji plodnosti odluka o rađanju djeteta podložna je ekonomski racionalnoj odluci (proces maksimiziranja korisnosti) i funkcija je ekonomske cijene i dobrobiti djece, koja je podložna ograničenju prihoda i preferencijama pojedinaca prema djeci (za razliku od karakteristika drugih dobara). Prema ovom modelu, očekuje se da će svako smanjenje troškova za djecu (kao rezultat javnih subvencija) ili svako povećanje prihoda (kao rezultat transfernih plaćanja) povećati potražnju za djecom (Becker, 1993). Posljedično se očekuje da će politike kao što su dječji i obiteljski

novčani doplatci, porezne olakšice za djecu, subvencije za skrb o djeci te naknade za porodiljni i roditeljski dopust imati pozitivan učinak na plodnost smanjenjem izravnih ili neizravnih (oportunitetnih) troškova za djecu ili povećanjem prihoda pojedinaca. Ovaj ekonomski model vrlo je utjecajan u literaturi i u središtu je pretpostavljenog odnosa između javnih politika i fertiliteta. Gauthier (2007: 327) navodi da obiteljske politike utječu na fertilitet kroz tri različita kanala: i) „kroz njihov utjecaj na troškove djece (npr. subvencije), ii) dohodak pojedinaca (npr. novčani transferi) i/ili iii) preferencije. Takav model također dopušta mogućnost "nesavršenih" informacija, neekonomskih troškova i koristi, te ulogu društvenih normi i sankcija“.

Parovi i obitelji dobivaju različite vrste pomoći kako bi ih se potaknulo da imaju djecu ili bi im se pomoglo u smanjenju troškova uzdržavanja djece. Financijska potpora obiteljima s djecom važan je i sastavni dio paketa široke obiteljske politike čiji se ciljevi svrstavaju u tri osnovne kategorije: „smanjenje dječjeg siromaštva, povećanje aktivnosti roditelja na tržištu rada i osiguranje demografske stabilnosti kroz visoke stope fertiliteta“ (Myck i sur., 2013: 62). Novčane potpore koje se pružaju obiteljima s djecom mogu se podijeliti na dvije glavne kategorije: naknade socijalne zaštite i porezne olakšice unutar sustava poreza na dohodak.

Naknade socijalne zaštite mogu biti univerzalne (engl. *universal benefits*), što znači da su dostupne svim obiteljima bez obzira na njihov dohodak ili imovinu ili ciljane (engl. *means-tested benefits*), što znači da ovise o dohotku ili imovini obitelji. Te naknade mogu varirati ovisno o dobi i broju djece u obitelji. Univerzalne naknade za djecu su najjednostavniji oblik i pružaju obiteljima novčanu potporu za svako dijete u jednakom iznosu, bez obzira na njihov financijski status. S druge strane, ciljane naknade ne ostvaruju sva djeca, već njihova dostupnost i visina ovise o dohotku ili imovini kućanstva. To znači da obitelji s nižim prihodima ili manjom imovinom mogu ostvariti veću financijsku potporu kako bi im se olakšali troškovi odgoja djece.

U okviru poreznog sustava roditelji mogu ostvariti porezne olakšice u obliku odbitaka i/ili umanjenja porezne obveze. Odbitak poreza (engl. *Tax allowance*) predstavlja olakšicu kojom se smanjuje porezna osnovica, dok umanjenje poreza (engl. *Tax credit*) izravno umanjuje iznos obračunatog poreza. Kada roditelji koriste pravo na odbitak za djecu, visina ostvarene porezne uštede ovisi o njihovom dohotku i primijenjenoj poreznoj stopi. S druge strane, umanjenje poreza omogućuje jednak iznos uštede za sve porezne obveznike, neovisno o visini dohotka. U slučajevima kada se neiskorišteni dio umanjenja isplaćuje poreznom

obvezniku (porezna obveza je niža od umanjenja poreza), riječ je o umanjenju s povratom (engl. *Refundable tax credit*), dok u suprotnom, kada povrat nije moguć, govorimo o umanjenju bez povrata (engl. *Non-refundable tax credit*).

Dodatni oblici podrške obiteljima s djecom, uz novčane transferne programe, čine i naknade u naravi i subvencije. Naknade u naravi i subvencije su oblici pomoći koje se ne isplaćuju u novcu, već u obliku dobara ili usluga koje obitelj može koristiti kako bi im se olakšao odgoj i skrb djece. Socijalno ugrožene obitelji, samohrani roditelji, roditelji koji imaju dijete s određenim oblikom invalidnosti uglavnom imaju pravo na više iznose naknada i dodatne naknade. Većina zemalja kombinira izravne i neizravne novčane transfere te naknade u naravi i subvencije.

Thévenon i Gauthier (2011: 201) podršku parovima i obiteljima dijele u pet glavnih kategorija:

1. „podrška budućim majkama tijekom trudnoće do poroda, npr. medicinska skrb, informacije ili savjetovanje (posebno o prehrani) i hospitalizacija za porođaj
2. podrška za rođenje djeteta, npr. set za bebe (uključujući bočicu i odjeću za novorođenče), vaučeri ili jednokratni iznos isplaćen povodom rođenja djeteta
3. redovna dugoročna financijska pomoć obiteljima za pokrivanje izravnih troškova djece (npr. obiteljske naknade, socijalni dodatci koji ovise o broju djece, porezne olakšice za obitelji s djecom ili potpora za pokrivanje nekih troškova obrazovanja)
4. podrška namijenjena pomoći roditeljima da usklade rad i odgoj djece (npr. prava na rodiljni dopust ili skrb za vrlo malu djecu ili bolesnu djecu, ustanove za čuvanje djece i obrazovanje te financijske pogodnosti i porezne olakšice vezane uz zaposlenje)
5. naknade isplaćene roditeljima koji nisu zaposleni ili koji prestanu raditi kako bi brinuli o maloj djeci“.

Vrlo slično, McDonald (2000) razlikuje tri kategorije mjera:

1. novčani poticaji (porezne olakšice, krediti ili odbitci, besplatne ili subvencionirane usluge i proizvodi za djecu, stambene subvencije, periodična novčana plaćanja, paušalna plaćanja i zajmovi)
2. podrška roditeljima u usklađivanju posla i obitelji (rodiljni i očinski dopust, briga o djeci, fleksibilno radno vrijeme i kratkotrajni dopust u roditeljske svrhe, antidiskriminacijsko zakonodavstvo i rodna ravnopravnost u praksi zapošljavanja)

3. društvena podrška djeci i roditeljstvu (inicijative za zapošljavanje, jednakost spolova, okruženje prilagođeno djeci, podrška za brak i veze, pozitivni društveni stavovi prema djeci i roditeljstvu).

Prethodna empirijska istraživanja o utjecaju novčanih transfera na makrorazini ukazuju na pozitivan utjecaj (Cowan i Wyndham Douds, 2022; Bano i sur., 2021; Laroque i Salanié, 2014; Thévenon i Gauthier, 2011; Luci i Thévenon, 2013; Gauthier, 2007; Monnier, 1990; Duclos i sur., 2001; González, 2013; Cohen i sur., 2013) na fertilitet.

Cowan, Wyndham Douds (2022) empirijski su istraživali utjecaj novčanih transfera na rađanje žena starosti između 15 i 44 godine na Aljasci. Rezultati logističke regresije pokazali su da novčani transferi uzrokuju povećanje kratkoročnih stopa plodnosti jednu i dvije godine nakon isplate, osobito među populacijama u nepovoljnom položaju. Količina transfera potrebna za izazivanje učinka ovisi o veličini kućanstva. Navedeno upućuje na to da novčani transferi uklanjaju ekonomske prepreke rađanju djece za neke ljude i stoga su održiv politički mehanizam za smanjenje nejednakosti u plodnosti i reproduktivnoj autonomiji. Autori također navode da novčani transferi, iako su osmišljeni za rješavanje problema siromaštva i ekonomskih nejednakosti, mogu uspješno smanjiti nejednakosti na makrorazini.

Laroque i Salanié (2013) su na uzorku od 16 891 žena mlađih od 40 godina istraživali utjecaj financijskih poticaja na namjeru rađanja (na temelju podataka iz Francuske ankete o radnoj snazi, engl. *French Labor Force Surveys* za 1997., 1998. i 1999. godinu). Rezultati pokazuju da su financijski poticaji imali značajan učinak na odluke o rađanju u Francuskoj. Dodatni novčani transfer od 150 EUR mjesečno je imao najjači učinak kod trećeg djeteta. Osim toga, došlo je do povećanja stope nataliteta za 3,3 postotna boda.

Na primjeru europskih i OECD zemalja Thévenon i Gauthier (2011) zaključili su da financijske naknade, neovisno o tome jesu li uvjetovane radnim statusom ili ne, imaju neosporan utjecaj na vrijeme rađanja. Daljnju potvrdu pozitivnog utjecaja instrumenata obiteljskog paketa na stope fertiliteta dali su i Luci i Thévenon (2013) koji su testirali utjecaj plaćenog dopusta, usluge skrbi o djeci i novčanih poticaja na primjeru 18 OECD zemalja u razdoblju od 1982. do 2007. godine. Također, Gauthier (2007; prema Finch i Bradshaw, 2003) navodi da je istraživanje provedeno na 17 OECD zemalja pokazalo snažnu korelacijsku povezanost između indeksa paketa mjera za djecu (koji uključuje različite novčane transfere i

porezne olakšice za djecu) i ukupne stope fertiliteta tijekom 2000. godine te između paketa mjera za siromašne obitelji i ukupne stope plodnosti.

Učinkovitost javnih politika na fertilitet potvrdila je i Monnier (1990) koja je istraživala utjecaj različitih pronatalitetnih mjera (uključujući produljeni rodiljni dopust i plaćeni dopust za brigu o djetetu) usvojenih 1976. godine u Njemačkoj Demokratskoj Republici. Naime, godišnji broj rođene djece počeo je naglo rasti 1976. godine i dostigao vrhunac od 245 132 rođenih 1980. godine, što predstavlja povećanje od 37 %.

Duclos i sur. (2001) na temelju Ankete o potrošačkim financijama 1981. – 1997. godine (engl. *Survey of Consumer Finances*) u pokrajini Quebec empirijski su dokazali da financijski poticaji (univerzalne naknade za malu djecu i novorođenčad ovisne o redu rođenja, porezne olakšice za uzdržavanu djecu i smanjenje poreza na dohodak obitelji) imaju snažan utjecaj na rađanje kod žena u dobi od 15 do 44 godine. Međutim, nije jasno jesu li financijski poticaji imali temporalni učinak ili učinak na ukupni fertilitet.

Odnos između statusa prihvaćanja uvjetnog novčanog transfera (engl. *Conditional Cash Transfer*[8]) u Indoneziji i namjera rađanja udanih žena u dobi od 15 do 49 godina (uzorak od 62 179 žena) na temelju podataka iz SUSENAS 2017[9] istraživali su Bano i sur. (2021). Kriterijska varijabla predstavljala je namjeru rađanja, odnosno namjeru žena da imaju dijete/još jedno dijete u budućnosti (za < 2 godine, ≥ 2 godine i izostanak namjere). Rezultati studije na temelju primijenjene logističke regresije pokazali su da je nakon kontrole učinaka individualnih i kontekstualnih varijabli visoka namjera plodnosti povezana s primanjem uvjetnih novčanih transfera. Žene iz kućanstava korisnika uvjetnih novčanih transfera imale su tendenciju maksimiziranja primljene pomoći povećanjem broja djece (moralno hazardno ponašanje) u odnosu na žene iz kućanstava koje nikada nisu primila uvjetni novčani transfer.

[8]Vlada Indonezije je 2007. godine pokrenula program Keluarga Harapan, prvi uvjetni program novčanih transfera u Indoneziji. Program nastoji poboljšati kvalitetu ljudskog kapitala pružanjem novčanih transfera uvjetovanih pristupom kućanstava određenim zdravstvenim i obrazovnim uslugama. Ciljane su obitelji s niskim primanjima s trudnicama/dojilje, djeca 0-6 godina, djeca školske dobi, starije osobe i osobe s invaliditetom (Bano, Samosir, Djutaharta, 2021)

[9] Sociodemografska i ekonomska istraživanja koje svake godine provodi Statistika Indonezije (Badan Pusat Statistik).

Učinak proširenja obveznog plaćenog rodiljnog dopusta[10], uvedenog u Švicarskoj 2005. godine na namjere rađanja proučavali su Barbos i Milovanska-Farrington (2019). Cilj rada bio je istražiti učinak ove reforme na srednjoročne namjere pojedinaca o namjeri rađanja u razdoblju od tri godine nakon datuma intervjua. U radu su korišteni podatci iz Europskog društvenog istraživanja (engl. *European Social Survey,* ESS) provedenog 2004. i 2010. godine, na uzorku od ukupno 902 muškarca i žena starosti između 25 i 42 godine (593 ispitanika iz istraživanja provedenog 2004. godine i 309 ispitanika iz istraživanja provedenog 2010. godine) u vrijeme istraživanja. Ispitanici su bili podijeljeni u dvije skupine: i) korisnici proširene i izdašnije politike rodiljinih naknada i ii) pojedinci koji su imali pravo na proširene naknade, ali ih još nisu koristili. Rezultati logističke regresijske analize upućuju na značajne razlike u namjeri rađanja između ove dvije skupine. Uzroke navedenih razlika autori pronalaze u mogućnosti da iskustvo pogodnosti povećava vjerojatnost da će pojedinac planirati imati još jedno dijete/još djece. Nadalje, kao drugi uzrok razlike autori navode da produženi rodiljni dopust smanjuje troškove odgoja starije djece, što može potaknuti pojedince da smanje razmak između rođenja djece, potencijalno utječući ili ne na ukupne namjere rađanja djece. Naposljetku, posljednji uzrok određuje činjenica da je reforma možda potaknula neke pojedince koji bi inače odgodili rođenje prvog djeteta da to dijete imaju ranije, istovremeno planirajući imati više djece.

Nadalje, provodeći bivarijatne korelacijske analize za 20 zemalja OECD-a, Castles (2003) nije pronašao statistički značajnu vezu između novčanih naknada i fertiliteta.

Empirijska istraživanja provedena na mikrorazini upućuju na općeniti zaključak o pozitivnom utjecaju financijskih poticaja i općih pokazatelja obiteljske politike na fertilitet, međutim, ne postoji jednoznačan zaključak s obzirom na to da utjecajne okolnosti ovise o broju djece koji već parovi imaju (Hart i Galloway, 2023; Raute, 2019; Spéder i sur., 2019; Riphahna i Wiyncka, 2017; Laroque i Salanie, 2008; Milligan, 2005; Laroque i Salanie, 2005).

Na primjeru Norveške, Hart i Galloway (2023) dokazali su da je reforma kojom se povećavaju univerzalni transferi i porezne olakšice povećala rađanje žena u ranim 20-ima (analiza je rađena na uzorku žena starosti od 20 do 39 godina). Učinak je najizraženiji kod

[10] Proširenje rodiljnih naknada (engl. *Maternity Benefits,* MB) provedeno je u Švicarskoj 2005. godine. Uključivalo je proširenje s osam tjedana rodiljnog dopusta, koji je prema izboru poslodavca mogao biti plaćeni ili neplaćeni, na 14 tjedana obveznog plaćenog dopusta.

prvog poroda, ali postoje i tendencije porasta kod drugog i trećeg poroda. Također, postoji porast trećeg rođenja među ženama u dobi od 35 do 39 godina u trenutku provedbe, što ukazuje na trajan učinak na plodnost. Navedeno ukazuje na zaključak da su niski izravni troškovi podizanja djece doprinijeli visokom fertilitetu. Nadalje, Riphahna i Wiyncka (2017) analizirali su reformu provedenu 1996. godine u Njemačkoj na primjeru parova u kojima je godišnja dob žene najmanje 25 godina. Reformom su povećani dječji doplatci, a iznos je bio ovisan o prihodu kućanstva i broju djece. Rezultati analize ukazuju da učinci reforme na parove s niskim primanjima nisu statistički značajni. Autori nalaze određenu potvrdu pozitivnim učincima na plodnost za parove s višim u odnosu na niže prihode koji se odlučuju na rađanje drugog djeteta.

Novčani poticaji povećavaju vjerojatnost imanja drugog djeteta za 20,5 % (Milligan, 2005), dok rezultati istraživanja provedenog u Francuskoj (Laroque i Salanie, 2008) pokazuju da financijski poticaji imaju značajnu ulogu pri odluci o rađanju prvog i trećeg djeteta, ali ne i drugog. Slično tomu, rezultati Laroque i Salanie (2004) na primjeru Francuske sugeriraju da financijski poticaji imaju utjecaj na vjerojatnost rađanja prvog djeteta, dok taj utjecaj izostaje kod rađanja trećeg djeteta.

Raute (2019) je u svojem radu analizirala utjecaj naknade za rodiljni dopust (ovisne o primanjima) na fertilitet i smanjenje jaza u broju rođene djece između visokoobrazovanih (s visokim primanjima) i manje obrazovanih (s niskim primanjima) žena. Analiza je rađena na primjeru reforme koja je uvedena u Njemačkoj, a odnosila se na znatno povećanje financijskih poticaja (do 21 000 EUR) za visokoobrazovane žene s višim primanjima. Koristeći velike razlike u naknadama za porodiljni dopust po obrazovnim i prihodovnim skupinama rezultati ukazuju na povećanje fertiliteta kod žena s tercijarnim obrazovanjem do 23 %. Autorica dokazuje pozitivan, statistički značajan učinak povećanih beneficija na fertilitet temeljen na ženama sa srednjom i gornjom distribucijom zarade. Zaključno, rezultati sugeriraju da su naknade za porodiljni dopust ovisne o zaradi, koje ženama nadoknađuju oportunitetni trošak rađanja i tako imaju utjecaj na smanjenje nejednakosti broja djece povezanu s obrazovanjem i primanjima majki. Važno je istaknuti činjenicu da prema novom sustavu visokoobrazovane žene imaju veću vjerojatnost da će imati prvo, ali i (dodatno) drugo dijete na kraju svog fertilnog razdoblja.

Spéder i sur. (2019) su na temelju rezultata Ankete o generacijama i spolu 2001. – 2012. godine (engl. *Generations and Gender Survey*) u Mađarskoj istraživali učinke novih obiteljskih

politika na rađanje trećeg djeteta među različitim socioekonomskim skupinama. Nove političke mjere odnosile su se na potpore za odgoj djece u obliku paušalnog iznosa isplaćivane od treće do osme godine najmlađeg djeteta (kao priznanje za majčinstvo koje uključuje ostanak kod kuće) te preuređeni i poboljšani sustav poreznih olakšica. Rezultati ukazuju na to da će paušalna potpora za odgoj djeteta uz dugo razdoblje roditeljskog dopusta vjerojatno motivirati roditelje nižeg socioekonomskog statusa da imaju više djece. Nasuprot tomu, izgleda da je mogućnost znatnih poreznih olakšica potaknula roditelje s visokim obrazovanjem i dvoje djece da imaju treće dijete, u konačnici je imala neznatan utjecaj na roditelje s niskim socio-ekonomskim statusom.

Osim novčanih transfera koji su prethodno prikazani na temelju recentne literature, nezanemariv je utjecaj i transfera u naravi i subvencija koje imaju za cilj smanjiti troškove odgoja djece. Naime, prethodna istraživanja pokazuju da je nejednakost u prihodima manja nakon što se uključe transferi u naravi u analizu (Evandrou i sur., 1993). Stoga je važno u analize uključiti ukupni prihod s obzirom na to da prihod kućanstva ne čine samo novčani transferi, već i transferi u naravi i subvencije (Rosen i Gayer, 2009).

Transferi u naravi u koje spadaju obrazovne i zdravstvene usluge, stanovanje, subvencije za prijevoz ili školski obroci, imaju znatno veću vrijednost za kućanstva s niskim primanjima. No, neki rezultati istraživanja pokazuju da siromašniji roditelji, ako imaju izbora, radije biraju novčane transfere umjesto transfera u naravi zbog nedostatka svijesti (Pezer i sur., 2023). S druge strane, subvencioniranje ustanova za skrb o djeci ima pozitivan učinak na stopu sudjelovanja majki na tržištu rada (Givord i Marbot, 2015; Lefebvre i sur., 2009). Navedeno je usko vezano i s istraživačkim spoznajama da transferi u naravi smanjuju siromaštvo djece (Pezer i sur., 2023; Nygård i sur., 2019; Förster i Verbist, 2012).

Christl i sur. (2020) empirijskim su istraživanjem na primjeru Austrije analizirali redistribuciju unutar sustava poreznih olakšica. Istraživanjem su obuhvaćeni izravni porezi i novčani transferi, neizravni porezi te transferi u naravi. Autori su promatrali dvije vrste redistribucije: između kućanstava koja pripadaju različitim dohodovnim skupinama i između generacija, uzimajući perspektivu životnog ciklusa. Rezultati upućuju na zaključak da neizravni porezi imaju regresivan učinak na sustav poreznih olakšica. Nasuprot tomu, transferi u naravi imaju progresivan učinak. Nadalje, indirektno oporezivanje bi kućanstvo s graničnim

dohotkom (iznad kojeg kućanstvo postaje neto platac) pomaknulo prema dolje, ali transferi u naravi ponovno bi ga pomaknuli prema gore.

Učinci politika obiteljske skrbi razlikuju se po regijama. Konkretno, efekti poticanja fertiliteta putem obiteljskih naknada najizraženiji su u sjevernoj Europi, dok su učinci roditeljskog dopusta najizraženiji u južnoj i istočnoj Europi (Zhang i sur., 2023). Nadalje, Yun (2015) je ukazao na snažnu povezanost između dostupnosti ustanova dječje skrbi i fertiliteta. Javna defamilijalizacija (oblik familijalizacije koji predstavlja opću i velikodušnu obiteljsku politiku) pokazuje najveću stopu plodnosti i gotovo nikakvu razliku među različitim društvenim slojevima. Međutim, privatni tip defamilijalizacije kojem nedostaje javna podrška za skrb otkriva najznačajniju razliku u stopi plodnosti različitih klasa. U različitim fazama razvoja, politike blagostanja trebale bi se dinamički prilagoditi.

Koristeći jednostavan model preklapajućih generacija neoklasičnog rasta, Fanti i Gori (2010) analizirali su učinke dječjih naknada i sustava javnog obrazovanja na stopu fertiliteta, BDP po stanovniku i individualno blagostanje tijekom života. Rezultati ukazuju na to da razvijene zemlje pogođene fertilitetom ispod razine zamjene i stagnacijom prihoda mogu istovremeno povećati BDP po stanovniku i stopu fertiliteta povećanjem javnih izdataka za obrazovanje umjesto korištenja dječjih naknada. Navedeni rezultati pokazuju da isto šteti dugoročnom neoklasičnom ekonomskom rastu i stopi rasta stanovništva. Osim toga, analiza blagostanja pokazala je postojanje stope obrazovnih doprinosa koja postiže Pareto-efikasnu i maksimalnu dobrobit.

McDonald (2000) naglašava da čak i ako bi tržište ostvarilo iznimno povoljne rezultate, s niskom nezaposlenošću i povećanjem stvarnih prihoda, to ne bi nužno potaknulo povećanje fertiliteta. Razlog tomu je što donošenje odluka o rađanju djece u tržišnoj ekonomiji ima više veze s relativnim blagostanjem nego s apsolutnim blagostanjem. Apsolutno blagostanje odnosi se na stanje u kojem pojedinci ili kućanstva posjeduju dovoljno resursa kako bi zadovoljili osnovne životne potrebe poput hrane, stanovanja, odjeće, obrazovanja i zdravstvene skrbi. Apsolutno blagostanje mjeri se u odnosu na određeni standard ili prag ispod kojeg se smatra da pojedinac ili kućanstvo živi u siromaštvu. Relativno se blagostanje pak odnosi na stanje u kojem pojedinci ili kućanstva procjenjuju svoje bogatstvo i standard života u usporedbi s drugim članovima društva ili zajednice. Relativno blagostanje fokusira se na društvene

nejednakosti i kako se distribucija resursa i prihoda unutar društva odražava na percepciju blagostanja među njegovim članovima.

Bez obzira na to koliko je uspješno tržište, prema trenutnim uvjetima u većini zemalja, uvijek će pružati manje koristi onima s djecom nego onima bez djece. Također, koristi koje tržište pruža će se smanjivati kako broj djece raste. Opadanje stopa rađanja u većini industrijaliziranih zemalja ukazuje na neuspjeh tržišnog pristupa u omogućavanju društvene reprodukcije. Postoji argument da je potreban novi socijalni ugovor koji omogućava tržišni pristup, ali istovremeno osigurava pravedne nagrade za društvenu reprodukciju. Stoga, iako postoji niz inicijativa javnih politika koje bi se mogle koristiti za rješavanje vrlo niskog fertiliteta, uspješna politika gotovo sigurno treba uključivati promjene u društvenoj i ekonomskoj organizaciji u znatno većem rasponu. Ove promjene moraju uključivati oživljavanje koncepta horizontalne pravednosti. Drugim riječima, uzimajući u obzir potencijal za zarađivanje prihoda, društvo mora pokušati izjednačiti ekonomske rezultate prilagođene za različite obiteljske konfiguracije. To je ekvivalentno snažnoj tvrdnji da su djeca društveno dobro, a ne samo privatno i opcionalno zadovoljstvo.

U kontekstu pravednosti, razlikuju se načelo horizontalne i vertikalne pravednosti. „Načelo horizontalne pravednosti bi značilo da treba postojati redistribucija od kućanstava bez djece prema onima s djecom jer bi u suprotnom kućanstvo bez djece, jednakog predfiskalnog dohotka kao i kućanstvo s djecom, imalo bolji životni standard“ (Pezer, 2020: 23).

S druge strane, vertikalna pravednost odnosi se na načelo da različiti slučajevi trebaju biti tretirani različito, ovisno o njihovim različitim potrebama i mogućnostima. Vertikalna pravednost usmjerava se na osiguranje da obitelji s djecom koje su u većoj financijskoj potrebi primaju više potpora kako bi im se osigurala odgovarajuća pomoć i podrška. To znači da bi obitelji s nižim prihodima i većim potrebama trebale primati veće potpore u usporedbi s obiteljima s višim prihodima i manjim potrebama. Načelo vertikalne pravednosti može se primijeniti i kod redovnih novčanih isplata za djecu, ako su isplate uvjetovane visinom dohotka, tj. ako se smanjuju ili ukidaju kako dohodak raste. Treba napomenuti, međutim, da isplate sukladno visini dohotka mogu djelovati kao sredstvo koje smanjuje želju za radom kod drugih članova obitelji, što pak može biti sredstvo koje smanjuje želju za rađanjem djece.

Na temelju iznesenih istraživačkih spoznaja može se zaključiti da niz relevantnih čimbenika treba uzeti u obzir prilikom kreiranja mjera javnih politika kako bi se povećale stope fertiliteta.

4.3.1.3. Pozadinski čimbenici

Pozadinski čimbenici u Teoriji planiranog ponašanja „mogu indirektno utjecati na namjere i ponašanja utječući na uvjerenja koja dovode do stava, subjektivnih normi i percipirane kontrole ponašanja“ (Ajzen i Klobas, 2013: 212). Tako Ciritel i sur. (2019) navode da su pozadinski čimbenici podijeljeni u tri grupe: i) individualni, ii) društveni i iii) informacijski čimbenici. Osim karakteristika osobnosti, općih životnih vrijednosti te osobnih stavova prema rodnim ulogama i demografski čimbenici kao što su dob, spol i obrazovanje igraju važnu ulogu u određivanju pozadinskih čimbenika. Individualni aspekti mogu biti pod utjecajem društvenih normi, poput očekivanja o pravilnoj dobi za roditeljstvo kod žena i muškaraca. Nacionalne i regionalne kulturne vrijednosti te institucionalni okvir, uključujući političko i ekonomsko okruženje, također imaju značajan utjecaj na ove pozadinske čimbenike (Fishbein, 1972; Ajzen i Klobas, 2013). Uz neizravni utjecaj, dokazan je i izravni utjecaj pozadinskih čimbenika na namjeru rađanja (Ciritel i sur., 2019; Billari i sur. 2009; Mencarini i sur., 2015; Philipov i sur., 2015).

Na primjer, Billari i sur. (2009) procijenili su ne samo posredni učinak pozadinskih čimbenika na namjere kroz stavove, subjektivne norme i percipiranu kontrolu ponašanja, već i izravni učinak tih čimbenika na namjere plodnosti. Dokazujući time izravne učinke demografskih i socioekonomskih karakteristika pojedinaca na namjere rađanja. Dommermuth i sur. (2011) zauzeli su sličan pristup i procijenili izravan učinak i objektivnih socio-ekonomskih i demografskih karakteristika pojedinaca (pozadinskih čimbenika) na vrijeme namjere da imaju prvo ili drugo dijete u Norveškoj.

S ekonomskog aspekta, a u skladu s prethodnim istraživanjima (Riederer i Buber-Ennser, 2019; Ciritel i sur., 2019; Kulu, 2013; De Beer i Deerenberg, 2007; Hank, 2001) kao pozadinski čimbenik u analizu čimbenika koji utječu na namjeru rađanja uključuje se i regionalni razvojni kontekst kao utjecajni čimbenik namjere rađanja u ovom doktorskom radu. Naime, u istraživačkim studijama uočene su značajne varijacije u fertilitetu ovisno o mjestu stanovanja. Ovakav obrazac uočen je u Grčkoj (Nickayin i sur., 2022), Rumunjskoj (Ciritel i

sur., 2019), Velikoj Britaniji (Kulu i Washbrook, 2014), Sloveniji (Černič Istenič i Kveder, 2008), Škotskoj (Boyle i sur., 2007), nordijskim zemljama (Kulu i sur., 2007), Nizozemskoj (De Beer i Deerenberg, 2007), Austriji, Poljskoj (Kulu, 2006), Njemačkoj (Hank, 2001) i Francuskoj (Fagnani, 1991).

Nadalje, Myrskylä i sur. (2009) te Fox i sur. (2018) navode da je negativna povezanost fertiliteta s gospodarskim i društvenim razvojem postala jedna od najčvršće utvrđenih i općeprihvaćenih empirijskih pravilnosti u društvenim znanostima. Utjecaj regionalnog konteksta na namjeru rađanja potvrđuju i Ciritel i sur. (2019) i Jemna (2015).

Riederer i Buber-Ennser (2019) proučavali su ostvarenje kratkoročnih namjera rađanja muškaraca i žena u dobi od 18 do 45 godina analizirajući jesu li oni koji su željeli još jedno dijete unutar tri godine (u prvom valu istraživanja) ostvarili svoje namjere do drugog vala provedene Ankete o generaciji i spolu (engl. *Generation and Gender Survey, GGS*). Autori su analizu realizacije namjere rađanja proveli na temelju jedanaest europskih država podijeljenih u dvije skupine: i) kontinentalna zapadna Europa (Austrija, Francuska, Njemačka i Nizozemska) i ii) istočna Europa (Bugarska, Češka, Gruzija, Mađarska, Litva, Poljska i Rusija). Istraživanjem je obuhvaćeno 11 329 ispitanika u prvom valu, odnosno 10 137 ispitanika u drugom valu istraživanju. Rezultati logističke regresije ukazuju na značajnost regionalnog konteksta u namjeri rađanja i realizaciji same namjere. Naime, realizacija namjere rađanja niža je u urbanim nego u ruralnim regijama, dok je istodobno u urbanim regijama odgađanje rađanja puno češće u odnosu na ruralne regije. U zemljama zapadne Europe manja je realizacija namjere i veće odgađanje u gradovima nego u ruralnim područjima. Uzrok tomu može se pronaći u većem udjelu osoba u zreloj reproduktivnoj dobi, samaca i parova koji trenutno ne žive zajedno, a planiraju imati dijete, odnosno još jedno dijete, u bliskoj budućnosti. Autori navode da veće ekonomske mogućnosti u gradovima potiču odgađanje rađanja, dok kultura koja podržava zapošljavanje žena (više dječjih vrtića, više zaposlenih majki) potiče ostvarivanje željenih potomaka i istovremeno potiče odustajanje od namjere rađanja. Naposljetku, autori su došli i do zanimljivih uvida u razlike između zemalja zapadne i istočne Europe. U skladu s razlikama u karakteristikama konteksta (npr. veći udio osoba s ekonomskim teškoćama, niže razine povjerenja u druge) došli su do rezultata koji ukazuju na niže stope ostvarivanja namjere u zemljama istočne Europe. Dok sastav urbanih i ruralnih populacija može objasniti relevantan dio razlika između urbanih i ruralnih područja u ostvarivanju

namjere u zemljama zapadne Europe, razlike u kontekstu mogu biti glavni razlog za veće odgađanje namjere rađanja u gradovima istočne Europe.

Značajan utjecaj regionalnog konteksta na namjeru rađanja potvrđuju i Ciritel i sur., 2019). Autori su dokazali da se namjera rađanja drugog djeteta značajno razlikuje među razvojnim regijama, predstavljajući kulturne i socioekonomske podjele unutar teritorija Rumunjske. Ostali pozadinski čimbenici (spol, dob, status veze, obrazovanje) također su bili uključeni u analizu. Rezultati pokazuju da dob ima značajan učinak na namjeru rađanja i kod parova koji nemaju dijete i kod parova koji imaju jedno dijete. Uzimajući u obzir spol, muškarci koji nemaju djecu imaju manje izraženu želju za postati roditeljem u sljedeće tri godine, dok spol nije povezan s namjerom za roditelje koji već imaju jedno dijete. Status partnerskog odnosa značajan je samo za odrasle osobe koje nemaju djecu.

Empirijska istraživanja pokazala su da visoko obrazovane žene s boljim pozicijama na tržištu rada rađaju u starijoj dobi (Gustafsson i Wetzels, 2000; Prioux, 2004; Amuedo-Dorantes i Kimmel, 2005; Modena i Sabatini, 2012). Dob majke pri rođenju prvog djeteta može se promatrati kao rezultat kompromisa između ulaganja u ljudski kapital i planiranja karijere s jedne strane, i majčinstva s druge strane (Gustafsson, 2001). Učinak prihoda na vrijeme i broj rođenja može slijediti različite putanje. Gustafsson (2005) sugerira da za mlade Šveđanke svaka dodatna godina obrazovanja utječe na plodnost putem odgode formiranja stabilnog para, umjesto odgađanja roditeljstva nakon što se par formira. Amuedo-Dorantes i Kimmel (2005) tvrde da majke s fakultetskom diplomom mogu profitirati od odgađanja roditeljstva jer su u poziciji pregovarati o radnom okruženju koje je prijateljsko i neformalno prema obitelji s fleksibilnim radnim vremenom.

Zaključno, natalitet značajno varira između urbano-ruralnih područja odgovarajući na društvene, političke, kulturne i teritorijalne pokretače promjena. Razlike se očituju i u veličini obitelji zbog dostupnosti posla i obrazovnog sustava, stoga je nužno u empirijsko istraživanje uključiti i niz pozadinskih čimbenika koji oblikuju namjeru rađanja, kao i njihove interakcije.

4.3.2. Usklađivanje obiteljskog i poslovnog života žena

Obrasci ponašanja muškaraca i žena na tržištu rada nisu samo odraz ekonomske situacije, kulturnog konteksta i individualnih uvjerenja. Oni su također rezultat postojećih institucionalnih okvira i aktivnosti u području socijalnih politika što u velikoj mjeri ima uvjetovanje utjecaja na oblikovanje ponašanja. Posebno su važne politike koje usklađuju obiteljske obveze s plaćenim radom, što postaje sve češće područje intervencije u mnogim zemljama. Dok su u početku politike usklađivanja obiteljskih obveza i plaćenog rada bile usmjerene isključivo na poticanje zapošljavanja žena i jačanje njihove povezanosti s tržištem rada, danas se u okvirima ciljeva postavljaju šire funkcije, ali i očekivanja. Sada se vjeruje da dodatna ulaganja u mjere na tom području mogu imati pozitivne učinke i na druge aspekte s kojima se suvremene socijalne države suočavaju. To podrazumijeva smanjenje dječjeg siromaštva i ublažavanje njegovih posljedica, unaprjeđenje obrazovnih postignuća kroz dodatna ulaganja u ljudski kapital, promicanje rodne ravnopravnosti, smanjivanje društvenih nejednakosti, smanjenje demografskih pritisaka te jačanje dugoročne održivosti sustava socijalnog osiguranja (Hegewisch i Gornick, 2011). Upravo iz tog razloga politike usklađivanja obiteljskih obveza i plaćenog rada dobivaju na sve većem značaju u europskim državama. Osim toga, Europska unija potiče zemlje članice na dodatna ulaganja u politike usklađivanja obiteljskih obveza i plaćenog rada (Europska komisija, 2013).

Preporuke o trajanju roditeljskog dopusta variraju od šest mjeseci do tri godine djetetova života, ovisno o različitim čimbenicima. Optimalna duljina dopusta ovisi o specifičnostima radnog mjesta, mogućnostima rada na skraćeno radno vrijeme, dostupnosti i pristupačnosti formalnih opcija skrbi za djecu te podršci unutar obitelji, poput brige baka i djedova, ali i osobnim preferencijama. Zbog toga europske zemlje sve više uvode fleksibilne sustave roditeljskog dopusta u sljedećim oblicima:

- „mogućnost uzimanja dopusta na puno radno vrijeme ili na nepuno radno vrijeme (tj. da roditelji mogu kombinirati nepuno radno vrijeme s nepunim dopustom)
- mogućnost uzimanja dopusta u jednom, neprekinutom bloku ili u nekoliko kraćih blokova
- mogućnost uzimanja duljih razdoblja dopusta s nižim naknadama ili kraćih razdoblja s višim naknadama
- mogućnost prijenosa prava na dopust skrbnicima koji nisu roditelji

- mogućnost korištenja cijelog ili dijela dopusta kada roditelji to odaberu, do određene dobi djeteta
- dodatni dopust u slučaju višestrukih rođenja ili, u nekim slučajevima, drugih okolnosti
- mogućnost da oba roditelja uzmu sve ili dio dopusta istovremeno“ (Središnji državni ured za demografiju i mlade, 2024: 27-28).

Roditeljski dopusti trebali bi biti usklađeni s dostupnošću sustava javne skrbi za djecu, osiguravajući kontinuiranu podršku roditeljima nakon povratka na posao. To znači da bi roditelj, po završetku dopusta, trebao imati pristup kvalitetnim opcijama skrbi za djecu. Nedostatak takvih opcija često otežava roditeljima povratak na posao ili ih prisiljava da ga odgađaju. Dugotrajni roditeljski dopust, poput trogodišnjeg, pomaže mnogim obiteljima, posebno tamo gdje je skrb o djeci ograničena. No, istovremeno se kritizira jer može negativno utjecati na zapošljivost žena, smanjenje njihovih prihoda i mirovinskih prava, kao i na ravnopravnost spolova. S obzirom na to da žene češće koriste roditeljski dopust u Hrvatskoj, to dovodi do diskriminacije na tržištu rada. Da bi se postigla ravnoteža, potrebno je procijeniti optimalno trajanje dopusta, njegov učinak na dobrobit djece i položaj žena na tržištu rada, kao i povezanost s formalnom skrbi za djecu te mogućnosti financiranja takvog sustava.

U ekonomiji se pojavljuju dvije suprotstavljene teorije koje objašnjavaju odnos između promjena u fertilitetu i sudjelovanja žena u radnoj snazi (Engelhardt i Prskawetz, 2004: 40): model Nove ekonomije kućanstva (engl. New *Home Economics model*) i Easterlinov model (engl. *Easterlin model*). Oba pristupa nastoje ponuditi objašnjenja za negativan odnos između sudjelovanja žena u radnoj snazi i fertiliteta, međutim razlikuju se u identificiranju pokretačke snage (Sanderson, 1976 u Engelhardt i Prskawetz, 2004): model „vrijednosti vremena“ (engl. *value of time model*) i model „relativnog prihoda“ (engl. *relative income model*). Nova ekonomija kućanstva prvenstveno se odnosi na promjene u vrijednosti vremena žena, dok se Easterlinov model usredotočuje na promjene u relativnom prihodu zbog demografskog ciklusa (engl. *baby boom* i *baby bust*). Hipoteza „nespojivosti uloga“, koja je istaknuta u sociološkoj i demografskoj literaturi i polazi od toga da su odgovori na društvenoj razini olakšali nespojivost između odgoja djece i ženskog zaposlenja. Međutim, hipoteza koja dobiva na važnosti za objašnjenje niskih razina fertiliteta koje idu zajedno s najnižim razinama sudjelovanja žena na

radnoj snazi temelji se na ideološkim čimbenicima koji obuhvaćaju društvene norme prema obiteljskim strukturama.

S ekonomskog gledišta, sukladno Becker (1993) očekuje se da će sve veća uloga žena na tržištu rada povećati oportunitetne troškove rađanja i time smanjiti fertilitet na makrorazini. Međutim, posljednjih desetljeća došlo je do promjena na tržištu rada u namjeri usklađivanja poslovnih i obiteljskih obveza. Navedene promjene uzrokovale su promjenu u odnosu između ishoda na tržištu rada i fertiliteta na makrorazini (Modena i sur., 2014). Krajem 1980-ih korelacija između sudjelovanja na tržištu rada i fertiliteta postala je pozitivna u zemljama OECD-a (Oshio, 2019; Mira i Ahn, 2002; Engelhardt i Prskawetz, 2004; Rindfuss i sur., 2003; Brewster i Rindfuss, 2000). Neki znanstvenici smatraju da je do smanjenja jaza između majčinstva i sudjelovanja na tržištu rada posljedica povećanja dostupnosti usluga čuvanja djece, honorarnih poslova (Del Boca i sur., 2007; Mira i Ahn, 2002; Apps i Rees, 2001), kao i povećanje plaće (Ferrero Martinez i Iza, 2004; Mira i Ahn, 2002). Nadalje, rezultati istraživanja autorica Apps i Rees (2001) sugeriraju da će zemlje s individualnim, a ne zajedničkim oporezivanjem i koje podupiru obitelji kroz poboljšanu dostupnost skrbi za djecu, umjesto kroz izravna plaćanja djece, vjerojatno imati i veću ponudu ženske radne snage i veći fertilitet.

Promjene u prioritetima na području socijalnih politika, osobito politika usklađivanja obiteljskog i poslovnog života, nastale su uslijed povećanja dvostrukih hranitelja u obiteljima, kako u Republici Hrvatskoj, tako i u drugim europskim zemljama. U zemljama s liberalnim režimima primjetna je slaba intervencija u području obiteljskih politika te nedostatak mehanizama koji bi roditeljima olakšali balansiranje između obiteljskog i poslovnog života. U takvim okolnostima, majke se često suočavaju s prisilom da se povuku s tržišta rada. S druge strane, nordijske zemlje odlikuje defamilizacija/individualizam u obiteljskim politikama, pružajući veće mogućnosti za usklađivanje obiteljskih obaveza i plaćenog rada. To je posljedica dobro razvijenih sustava dopusta koji su usmjereni na oba roditelja, kao i razvijenih javnih usluga predškolskog odgoja i obrazovanja (Dobrotić, 2015).

Usklađivanje roditeljskih obaveza sa zaposlenjem na puno radno vrijeme i dalje predstavlja značajan izazov, osobito za žene (Thévenon, 2009). Radna okruženja prilagođena obiteljskim potrebama nude moguće rješenje, a postaju sve raširenija. Primjerice, u Europskoj uniji takva radna okruženja izravno podupire Direktiva EU-a o ravnoteži između poslovnog i privatnog života, koja je stupila na snagu 2019. godine. Pokazalo se da ovakvi programi

poboljšavaju ravnotežu između poslovnog i privatnog života zaposlenika, njihovu opću dobrobit te povećavaju vjerojatnost nastavka zaposlenja majki nakon rođenja djeteta (Chung, 2017).

Politike radnih mjesta prilagođenih obitelji mogu uključivati: fleksibilne radne aranžmane koji roditeljima omogućuju prilagodbu radnog vremena ili rad od kuće; dječje vrtiće u sklopu radnog mjesta i pomoć u organizaciji skrbi za djecu; rodiljni i očinski dopust uz punu naknadu plaće; zdravstvene pogodnosti za uzdržavane članove obitelji; pauze za dojenje te dopust za njegu bolesnog djeteta. Ipak, takve politike dostupne su premalom broju radnika na globalnoj razini (UNICEF, n.d.).

Povezanost politika usklađivanja obiteljskih obveza i plaćenog rada te sudjelovanja roditelja na tržištu rada izuzetno je kompleksna zbog raznolikosti mjera obuhvaćenih tim politikama. Navedene politike obuhvaćaju širok spektar mjera u okviru obiteljske politike, kao što su rodiljni i roditeljski dopusti, naknade, usluge za uzdržavane članove obitelji, ali i mjere na tržištu rada, uključujući fleksibilne mogućnosti poput djelomičnog radnog vremena, rada na daljinu te različite prilagodbe radnog vremena. Također, obuhvaćaju i mjere usmjerene ka postizanju rodne ravnopravnosti u javnom i privatnom sektoru (Lewis i Giullari, 2005; Dobrotić, 2015). Niska plodnost smatra se odgovorom na rodni jaz u radnom opterećenju koji se može pojaviti kada žene povećaju svoje sudjelovanje u radnoj snazi. Očekuje se da će se ovaj trend preokrenuti i da će se stope fertiliteta donekle povećati kada se muškarci više angažiraju u kućanstvu, a razlika u radnom opterećenju spolova se smanji (Lappegård, 2020). U kontekstu usklađivanja obiteljskog i poslovnog života žena, prethodna istraživanja uglavnom su usmjerena na učinke dopusta namijenjenih skrbi za djecu te dostupnosti institucija predškolskog odgoja i obrazovanja.

Provodeći bivarijatne korelacijske analize za 21 zemlju OECD-a, Castles (2003) je utvrdio statistički značajnu korelacijska povezanost između kompozitnog indeksa za usklađivanje posla i obiteljskog života i fertiliteta. Nadalje, Oshio (2019) je proveo istraživanje na 24 OECD zemlje, uzimajući u obzir žene starosti između 15 i 65 godina. Autor je potvrdio zaokret korelacijske povezanosti stope sudjelovanja ženske radne snage i totalne stope fertiliteta u proučavanim zemljama sredinom 1980-ih te time potvrdio činjenicu koja je već zamijećena u prethodnim istraživačkim studijama. Osim toga, došao je do važnog empirijskog zaključka da javna potrošnja za obitelji, posebno u obliku naknada u naravi, počinje rasti kada

stopa sudjelovanja ženske radne snage (engl. *Female labor force participation rate*) postane dovoljno visoka.

Daljnja istraživanja pokazuju da bi potpora koja omogućuje zaposlenim roditeljima da kombiniraju obiteljski i poslovni život također mogla imati veliki učinak, budući da pomaže smanjiti oportunitetne troškove djece do kojih dolazi kada roditelji, a posebno žene moraju napustiti plaćeni posao bi se posvetili brizi o djeci (Willis, 1973; Hotz i sur., 1997). Međutim, dopusti za skrb o djeci, koji obuhvaćaju rodiljne i roditeljske dopuste, omogućuju roditeljima privremeni izlazak s tržišta rada, čime izravno podržavaju roditeljsku skrb u ranom djetinjstvu i doprinose dobrobiti djeteta. „Pri tome samo dobro plaćeni dopusti kombinirani sa zaštitom zaposlenja omogućavaju zaposlenim roditeljima nesmetanu mogućnost korištenja tog prava. Štoviše, izdašnost je naknada za vrijeme trajanja dopusta (posebice roditeljskih) ključni čimbenik korištenja prava na dopuste te bitno određuje i stvarni učinak dopusta“ (Dobrotić, 2015).

Istraživanja ukazuju na pozitivnu povezanost plaćenih dopusta i sudjelovanja žena na tržištu rada, odnosno doprinos plaćenih dopusta većim stopama zaposlenosti žena (Ruhm, 1998; Thévenon i Solaz, 2013) i povećanju vjerojatnosti povratka žena kod istog poslodavca nakon rođenja djeteta (Hofferth i Curtin, 2003). Pozitivan učinak plaćenog dopusta na stopu zaposlenosti žena zabilježen je samo u slučaju plaćenog dopusta koje nije prelazilo dvije godine. Dodatni tjedni dopusta imaju negativan utjecaj na stopu zaposlenosti žena i razliku u zapošljavanju između spolova. Istraživačke spoznaje također pokazuju da tjedni plaćenog dopusta pozitivno utječu na prosječan broj radnih sati žena u usporedbi s muškarcima, uz uvjet da ukupno trajanje dopusta ne prelazi određene granice. Nasuprot tomu, pružanje plaćenog dopusta povećava rodni jaz u plaćama među zaposlenicima koji rade puno radno vrijeme (Thévenon i Solaz, 2013). Rezultati istraživanja Hofferth i Curtin (2003) također ukazuju na zaključak da pristup neplaćenom dopustu zaštićenom poslom potiče žene da ostanu kod svog poslodavca i uzmu kraći dopust umjesto da odu na duže razdoblje i iskoriste priliku da kasnije pronađu posao kod drugog poslodavca.

Dakle, jasno je kako dopust olakšava napuštanje tržišta rada i ostvarivanje prava na skrb o djetetu u prvim godinama života i kako olakšava usklađivanje obiteljskih obveza s plaćenim radom te je implicitno kako dopusti umjerenog trajanja jačaju vezu između roditelja (uglavnom žena) i tržišta rada. Isto tako, postoji vjerojatnost da će duži dopust imati nepovoljne

učinke koji pridonose rodnoj segregaciji na tržištu rada, bilo u smislu samog sudjelovanja na tržištu rada ili nekih njegovih karakteristika kao što su niže plaće, profesionalna segregacija ili sporije napredovanje u karijeri (osobito za žene s višim stupnjem obrazovanja). Dobrotić (2015) uzrok tomu pronalazi u brzom razvoju tehnologije i sve većem značaju stalnih ulaganja u ljudski kapital kako bi se sačuvala konkurentnost na tržištu rada. S obzirom na rezultate koji su predstavljeni i perspektivu s visokom povezanošću s tržištem rada, umjereno dugotrajni dopusti smatraju se najboljom opcijom za roditelje u tom pogledu jer minimiziraju negativne učinke na znanje, iskustvo i vještine te tako oportunitetno pozitivno utječe na buduće karijere i plaće.

Posljednja dva desetljeća u velikoj mjeri dolazi do revidiranja aktivnosti institucija tržišta rada kako bi se ženama olakšalo spajanje karijere i obitelji, što je uzrokovalo promjenu u odnosu između ishoda na tržištu rada i plodnosti na makrorazini (Modena i sur., 2014). Korelacija između sudjelovanja žena u radnoj snazi i plodnosti, koja je bila negativna od 1970-ih, postala je pozitivna krajem 1980-ih u zemljama OECD-a (Ahn i Mira, 2002; Morgan, 2003; Engelhardt i Prskawetz, 2004). Taj se pomak objašnjava kao rezultat sve veće dostupnosti usluga skrbi o djeci i poslova s nepunim radnim vremenom (Del Boca i Locatelli, 2006; Del Boca i sur., 2007). Razvoj institucija predškolskog odgoja i obrazovanja omogućava sudjelovanje roditelja na tržištu rada te doprinosi i pomaže usklađivanju obiteljskog i poslovnog života. Javno financiranje i sufinanciranje ustanova skrbi za djecu omogućuje roditeljima veći raspoloživi dohodak i olakšava odgoj djece (Gornick i Meyers, 2004). Istraživanja pokazuju da upravo zemlje s razvijenijim i dostupnijim sustavima predškolskog odgoja i obrazovanja bilježe više stope participacije žena na tržištu rada (Anukriti i sur., 2023; Halim i sur., 2023; Olivetti i Petrongolo, 2017; Del Boca i sur., 2008). Tako na primjer nordijske zemlje primjenjuju velikodušnije sustave zaštite kako bi se uskladilo majčinstvo s poslom, a usluge skrbi o djeci i poslovi s nepunim radnim vremenom postali su sve dostupniji (Engelhardt i Prskawetz, 2004; Del Boca i Sauer, 2009).

Tablica 9. prikazuje postotak zaposlenosti žena, ukupne stope fertiliteta i starost majke pri prvom porodu uspoređujući 2013. godinu i 2021. godinu u odabranim europskim zemljama

Tablica 9. Zaposlenost žena, stopa fertiliteta i starost majke pri prvom porodu

	% zaposlenih žena[11]		ukupna stopa fertiliteta		starost majke pri prvom porodu	
	2013.	**2021.**	**2013.**	**2021.**	**2013.**	**2021.**
EU – 27 zemalja (od 2020.)	**61,1**	69,2	**1,51**	**1,53**	**28,8**	**29,7**
europodručje – 20 zemalja	**61,9**	68,9	n. p.	**1,52**	n. p.	**30**
Belgija	62,1	68,1	1,76	1,60	28,5	29,5
Bugarska	60,2	72,1	1,48	1,58	25,7	26,5
Češka	63,8	73,7	1,46	1,83	28,1	28,8
Danska	71,2	77,4	1,67	1,72	29	30
Njemačka	71,5	76,7	1,42	1,58	29,3	30,1
Estonija	71,6	80,4	1,52	1,61	26,5	28,5
Irska	61,2	72,6	1,93	1,78	29,6	31,2
Grčka	42,9	55,9	1,29	1,43	29,9	31
Španjolska	53,8	63,7	1,27	1,19	30,4	31,6
Francuska	66,4	71,2	1,99	1,84	28,1	29,1
Hrvatska	**52,8**	**65,5**	**1,46**	**1,58**	**28**	**29,2**
Italija	49,6	55,0	1,39	1,25	30,6	31,6
Cipar	62,2	72,1	1,3	1,39	29	30,3
Latvija	67,5	75,5	1,52	1,57	26,1	27,7
Litva	68,6	78,6	1,59	1,36	26,7	28,3
Luksemburg	63,9	71,5	1,55	1,38	30	31,3
Mađarska	61,2	75,3	1,35	1,61	27,7	28,6
Malta	51,7	72,9	1,36	1,13	28,4	29,5
Nizozemska	71,7	79,0	1,68	1,62	29,4	30,3
Austrija	70,0	73,4	1,44	1,48	28,8	29,9
Poljska	56,3	70,3	1,29	1,33	26,7	28,1
Portugal	60,5	74,3	1,21	1,35	28,9	30,4
Rumunjska	48,2	59,1	1,46	1,81	25,9	27,1
Slovenija	62,6	74,3	1,55	1,64	28,5	29
Slovačka	62,0	72,6	1,34	1,63	26,9	27,3
Finska	71,0	77,8	1,75	1,46	28,5	29,8
Švedska	76,4	79,1	1,89	1,67	29,1	29,8
Island	79,5	82,1	1,93	1,82	27,4	28,6
Norveška	78,4	78,0	1,78	1,55	28,6	30
Švicarska	75,3	78,4	1,52	1,52	30,4	31,2
Srbija	44,3	61,8	1,43	1,52	27,3	28,1

Izvor: izrada doktorandice (Eurostat, 2024a)

U gotovo svim promatranim zemljama, izuzev Norveške, došlo je do porasta udjela žena koje su aktivne na tržištu rada tijekom 2021. godine u odnosu na 2013. godinu. Osim toga,

[11] Ukupno zaposlene žene, % od ukupne populacije (starosti od 20 do 64 godine).

statistički podatci pokazuju da je došlo i do promjena u ukupnoj stopi fertiliteta tijekom 2021. u odnosu na 2013. godinu, pri čemu najveći pad ukupne stope fertiliteta bilježi Finska tijekom 2021. godine u odnosu na 2013. godinu (za 0,29). S druge strane, najveći porast ukupne stope fertiliteta bilježi Češka (0,37). Prosječna starost majke pri prvom porodu na razini svih zemalja članica Europske unije porasla je za 0,9 godina u 2021. godini u odnosu na 2013. godinu i ona iznosi 29,7 godina. Promatrajući članice europodručja, prosječna starost majke pri prvom porodu tijekom 2021. godine je bila 30 godina. Najveći porast u odgađanju rađanja prvog djeteta, za čak dvije godine (s 26,5 godine u 2013. godini na 28,5 godina u 2021. godini) bilježi Estonija. Kod svih ostalih promatranih zemalja bilježi se negativan trend i može se zaključiti da porastom zaposlenosti žena raste starosna dob za rađanje prvog djeteta, tj. dolazi do odgađanja rađanja prvog djeteta.

Prema podatcima Eurostata (2023n), stopa zaposlenosti žena u dobi od 20 do 64 godine u Europskoj uniji tijekom 2021. godine i dalje je za 10,8 postotnih bodova niža od stope zaposlenosti muškaraca. Žene češće rade nepuno radno vrijeme, unatoč tomu što su često visokoobrazovanije od muškaraca. U Republici Hrvatskoj, razlika u stopi zaposlenosti žena i muškaraca iznosi devet postotnih bodova. Povećanje zaposlenosti žena moguće je kroz mjere koje promiču ravnopravnu participaciju žena i muškaraca u plaćenom i neplaćenom obiteljskom radu, uključujući podršku pojedincima i obiteljima u postizanju bolje ravnoteže između poslovnog i privatnog života. Unapređenje rodne ravnopravnosti na tržištu rada i smanjenje rodno uvjetovanih nejednakosti moglo bi potaknuti veće uključivanje muškaraca u kućanske poslove i brigu o obitelji, osobito ako se takvi napori kombiniraju sa strukturnim reformama poreznog i socijalnog sustava. Ključne mjere u tom smjeru već su definirane u Strategiji Europske unije za rodnu ravnopravnost za razdoblje 2020. – 2025. godine.

Kompleksnost usklađivanja obiteljskog i poslovnog života očituje se kroz sveobuhvatan pristup obiteljskih politika koje bi istodobno trebale obuhvatiti financijske učinke rađanja djece, skrb o djeci u ranoj dobi, obrazovanje u ranom djetinjstvu te uređenje radnog vremena. Obiteljske politike sastoje se od kombinacija politika koje se međusobno nadopunjuju i međusobno djeluju. Stoga se prilikom evaluacije treba uzeti u obzir cijeli paket mjera zajedno (Letablier i sur., 2009). Na temelju prethodnih istraživačkih spoznaja, može se zaključiti da zemlje s razvijenijim politikama usklađivanja obiteljskog i poslovnog života koje karakteriziraju plaćeni dopusti i dostupnost ustanova predškolskog odgoja i obrazovanja doprinose većem zapošljavanju žena u odnosu na zemlje koje primjenjuju politike dopusta

dužeg trajanja praćenih niskim naknadama i odsustvom usluga predškolskog odgoja i obrazovanja.

4.3.3. Odgađanje rađanja i fertilni jaz

Društvene promjene koje su se dogodile u srednjoj i istočnoj Europi tijekom 1990-ih i 2000-ih godina pokrenule su brze demografske promjene, posebno u pogledu ponašanja u rađanju djece (Basten i Frejka, 2015). Došlo je do intenzivnijeg odgađanja stupanja u brak i rađanja, a posljedično i do smanjenja stopa fertiliteta.

Kako je već prethodno navedeno, razlozi za smanjenje fertiliteta nisu jednoznačni, ali prema Letablier i sur. (2009), odgađanje rađanja smatra se jednim od uzroka. Međutim, nije potpuno jasno je li odgađanje rađanja dovelo do smanjenja ukupnog broja rođene djece ili je imalo temporalni učinak. Analiza dobno-specifičnih stopa fertiliteta sugerira da bi temporalni faktor mogao biti ključan u određivanju razine plodnosti. Unatoč tomu, stope fertiliteta kod žena mlađih od 30 godina neprestano opadaju posljednjih desetljeća i nastavljaju padati u većini država članica Europske unije, dok plodnost nakon 30. godine raste, što ukazuje na to da mnoge žene odgađaju trenutak postajanja majkama. Porast stopa plodnosti u starijim dobima ubrzao se u nekim zemljama poput Francuske od početka 2000-ih godina (Prioux, 2007), dok se smanjenje u mlađim dobima usporilo u mnogim državama članicama i čak zaustavilo u nekim zemljama. Kombinacija ovih dvaju trendova objašnjava zašto se smanjenje ukupnih stopa plodnosti usporilo u nekim zemljama ili čak preokrenulo u povećanje, što sugerira da stabilizacija ili porast u stopama plodnosti mogu proizaći iz efekta „nadoknađivanja“ od strane žena koje su odgodile rađanje umjesto da su potpuno odustale od majčinstva.

Široko je rasprostranjeno mišljenje da što žena duže odgađa rađanje, to je niža njezina završena plodnost[12] (Marini i Hodsdon, 1981; Billari i Kohler, 2002). Ovaj fenomen, koji se naziva efektom odgode, pripisuje se poboljšanju razine obrazovanja i zaposlenosti žena, odgađanju u formiranju obitelji (Kohler i sur., 2002; D'Addio i D'Ercole, 2005) te promjenama u vrijednostima koje dijele mlađe žene o njihovoj ulozi u obitelji i na tržištu rada (McDonald, 2000; Kertzer i sur., 2009). Uz to, dob napuštanja roditeljskog doma snažno je povezana s

[12] Ukupan broj djece koje je žena rodila do kraja svog fertilnog razdoblja.

plodnošću, odnosno, odgoda o napuštanju roditeljskog doma dovodi do smanjenja broja djece (Kohler i sur., 2002; Becker i sur., 2010).

Važno je napomenuti kako su određeni znanstvenici istaknuli činjenicu da je 1970-ih godina postojala značajna i pozitivna korelacija između sudjelovanja žena u radnoj snazi i odgađanja rađanja u zemljama OECD-a, što je zauzvrat dovelo do pada stopa plodnosti (Ahn i Mira, 2002; Adsera, 2004), uglavnom zbog povećanja razine obrazovanja i zaposlenosti žena. Novija literatura naglašava ulogu „fleksibilnog“ zapošljavanja u odgađanju rađanja (McDonald, 2000; Adsera, 2004; Blossfeld i sur., 2005; Scherer, 2009; Hondroyiannis, 2010; Kreyenfeld i sur., 2012). Osim toga, žene koje imaju ugovor na određeno vrijeme odgađaju odluku o majčinstvu (Rica i Iza, 2005; Vignoli i sur., 2012). Kako je već prethodno navedeno, ekonomska nesigurnost i neizvjesnost u literaturi su identificirane kao ključni čimbenici koji utječu na odgađanje rađanja (Kreyenfeld, 2010) i dovode do smanjenja stopa fertiliteta (Koahler i sur., 2002). Nizak stupanj bogatstva kućanstva značajno i pozitivno utječe na odluku o odgađanju rađanja prvog djeteta (Modena i sur., 2014).

Nemogućnost potpune kontrole i prisutna neizvjesnost u vezi s odlukama o začeću, sklapanju i razvodu braka, financijskim pitanjima, promjenama na tržištu rada te drugim promjenljivim faktorima utječu na odluku parova o tome hoće li imati dijete i kada (Norling, 2021; Heckman i Willis, 1976). S obzirom na to da ovi čimbenici često sprječavaju ljude da precizno predviđaju stvarni broj djece u odnosu na onaj koji izražavaju kao svoju namjeru, često se javlja jaz između željenog i stvarnog broja djece (Bachrach i Morgan, 2013). Chesnais (1999) upotrebljava pojam „fertilni jaz” (engl. *Fertility gap*) za označavanje znatne razlike između stvarne stope fertiliteta i željenog broja djece. Nadalje, današnje društvo karakteriziraju ogromne i brze promjene, nestalne karijere, rodna diskriminacija, nepravde i nejednakosti. Diskriminacija uključuje profesionalnu i obrazovnu segregaciju, rodni jaz u plaćama, stereotipne rodne uloge i društvena očekivanja. U tom kontekstu sve su prisutnije niže stope fertiliteta i time se stvara sve veći fertilni jaz.

Razumijevanje jaza između željene veličine obitelji i stvarnog fertiliteta važno je jer je usredotočeno na razloge koji stoje iza nemogućnosti žena da postignu željeni broj djece. Osim toga, utvrđivanje razloga fertilnog jaza može pridonijeti ciljanom djelovanju ka otklanjanju fertilnog jaza kroz javne politike i programske intervencije. Jaz između željenog broja djece i

stvarnog broja jedan je od temeljnih izazova za tvorce javnih politika koji nastoje omogućiti parovima da ostvare željeni broj djece (Philipov, 2009).

Camussi i sur. (2023) istraživali su percepcije 835 žena u Italiji o želji za majčinstvom i povezanim poteškoćama koje dovode do fertilnog jaza. Rezultati istraživanja ukazuju na značajnu razliku između broja djece koju žene realno planiraju i idealnog broja djece koju bi željele. Postojanost rodnih stereotipa u ženskoj i muškoj populaciji, prisutnost rodnog nasilja, niska zastupljenost žena na tržištu rada, nedostatak socijalne infrastrukture te ustrajnost modela obiteljske dobrobiti koji rasterećuje život žene, uzrokuju razne negativne posljedice. Te posljedice uključuju dobrovoljno odricanje od plaćenog rada, kao i razliku između željenog i ostvarenog broja djece. Kao što pokazuju rezultati ove studije, željeni broj od dvoje djece u Italiji nije postignut, a čest uzrok očituje se u lošim društvenim i ekonomskim uvjetima.

Prethodna istraživanja pokazala su da ekonomska nesigurnost, u smislu nesigurnosti posla, prihoda i neadekvatnih stambenih uvjeta, utječe na negativan jaz između željenog i ostvarenog broja djece (Beaujouan, i Berghammer, 2019; Adsera, 2006; Ahn i Mira, 2001; Gutiérrez-Domènech, 2006; Abbasi-Shavazi i Khani, 2014).

Istraživanje (Norling, 2021) provedeno među uzorkom žena bez djece u dobi od 18 do 44 godine (u trenutku provođenja longitudinalnog istraživanja *Panel Study of Income Dynamics* 1985. godine) pokazalo je da je prosječni planirani broj buduće djece iznosio 1,44, ali ukupno žene u prosjeku imaju samo 0,99 djece. Autorica navodi da je planirani broj djece među promatranim ženama znatno niži u odnosu na stvarni broj zbog neplodnosti, nemogućnosti pronalaženja odgovarajućeg partnera ili drugih okolnosti koje mogu spriječiti osobu koja namjerava imati dijete da to i učini, no iskustvo odgajanja prvog djeteta može utjecati na želju roditelja za drugim djetetom.

Prema istraživanju Eurobarometer (engl. *Childbearing Preferences and Family Issues in Europe*) iz 2006. godine, prisutnost partnera koji pruža podršku najvažniji je čimbenik u odlukama o rađanju, s druge strane nedostatak pravog partnera za odgoj djece najčešći je razlog koji su ispitanici naveli za neispunjenje želja za brojem djece. Visoki troškovi uzdržavanja djece i financijski problemi pokazali su se kao važni razlozi glede stvaranja jaza između željenog i ostvarenog broja djece.

Uzročnike jaza između željenog i ostvarenog broja djece među ženama u Španjolskoj na temelju Španjolske ankete o plodnosti (engl. *Spanish Fertility Surveys*) iz 1985. i 1999. godine proučavala je Adsera (2006). Analiza provedenog istraživanja obuhvaćala je ukupno 9542 udane žene (5220 iz 1985. godine i 4322 žene iz 1999. godine) starosti između 15 i 49 godina. Rezultati regresijske analize upućuju na zaključak da su ekonomski uvjeti i nezaposlenost snažni čimbenici razlike između željenog i stvarnog fertiliteta. Nadalje, žene koje su bile zaposlene u javnom sektoru lakše su se suočile s ravnotežom između poslovnog i privatnog života te postizanjem željenog fertiliteta. Razlika između željenog i stvarnog fertiliteta kod zaposlenih žena u javnom sektoru slična je veličini razlike kod žena koje nisu zaposlene i manja je od razlike kod žena u privatnom sektoru. Dodatni rezultati ukazuju na to da privremeni ugovori povećavaju nesigurnost žena i doprinose tomu da zaposlenost stvara prepreke za ostvarenje očekivanog fertiliteta žena. Na koncu, autorica zaključuje da je nezaposlenost u Španjolskoj tijekom posljednja dva desetljeća uvelike povećala ekonomsku neizvjesnost mladih skupina i rezultirala odgađanjem rađanja.

Do sličnih zaključaka o odgađanju i ograničavanju rađanja među Španjolcima, kao odgovor na negativan učinak na dohodak zbog visoke i stalne stope nezaposlenosti u zemlji od ranih 1980-ih, došli su autori Ahn i Mira (2001) i Gutiérrez-Domènech (2006).

Rezultati istraživanja Golub i sur. (2023) ukazuju na postojeće poteškoće u ostvarivanju željene veličine obitelji zbog socio-demografskih čimbenika koji snažno utječu na odluke o rađanju željenog broja djece. Autorice Beaujouan i Berghammer (2019) istraživale su jaz između željenog i ostvarenog broja djece među ženama u Europi i SAD-u. U svim zemljama, žene su u prosjeku imale manje djece nego što su očekivale, a češće nego što su planirale ostale su bez djece. Najveći jaz uočen je u zemljama južne Europe - više od 0,6 djece po ženi u Italiji, Grčkoj i Španjolskoj. Regionalni kontekst, obrazovanje, norme o roditeljstvu, politike usklađivanja rada i obitelji, loša ekonomska situacija i nezaposlenost predstavljaju čimbenike koji oblikuju ciljeve fertiliteta žena, ukupnu obiteljsku veličinu i jaz između njih.

Panel istraživanje u Mađarskoj proveli su autori Spéder i Kapitány (2009) kako bi analizirali namjere ispitanika starosti od 18 do 39 godina (n = 4 471) da imaju dijete unutar 3 godine, na temelju usporedbe iskazane namjere rađanja zabilježene tijekom prvog vala istraživanja 2001./2002. godine (engl. *Turning Points of the Life Course*) i stvarnog ishoda tijekom drugog vala istraživanja 2004./2005. godine. Istraživački rezultati pokazuju da su

među čimbenicima koji objašnjavaju ostvarenje, odgađanje ili odustajanje od namjere rađanja demografske osobne karakteristike kao što su dob, partnerski status i paritet. Među strukturnim čimbenicima autori ističu važnost radnog statusa, dok među čimbenicima stava ističu zadovoljstvo životom koje pridonosi ostvarenju namjere za rađanjem djeteta.

Istraživanje ukupnog jaza između željenog i ostvarenog broja djece u 19 europskih država i SAD – u autorica Beaujouan i Berghammer (2017) ukazuje na značajne spoznaje o fertilnom jazu. Naime, istraživanje su temeljile na kohortnom modelu, uspoređujući prosječan broj željene djece među mladim ženama u dobi od 20 do 24 godine (rođenih početkom sedamdesetih godina) isto je mjereno tijekom devedesetih godina u Istraživanjima plodnosti i obitelji i sadrži podatke o završenoj plodnosti u istim kohortama oko dobi od 40 godina. Istraživanje se temelji na kognitivno-društvenom modelu namjera o plodnosti koji su razvili Bachrach i Morgan (2013). Rezultati ukazuju na to da su žene u prosjeku, u usporedbi s ranijim očekivanjima i namjerama, imale manje djece i češće su ostajale bez djece. Fertilni jazovi razlikovali su se prema zemlji i razini obrazovanja. Rezultati otkrivaju jasne regionalne obrasce, koji su najuočljiviji kod bezdjetnosti[13]. Jaz između željene i stvarne bezdjetnosti najširi je u južnoeuropskim i njemačko-govornim zemljama, a najmanji u srednjoeuropskim i istočnoeuropskim zemljama. Iako su tradicionalno veličine obitelji rezultirale visokim namjerama za plodnost, nestabilni uvjeti na tržištu rada i nedostatak podrške usklađivanju rada i obiteljskog života spriječili su žene da ostvare ove namjere. U većini europskih zemalja, najveći jazovi pronađeni su među visokoobrazovanim ženama. Razlike među zemljama sugeriraju da kontekstualni faktori kao što su norme o roditeljstvu, politike rada i obitelji, nezaposlenost oblikuju ciljeve žena u vezi s plodnosti, ukupnu veličinu obitelji i jaz između njih.

Prema Bachrachu i Morganu (2013) za bolje razumijevanje fertilnog jaza ključno je istražiti odnos s ekonomskim i društvenim čimbenicima zemlje. Jednako je važno uzeti u obzir i konkurentne ciljeve (obrazovanje, posao i slobodno vrijeme) i nepovoljnih okolnosti u vidu stope nezaposlenosti (Bongaarts, 2001). Smanjenje nataliteta predstavlja značajne izazove sadašnjoj i budućoj održivosti fertiliteta. Rješavanje problema niskih stopa fertiliteta i fertilnog jaza od središnje je važnosti i za politiku Europske unije o održivosti, o čemu svjedoči objavljivanje Zelene knjige o starenju (Europska komisija, 2021).

[13] Prema Hrvatskom jezičnom portalu, bezdjetnost se definira kao stanje (braka) bez djece, neimanje djece.

Kako je već ranije spomenuto, mjere obiteljske politike pokušavaju neutralizirati ili barem smanjiti negativan utjecaj psiholoških, socijalnih i ekonomskih ograničenja i prepreka za osnivanje obitelji, kao i jaz između željenog i ostvarenog broja djece (Stropnik, 1995; Goldstein i sur., 2003). Upravo financijska sredstva u obliku novčanih potpora pomažu neutralizirati negativan utjecaj ekonomskih ograničenja.

4.4. Fiskalni instrumenti u domeni socijalne politike u Republici Hrvatskoj i zemljama članicama Europske unije

Ovo potpoglavlje usredotočuje se na izravne i neizravne novčane transfere te transfere u naravi i subvencije, kao i njihov utjecaj na fertilitet. Posebna pažnja posvećena je analizi različitih oblika financijske podrške koje države pružaju obiteljima s djecom, uključujući dječje doplatke, rodiljne i roditeljske naknade te porezne olakšice za obitelji. Uz to, istražuje se uloga subvencioniranih usluga kao što su vrtići, troškovi obrazovanja, prijevoz itd., a koje mogu značajno utjecati na odluku obitelji o broju djece. Usporedba između Hrvatske i drugih zemalja članica Europske unije omogućava uvid u različite pristupe i njihove učinke na demografske trendove.

Izravni novčani transferi su oblici financijske potpore koji se dodjeljuju obiteljima s djecom putem izravnih isplata novca. Novac izravno dolazi iz državnog proračuna ili drugih javnih fondova i prenosi se izravno na obitelji.

Izravne novčane transfere čine:

- doplatci za djecu
- jednokratne novčane potpore za novorođeno dijete
- zajamčena minimalna naknada
- rodiljne i roditeljske potpore.

S druge strane, neizravni novčani transferi odnose se na porezne olakšice ili porezne beneficije koje su namijenjene obiteljima s djecom. Ove olakšice smanjuju iznos poreza koji obitelji moraju platiti, što im omogućuje da zadrže više dohotka. Na primjer, neke države omogućuju roditeljima da odbiju određeni iznos poreza po djetetu. Osim toga, neke države

nude porezne kredite za djecu, što znači da roditelji dobiju povrat dijela poreza koji su već platili.

Transferi u naravi i subvencije su oblici pomoći koje se ne isplaćuju u novcu, već u obliku dobara ili usluga koje obitelj može koristiti kako bi im se olakšao odgoj i skrb djece. Dodjeljuju se kao dodatni oblici podrške, uz novčane transferne programe. Ovi transferi uglavnom se određuju na lokalnoj razini, a obuhvaćaju: sufinanciranje udžbenika, subvencije prijevoza, sufinanciranje troškova prehrane, sufinanciranje smještaja u učeničkim/studentskim domovima itd.

Obje vrste transfera, kako novčani tako i u naravi, imaju za cilj olakšati financijske terete obiteljima s djecom i potaknuti veći broj djece u društvu.

Tablica 10. opisuje mjere socijalne politike u Republici Hrvatskoj na razini središnje države te jedinica lokalne i regionalne samouprave kroz novčane transfere te transfere u naravi i subvencije. Novčani transferi središnje države uključuju, između ostalih, doplatak za djecu, rodiljne i roditeljske potpore, naknadu za novorođenče, zajamčenu minimalnu naknadu i porezne olakšice za uzdržavanu djecu. Nenovčani transferi središnje države uključuju zdravstvenu skrb i obrazovanje. Osim toga, prikazani su novčani transferi te transferi u naravi i subvencije jedinica lokalne i regionalne samouprave koji su uglavnom isti u svim jedinicama lokane i regionalne razine vlasti, ali se razlikuju u visini iznosa, uvjetima prihvatljivosti i sl. Mjere socijalne politike na razini središnje države te jedinica lokalne i regionalne samouprave prikazuju stanje u 2025. godini (tablica 10.).

Tablica 10. Mjere socijalne politike usmjerene obiteljima s djecom u Republici Hrvatskoj

Mjera	Razina vlasti/Regulirajući zakon	Opis
Zajamčena minimalna naknada	Središnja država/Zakon o socijalnoj skrbi NN 18/22, 46/22, 119/22, 71/23, 156/23, 61/25	Izravni novčani transfer namijenjen samcu ili kućanstvu koji nemaju sredstva za podmirenje osnovnih životnih potreba. Iznos ovisi o broju članova kućanstva, radnoj sposobnosti i visini prihoda. Osnovica za izračun: 160 EUR.
Naknada za redovito studiranje	Središnja država/Zakon o socijalnoj skrbi NN 18/22,	Pravo na naknadu ostvaruje korisnik usluge smještaja ili organiziranog stanovanja za vrijeme studiranja u

	46/22, 119/22, 71/23, 156/23, 61/25	iznosu od 400 % osnovice (300 EUR). Pravo se ostvaruje do 26. godine starosti, bez obzira na imovinsko stanje.
Troškovi smještaja u učeničkom domu	Središnja država/Zakon o socijalnoj skrbi NN 18/22, 46/22, 119/22, 71/23, 156/23, 61/25	Pravo na pokrivanje troškova smještaja ostvaruju djeca slabijeg imovinskog stanja koja su polaznici srednje škole, a čije kućanstvo nije korisnik zajamčene minimalne naknade. Pravo na pokriće troškova imaju i djeca smještena u udomiteljskim obiteljima koja pohađaju školu izvan mjesta prebivališta.
Inkluzivni dodatak	Središnja država/Zakon o inkluzivnom dodatku NN 156/23	Novčana naknada namijenjena osobi s invaliditetom. Osnovica za izračun iznosi 120 EUR. Dodatak se kreće od 138 EUR za petu razinu do 720 EUR za prvu razinu.
Doplatak za djecu	Središnja država/Zakon o doplatku za djecu NN 94/01, 138/06, 107/07, 37/08, 61/11, 112/12, 82/15, 58/18, 156/23	Novčana naknada prema dohodovnom cenzusu kućanstva. Ovisi o visini ukupnog dohotka, broju djece, invaliditetu. Iznos doplatka kreće se od 30,90 EUR do 61,80 EUR[14].
Pronatalitetni dodatak	Središnja država/Zakon o doplatku za djecu NN 94/01, 138/06, 107/07, 37/08, 61/11, 112/12, 82/15, 58/18	Korisnik uz utvrđenu svotu doplatka za djecu može ostvariti i dodatak u iznosu od 66,36 EUR za treće i 132,72 EUR za četvrto i svako sljedeće dijete. Ovaj iznos dodaje se za treće i četvrto dijete na već utvrđeni iznos doplatka za djecu.
Porezni odbitak za uzdržavanu djecu	Središnja država/Zakon o porezu na dohodak NN 114/23, NN 152/2024	Olakšica poreza na dohodak koja se progresivno povećava sa svakim sljedećim djetetom. Neoporezivi dio dohotka poreznog obveznika za prvo dijete iznosi 300 EUR, drugo dijete 420 EUR, treće dijete 600 EUR itd.
Rodiljne i roditeljske potpore	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Socijalna naknada koja zamjenjuje dohodak za zaposlene i samozaposlene roditelje. Visina naknade ovisi o primanjima ostvarenim u razdoblju prije rodiljnog (roditeljskog) dopusta. Naknada tijekom prvih 6 mjeseci djetetova života iznosi 100% osnovice za naknadu plaće, kao i naknada za vrijeme trajanja roditeljskog dopusta (do max. 3 000 EUR). Naknada za

[14] HZMO (2025) Određivanje svote doplatka za djecu za 2025. Dostupno na: https://www.mirovinsko.hr/hr/odredjivanje-svote-doplatka-za-djecu/270 Pristupljeno: 22. 2. 2025.

		roditeljski dopust za roditelje koji rade na pola radnog vremena do prve godine djetetova života iznosi 972 EUR.
Rodiljne i roditeljske potpore za poštedu od rada i brigu djeteta	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Dostupno roditeljima novorođenog djeteta koji su zaposleni na određeno vrijeme, radnici u poljoprivredi, nezaposlene osobe ili neaktivne osobe. Mjesečna naknada iznosi 309,01 EUR.
Jednokratna novčana potpora za novorođeno dijete	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Izravni novčani transfer u obliku jednokratne novčane potpore 618 EUR.
Potpora za rad s polovicom punog radnog vremena radi pojačane njege djeteta	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Novčana naknada u iznosu od 701 EUR mjesečno ostvaruje se na temelju prijedloga liječnika radi pojačane brige i njege djeteta, nakon isteka roditeljskog dopusta. Pravo ostvaruje samo jedan od zaposlenog/samozaposlenog roditelja.
Potpora za rad s polovicom punog radnog vremena radi pojačane njege djeteta s težim smetnjama u razvoju	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Novčana potpora dodjeljuje se mjesečno jednom od roditelja koji radi s polovicom punog radnog vremena radi pojačane njege djeteta s težim smetnjama u razvoju. Pravo na ovu naknadu roditelj ostvaruje do navršene osme godine djetetova života, u iznosu od 803 EUR. Za zaposlene i samozaposlene roditelje koji primaju minimalnu plaću, naknada iznosi 701 EUR za puno radno vrijeme, odnosno 503 EUR za nepuno radno vrijeme.
Potpora radi njege djeteta s težim smetnjama u razvoju	Središnja država/Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Osoba ima pravo na mjesečnu novčanu potporu od 803 EUR nakon završetka prava na rodiljni dopust ili tijekom korištenja ili nakon isteka prava na roditeljski dopust. Pravo se ostvaruje na temelju nalaza i mišljenja Zavoda za vještačenje, profesionalnu rehabilitaciju i zapošljavanje osoba s invaliditetom, a može ga koristiti isključivo jedan od roditelja koji je zaposlen ili samozaposlen.
Očinski dopust	Zakon o izmjenama i dopunama Zakona o rodiljnim i roditeljskim potporama NN 85/2022, 34/2025	Dopust namijenjen ocu povodom rođenja djeteta radi brige i njege djeteta. Trajanje dopusta ovisi o broju rođene djece – od 20 dana (za rođenje jednog djeteta) do 30 radnih dana (za rođenje blizanaca, trojki ili istodobnog rođenja više djece). Otac ima pravo

		koristiti očinski dopust do navršenih šest mjeseci djetetova života. Tijekom trajanja dopusta isplaćuje se naknada plaće u visini od 100 % osnovice utvrđene prema propisima obveznog zdravstvenog osiguranja.
Rodiljni i roditeljski dopust	Zakon o rodiljnim i roditeljskim potporama NN 152/22, 34/2025	Rodiljni dopust namijenjen je trudnici odnosno majci u trajanju od 28 dana (odnosno 45 dana) prije dana očekivanog poroda do navršenih šest mjeseci života djeteta. Roditeljski dopust mogu koristiti zaposleni i samozaposleni roditelji od dana navršetka šest mjeseci života djeteta do osme godine starosti djeteta. Dužina trajanja roditeljskog dopusta ovisi o broju rođene djece – od 8 mjeseci (za prvo i drugo rođeno dijete) do 30 mjeseci (za blizance, treće i svako sljedeće dijete).

Izvor: izrada doktorandice

Osim naknada namijenjenih obiteljima s djecom u okviru sustava socijalne skrbi, u Republici Hrvatskoj u okviru poreznog sustava porezni obveznici s djecom mogu s osobnim odbitkom za uzdržavanu djecu uvećati neoporezivi dio dohotka čime ostvaruju veći raspoloživi dohodak u odnosu na osobe koje nemaju djecu. Sukladno zakonskoj regulativi uzdržavanom djecom smatraju se „djeca koju roditelji, posvojitelji, maćehe odnosno očusi, posvojitelji, udomitelji i skrbnici uzdržavaju. Djecom se smatraju i djeca nakon završetka redovnog školovanja do prvog zapošljavanja“ (NN 114/23).

Tablica 11. pruža pregled definiranih koeficijenata i iznosa osobnog odbitka za 2025. godinu. Iznosi odbitka računaju se kao umnožak koeficijenta i osnovice osobnog odbitka, koja iznosi 600 EUR. Roditelji djece imaju mogućnost zajedničkog dijeljenja ukupnog iznosa odbitka za djecu kako bi oboje smanjili svoju poreznu osnovicu. Učinak ovog dijeljenja ovisi o ukupnom dohotku oba roditelja.

Tablica 11: Koeficijenti i iznosi osobnog odbitka za uzdržavanu djecu poreznog obveznika u Republici Hrvatskoj (2025. godina)

Osobni odbitak	Koeficijent	Mjesečni iznos (EUR)	Godišnji iznos (EUR)
prvo dijete	0,5	300	3 600
drugo dijete	0,7	420	5 040
treće dijete	1,0	600	7 200
četvrto dijete	1,4	840	10 080
peto dijete	1,9	1.140	13 680
šesto dijete	2,5	1.500	18 000
sedmo dijete	3,2	1.920	23 040
osmo dijete	4,0	2.400	28 800
deveto dijete	4,9	2.940	35 280
porezni obveznik i svaki uzdržavani član uže obitelji i svako dijete, ako su osobe s invaliditetom	0,3	180	2 160
porezni obveznik i svaki uzdržavani član uže obitelji i svako dijete ako su osobe kojima je rješenjem, na temelju posebnih propisa, utvrđena invalidnost po jednoj osnovi 100% i/ili koji radi invalidnosti imaju, na temelju posebnih propisa, pravo na tuđu pomoć i njegu.	1,0	600	7 200

Izvor: izrada doktorandice (Ministarstvo financija – Porezna uprava, 2025)

U sustavu socijalnih naknada osnovna naknada koja se pruža obiteljima s djecom je i doplatak za djecu koji ovisi o dohodovnom pragu cenzusa (tablica 12.). Doplatak za djecu, kao izravna potpora natalitetu, predstavlja značajan doprinos društva u pokrivanju troškova odgoja djece. Ova mjera često se koristi u populacijskoj i obiteljskoj politici te ima ključnu ulogu u smanjenju dječjeg siromaštva, posebno u obiteljima s više djece. Dakle, doplatak za djecu ima trostruku funkciju: sprječavanje siromaštva i socijalne isključenosti djece, poboljšanje kvalitete obiteljskog života te poticanje nataliteta (Vlada Republike Hrvatske, 2018). Uvođenjem populacijskog kriterija (novčanog dodatka za treće i četvrto dijete), ova mjera socijalne podrške obiteljima dobiva prepoznatljiv pronatalitetni karakter.

Tablica 12. Iznosi doplatka za djecu i dohodovni pragovi cenzusa za kućanstvo u Republici Hrvatskoj (2025. godina)

Ukupni dohodak kućanstva po članu (mjesečno)	**Doplatak za djecu (mjesečno)**
do 88,29 EUR	61,80 EUR
od 88,30 EUR do 176,58 EUR	55,18 EUR
od 176,59 EUR do 264,86 EUR	48,56 EUR
od 264,87 EUR do 441,44 EUR	39,73 EUR
od 441,45 EUR do 618,02 EUR	30,90 EUR
Izuzetci	
za dijete bez oba roditelja ili za dijete čija su oba roditelja nepoznata ili nepoznatog prebivališta ili potpuno nesposobni za samostalan život i rad ili im je oduzeta poslovna sposobnost	povećava se za 25 %
za dijete bez jednog roditelja ili za dijete čiji je jedan roditelj nepoznat ili nepoznatog prebivališta ili potpuno nesposoban za samostalan život i rad ili mu je oduzeta poslovna sposobnost	povećava se za 15 %
za korisnike koji pravo ostvaruju prema članku 122. Zakona o hrvatskim braniteljima iz Domovinskog rata i članovima njihovih obitelji (za dijete smrtno stradalog ili nestalog hrvatskog branitelja).	77,25 EUR

Izvor: izrada doktorandice (Hrvatski zavod za mirovinsko osiguranje, 2025)

S obzirom na izazove s niskom stopom nataliteta u Republici Hrvatskoj, važno je poduzeti dodatne korake za poticanje rađanja te implementirati pravne i financijske mehanizme koji jačaju obitelji i podržavaju brigu o djeci. Također, treba uzeti u obzir kriterije vezane uz dosadašnju primjenu novčanih poticaja, posebno kod manje imućnog stanovništva, s ciljem smanjenja siromaštva, održavanja određene razine prihoda te prevencije dječjeg siromaštva, uz istodobno poboljšanje ekonomskih i socijalnih uvjeta u takvim obiteljima.

Roditelj ili druga osoba s pravom na novčanu naknadu za uzdržavanje i odgoj djece ima to pravo prema odredbama Zakona o doplatku za djecu. Sve administrativne obveze oko ostvarivanja tog prava obavlja Hrvatski zavod za mirovinsko osiguranje (HZMO). Prema podatcima iz 2025. godine (HZMO, 2025a), doplatak za djecu ostvaruje se do navršene 15. godine života djeteta, a nakon toga do završetka srednjoškolskog obrazovanja, najdulje do kraja

školske godine u kojoj dijete navršava 19 godina. U posebnim slučajevima, učenici petogodišnjih srednjih škola imaju pravo na doplatak do kraja školske godine u kojoj navršavaju 20 godina. Dijete koje ima zdravstveno oštećenje prema posebnim propisima zadržava pravo na doplatak za djecu i nakon što navrši 19 godina, ali najdulje do 21. godine života. Uz dobno ograničenje, uvjeti za stjecanje prava na doplatak za djecu propisuju i ograničenje ukupno ostvarenog dohotka koji u prethodnoj kalendarskoj godini po članu kućanstva mjesečno ne prelazi 140 %. Proračunska osnovica za 2025. godinu iznosi 441,44 EUR (HZMO, 2025b). Ukupni dohodak kućanstva, prema Zakonu o doplatku za djecu (NN 58/18), zbroj je oporezivih dohodaka prema propisima o porezu na dohodak i drugih primitaka koje ostvari korisnik i članovi njegovog kućanstva. Drugim primitcima smatraju se mirovine, plaće ostvarene kod poslodavca za rad u inozemstvu, naknade za njegu i skrb o djetetu, naknade za vrijeme privremene spriječenosti za rad, naknade za nezaposlenost i naknade zbog profesionalne rehabilitacije.

Pri utvrđivanju porezne osnovice ne uzimaju se u obzir doplatak za djecu, minimalni iznos rodiljnih i roditeljskih potpora, potpore za novorođenče i slični primitci, uključujući socijalne naknade, novčane potpore propisane Zakonom o rodiljnim i roditeljskim potporama, primitci za novorođenče ili opremu za novorođenčad, obiteljske mirovine djece nakon smrti roditelja, stipendije, nagrade za izvrsnost učenika i studenata te drugi srodni primitci. Time se omogućuje korisnicima da istodobno primaju doplatak za djecu i ostvaruju pravo na porezni odbitak, čak i u slučajevima kada ostvaruju dovoljno visok dohodak.

Korisnici koji ostvaruju pravo na doplatak za troje ili više djece ostvaruju pravo i na pronatalitetni dodatak doplatku za djecu. U tom slučaju primaju dodatnih 66,36 EUR za treće dijete, odnosno 132,72 EUR za četvrto i svako sljedeće dijete.

Ministarstvo demografije i useljeništva prikuplja podatke o demografskim mjerama koje se provode na razini jedinica lokalne i regionalne samouprave (2020. – 2024.), stoga se u nastavku analiziraju najznačajnije demografske mjere tijekom 2023. godine. Novčane potpore za rođenje djeteta isplaćivale su gotovo sve općine i gradovi (izuzev općina Kotoriba, Mala Subotica, Orehovica, Petrijanec, Podturen), dok je samo devet županija (Bjelovarsko-bilogorska, Karlovačka, Krapinsko-zagorska, Osječko-baranjska, Sisačko-moslavačka, Splitko-dalmatinska, Zadarska, Zagrebačka i Grad Zagreb) isplaćivalo navedenu potporu.

Od prvog uvođenja potpore za rođenje djeteta do 2023. godine, financijska potpora na razini gradova se je prosječno povećala za 173 % za rođenje prvog djeteta (prosječno sa 157 na 430 EUR), za rođenje drugog djeteta za 232 % (prosječno sa 177 EUR na 589 EUR), a za rođenje trećeg djeteta 380 % (prosječno s 229 EUR na 1101 EUR). Među općinama, od prvog uvođenja potpore do 2023. godine, potpora za rođenje prvog djeteta prosječno se je povećala za 123 % (prosječno sa 193 EUR na 471 EUR), za rođenje drugog djeteta za 164 % (prosječno s 225 EUR na 595 EUR), a za rođenje trećeg djeteta evidentirano je prosječno povećanje za 198 % (prosječno s 299 EUR na 891 EUR). Kod županija se je dogodilo smanjenje potpore za 19 % za rođenje prvog djeteta (sada prosječno iznosi 171 EUR), smanjenje za 64 % za drugorođeno dijete (prosječan iznos potpore je 155 EUR) i smanjenje za 64 % za rođenje trećeg djeteta (prosječno 291 EUR). Promatrajući s aspekta indeksa razvijenosti, najrazvijenije jedinice lokalne samouprave izdvajaju veće iznose potpora za rođenje djeteta, neovisno o redu rođenja.

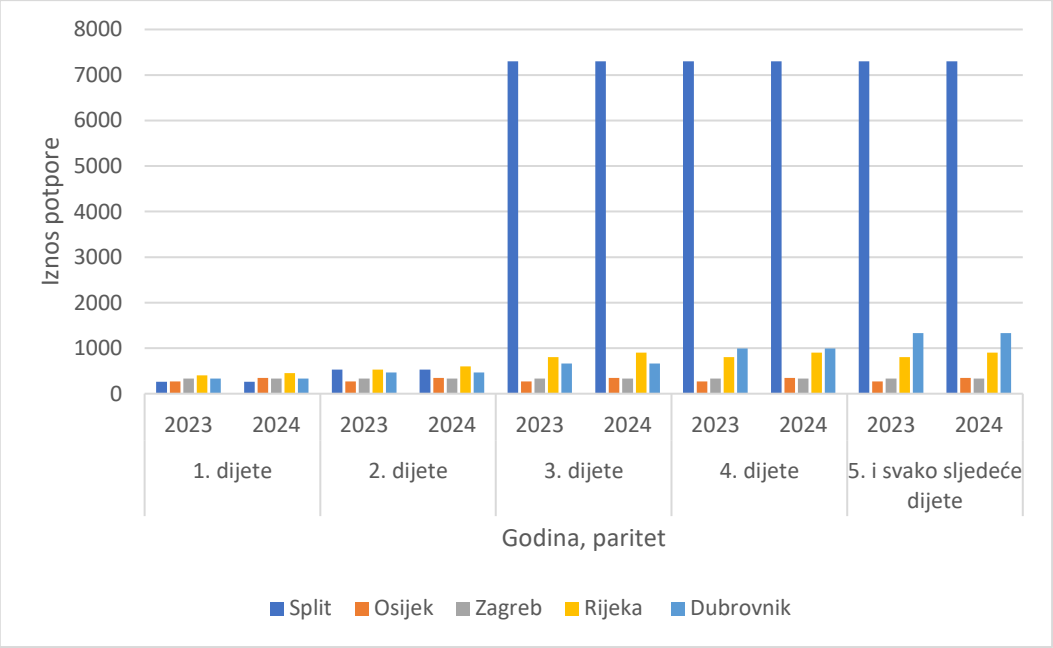

Grafikon 2. Potpore za rođenje djeteta tijekom 2023. i 2024. godine u najvećim gradovima Republike Hrvatske
Izvor: izrada doktorandice (Ministarstvo demografije i useljeništva, 2025)

Iz grafikona 2. vidljivo je da je u gotovo svim gradovima, izuzev Zagreba, došlo do povećanja novčane potpore za rođenje djeteta u 2024. godini u odnosu na 2023. godinu.

Najveći iznos potpore za prvo dijete (450 EUR) i za drugo dijete (600 EUR) isplaćivao je grad Rijeka, dok za treće i svako sljedeće rođeno dijete najveći iznos potpore tijekom 2024. godine isplaćivao je grad Split. Najmanji iznos potpore za rođenje prvog djeteta isplaćivao je grad Split (265 EUR), a za drugo i svako sljedeće rođeno dijete grad Zagreb (331 EUR).

Cijena roditeljskog udjela u ekonomskoj cijeni vrtića tijekom 2023. kretala se je od 63 EUR do 79 EUR za prvo dijete ovisno o razvijenosti jedinice lokalne samouprave (blago povećanje roditeljskog udjela s povećanjem razvijenosti jedinice lokalne samouprave). Za drugo dijete roditelji sudjeluju s udjelom od 53 EUR do 67 EUR, dok za treće dijete roditelji plaćaju od 24 EUR do 38 EUR. Prosječna cijena jaslica koju su roditelji plaćali za prvo dijete bila je u rasponu od 71 EUR do 97 EUR, pri čemu je veći udio roditeljskog financiranja u razvijenijim jedinicama lokalne samouprave. Za drugo dijete roditelji sudjeluju s financiranjem jaslica od 59 EUR do 69 EUR, dok za treće dijete roditeljsko financiranje prosječno iznosi između 26 EUR i 37 EUR. Primjetno je veća cijena jaslica u odnosu na cijenu vrtića koju moraju roditelji sufinancirati pa je tako na razini gradova prosječna cijena sufinanciranja jaslica za prvo dijete 84 EUR, a na razini općina 91 EUR. Za drugo dijete u gradovima roditelji trebaju izdvojiti 61 EUR, dok u općinama 68 EUR. Značajna razlika između gradova i općina očituje se i kod trećeg djeteta gdje je udio roditeljskog sudjelovanja u cijeni jaslica u gradovima 22 EUR, a u općinama čak 34 EUR. Najnoviji podatci ukazuju na daljnji trend problema rada vrtića u dvije smjene (35 % vrtića u gradovima i 13 % vrtića u općinama ima dvosmjenski rad). Osim toga, nedovoljni jaslički kapaciteti bilježe se u gradovima, za razliku od općina u kojima uglavnom ima dovoljno kapaciteta za brigu o djeci starosti od 0 do 2 godine te nema djece na listama čekanja.

U odnosu na prethodne godine, primjetan je porast ulaganja jedinica lokalne samouprave u predškolsku djelatnost. Pa je tako tijekom 2022. godine 49 % općina i 35 % gradova ulagalo do 10 % lokalnog proračuna u predškolsku djelatnost, između 10 % i 20 % lokalnog proračuna izdvajalo je 46 % gradova i 39 % općina. 12 % gradova i 8 % općina u lokalnom proračunu osiguralo je 20 % do 30 % sredstava za ulaganje u predškolski odgoj i obrazovanje, dok je samo 7 % gradova i 4 % općina sudjelovalo s više od 30 % proračunskih sredstava u financiranju predškolskog odgoja i obrazovanja. Besplatan vrtić osigurava 6 % općina i 4 % gradova.

Što se tiče zdravstvene politike, 57 % gradova, 39 % općina i 81 % županija sudjeluje u sufinanciranju zdravstvenih troškova. „U gradovima i općinama se često radi o sufinanciranju dodatnih timova hitne pomoći, rada ordinacija, ljekarni, specijalista i dr., dok županije financiraju zdravstvene programe, djelatnost domova zdravlja i slično. Ostali troškovi uključuju financiranje preventivnih pregleda, laboratorijskih pretraga, sufinanciranje ortopedskih pomagala, lijekova, terapija za djecu, medicinski potpomognute oplodnje, prijevoza i stanarine medicinskog osoblja“ (Središnji državni ured za demografiju i mlade, 2023a: 30).

Kada se govori o politici stambenog zbrinjavanja, čak 289 jedinica lokalne samouprave ne provodi mjere stambenog zbrinjavanja mladih obitelji. Samo 30 % jedinica lokalne samouprave sufinancira kupnju prve nekretnine i to u većoj mjeri općine u odnosu na gradove. Pozitivan pomak u odnosu na 2022. godinu vidljiv je u mjeri oslobođenja i smanjenja komunalnog doprinosa. Navedenu mjeru provodi 15 % jedinica lokalne samouprave. Jedinice lokalne samouprave u Hrvatskoj provode i druge mjere stambene politike kako bi olakšale stambeno zbrinjavanje mladih obitelji. Iako su ove mjere manje zastupljene, uključuju korisne inicijative poput subvencioniranja kamata na stambene kredite, sufinanciranja najamnina te dodjele ili koncesije zemljišta. U 2023. godini primjetan je porast broja jedinica lokalne samouprave koje provode ovakve mjere u usporedbi s prethodnom godinom. Osim toga, mnoge županije raspisuju javne pozive kojima nude bespovratna sredstva za mlade obitelji za kupnju, izgradnju, adaptaciju ili rekonstrukciju nekretnina, osobito u ruralnim područjima. Ove mjere imaju za cilj zadržavanje mladih obitelji, poticanje naseljavanja ruralnih sredina i ublažavanje demografskih izazova u Hrvatskoj.

Konačno, potrebno je još razmotriti podatke koji se odnose na obrazovnu politiku i mjere koje provode jedinice lokalne i područne (regionalne) samouprave. Sredstava za nabavku udžbenika za osnovnoškolsko obrazovanje su od školske godine 2019./2020. osigurana u državnom proračunu, stoga roditelji nemaju trošak financiranja istih. Financiranje udžbenika za srednje škole dijelom je osigurano u lokalnim proračunima pa je tako 29 % gradova i 18 % općina tijekom 2023. godine sudjelovalo u sufinanciranju istih. Kako je već prethodno spomenuto, radne bilježnice i popratni materijali nisu predmet financiranja državnog proračuna, ali iste sufinancira 91 % gradova i 88 % općina. U osnovnim školama 61 % gradova, 29 % županija i 25 % općina financira troškove produženog boravka. Pozitivan trend uočava se u financiranju troškova prijevoza jer jedinice lokalne i regionalne samouprave svake godine

izdvajaju sve izdašnija sredstva za sufinanciranje prijevoza učenika i studenata. Čak 81 % gradova i 74 % općina sudjeluje u sufinanciranju prijevoza učenika i studenata. Ovu mjeru provode i županije koje nerijetko sklapaju sporazume s prijevoznicima čime pokrivaju troškove prijevoza učenicima i studentima. Kada se promatra sufinanciranje smještaja u učeničkim i studentskim domovima, samo 7 % gradova sufinancira iste, zatim slijede općine sa 16 % i županije s 52 %. Čak 96 % gradova, 79 % općina i 76 % županija u svojim proračunima osiguravaju sredstva za stipendije studentima, dok 68 % gradova, 40 % općina i 62 % županija dodjeljuje stipendije učenicima u prosječnom iznosu od 59 EUR do 87 EUR. Studentske stipendije dodjeljuju se u iznosu od 112 EUR na razini gradova, 99 EUR u općinama, dok županije prosječno dodjeljuju studentske stipendije u iznosu od 163 EUR.

Luci i Thevenon (2013) empirijski su testirali utjecaj različitih mjera obiteljske politike na fertilitet, koristeći podatke iz 18 zemalja OECD-a u razdoblju od 1982. do 2007. godine. Rezultati potvrđuju da svaki instrument paketa obiteljske politike (plaćeni dopust, usluge čuvanja djece i financijski transferi) ima pozitivan utjecaj, sugerirajući da bi proširivanje paketa ovih mjera roditeljima koji rade u kontinuitetu tijekom rane dječje dobi vjerojatno olakšao izbor da imaju djecu, odnosno utjecao na namjeru rađanja. Međutim, poluge mjera obiteljske politike nemaju istu težinu. Rezultati istraživanja ukazuju na zaključak da novčani transferi koji se dodjeljuju u ranom djetinjstvu (nakon prve godine rođenja) i dostupnost usluga čuvanja djece za djecu mlađu od tri godine imaju veći potencijalni utjecaj na fertilitet od prava na dopust i naknada dodijeljenih oko rođenja djeteta.

U nastavku su prikazani statistički podatci o naknadama socijalne zaštite namijenjene rješavanju rizika i potreba povezanih s obitelji i djecom.

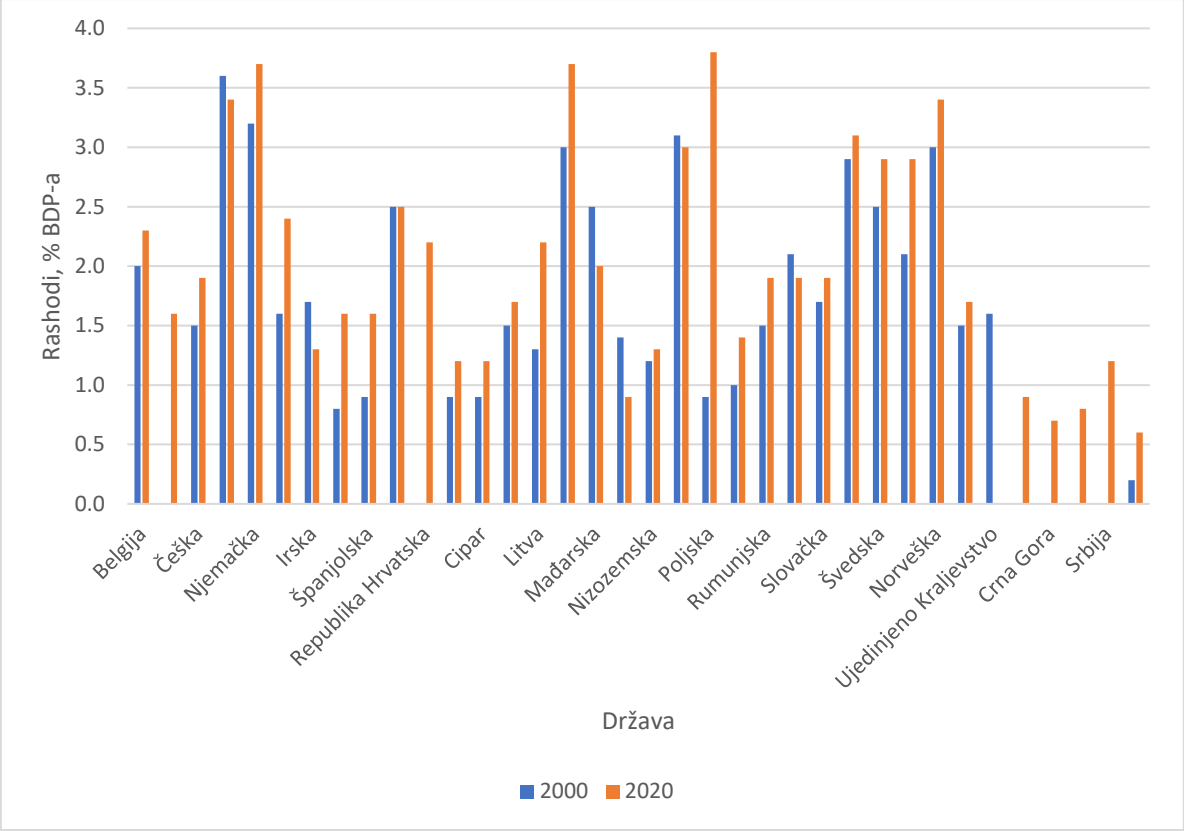

Grafikon 3. Rashodi za obiteljske/dječje naknade (% BDP-a) u 2000. i 2020. godini
Izvor: izrada doktorandice (Eurostat, 2024; online tablični kod: spr_exp_func)

Grafikon 3. prikazuje rashode za obiteljske i dječje naknade kao % BDP-a na razini europskih zemalja tijekom 2000. i 2020. godine. Tijekom 2020. godine najveće izdvajanje za obiteljske i dječje naknade je imala Poljska s 3,8 % BDP-a, zatim slijede Njemačka (3,7 %), Luksemburg (3,7 %) te Danska i Norveška (3,4 %). Za obiteljske i dječje naknade najmanji postotak BDP-a su tijekom 2020. izdvajale Malta i Bosna i Hercegovina s 0,9 %, Crna Gora (0,7 %), Albanija (0,8 %) i Turska (0,6 %). Prosječno izdvajanje na razini cijele Europske unije (EU-27) bilo je 2,5 % BDP-a, dok je 2000. (EU-15) bilo 2 % BDP-a.

Tablica 13. prikazuje rashode za obiteljske/dječje naknade prema vrsti isplate.

Tablica 13. Trend rashoda za obiteljske/dječje naknade u stalnim cijenama prema vrsti isplate, EU, 2000. – 2020. (indeks 2000 = 100)

	2000.	**2005.**	**2010.**	**2015.**	**2020.**
Ukupno	100,0	109,0	122,9	126,4	150,5
Periodične novčane naknade	100,0	104,6	111,3	110,7	130,5

Jednokratne novčane naknade	100,0	112,5	116,4	77,9	97,7
Naknade u naravi	100,0	120,2	153,4	173,3	208,7

Izvor: izrada doktorandice (Eurostat, 2024; online tablični kod: spr_exp_ffa i nama_10_gdp)

Na razini Europske unije tijekom promatranog desetogodišnjeg razdoblja zabilježeno je najveće povećanje naknada u naravi, dok je u istom razdoblju došlo do smanjenja jednokratnih novčanih naknada (tablica 13.). Analitički prikaz izdataka za obiteljske i dječje naknade prikazan je u tablici 14.

Tablica 14. Izdatci za obiteljske/dječje naknade prema vrsti, Europska Unija, 2000. – 2020. godina

	Trenutne cijene (u mil. EUR)			**Udio naknade za obitelj/djecu (%)**	
	2000.	**2020.**	**% promjene 2020./2000.**	**2000.**	**2020.**
Ukupno	**165 800,10**	**337 068,20**	**103,30**	**100,00**	**100,00**
Periodične novčane naknade	**115 630,34**	**203 602,22**	**76,08**	**69,74**	**60,40**
Rodiljne naknade	10 123,65	24 358,17	140,61	6,11	7,23
Naknada za roditeljski dopust	8764,80	20 055,74	128,82	5,29	5,95
Obiteljski/dječji doplatak	89 548,16	142 505,57	59,14	54,01	42,28
Ostale periodične naknade	7193,75	16 682,74	131,91	4,34	4,95
Jednokratne novčane naknade	**5546,40**	**7278,50**	**31,23**	**3,35**	**2,16**
Pomoć pri rođenju	332,75	1061,03	218,87	0,20	0,31
Naknade za roditeljski dopust	226,57	100,54	-55,63	0,14	0,03
Ostale paušalne naknade	4987,10	6116,92	22,65	3,01	1,81
Naknade u naravi	**44 623,34**	**126 187,51**	**182,78**	**26,91**	**37,44**
Dnevni boravak djece	23 794,55	76 055,51	219,63	14,35	22,56
Smještaj	6984,85	15 657,39	124,16	4,21	4,65
Pomoć u kući	2125,44	1132,73	-46,71	1,28	0,34
Ostale naknade u naravi	11 718,52	33 341,88	184,52	7,07	9,89

Izvor: izrada doktorandice (Eurostat, 2024; online tablični kod: spr_exp_ffa)

Promatrajući vrste naknada usmjerene obiteljima s djecom na razini Europske unije (tablica 14.), periodične novčane naknade najzastupljenije su u ukupnim naknadama s udjelom od 69,74 % tijekom 2000. godine. Međutim, 2020. godine taj udio smanjen je na 60,4 %, no i dalje su zastupljenije od jednokratnih novčanih naknada i naknada u naravi. Doplatak za djecu sudjeluje s udjelom od oko 70 % u ukupnim periodičnim novčanim naknadama tijekom 2020. godine. Izdatci za naknade u naravi porasli su za gotovo 11 % u 2020. u odnosu na 2000. godinu. U strukturi naknada u naravi tijekom 2020. godine najzastupljeniji su izdatci za dnevni boravak djece (oko 60 %), dok su najmanja izdvajanja za pomoć u kući (0,9 %). Izdatci za jednokratne novčane naknade povećani su za oko 31 % u 2020. godini u odnosu na 2000. godinu, ali se njihov udio u ukupnim naknadama za obitelji s djecom smanjio.

Promatrajući izolirano Republiku Hrvatsku, prema dostupnim statističkim podatcima prikazana su izdvajanja za obiteljske/dječje naknade u tablici 15.

Tablica 15. Izdaci za obiteljske/dječje naknade prema vrsti, Republika Hrvatska, 2008. – 2020. godina[15]

	Trenutne cijene (u mil. EUR)			**Udio naknade za obitelj/djecu (%)**	
	2008.	**2020.**	**% promjena 2020./2008.**	**2008.**	**2020.**
Ukupno	**699,48**	**1 102,28**	**57,59**	**100,00**	**100,00**
Periodične novčane naknade	**541,90**	**616,44**	**13,76**	**77,47**	**55,92**
Rodiljne naknade	123,50	146,36	18,51	17,66	13,28
Naknada za roditeljski dopust	135,55	222,24	63,95	19,38	20,16
Obiteljski/dječji doplatak	280,95	178,89	-36,33	40,17	16,23
Ostale periodične naknade	1,90	68,95	3528,95	0,27	6,26
Jednokratne novčane naknade	**23,51**	**81,65**	247,30	**3,36**	**7,41**
Pomoć pri rođenju	23,51	45,74	94,56	3,36	4,15
Naknade za roditeljski dopust	0,00	0,00		0,00	0,00
Ostale paušalne naknade	0,00	35,91		0,00	3,26
Naknade u naravi	**134,07**	**404,19**	**201,48**	**19,17**	**36,67**
Dnevni boravak djece	93,43	336,66	260,33	13,36	30,54
Smještaj	38,37	50,72	32,19	5,49	4,60
Pomoć u kući	0,00	0,00		0,00	0,00

[15] Podatci za 2000. godinu nisu dostupni

Ostale naknade u naravi	2,27	16,81	640,53	0,32	1,53

Izvor: izrada doktorandice (Eurostat, 2024; online tablični kod: spr_exp_ffa)

Tablica 15. prikazuje raspodjelu naknada za obitelji i djecu u Republici Hrvatskoj u 2008. i 2020. godini, podijeljeno na različite vrste potpora (periodične novčane naknade, jednokratne novčane naknade i naknade u naravi), s podatcima o njihovoj vrijednosti i postotnom udjelu u ukupnim naknadama za obitelji i djecu. Iz prikazanih podataka vidljivo je da su ukupne naknade za obitelji/djecu porasle za 57,59 % od 2008. do 2020. godine, s 699,48 milijuna EUR na 1102,28 milijuna EUR. Iako su periodične novčane naknade porasle nominalno (s 541,90 na 616,44 milijuna EUR), njihov udio u ukupnim naknadama je značajno pao sa 77,47 % u 2008. na 55,92 % u 2020. Najveći pad zabilježen je u izdvajanjima za doplatke za djecu gdje je smanjenje iznosilo 36,33 %. Naknade za roditeljski dopust su porasle za 63,95 %, a rodiljne naknade za 18,51 %. Eksponencijalni rast vidljiv je kod ostalih periodičnih naknada, iako vrlo male u 2008., narasle su više od 3500 % do 2020., čineći 6,26 % svih naknada. Jednokratne novčane naknade porasle su za čak 247,30 %, posebno kroz pomoć pri rođenju, ali je njihov ukupni udio u ukupnim naknadama i dalje relativno mali (7,41 %). Posebno značajan porast zabilježen je u naknadama u naravi, koje su se povećale za 201,48 %, s 134,07 milijuna EUR u 2008. na 404,19 milijuna EUR u 2020. godini. To uključuje značajan rast izdvajanja za dnevni boravak djece (porast od 260,33 %).

Zaključno, dok se ukupni izdatci za obitelji i djecu značajno povećavaju, struktura potpora se mijenja. Vidljivo je smanjenje udjela periodičnih novčanih naknada, dok raste značaj jednokratnih novčanih naknada i naknada u naravi, što sugerira promjene u prioritetima u socijalnim politikama za obitelji i djecu.

Prema najnovijim objavljenim statističkim podatcima Eurostata (Eurostat, 2024a) za 2021. godinu, najveći postotak BDP-a za obiteljske/dječje naknade izdvajale su sljedeće zemlje članice Europske unije: Njemačka (3,6 %), Poljska (3,4 %), Danska i Luksemburg (3,2 %). Republika Hrvatska je tijekom 2021. smanjila izdvajanje za obiteljske i dječje naknade za 0,2 % BDP-a u odnosu na prethodnu godinu. Sukladno navedenom, u nastavku se detaljnije analizira sustav potpora i naknada (2024. godina) za obitelji s djecom u zemljama članicama Europske unije koje su tijekom 2021. izdvajale najveći udio BDP-a za obiteljske/dječje

naknade. U nastavku su prikazane potpore i naknade namijenjene obiteljima s djecom u odabranim zemljama članicama Europske unije (tablica 16.).

Tablica 16. Potpore i naknade namijenjene obiteljima s djecom u odabranim zemljama članicama Europske unije

Zemlja/Potpore i naknade	Njemačka	Poljska	Danska	Luksemburg
Doplatak za djecu	Dječji doplatak isplaćuje se mjesečno i iznosi 250,00 EUR po djetetu. Nema razlike prema dobi.	Mjesečni iznosi po djetetu ovise o dobi djeteta i obiteljskim prihodima: - mlađi od 5 godina: oko 22 EUR - od 5 do 18 godina: oko 29 EUR - od 18 do 24 godina: oko 31 EUR Doplatak za odgoj djece : Mjesečni iznos po djetetu iznosi oko 184 EUR i ne ovisi o dobi djeteta. Iznos naknade ne ovisi o obiteljskim prihodima. „Obiteljski kapital za skrb“ iznosi oko 2768 EUR.	Dječja i mladenačka naknada (kvartalna): - za svako dijete od 0 do 2 godine: 687 EUR - za svako dijete od 3 do 6 godina: 544 EUR - za svako dijete od 7 do 14 godina: 428 EUR - za svako dijete od 15 do 17 godina: 143 EUR mjesečno. Doplatak za djecu (kvartalno): 216 EUR	Mjesečni iznos: 299,86 EUR po djetetu. Nema modifikacije prema dohotku. Povećanja temeljem dobi: - od 6 godina: 22,67 EUR mjesečno - od 12 godina: 56,57 EUR mjesečno.
Roditeljski dopust	Naknada za roditeljski dopust iznosi najmanje 300 EUR i najviše 1800 EUR. Naknada za roditeljski dopust Plus iznosi najmanje 150 EUR mjesečno i najviše 900	Mjesečna naknada iznosi 70 %, odnosno 81,5 % referentne plaće mjesečno. Naknada za podizanje djeteta tijekom roditeljskog dopusta iznosi oko 92 EUR mjesečno.	Rodiljni/očinski/ roditeljski dopust i novčane naknade za posvojenje iznose 630 EUR tjedno ili 17 EUR po satu.	Roditeljska naknada je adekvatna zamjena za prihod koja se izračunava na temelju prihoda koji ostvaruje roditelj i prosječnog broja radnih sati u 12 mjeseci koji prethode početku

	EUR mjesečno. U slučaju višestrukih rođenja, naknada se povećava za 300 EUR mjesečno za svako dijete iz višestrukog rođenja; a naknada Plus povećava se za 150 EUR mjesečno. Obitelji s više djece mogu primiti bonus za braću i sestre u iznosu od 10 % roditeljske naknade (najmanje 75 EUR mjesečno).	Roditeljska naknada iznosi oko 231 EUR mjesečno.		roditeljskog dopusta. Za puni roditeljski dopust za radnika s punim radnim vremenom, prihod je ograničen na 5/3 minimalne socijalne plaće (4284,88 EUR mjesečno) i ne može biti manji od minimalne socijalne plaće (2570,93 EUR mjesečno).
Naknade za skrb o djeci	n/a	n/a	Subvencije za brigu o vlastitoj djeci ne mogu prelaziti 85 % neto operativnih troškova za dijete smješteno u vrtić. Subvencije za privatni program dnevne skrbi čine najmanje 75 % najjeftinijeg planiranog neto operativnog troška po mjestu u javnom vrtiću. Ne može premašiti 75 % dokumentiranih troškova.	n/a
Jednokratne naknade za novorođenčad	Nema posebnih naknada.	Jednokratna isplata za rođenje djeteta iznosi od 231 EUR po djetetu.	Subvencija za posvajanje u slučaju posvajanja stranog djeteta iznosi jednokratno 8194 EUR.	Naknada od 1740,09 EUR (jednokratno).

Naknada za samohrane roditelje	Nema posebnih naknada.	Naknada za uzdržavanje djece za samohrane roditelje u iznosu od oko 44 EUR po djetetu, do maksimalno 89 EUR po obitelji. Iznos se povećava za 18 EUR u slučaju djece s invaliditetom.	216 EUR po djetetu po kvartalu i nadopunjuje se dodatnim dječjim doplatkom od 220 EUR po kvartalu po kućanstvu (neovisno o broju djece).	Nema posebnih obiteljskih naknada za samohrane roditelje.
Posebne naknade za djecu s invaliditetom	Nema posebnih naknada.	Iznos oko 49 EUR mjesečno. Naknada za obrazovanje i rehabilitaciju djeteta s invaliditetom iznosi oko 21 EUR po djetetu do 5 godina ili 25 EUR po djetetu između 5 i 24 godine. Poseban doplatak za njegu: 143 EUR do 689 EUR mjesečno. Doplatak za skrbnika: 143 EUR mjesečno. Jednokratni dodatak: oko 923 EUR.	Naknada za zamjenu prihoda za kućnu njegu i/ili obrazovanje djeteta s invaliditetom mlađeg od 18 godina iznosi maksimalno 4728 EUR mjesečno. Nadoknada dodatnih troškova za čuvanje djeteta s invaliditetom u kući. Troškovi moraju iznositi minimalno 740 EUR godišnje.	Dodatni dodatak od 200 EUR mjesečno za svako dijete mlađe od 25 godina koje prima obiteljsku naknadu i ima insuficijenciju ili trajno smanjenje od najmanje 50 % fizičke ili mentalne sposobnosti u usporedbi sa zdravim djetetom iste dobi.
Predujam uzdržavanja	Iznos uzdržavanja do 395 EUR mjesečno, ovisno o dobi djeteta.	Doplatak iz fonda za alimentaciju dodjeljuje se ako alimentacija koju je odredio sud nije isplaćena i ako prosječni mjesečni prihod ne premašuje oko 279 EUR neto po osobi.	Iznos uzdržavanja od 208 EUR po djetetu mjesečno.	Svaka alimentacija koja pripada supružniku ili potomku isplaćuje se na zahtjev i pod određenim uvjetima od strane nacionalnog fonda solidarnosti te je on naknadno potražuje.

Ostali dodatci	Roditelji imaju pravo na dodatak na dječji doplatak za svoju nevjenčanu djecu mlađu od 25 godina koja i dalje žive u istom kućanstvu u iznosu do 292 EUR mjesečno po djetetu koje ispunjava uvjete.	Dodatak za početak školske godine: Iznos je jednokratni i iznosi oko 23 EUR po djetetu. Dodatak „Dobar početak“ – oko 69 EUR dodjeljuje se jednom godišnje za svako dijete koje započinje školsku godinu do navršene 20. godine (24 godine za djecu s invaliditetom). Doplatak se ne temelji na prihodima. Doplatak za obrazovanje izvan mjesta prebivališta iznosi oko 26 EUR po djetetu ili oko 16 EUR za troškove prijevoza, isplaćuje se tijekom 10 mjeseci školske godine. Doplatak za veliku obitelj iznosi oko 22 EUR mjesečno za svako treće i svako sljedeće dijete u obitelji. Dodatna roditeljska naknada jednaka je najnižoj mirovini i iznosi oko 366 EUR.	Posebna naknada za roditelje koji se obrazuju: 284 EUR po djetetu po kvartalu. Dodatna naknada za djecu namijenjena je roditeljima tijekom pripravničkog staža i školskih godina: iznosi 55 % razlike između državne obrazovne potpore za roditelje i trenutnog prihoda. Naknada se isplaćuje mjesečno i može se dodijeliti samo jednom za svakog roditelja, bez obzira na broj djece. Naknade za više djece iznose 356 EUR po djetetu po kvartalu do 7. rođendana djece. Posebna naknada za djecu isplaćuje se roditeljima koji su odlučili usvojiti dijete kao samohrani roditelj i iznosi 623 EUR po djetetu po kvartalu.	Dodatak za novu školsku godinu za djecu stariju od 6 godina: - od 6 do 11 godina: 115 EUR - 12 godina i više: 235 EUR

Izvor: izrada doktorandice (MISSOC, 2024)

Sve europske zemlje imaju određeni oblik mjesečnog dječjeg doplatka koji se isplaćuje do navršenih 16 ili do 21 godine djetetova života, a u posebnim slučajevima, poput školovanja ili invaliditeta i do 26. godine. U nekim zemljama, primjerice, doplatci su viši za djecu s invaliditetom, djecu samohranih roditelja te za siročad, pri čemu njihova visina varira među državama. Dodatno, iznos doplatka može biti uvjetovan dobi djeteta, redoslijedom rođenja ili ukupnim brojem djece u obitelji. Većina zemalja EU-a pruža univerzalne novčane transfere za djecu. Argumenti u korist univerzalnih obiteljskih naknada uključuju promicanje horizontalne jednakosti, smanjenje moralnog hazarda i pojednostavljenje administracije koje bi inače zahtijevalo složene provjere dohotka ili imovine. S druge strane, protivnici univerzalnih naknada ističu zabrinutost zbog moguće zloupotrebe, rizik od stvaranja ovisnosti korisnika o socijalnoj pomoći te potrebu da se sredstva usmjere prema djeci kojoj su najpotrebnija. Iz tablice 16. vidljivo je da Njemačka i Luksemburg nude relativno visoke i fiksne iznose dječjih doplataka bez obzira na dob djeteta, dok se u Poljskoj i Danskoj iznosi prilagođavaju prema dobi. Nadalje, Danska nudi najveću financijsku podršku za najmlađu djecu, ali iznos značajno opada kako dijete odrasta, dok Poljska nudi dodatnu potporu za odgoj i posebnu godišnju naknadu za skrb, što je specifično za ovu zemlju. Luksemburg dodatno stimulira obitelji s djecom starijom od 6 i 12 godina kroz dodatne mjesečne iznose, što omogućava veću podršku obiteljima s adolescentima.

Prema dostupnim podatcima MISSOC (2024), u Njemačkoj roditeljski dopust omogućuje majkama da se povuku s tržišta rada do tri godine po djetetu. To je omogućeno čak i majkama koje prethodno nisu bile zaposlene, ali tada primaju minimalnu naknadu od 300 EUR. Osim rodiljnog dopusta koji uključuje šest tjedana prije poroda i osam tjedana nakon rođenja, s naknadom koja iznosi 100 % prethodne plaće, dostupna je i naknada za roditeljski dopust (njem. *Elterngeld*). Inspiriran švedskim modelom, *Elterngeld* osigurava roditeljima od 65 % do 67 % (ovisno o visini neto dohotka) prosječne neto plaće u razdoblju od 12 mjeseci nakon rođenja djeteta. Ova naknada smanjuje se za dva mjeseca u slučaju korištenja rodiljnog dopusta i oslobođena je oporezivanja. Najviši mjesečni iznos naknade iznosi 1800 EUR, uz dodatnih 300 EUR u slučaju višestrukih rođenja. Kada oba roditelja podijele korištenje *Elterngeld-a*, a otac preuzme najmanje dva mjeseca, trajanje naknade se produžuje s 12 na 14 mjeseci. Njemačka je 2015. godine uvela mjere *ElterngeldPlus* (dodatni obiteljski doplatak) i *Partnerschaftsbonus* (partnerski bonus) s ciljem financijskog poticanja oba roditelja da rade na

skraćeno radno vrijeme (25 do 30 sati tjedno) i ravnopravno podijele roditeljske obveze dok imaju malu djecu. Ove mjere nude alternativu potpunom napuštanju radnog mjesta nakon rođenja djeteta. Dodatni obiteljski doplatak može zamijeniti standardnu potporu za roditeljski dopust, pružajući zamjenski dohodak koji pokriva između 65 % i 100 % izgubljene plaće zbog smanjenja radnih sati, u rasponu od 150 do 900 EUR. Ako roditelji odluče raditi skraćeno, pravo na ovaj doplatak udvostručuje se pa im financijska potpora traje duže – produžujući roditeljski doplatak s 12 na 24 mjeseca za jednog roditelja, odnosno s 14 na 28 mjeseci za oba roditelja koji rade skraćeno radno vrijeme. Dodatna četiri mjeseca doplatka poznata su kao „partnerski bonus“ i dodjeljuju se kao nagrada roditeljima koji ravnomjerno dijele obaveze skrbi za dijete. U njemačkom sustavu postoji i predujam za uzdržavanje, odnosno naknadu za neplaćene obveze uzdržavanja od strane drugog roditelja. Minimalno uzdržavanje isplaćuje se za djecu mlađu od 18 godina koja žive u kućanstvu samohranog roditelja i koja su rezidenti Njemačke ili tamo obično borave. Za djecu od 12 godina, predujam za uzdržavanje može se tražiti do navršene 18. godine. Iznos uzdržavanja može biti do 395 EUR mjesečno, ovisno o dobi djeteta. Od ostalih dodataka namijenjenih djeci, može se izdvojiti pravo na dodatak na doplatak u iznosu od 292 EUR za nevjenčanu djecu mlađu od 25 godina, a koja i dalje žive u istom kućanstvu (Svjetska banka, 2019; MISSOC, 2024).

Poljska vlada je 2022. godine uvela program „Obiteljski kapital za skrb“ (Ministry of Family, Labour and Social Policy, Republic of Poland, 2021). Ovo je naknada u iznosu od 12 000 PLN (2768 EUR) za drugo i svako sljedeće dijete u dobi od 12 do 36 mjeseci, kao i financijska podrška za skrb u vrtićima u slučaju roditelja djece koja ne primaju ovu naknadu. Od siječnja 2024. na snazi je i program „Obitelj 800+“ koji je osmišljen kako bi podržao obitelji u djelomičnom pokrivanju troškova odgoja djece, uključujući brigu o djeci i zadovoljenje njihovih životnih potreba. U okviru ovog programa obitelji s uzdržavanom djecom imaju pravo na naknadu za odgoj djece do navršene 18. godine života djeteta, bez obzira na prihod koji obitelj ostvaruje. Od 1. siječnja 2024., iznos naknade za odgoj povećan je na 800 PLN (184 EUR) mjesečno po djetetu, bez obzira na dohodak obitelji i dob djeteta. Mjesečna naknada za roditeljski dopust iznosi 70 % referentne plaće po mjesecu. Međutim, ako zaposlenik zatraži puni roditeljski dopust najkasnije 21 dan nakon rođenja djeteta, tada mjesečni iznos za razdoblje rodiljnog i očinskog dopusta iznosi 81,5 % referentne plaće. Dodatak za skrb o djetetu tijekom korištenja dopusta za podizanje djeteta iznosi 400 PLN (92 EUR) mjesečno. Prema podatcima MISSOC baze (2024) roditeljska naknada iznosi 231 EUR mjesečno. Za rođenje djeteta ostvaruje se naknada u iznosu od 231 EUR. Naknada za samohrane roditelje

mjesečno se isplaćuje se roditelju ili skrbniku djeteta ili punoljetnom studentu čiji su roditelji umrli ili koji nije ovisan o njima na temelju sudske odluke o alimentaciji, u iznosu od oko 44 EUR po djetetu do maksimalno 89 EUR po obitelji. Iznos se povećava za oko 18 EUR u slučaju djece s invaliditetom, unutar limita od oko 37 EUR po obitelji. Za djecu invalide i djecu do 16 godina koja zahtijevaju stalnu pomoć druge osobe oko 49 EUR mjesečno. Osim toga, invalidnoj djeci dostupni su i novčani dodatci za obrazovanje i rehabilitaciju u iznosu od 21 EUR do 25 EUR, ovisno o starosti djeteta. Ako osoba koja ima obvezu uzdržavanja djeteta napusti zaposlenje zbog potrebe da pruža stalnu njegu djetetu, ostvaruje se pravo na poseban doplatak za njegu u mjesečnom iznosu od oko 143 EUR, a u slučaju da osoba nije zaposlena, doplatak za njegu iznosi 689 EUR. Jednokratna naknada prema Zakonu o potpori trudnicama i njihovim obiteljima isplaćuje se roditelju ili skrbniku za rođenje djeteta koje je dijagnosticirano s teškim i nepovratnim invaliditetom ili neizlječivom bolesti koja ugrožava život, a koja je nastala tijekom prenatalnog razvoja djeteta ili tijekom poroda (oko 923 EUR). Doplatak iz fonda za alimentaciju dodjeljuje se ako alimentacija koju je odredio sud nije isplaćena i ako prosječni mjesečni prihod ne premašuje 279 EUR neto po osobi. Ovaj doplatak namijenjen je neudatim samohranim roditeljima ili skrbnicima, kao i oženjenim osobama koje ne mogu naplatiti alimentaciju od svog supruga ili supruge. Primjenjuje se mehanizam koji omogućava osobama s prihodom malo iznad navedenog praga da prime doplatak iz fonda za alimentaciju. To konkretno znači da se iznos doplatka umanjuje za iznos kojim prihod obitelji premašuje postavljeni prag. Na primjer, ako prihod premašuje prag za oko 23 EUR, taj se iznos oduzima od doplatka koji bi inače bio isplaćen. Doplatak iz fonda za alimentaciju mora se vratiti od strane osobe koja je dužna plaćati alimentaciju (dužnik za alimentaciju). Iznos alimentacije određuje sud i ne može premašiti 500 PLN, odnosno oko 115 EUR po djetetu. Od ostalih naknada izdvajaju se naknada za početak školske godine u iznosu od 23 EUR po djetetu, dodatak „Dobar početak“ u iznosu od oko 69 EUR za svako dijete koje započinje školsku godinu do navršene 20. godine (24 godine za djecu s invaliditetom). Naknada za obrazovanje izvan mjesta prebivališta dodjeljuje se roditelju ili skrbniku djeteta ili punoljetnom učeniku kako bi se djelomično pokrili troškovi smještaja djeteta u prostorijama škole ili troškovi prijevoza do škole iz mjesta prebivališta. Iznos doplatka iznosi oko 26 EUR po djetetu ili oko 16 EUR za troškove prijevoza, a isplaćuje se tijekom 10 mjeseci školske godine. Doplatak za veliku obitelj namijenjen je obiteljima s troje i više djece koje imaju pravo na obiteljsku naknadu. Doplatak iznosi 22 EUR mjesečno za svako treće i svako sljedeće dijete u obitelji. Uz to, na raspolaganju je dostupna i dodatna roditeljska naknada u iznosu od oko 366 EUR (MISSOC, 2024).

U danskom sustavu postoji dječja i mladenačka naknada koja se isplaćuje kvartalno za svako dijete, ovisno o dobi (MISSOC, 2024). Pri čemu se naknade smanjuju s povećanjem dobi djeteta. Djeca od 0 do 2 godine dobivaju kvartalnu naknadu u iznosu od 687 EUR, djeca starosti od 3 do 6 godina dobivaju naknadu u iznosu od 544 EUR, a 428 EUR kvartalno isplaćuje se za djecu starosti od 7 do 14 godina. Najmanju naknadu dobivaju djeca u dobi od 15 do 17 godina i ona iznosi 143 EUR. Doplatak za dijete isplaćuje se kvartalno u iznosu od 216 EUR i uglavnom se isplaćuje majci, odnosno roditelju koji ima pravni roditeljski status ili roditelju s kojim dijete živi u slučajevima kada roditelji ne žive zajedno. Rodiljni / očinski / roditeljski dopust i novčane naknade za posvojenje iznose 630 EUR tjedno ili 17 EUR po satu. Subvencije za skrb o vlastitoj djeci ne smiju prelaziti 85 % neto operativnih troškova za dijete smješteno u ustanovi za dnevnu skrb u općini, dok Subvencija za privatni program dnevne skrbi mora iznositi najmanje 75 % od najnižih planiranih neto operativnih troškova po mjestu u javnoj ustanovi za dnevnu skrb. Ne smije prelaziti 75 % dokumentiranih troškova roditelja. Postoji i Subvencija za posvajanje koja u slučaju posvajanja stranog djeteta iznosi 8194 EUR. Naknada za samohrane roditelje isplaćuje se kao dodatak uz opći doplatak za djecu u iznosu 73 EUR mjesečno, po kućanstvu (neovisno o broju djece). Doplatak za zamjenu prihoda za kućnu njegu i/ili obrazovanje djeteta s invaliditetom mlađeg od 18 godina iznosi maksimalno 4728 EUR mjesečno. Također se nadoknađuju dodatni troškovi za čuvanje djeteta s invaliditetom u kući, kao što su troškovi prijevoza i lijekova. Troškovi moraju iznositi minimalno 740 EUR godišnje. Predujam za uzdržavanje u danskom sustavu isplaćuje se u iznosu od 208 EUR mjesečno. Od ostalih naknada izdvaja se Posebna naknada za roditelje koji studiraju i ona iznosi 284 EUR po djetetu po kvartalu, a isplaćuje se svakog kvartala. Naknada se smanjuje kada godišnji prihod korisnika premaši 22 684 EUR. Dodatna naknada za djecu namijenjena je roditeljima tijekom pripravničkog staža i školskih godina, ona iznosi 55 % razlike između državne obrazovne potpore za roditelje i trenutnog prihoda. Naknada se isplaćuje mjesečno i može se dodijeliti samo jednom za svakog roditelja, bez obzira na broj djece. Naknade za više djece iznose 356 EUR po djetetu po kvartalu do 7. rođendana djece, u slučaju rođenja više djece ili usvajanja više djece – braće i/sestra rođene na isti datum. Posebna naknada za djecu isplaćuje se roditeljima koji su, primjerice, odlučili usvojiti kao samohrani roditelj, umirovljenicima itd. i ona iznosi 623 EUR po djetetu po kvartalu. Posebna naknada za umirovljene roditelje može se smanjiti ako obiteljski prihod premaši postavljenu granicu za doplate na socijalne mirovine.

U Luksemburgu doplatak za djecu ne ovisi o dohodovnom cenzusu i iznosi oko 299 EUR mjesečno po djetetu, uz povećanje ovisno o dobi djeteta za oko 22 do oko 57 EUR mjesečno. Roditeljski dopust adekvatna je zamjena za prihod koja se izračunava na temelju prihoda koji ostvaruje roditelj i prosječnog broja radnih sati u 12 mjeseci koji prethode početku roditeljskog dopusta. Za puni roditeljski dopust za radnika s punim radnim vremenom, prihod je ograničen na 5/3 minimalne socijalne plaće (4284,88 EUR mjesečno) i ne može biti manji od minimalne socijalne plaće (2570,93 EUR mjesečno). Naknada za novorođenčad od 1740,09 EUR (jednokratno) dostupna je ženama koje su stanovnice Luksemburga, pod uvjetom da i majka i dijete prođu potrebne medicinske preglede. Posebni dodatak od 200 EUR mjesečno isplaćuje se za svako dijete mlađe od 25 godina koje prima obiteljsku naknadu i ima insuficijenciju ili trajno smanjenje od najmanje 50 % fizičke ili mentalne sposobnosti u usporedbi sa zdravim djetetom iste dobi. U luksemburškom sustavu svaka se alimentacija koja se duguje supružniku ili potomku isplaćuje na zahtjev i pod određenim uvjetima iz nacionalnog solidarnog fonda. Od drugih dodataka za djecu dostupan je dodatak na novu školsku godinu za djecu stariju od 6 godina u iznosu od 115 EUR (od 6 do 11 godina starosti djeteta), odnosno u iznosu od 235 EUR za djecu starosti 12 i više godina (MISSOC, 2024)

U zemljama poput Republike Hrvatske pronatalitetne mjere u populacijskoj politici predstavljaju alat za poticanje gospodarskog rasta, koji je djelomično usporen zbog depopulacije. U Hrvatskoj su žene rođene početkom 20. stoljeća posljednje imale kohortnu stopu fertiliteta iznad troje djece. Odluke o broju djece pod utjecajem su brojnih ekonomskih i kulturoloških čimbenika (Čipin i Međimurec, 2017). Pezer (2020) navodi da je provedeno istraživanje iz 2005. godine pokazalo da žene u Republici Hrvatskoj žele imati više djece (često troje) pod uvjetom da država pruži podršku u rješavanju stambenog pitanja, smanjenju nezaposlenosti i osiguranju društvene infrastrukture koja olakšava majkama ravnotežu između obiteljskog i profesionalnog života. Iako su populacijska i obiteljska politika različite u ciljevima, neke mjere su im zajedničke i međusobno se nadopunjuju. Prethodno prikazana analiza na odabranim zemljama članicama Europske unije može poslužiti kao temelj za uvođenje nekih novih pronatalitetnih mjera koje će pridonijeti demografskom oporavku Republike Hrvatske.

5. EMPIRIJSKO ISTRAŽIVANJE EKONOMSKIH PREDIKTORA NAMJERE RAĐANJA U REPUBLICI HRVATSKOJ

Nakon uvodnih i teorijskih razmatranja u kojima su detaljno objašnjeni demografski tranzicijski procesi kroz temeljne etape demografske tranzicije, ekonomske teorije fertiliteta te javne politike i njihov utjecaj na namjeru rađanja, u ovom poglavlju doktorskog rada pozornost je posvećena metodologiji istraživanja. Polazište za metodološki pristup čine istraživački ciljevi i hipoteze te se potom pristupa metodama koje su primijenjene za prikupljanje podataka i testiranje postavljenih istraživačkih hipoteza.

Testiranje postavljenih hipoteza temelji se na primjeni kvantitativne metodologije koja je uobičajena u društvenim znanostima i zahtijeva testiranje pouzdanosti i valjanosti podataka. Kvantitativna istraživanja su istraživačke metode koje se koriste za prikupljanje, analizu i interpretaciju numeričkih podataka kako bi se razumjeli i objasnili određeni fenomeni, veze između varijabli, i obrasci ponašanja u populaciji ili uzorku. Ova vrsta istraživanja usmjerava se na kvantifikaciju podataka i primjenu statističkih analiza radi donošenja zaključaka. Horvat i Mijoč (2019: 310) pouzdanost definiraju kao „dosljednost ispitanikovih odgovora pri istovjetnom ili sličnom pitanju, a istraživači nastoje odgovoriti na pitanje mjeri li skup promatranih varijabla (čestica) isti konstrukt“. Kvantitativna istraživanja, uključujući i anketno istraživanje, često su povezana s deduktivnim istraživačkim pristupom. Brojne su prednosti kvantitativnih istraživanja, a Goertzen (2017: 13) izdvaja najznačajnije: a) rezultati se mogu generalizirati na određenu populaciju, b) instrumenti i metode mogu se dijeliti i replicirati te c) standardizirani pristupi omogućuju ponavljanje istraživanja tijekom vremena.

Kvantitativne metode koje su primijenjene u doktorskom radu: anketiranje, arhivska metoda te neparametrijske statističke metode.

5.1. Metodologija istraživanja

Prilikom izrade doktorskog rada korišteni su sekundarni kvantitativni podatci koji su kroz empirijsko istraživanje upotpunjeni dobivenim primarnim podatcima metodom anketiranja. Sekundarni podatci, koji podrazumijevaju sustavno kategorizirana prethodna istraživanja iz znanstvenih članaka i knjiga, čine teorijski dio doktorskog rada, odnosno pregled

literature. Povijesni pregled dosadašnjih istraživanja važnih za razumijevanje ključnih pojmova i dosadašnjih teorijskih spoznaja omogućio je proširenje znanja o predmetu istraživanja dok je analiza primarnih podataka osigurala ostvarenje glavnog cilja doktorskog rada.

Analiza podataka dobivenih primarnim istraživanjem obuhvaća *univarijatnu* (deskriptivna statistika, frekvencije, aritmetičke sredine i standardne divijacije), *bivarijatnu* (Spearmanov koeficijent korelacije ranga, Kruskal-Wallisov test i Mann-Whitney U test) i *multivarijatnu* statistiku (logistički regresijski model).

Za testiranje postavljenih hipoteza H1 i H3 (potpoglavlje 1.3.) odabrana je logistička regresija jer je namjera rađanja kreirana kao dihotomna varijabla, dok je npr. modeliranje strukturalnim jednadžbama primarno usmjereno na varijable na intervalnoj ili omjernoj ljestvici. Nadalje, *logit* model omogućuje strukturiranu i analitički valjanu analizu koja uzima u obzir specifičnosti binarne kriterijske varijable. Dodatno, ova metoda je dovoljno fleksibilna da na primjeren način uzme u obzir kako i raznolikost čimbenika (prediktora) rađanja, tako i njihove eventualne nelinearnosti i/ili međuovisnosti. Odabrana statistička analiza u skladu je i s dosadašnjim provedenim istraživanjima u kojima su autori koristili *probit*/*logit* modele prilikom ispitivanja namjere i realizacije rađanja (Chen i sur., 2024; Golub i sur., 2023; Peng i sur., 2023; Li i Xu, 2022; Hu i sur., 2022; Bano i sur., 2021; Ciritel i sur., 2019; Riederer i Buber-Ennser, 2019; Barbos i Milovanska-Farrington, 2019; Azmoude i sur., 2017; Modena i sur., 2014; Fiori i sur., 2013; Adsera, 2006). *Probit* i *logit* regresijski modeli objašnjeni su u potpoglavlju 5.6.3.

U statističku analizu uključene su i kontrolne varijable koje se vežu uz svakog pojedinog ispitanika, poput starosne dobi žene, pariteta, sektora zaposlenja, vrste ugovora o radu, radnog vremena, prihoda kućanstva, mogućnosti podmirivanja financijskih obveza, tipa naselja, regionalne razvijenosti, stupnja obrazovanja ili statusa vlasništva nad nekretninom.

Analiza rezultata primarnog istraživanja univarijatne, bivarijatne i multivarijatne statistike izvršena je primjenom programskog paketa *Statistical Package for the Social Science* (SPSS) for Windows 25.0.

5.2. Dizajn istraživanja

Dizajn istraživanja opći je plan za dobivanje odgovora na istraživačka pitanja sukladno postavljenim istraživačkim ciljevima i svrsi istraživanja, prikupljanje podataka te njihovu analizu i interpretaciju. Istraživačka pitanja u doktorskom radu proizašla iz postavljenih ciljeva i svrhe istraživanja:

1. Utječe li ekonomska sigurnost na namjeru rađanja u Republici Hrvatskoj?
2. Dovodi li ekonomska nesigurnost do jaza između željenog i ostvarenog broja djece?
3. Utječu li fiskalni instrumenti javnih politika na namjeru rađanja?
4. Je li stupanj razvijenosti četiriju hrvatskih regija, a koji je mjeren indeksom razvijenosti, relevantan za objašnjenje namjere rađanja?

Sukladno postavljenim istraživačkim pitanjima i ciljevima, nužno je odabrati istraživačku strategiju koja će se dosljedno primjenjivati tijekom cijelog istraživačkog procesa. Taj proces obuhvaća šest ključnih koraka: istraživačku filozofiju, istraživačku logiku, istraživačku strategiju, istraživački pristup, vremenski horizont te metode prikupljanja podataka (Saunders i sur., 2019).

Kako bi se osigurala pouzdanost i valjanost provedenog istraživanja, u doktorskom radu primijenjeni su koraci istraživačkog procesa. Istraživački proces na ilustrativan način prikazuje metode i postupke koji se mogu koristiti u istraživačkom procesu s ciljem razvoja konačnog dizajna istraživanja (Saunders, i sur., 2019). Koraci istraživačkog procesa prikazani na slici 7. često se nazivaju i „istraživački luk“ te su ga autori Saunders, i sur. (2019) kreirali kako bi pomogao istraživačima u procesu donošenja odluka te pronašli odgovarajuće metode za svoje istraživanje. Muranganwa (2016) navodi da koncepti istraživačkog luka stvaraju čvrstu osnovu za razvoj koherentnog i opravdanog istraživačkog dizajna. Raithatha (2017) također tvrdi da se na temelju modela istraživačkog luka može korak po korak osmisliti odgovarajuća istraživačka metodologija koja će rezultirati uspješnim istraživačkim radom te se stoga može koristiti kao glavni model za akademsko istraživanje. Istraživački luk je učinkovit model široko korišten u društvenim i prirodnim znanostima (Raithatha, 2017; Ramdhani i sur., 2017; Muranganwa, 2016).

Dobro promišljen i dosljedan skup pretpostavki čini vjerodostojnu istraživačku filozofiju koja podupire metodološki izbor, strategiju istraživanja i tehnike prikupljanja podataka i postupke analize. To omogućava osmišljavanje koherentanog istraživačkog projekta u koji se uklapaju svi elementi istraživanja. Johnson i Clark (2006, u Saunders i sur., 2019) naglašavaju da izbor istraživačke strategije ima značajan utjecaj na shvaćanje predmeta istraživanja, načina provođenja istraživanja te načina razumijevanja istoga.

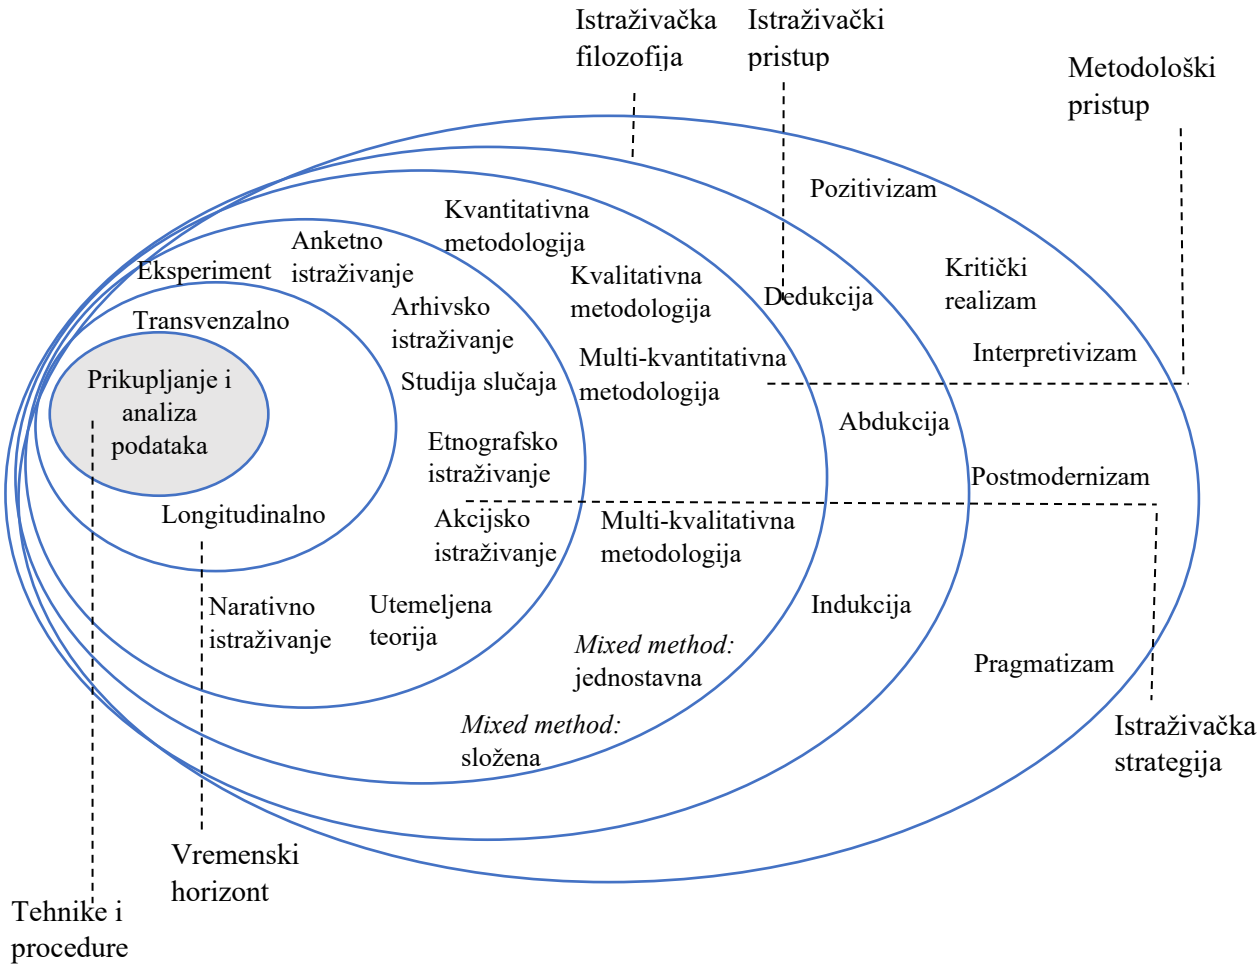

Slika 7. Koraci istraživačkog procesa
Izvor: izrada doktorandice (Saunders i sur., 2019: 174)

U nastavku su objašnjeni koraci istraživačkog dizajna, stavljajući naglasak na elemente koji su korišteni u ovome doktorskom radu. Prvi korak istraživačkog procesa obuhvaća izbor

istraživačke filozofije koja predstavlja skup osnovnih uvjerenja na temelju kojih se provodi istraživanje. Pet je vrsta istraživačke filozofije: pozitivizam, kritički realizam, interpretizam, postmodernizam i pragmatizam. Prema Žukauskas i sur. (2018) filozofija znanstvenog istraživanja je sustav mišljenja istraživača na temelju kojeg se dolazi do novih, pouzdanih spoznaja o predmetu istraživanja. Drugim riječima, to je temelj istraživanja koji uključuje izbor strategije istraživanja, formuliranje problema, prikupljanje, obradu i analizu podataka. Paradigmu znanstvenog istraživanja pak čine ontologija, epistemologija, metodologija i metode.

Prema Scotland (2012) ontologija je proučavanje bića. Ontološke pretpostavke bave se onim što čini stvarnost, drugim riječima što jest. Istraživači moraju zauzeti stav o svojim percepcijama o tome kako stvari stvarno stoje i kako stvari stvarno funkcioniraju. Nadalje, autor epistemiologiju temelji na znanju. Epistemološke pretpostavke bave se time kako se znanje može stvoriti, steći i komunicirati, drugim riječima što znači znati.

„Svaka paradigma temelji se na vlastitim ontološkim i epistemološkim pretpostavkama. Budući da su sve pretpostavke nagađanja, filozofska podloga svake paradigme nikada se ne može empirijski dokazati ili opovrgnuti. Različite paradigme inherentno sadrže različite ontološke i epistemološke poglede; stoga imaju različite pretpostavke o stvarnosti i znanju koje podupiru njihov poseban istraživački pristup. To se ogleda u njihovoj metodologiji i metodama“ (Scotland, 2012: 9).

Metodologija predstavlja strategiju ili plan djelovanja koji stoji iza izbora i upotrebe određenih metoda. Prema tomu, metodologija se bavi time zašto, što, odakle, kada i kako se podatci prikupljaju i analiziraju. Guba i Lincon (1994. u Scotland, 2012) objašnjavaju da metodologija postavlja pitanje: kako ispitivač može pronaći ono što vjeruje da se može znati?

Metode su specifične tehnike i postupci koji se koriste za prikupljanje i analizu podataka. Prikupljeni podatci mogu biti kvalitativni ili kvantitativni. Sve paradigme mogu koristiti i kvantitativne i kvalitativne podatke. Metode istraživanja mogu se pratiti unatrag, kroz metodologiju i epistemologiju, do ontološke pozicije.

Istraživačka filozofija prvi je korak u istraživačkom procesu i može biti opisana sukladno ontološkom ili epistemološkom pristupu na temelju čijih se karakteristika izabire

metodologija, a potom i metode. Ovaj doktorski rad temelji se na epistemološkom pristupu, odnosno istraživačkoj filozofiji pozitivizma. Prema Saunders i sur. (2019) pozitivisti se usredotočuju na otkrivanje vidljivih i mjerljivih činjenica i pravilnosti, a samo fenomeni koji se mogu promatrati i mjeriti dovode do stvaranja vjerodostojnih i smislenih podataka. Pozitivisti su usredotočeni na traženje uzročnih odnosa u podatcima i generalizaciju. Autori navode da istraživači koji svoje istraživanje temelje na pozitivizmu mogu koristiti postojeću teoriju kako bi postavili hipoteze koje će se potom testirati i ne odbaciti (u cijelosti ili djelomično), ili pak odbaciti, što će na koncu dovesti do daljnjeg razvoja teorije koja se može testirati dodatnim istraživanjem. Međutim, navedeno ne znači da istraživač mora nužno započeti s postojećom teorijom. Sve prirodne znanosti razvile su se iz interakcije sa svijetom u kojem su prikupljeni podatci i promatranja napravljena prije formuliranja i testiranja hipoteza. Zapravo, originalni pozitivisti naglašavali su važnost induktivnog istraživanja zbog važnosti empirijskih podataka, iako se danas pozitivistička istraživanja često okreću prema deduktivnom pristupu. U ovome pristupu, pozitivisti moraju zadržati neutralnost prilikom istraživanja i prikupljanja podataka kako bi se izbjegao utjecaj na istraživačke nalaze/rezultate.

Istraživački pristup drugi je korak u istraživačkom procesu te može biti induktivni, deduktivni i abduktivni. Kako je prethodno navedeno, uz pozitivistička istraživanja veže se deduktivni pristup, stoga se u ovome doktorskom radu primjenjuje navedeni istraživački pristup. Saunders i sur. (2019) navode nekoliko važnih karakteristika deduktivnog pristupa: traženje objašnjenja uzročnih odnosa između pojmova i varijabli; korištenje visoko strukturirane metodologije kako bi se olakšala reprodukcija, što je važno pitanje za osiguranje pouzdanosti istraživanja; operacionalizacija pojmova na način koji omogućuje mjerenje činjenica, često kvantitativno te generalizacija koja se veže uz odabir uzorka i njegove veličine.

Treći korak u istraživačkom procesu je metodološki pristup. Razlikujemo kvantitativno i kvalitativno istraživanje. Prema Saunders i sur. (2019) jedan način razlikovanja kvantitativnog istraživanja od kvalitativnog istraživanja je razlikovanje između numeričkih podataka (brojeva) i nenumeričkih podataka (riječi, slike, audiozapisi, videoisječci i drugi slični materijali). Na taj način, „kvantitativno“ se često koristi kao sinonim za bilo koju tehniku prikupljanja podataka (kao što je upitnik) ili postupak analize podataka (kao što su grafovi ili statistika) koji generira ili koristi numeričke podatke. Nasuprot tomu, „kvalitativno“ se često koristi kao sinonim za bilo koju tehniku prikupljanja podataka (kao što su intervjui) ili postupak analize podataka (kao što je kategorizacija podataka) koji generira ili koristi nebrojčane

podatke. Kako bi se postigao cilj istraživanja korištena je kvantitativna metodologija. Kvantitativni dizajni istraživanja općenito su povezani s pozitivizmom, osobito kada se koriste s unaprijed određenim i visoko strukturiranim tehnikama prikupljanja podataka.

Istraživačka strategija četvrti je korak u procesu istraživanja i predstavlja plan djelovanja za postizanje istraživačkog cilja. U ovom doktorskom radu primijenjeno je anketno i arhivsko istraživanje (engl. *Archival research*). Anketno istraživanje često je povezano s deduktivnim istraživačkim pristupom i kvantitativnim istraživanjem. Saunders sur. (2019) navode da se podatci prikupljeni upitnikom mogu kvantitativno analizirati s pomoću deskriptivne i inferencijalne statistike, osim toga, prikupljeni podatci upućuju na moguće razloge određenih odnosa između varijabli i koriste se za izradu modela na temelju utvrđenih odnosa. Korištenje strategije ankete istraživaču daje veću kontrolu nad procesom istraživanja i kada se koristi uzorkovanje vjerojatnosti, moguće je generirati nalaze koji su statistički reprezentativni za cijelu populaciju po nižoj cijeni od prikupljanja podataka za cijelu populaciju. Arhivsko istraživanje temelji se na sekundarnim podatcima koji su objavljeni i javno dostupni. Primjena arhivskog istraživanja u doktorskom radu odnosi se na prikupljanje kvantitativnih podataka koji su korišteni za prikaz demografskih trendova.

Peti korak u istraživačkom procesu odnosi se na vremenski horizont u kojemu se istraživač opredjeljuje između longitudinalnog i transverzalnog istraživanja. Longitudinalno istraživanje provodi se kroz više trenutaka/razdoblja kako bi se proučile promjene i razvoj predmeta istraživanja. Za razliku od longitudinalnog, transverzalno istraživanje uključuje istraživanje predmeta istraživanja u određenom trenutku. Sukladno postavljenim istraživačkim ciljevima doktorskog rada, primjenjuje se transverzalno istraživanje.

Tehnike i procedure vezane uz prikupljanje i analizu podataka predstavljaju posljednji korak u istraživačkom procesu. U kontekstu prethodno opisanih istraživačkih koraka, slika 8. prikazuje skraćeni dizajn istraživanja ovog doktorskog rada.

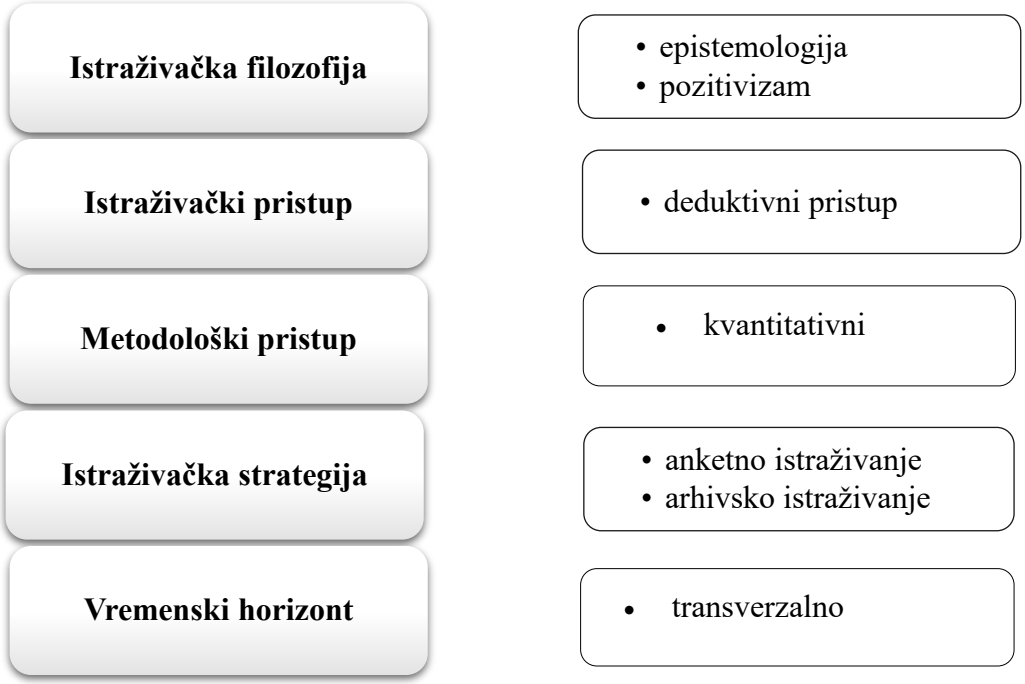

Slika 8. Dizajn istraživanja doktorskog rada
Izvor: izrada doktorandice prema slici 6.

U nastavku je opisan okvir izbora uzorka za provođenje empirijskog istraživanja.

5.3. Okvir izbora uzorka

Dobna granica žena koje su obuhvaćene istraživanjem definirana je uzimajući u obzir reproduktivno razdoblje žene te trend broja rođene djece prema starosti majke (grafikon 4. i tablica 17.). Stoga se za potrebe ovog doktorskog rada u istraživanju obuhvaćaju žene starosti 22 do 49 godina. Veličina populacije za navedenu dobnu skupinu je N = 668 603 (Državni zavod za statistiku, 2021a) i prikazana je u tablici 17.

Tablica 17. Živorođeni prema starosti majke

Starost majke	**Broj rođene djece**						**Ukupan broj žena 2021.**
	2016.	**2017.**	**2018.**	**2019.**	**2020.**	**2021.**	
22	997	961	943	923	914	793	19 919
23	1216	1081	1152	1084	1122	1088	21 057
24	1368	1336	1264	1244	1261	1280	21 914
25	1643	1534	1524	1454	1470	1578	21 877
26	1835	1818	1811	1738	1711	1757	21 093
27	2238	2109	2072	1974	2079	2079	20 986

28	2537	2331	2295	2291	2241	2315	20 883
29	2693	2555	2616	2392	2531	2458	20 189
30	2715	2692	2743	2583	2543	2655	21 768
31	2860	2581	2640	2612	2576	2671	21 943
32	2682	2646	2644	2529	2510	2546	22 089
33	2365	2446	2503	2384	2317	2330	22 904
34	2157	2117	2257	2220	2206	2158	23 304
35	1868	1890	1969	2008	1937	2056	23 778
36	1562	1596	1678	1665	1665	1848	24 806
37	1267	1369	1310	1371	1342	1476	25 712
38	929	1007	1030	1082	1118	1109	25 808
39	705	747	758	809	830	895	26 146
40	533	539	517	618	596	682	26 270
41	315	315	390	365	419	430	26 662
42	176	193	239	239	258	265	26 963
43	126	127	121	114	147	132	26 469
44	58	77	70	94	67	73	26 301
45	28	32	32	41	41	35	26 311
46	13	16	18	18	13	18	25 939
47	7	8	7	14	6	8	25 761
48	3	4	7	5	6	6	25 909
49	2	1	1	4	3	4	25 842
Ukupno	**34 898**	**34 128**	**34 611**	**33 875**	**33 929**	**34 745**	**668 603**

Izvor: izrada doktorandice (Državni zavod za statistiku, 2021a, 2021b)

Iz tablice 17. i grafikona 4. vidljivo je da je tijekom 2021. godine rođeno ukupno 34 745 djece, pri čemu je najveći broj živorođene djece od majki starosti 30 i 31 godine. Očekivano, žene koje su pri kraju svog fertilnog razdoblja rodile su najmanje djece tijekom 2021. godine.

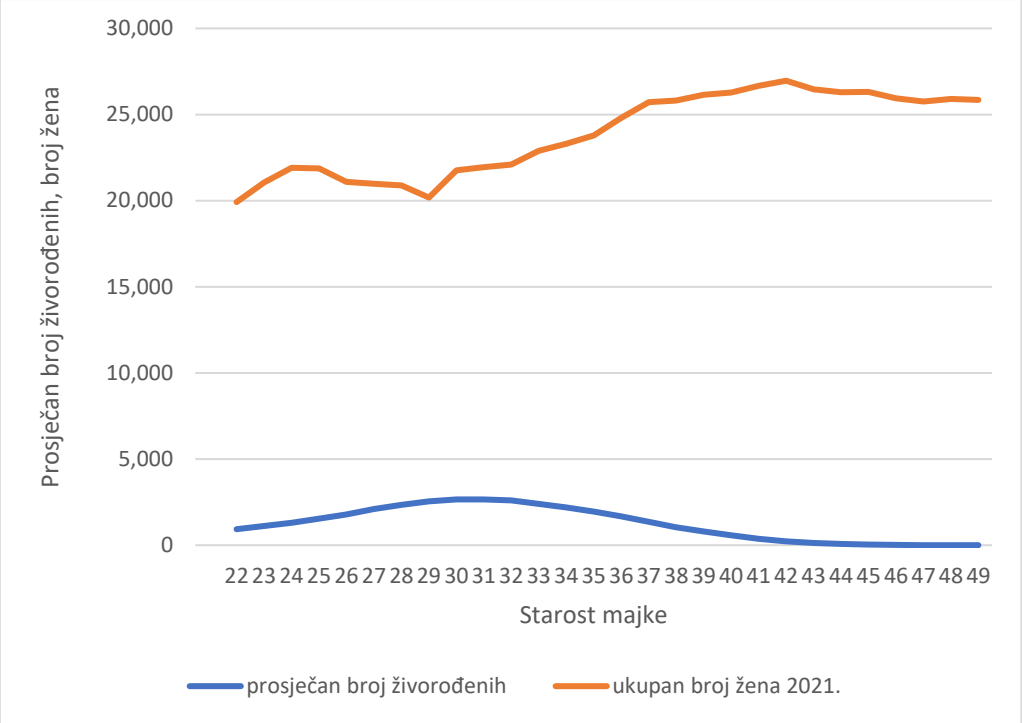

Grafikon 4. Prosječan broj živorođenih prema starosti majke
Izvor: izrada doktorandice prema tablici 17.

Sukladno veličini populacije, uz razinu pouzdanosti od 95 % i dopuštenu pogrešku od 5 %, potrebna veličina uzorka je 384 (Horvat i Mijoč, 2019: 346).

Istraživanje je provedeno na razini cijele Republike Hrvatske, prostorno obuhvaćajući jedinice područne (regionalne) samouprave podijeljene u četiri skupine sukladno indeksu razvijenosti. Jedinice područne (regionalne) samouprave razvrstane su prema indeksu razvijenosti[16]:

- „I. skupinu jedinica područne (regionalne) samouprave: Brodsko-posavska županija, Požeško-slavonska županija, Sisačko-moslavačka županija, Virovitičko-podravska županija i Vukovarsko-srijemska županija
- II. skupinu jedinica područne (regionalne) samouprave: Bjelovarsko-bilogorska županija, Karlovačka županija, Koprivničko-križevačka županija, Ličko-senjska županija, Osječko-baranjska županija i Šibensko-kninska županija

[16] Više o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti dostupno u NN 3/2024 (https://narodne-novine.nn.hr/clanci/sluzbeni/2024_01_3_60.html)

- III. skupinu jedinica područne (regionalne) samouprave: Krapinsko-zagorska županija, Međimurska županija, Primorsko-goranska županija, Splitsko-dalmatinska županija i Varaždinska županija
- IV. skupinu jedinica područne (regionalne) samouprave: Dubrovačko-neretvanska županija, Grad Zagreb, Istarska županija, Zadarska županija i Zagrebačka županija“ (NN 3/2024).

U nastavku su objašnjene metode i proces prikupljanja podataka za ostvarenje postavljenih ciljeva doktorskog rada.

5.4. Metode i proces prikupljanja podataka

Sastavni dio istraživačkog procesa jest prikupljanje podataka i odabir prikladne metode za prikupljanje podataka. Razlikujemo primarne i sekundarne podatke. Primarni podatci se odnose na primarno prikupljanje podataka za potrebe istraživanja kako bi se ostvario istraživački cilj. Za razliku od primarnih podataka, sekundarni podatci već su prikupljeni i objavljeni u neku drugu svrhu, a omogućuju prijenos podataka kroz vrijeme i prostor i ponovnu analizu u svrhu koja se razlikuje od one za koju su izvorno prikupljeni.

Dok je glavna prednost primarnih podataka originalnost sukladno specifičnim potrebama predmeta istraživanja, nedostatci se ogledaju u raspoloživosti vremena za prikupljanje podataka, financijskim implikacijama prikupljanja i unosa podataka te dostupnosti pomoćnika ili ovlaštenih agencija za provođenje istraživanja. Budući da su sekundarni podatci prikupljeni u drugu svrhu od one koja se provodi istraživanjem, nužno je provesti evaluaciju takvih podataka sukladno sljedećim kriterijima:

- vrijeme prikupljanja podataka: podatci moraju biti ažurirani
- točnost podataka: odnosi se na svrhu (prezentiranje) podataka; tko je prikupio podatke i način prikupljanja podataka
- relevantnost podataka: važno je da su podatci primjenjivi na istraživačke ciljeve i istraživačka pitanja; podatci mogu biti točni i ažurirani, ali možda neće biti relevantni za naše specifične istraživačke potrebe

- troškovi podataka: ako troškovi nadmašuju koristi treba razmisliti o drugim metodama prikupljanja podataka (Sekaran i Bougie, 2016: 38).

Prilikom pisanja doktorskog rada uvaženi su svi prethodno navedeni kriteriji.

Sukladno postavljenim ciljevima i istraživačkim pitanjima, u doktorskom radu su korišteni primarni podatci prikupljeni metodom upitnika te sekundarni podatci koristeći se arhivskom metodom prikupljanja kvantitativnih podataka iz javno dostupnih izvora.

5.4.1. Arhivsko istraživanje

Digitalizacija podataka i stvaranje *online* baza podataka dalo je na značaju arhivskoj ili dokumentiranoj istraživačkoj strategiji. Ovu strategiju odlikuje mogućnost pristupa podatcima iz svih dijelova svijeta te je time istraživačima omogućeno da oblikuju istraživačke aktivnosti koristeći različite izvore sekundarnih podataka. Za potrebe ovog doktorskog rada korišteni su dokumenti poput publikacija, izvješća i statističkih podataka za koje autori Saunders i sur. (2019) navode da pripadaju sekundarnim podatcima prikupljenim arhivskim istraživanjem.[17]

5.4.2. Anketno istraživanje

Sekaran i Bougie (2016) navode da je upitnik instrument za prikupljanje informacija od ljudi ili o njima kako bi se opisivalo, uspoređivalo ili objašnjavalo njihovo znanje, stavovi i ponašanje. Nadalje, „upitnik je unaprijed formuliran pisani skup pitanja na koje ispitanici bilježe svoje odgovore, obično unutar prilično usko definiranih alternativa“ (Sekaran i Bougie, 2016: 142).

Metoda ankete vrlo je popularna u istraživanjima u poslovnom svijetu jer omogućava istraživaču prikupljanje kvantitativnih i kvalitativnih podataka sukladno istraživačkom problemu i pitanjima. Upitnici su općenito dizajnirani za prikupljanje velikog broja kvantitativnih podataka. Mogu se provoditi osobno, distribuirati ispitanicima elektroničkim ili *online* kanalom ili elektroničkom poštom. Upitnici su općenito jeftiniji i dugotrajniji od intervjua i promatranja, ali također donose mnogo veću mogućnost neodgovaranja i greške u neodgovaranju. U nastavku tablica 18. prikazuje prednosti i nedostatke različitih vrsta upitnika.

[17] Obuhvat tekstualnih dokumenata u arhivskom i dokumentiranom istraživanju naveden je u Saunders, Lewis i Thornhill (2019: 195).

Tablica 18. Prednosti i nedostatci različitih vrsta upitnika

Način prikupljanja podataka	Prednosti	Nedostaci
Osobno	• moguće je uspostaviti odnos i motivirati ispitanika • moguće je razjasniti nedoumice • manji troškovi kada se primjenjuju na grupe ispitanika • gotovo 100 % stopa odgovora zajamčena • anonimnost ispitanika je visoka • simbolični pokloni kao zahvala	• pristranost prilikom objašnjavanja • iziskuje puno vremena i truda
Elektroničkim ili online kanalom	• lako za provoditi • moguće doseći globalno • vrlo jeftino • brza dostava odgovora • ispitanici mogu odgovarati kada im odgovara • automatska obrada odgovora	• informatička pismenost • problem uzorkovanja • visoka stopa neispunjavanja • izostanak motivacije za ispunjavanje upitnika • ljudi smatraju da su pozivnice putem e-pošte nepristojne i uvredljive; e-pošte se brišu ili se ljudi žale
Elektroničkom poštom	• visoka razina anonimnosti • mogućnost primjene na širokim geografskim rasponima • simbolični pokloni kao motivacija i zahvala • ispitanik može izdvojiti više vremena za ispunjavanje upitnika iz udobnosti vlastitog doma.	• niska stopa ispunjavanja • izostanak mogućnosti pojašnjavanja pitanja • nužno je primijeniti postupke praćenja za nepostojeće odgovore.

Izvor: prilagodba doktorandice (Sekaran i Bougie, 2016: 144)

U svrhu prikupljanja primarnih podataka doktorandica je kreirala upitnik na temelju standardiziranih validiranih upitnika (Gauthier i sur., 2022; Testa, 2006; United Nations Economic Commission for Europe UNECE, 1992) te na temelju prethodnih empirijskih istraživanja (Riederer i Buber-Ennser, 2019; Ciritel i sur., 2019; Fiori i sur., 2013; Fahlén i Oláh; 2015; Modena i sur., 2014; Adsera, 2006) u skladu s prethodno postavljenim ciljevima i hipotezama.

Empirijsko anketno istraživanje je provedeno na reprezentativnom uzorku od 1233 ispitanika od čega je 1055 ispitanika odgovorilo na upitnik u cijelosti. Nakon logičke kontrole odgovora te provjere dužine odgovaranja na upitnik iz baze je obrisano 19 ispitanika. Provjera je obuhvatila pregled otvorenih odgovora, logičku kontrolu međusobno usporedivih odgovora, kontrolu *straightlining-a*. Na temelju tih komponenti, prepoznati su sudionici sa nešto nižom kvalitetom odgovora. Konačna baza sadržavala je odgovore 1036 žena.

Tijekom veljače 2024. godine stručnjaci iz agencije za ispitivanje javnog mnijenja Valicon d. o. o. proveli su kvantitativno istraživanje na pripadnicima ženske opće populacije građana Republike Hrvatske starih od 22 do 49 godina s djecom i bez djece, prostorno obuhvaćajući jedinice područne (regionalne) samouprave podijeljene u četiri skupine sukladno indeksu razvijenosti. Prikupljanje za ovo istraživanje započeto je 8. veljače 2024. a završeno 15. veljače 2024. 8. veljače 2024. pozvan je 181 panelist kako bi se na manjem uzorku provjerila točnost samog upitnika, a potom je primijenjena sljedeća dinamika pozivanja ispitanika i slanja podsjetnika prikazana u tablici 19.

Tablica 19. Dinamika pozivanja ispitanika i broj poziva

Datum	**Vrsta poziva**	**Broj poziva**
8. 2. 2024.	Pozivnica	181
9. 2. 2024.	Pozivnica	278
9. 2. 2024.	Pozivnica	1643
10. 2. 2024.	Pozivnica	1593
11. 2. 2024.	Podsjetnik	753
12. 2. 2024.	Pozivnica	628
12. 2. 2024.	Pozivnica	242
13. 2. 2024.	Pozivnica	48
14. 2. 2024	Podsjetnik	158
15. 2. 2024	Pozivnica	103

Izvor: Valicon d. o. o.

Nakon prvog poziva za sudjelovanje u anketi i provjere ispravnosti upitnika poslan je poziv na preostale kontakte. Nakon prvog poziva poslano je sedam dodatnih poziva te dva podsjetnika. Odaziv na ovo istraživanje bio je 26,14 % ukoliko se u obzir uzmu svi koji su sudjelovali u istraživanju, odnosno 22,37 % ako se u obzir uzmu samo ispitanici koji su u cijelosti odgovorili na anketu. Podsjetnike su primali samo panelisti, unutar kvota koje nisu bile popunjene, koji do tog trenutka nisu uopće započeli anketu i oni koji su započeli, ali ju nisu popunili do kraja.

Anketiranje je provedeno CAWI tehnikom (engl. *Computer-assisted web interviewing*), odnosno tehnikom kompjuterski podržanog osobnog anketirana ispitanika putem *web* linka. Kod *online* djela istraživanja ispitanici su unaprijed dali privolu za sudjelovanje u istraživanjima i korištenjem osobnih podataka pri učlanjenju u panel agencije u skladu s Općom uredbom o zaštiti podataka (GDPR).

Upitnik je sadržavao izjave mjerene Likertovom ljestvicom od 1 do 5 te socio-demografska pitanja, odnosno pitanja kojima su se prikupili podatci o socio-demografskim karakteristikama ispitanika.

Ponderiranje je provedeno pomoću RIM (engl. *Random Iterative Method*) procedure ponderiranja, a ponderi su kreirani na osnovu populacijskih podataka iz popisa stanovništva Državnog zavoda za statistiku iz 2021. Korištena je RIM procedura koja prilagođava distribuciju kontrolnih varijabli prema strukturi populacije. RIM ponderiranje dizajnirano je tako da ponderira karakteristike simultano. Tijekom postupka RIM ponderiranja procedura nastoji zadržati sve željene proporcije istovremeno „iskrivljujući“ svaku varijablu što je manje moguće. RIM ponderiranje izračunava pondere koristeći različite regresijske analize. Ovaj postupak ima dva uvjeta:

- limit – koji definira koliko se blizu primjenom procedure ponderiranja treba približiti ciljnim vrijednostima kako bi ponderi bili prihvatljivi
- broj iteracija – koji definira koliko se puta postupak izračunavanja pondera može ponavljati s ciljem dosezanja željenih vrijednosti.

U nastavku se nalazi tablica podataka prema omjerima unutar regija, obrazovanja i dobnih skupina gdje su uspoređeni populacijski podatci, prikupljeni neponderirani podatci te u konačnici ponderirani podatci RIM metodom.

Tablica 20. Ponderiranje podataka korištenjem RIM procedure

	Populacijski podatci	**Ponderirani podatci**	**Neponderirani podatci**
I. skupina razvijenosti	13,8 %	13,8 %	14,2 %
II. skupina razvijenosti	23,5 %	23,5 %	19,0 %
III. skupina razvijenosti	20,5 %	20,5 %	21,8 %
IV. skupina razvijenosti	42,2 %	42,2 %	45,0 %
Ukupno	100,0 %	100,0 %	100,0 %
Srednje ili niže obrazovanje	58,4 %	58,4 %	41,5 %
Više obrazovanje	41,6 %	41,6 %	58,5 %
Ukupno	100,0 %	100,0 %	100,0 %
22-29	24,9 %	24,9 %	23,7 %
30-39	35,8 %	35,8 %	37,1 %
40-49	39,3 %	39,3 %	39,2 %
Ukupno	100,0 %	100,0 %	100,0 %

Izvor: Valicon d. o. o.

U nastavku su objašnjene metode ocjenjivanja pouzdanosti i valjanosti mjernog instrumenta.

5.5. Metode ocjenjivanja pouzdanosti i valjanosti mjerenja

Glavni izazov mjernih instrumenata je interna konzistentnost stavki, odnosno provjera koliko se odabrane stavke međusobno usklađuju. Pouzdanost konstrukata definira se kao „procjena stupnja konzistentnosti između različitih mjernih čestica jedne varijable“ (Hair i sur., 2010: 125). Najčešće korištena mjera unutarnje pouzdanosti konstrukata je Cronbachova alfa. Osim metoda unutarnje konzistentnosti (koeficijent unutarnje dosljednosti – Cronbachova alfa i metoda ekvivalentnih polovina) moguće je primijeniti i metode stabilnosti (test-retest i metoda alternativnog oblika).

Cronbachova alfa u doktorskom radu korištena je za testiranje pouzdanosti prediktorskih varijabla: financijska sigurnost, sigurnost posla, stambeni uvjeti, neizravni novčani transferi, izravni novčani transferi, transferi u naravi, stavovi, subjektivne norme i

percipirana kontrola ponašanja. „Koeficijent Cronbachova alfa odgovara na pitanje donosi li skup različitih čestica (izjava) dosljedne rezultate“ (Horvat i Mijoč, 2019: 312).

Matematički izraz za izračun pouzdanosti konstrukta je sljedeći:

$$\alpha = \frac{n}{n-1}\left(1 - \frac{\sum s_i^2}{s_x^2}\right)$$

pri čemu je:

α – koeficijent Cronbachove alfe

n – broj čestica mjernog instrumenta

s_i^2 – varijanca *i*-čestice, gdje je i = 1, 2, 3, …, k

s_x^2 – varijanca mjernog instrumenta.

Rezultati koeficijenta kreću se u intervalu 0 do 1, pri čemu vrijednosti bliže 1 ukazuju na veću pouzdanost mjernog instrumenta. Istraživači imaju različite pristupe u tumačenju prihvatljivih granica vrijednosti koeficijenta Cronbachove alfe. Stoga Bagozzi i Yi (1988) smatraju prihvatljivom vrijednosti iznad 0,6, dok Nunnally (1979) smatra prihvatljive rezultate veće od 0,7, ali navodi da je uputno težiti koeficijentima iznad 0,8.

Vrijednosti koeficijenata Cronbachove alfe osjetljivi su na broj čestica. Stoga treba pomno odabrati broj čestica vodeći računa da se ne uključuje premali niti preveliki broj čestica u konstrukt, jer se može očekivati da će manji broj čestica rezultirati manjom vrijednošću koeficijenta i obrnuto. Rezultati pouzdanosti konstrukta prikazani su u nastavku.

Važno je napomenuti da su prije kreiranja konstrukata provjerene aritmetičke sredine i medijalne vrijednosti te je utvrđeno da medijalne vrijednosti ne odstupaju značajno od prosjeka, stoga su konstrukti kreirani na temelju prosječnih vrijednosti.

Tablica 21., tablica 22. i tablica 23. prikazuju čestice kojima su mjereni konstrukti u upitniku, odnosno prediktorske varijable za testiranje postavljenih hipoteza. Ispitanice su izrazile stupanj utjecaja na njihovu odluku o tome da imaju dijete/još jedno dijete koristeći Likertovu ljestvicu: 1 – u potpunosti ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 – u potpunosti bi utjecalo.

Tablica 21. Mjerenje ekonomske sigurnosti

Konstrukt	Čestica	n*	Min	Max	x̄	s
Financijska sigurnost	Q7_FS.1 Visina prihoda kućanstva	363	1	5	3,87	1,131
	Q7_FS.2 Ušteđevina	363	1	5	3,63	1,194
	Q7_FS.3 Financijska pomoć od strane obitelji/prijatelja/bliskih ljudi	363	1	5	3,12	1,251
	Q7_FS.4 Financijska mogućnost da se nosite s neočekivanim troškovima	363	1	5	3,82	1,121
	DQ8_FS.1 Visina prihoda kućanstva	673	1	5	3,33	1,278
	DQ8_FS.2 Ušteđevina	673	1	5	2,97	1,260
	DQ8_FS.3 Financijska pomoć od strane obitelji/prijatelja/bliskih ljudi	673	1	5	2,68	1,203
	DQ8_FS.4 Financijska mogućnost da se nosite s neočekivanim troškovima	673	1	5	3,24	1,236
Aritmetička sredina konstrukta Q7_FS: 3,61 **Standardna devijacija konstrukta Q7_FS: 1,012** **Aritmetička sredina konstrukta DQ8_FS: 3,05** **Standardna devijacija konstrukta DQ8_FS: 1,073** **Cronbachov alfa koeficijent: 0,884 i 0,885**						
Sigurnost posla	Q7_SP.1 Status zaposlenja (zaposlena/nezaposlena)	363	1	5	3,48	1,412
	Q7_SP.2 Sigurnost/stabilnost posla	363	1	5	3,57	1,325
	Q7_SP.3 Vrsta ugovora o radu (neodređeno/određeno)	363	1	5	3,33	1,435
	Q7_SP.4 Vrsta radnog odnosa – samozaposlena	363	1	5	2,99	1,321
	Q7_SP.5 Vrsta radnog odnosa – zaposlena kod drugog poslodavca (privatni sektor)	363	1	5	3,09	1,349
	Q7_SP.6 Vrsta radnog odnosa – zaposlena kod drugog poslodavca (javni sektor)	363	1	5	3,01	1,320
	DQ8_SP.1 Status zaposlenja (zaposlena/nezaposlena)	673	1	5	3,00	1,348
	DQ8_SP.2 Sigurnost/stabilnost posla	673	1	5	3,06	1,360
	DQ8_SP.3 Vrsta ugovora o radu (neodređeno/određeno)	673	1	5	2,84	1,377
	DQ8_SP.4 Vrsta radnog odnosa – samozaposlena	673	1	5	2,68	1,299
	DQ8_SP.5 Vrsta radnog odnosa – zaposlena kod drugog poslodavca (privatni sektor)	673	1	5	2,78	1,268
	DQ8_SP.6 Vrsta radnog odnosa – zaposlena kod drugog poslodavca (javni sektor).	673	1	5	2,65	1,259

Aritmetička sredina konstrukta Q7_SP: 3,25 **Standardna devijacija konstrukta Q7_SP: 1,172** **Aritmetička sredina konstrukta DQ8_SP: 2,84** **Standardna devijacija konstrukta DQ8_SP: 1,146** **Cronbachov alfa koeficijent: 0,930 i 0,935**						
Stambeni uvjeti	Q7_SU.1 Posjedovanje nekretnine	363	1	5	3,71	1,306
	Q7_SU.2 Stambeni uvjeti adekvatni za proširenje obitelji	363	1	5	3,91	1,205
	DQ8_SU.1 Posjedovanje nekretnine	673	1	5	3,08	1,328
	DQ8_SU.2 Stambeni uvjeti adekvatni za proširenje obitelji	673	1	5	3,22	1,312
Aritmetička sredina konstrukta Q7_SU: 3,81 **Standardna devijacija konstrukta Q7_SU: 1,186** **Aritmetička sredina konstrukta DQ8_SU: 3,15** **Standardna devijacija konstrukta DQ8_SU: 1,254** **Cronbachov alfa koeficijent: 0,878 i 0,893**						

***n – broj žena bez djece i s djecom**

Izvor: izrada doktorandice

Za mjerenje povezanosti fiskalnih instrumenata i namjere rađanja u sljedeće dvije godine korištena je Likertova ljestvica: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo. Ispitanice koje nisu upoznate s navedenom demografskom mjerom dale su ocjenu 6 i te su ispitanice isključene prilikom kreiranja konstrukta.

Tablica 22. Mjerenje fiskalnih instrumenata javnih politika

Konstrukt	Čestica	n	Min	Max	x̄	s
Neizravni novčani transferi	Q9A_T.1 Smanjeni porezi na dohodak za ljude s uzdržavanom djecom	344	1	5	3,62	1,25
	Q9A_T.5 Snižene stope PDV-a za dječje potrepštine	344	1	5	3,74	1,30
	Q10A_T.1 Smanjeni porezi na dohodak za ljude s uzdržavanom djecom	626	1	5	3,48	1,31
	Q10A_T.5 Snižene stope PDV-a za dječje potrepštine	626	1	5	4,49	1,32

Aritmetička sredina konstrukta Q9A_T: 3,42 **Standardna devijacija konstrukta Q9A_T: 1,45** **Aritmetička sredina konstrukta Q10A_T: 3,40** **Standardna devijacija konstrukta Q10A_T:1,29** **Cronbachov alfa koeficijent: 0,892 i 0,866**						
	Q9A_T.2 Dječji doplatak za obitelji s djecom neovisan o veličini obiteljskih primanja	290	1	5	3,51	1,31
	Q9A_T.3 Dječji doplatak za majku ili oca koji ne rade jer žele skrbiti o svojoj djeci	290	1	5	3,33	1,35
	Q9A_T.4 Značajno povećanje izdvajanja za dječje doplatke iz proračuna.	290	1	5	3,52	1,29
	Q9A_T.6 Povećanje naknade tijekom poštede od rada.	290	1	5	3,62	1,32
	Q9A_T.7 Novčana pomoć za opremu novorođenog djeteta.	290	1	5	3,59	1,33
	Q9A_T.8 Plaćeni očinski dopust.	290	1	5	3,57	1,28
	Q9A_T.9 Rodiljne i roditeljske potpore.	290	1	5	3,66	1,30
	Q9A_T.10 Povećanje naknade kod korištenja prava na rad s polovicom radnog vremena radi pojačane njege djeteta	290	1	5	3,59	1,26
	Q9A_T.11 Povećanje jednokratne novčane potpore za novorođeno dijete	290	1	5	3,51	1,32
	Q9A_T.12 Povećanje pronatalitetnog dodatka uz doplatak	290	1	5	3,55	,29
	Q9A_T.13 Povećanje zajamčene minimalne naknade za kućanstva koja imaju djecu	290	1	5	3,47	1,29
Izravni novčani transferi	Q10A_T.2 Dječji doplatak za obitelji s djecom neovisan o veličini obiteljskih primanja	574	1	5	3,46	1,34
	Q10A_T.3 Dječji doplatak za majku ili oca koji ne rade jer žele skrbiti o svojoj djeci	574	1	5	3,35	1,37
	Q10A_T.4 Značajno povećanje izdvajanja za dječje doplatke iz proračuna	574	1	5	3,42	1,32
	Q10A_T.6 Povećanje naknade tijekom poštede od rada	574	1	5	3.52	1,31
	Q10A_T.7 Novčana pomoć za opremu novorođenog djeteta	574	1	5	3,40	1,31
	Q10A_T.8 Plaćeni očinski dopust	574	1	5	3,41	1,28

	Q10A_T.9 Rodiljne i roditeljske potpore	574	1	5	3,60	1,29
	Q10A_T.10 Povećanje naknade kod korištenja prava na rad s polovicom radnog vremena radi pojačane njege djeteta	574	1	5	3,47	1,32
	Q10A_T.11 Povećanje jednokratne novčane potpore za novorođeno dijete	574	1	5	3,29	1,38
	Q10A_T.12 Povećanje pronatalitetnog dodatka uz doplatak	574	1	5	3,43	1,31
	Q10A_T.13 Povećanje zajamčene minimalne naknade za kućanstva koja imaju djecu	574	1	5	3,34	1,32
Aritmetička sredina konstrukta Q9A_T: 3,37 **Standardna devijacija konstrukta Q9A_T: 1,27** **Aritmetička sredina konstrukta Q10A_T: 3,40** **Standardna devijacija konstrukta Q10A_T: 1,19** **Cronbachov alfa koeficijent: 0,971 i 0,973**						
Transferi u naravi	Q9B_T.14 Sufinanciranje cijene dječjih vrtića	332	1	5	3,77	1,26
	Q9B_T.15 Značajno smanjenje troškova obrazovanja za djecu.	332	1	5	3,67	1,25
	Q9B_T.16 Sufinanciranje troškova produženog boravka	332	1	5	3,55	1,26
	Q9B_T.17 Sufinanciranje kupnje školskih potrepština	332	1	5	3,58	1,27
	Q9B_T.18 Sufinanciranje troškova prehrane	332	1	5	3,56	1,26
	Q9B_T.19 Sufinanciranje smještaja u učeničkim/studentskim domovima	332	1	5	3,44	1,30
	Q9B_T.20 Sufinanciranje najamnine za stanovanje	332	1	5	3,57	1,30
	Q9B_T.21 Koncesija ili darovanje zemljišta za izgradnju prve nekretnine za roditelje.	332	1	5	3,64	1,36
	Q9B_T.22 Subvencioniranje kamata na stambene kredite	332	1	5	3,74	1,29
	Q9B_T.23 Sufinanciranje prijevoza učenika/studenata	332	1	5	3,55	1,25
	Q9B_T.24 Dodjeljivanje učeničkih/studentskih stipendija	332	1	5	3,51	1,28
	Q9B_T.25 Sufinanciranje savjetovališta za obitelj, brak, roditeljstvo	332	1	5	3,23	1,29
	Q9B_T.26 Sufinanciranje kupnje prve nekretnine za sve građane	332	1	5	3,78	1,34

	Q10B_T.14 Sufinanciranje cijene dječjih vrtića	603	1	5	3,68	1,31
	Q10B_T.15 Značajno smanjenje troškova obrazovanja za djecu	603	1	5	3,58	1,29
	Q10B_T.16 Sufinanciranje troškova produženog boravka	603	1	5	3,49	1,27
	Q10B_T.17 Sufinanciranje kupnje školskih potrepština	603	1	5	3,55	1,31
	Q10B_T.18 Sufinanciranje troškova prehrane	603	1	5	3,47	1,27
	Q10B_T.19 Sufinanciranje smještaja u učeničkim/studentskim domovima	603	1	5	3,41	1,29
	Q10B_T.20 Sufinanciranje najamnine za stanovanje	603	1	5	3,40	1,31
	Q10B_T.21 Koncesija ili darovanje zemljišta za izgradnju prve nekretnine za roditelje	603	1	5	3,45	1,33
	Q10B_T.22 Subvencioniranje kamata na stambene kredite	603	1	5	3,47	1,33
	Q10B_T.23 Sufinanciranje prijevoza učenika/studenata	603	1	5	3,49	1,29
	Q10B_T.24 Dodjeljivanje učeničkih/studentskih stipendija	603	1	5	3,47	1,28
	Q10B_T.25 Sufinanciranje savjetovališta za obitelj, brak, roditeljstvo	603	1	5	3,14	1,28
	Q10B_T.26 Sufinanciranje kupnje prve nekretnine za sve građane	603	1	5	3,52	1,36
Aritmetička sredina konstrukta Q9B_T: 3,51 **Standardna devijacija konstrukta Q9B_T: 1,23** **Aritmetička sredina konstrukta Q10B_T: 3,46** **Standardna devijacija konstrukta Q10B_T: 1,8** **Cronbachov alfa koeficijent: 0,980 i 0,979**						

Izvor: izrada doktorandice

Mjerenje namjere rađanja prema Teoriji planiranog ponašanja prikazano je u tablici 23. Za mjerenje stavova korištene su čestice kojima se mjeri utjecaj rađanja na različite aspekte života koristeći sljedeću ljestvicu: 1 – jako loš, 2 – loš, 3 – niti loš niti dobar, 4 – dobar, 5 – jako dobar. Ocjenu 6 ispitanice su dodijelile izjavama koje nisu primjenjive ili za koje nisu mogle procijeniti utjecaj i te su ispitanice isključene iz analize prilikom kreiranja konstrukta.

Konstrukt subjektivnih normi sastoji se od čestica kojima se mjeri stupanj slaganja s

izjavama o tome što bi drugi ljudi mogli misliti o budućim namjerama rađanja ispitanica, ali i važnosti njihova mišljenja pri odluci o rađanju. Pri tomu je korištena sljedeća ljestvica: 1 – uopće se ne slažem, 2 – ne slažem se, 3 – niti se slažem, niti se ne slažem, 4 – slažem se, 5 – u potpunosti se slažem. Kao i kod mjerenja stavova, ocjena 6 odnosila se je na izjave za koje nisu bile primjenjive za ispitanicu ili za koje nisu mogle procijeniti stupanj slaganja. Također, te su ispitanice isključene iz analize prilikom kreiranja konstrukta.

Percipirana kontrola ponašanja odnosila se je na uvjete za koje žene smatraju da će imati ispunjene za rađanje djeteta te je mjerena sljedećom ljestvicom: 1 – definitivno ne, 2 – vjerojatno ne, 3 – nisam sigurna, 4 – vjerojatno da, 5 – definitivno da.

Tablica 23. Mjerenje elemenata Teorije planiranog ponašanja

Konstrukt	Čestica	n	min.	max.	x̄	s
Stavovi	Q1_ATT.1 Mogućnost da radite što želite	341	1	5	2,91	1,14
	Q1_ATT.2 Vašu financijsku situaciju	341	1	5	2,92	1,08
	Q1_ATT.3 Mogućnost da ostvarite neke druge životne ciljeve	341	1	5	3,23	1,1
	Q1_ATT.4 Radost i zadovoljstvo koje dobivate od života	341	1	5	4,16	0,98
	Q1_ATT.5 Vaše daljnje mogućnosti zapošljavanja	341	1	5	3,11	1,11
	Q1_ATT.6 Vaš trenutni posao	341	1	6	3,30	1,11
	Q1_ATT.7 Mogućnosti zapošljavanja Vašeg partnera	341	1	5	3,60	0,90
	Q1_ATT.8 Skrb i sigurnost koju možete dobiti u starosti	341	1	5	3,60	0,90
	Q1_ATT.9 Bliskost između vas i Vašeg partnera	341	1	5	3,99	1,04
	DQ1_ATT.1 Mogućnost da radite što želite	609	1	5	2,86	1,09
	DQ1_ATT.2 Vašu financijsku situaciju	609	1	5	3,01	0,92
	DQ1_ATT.3 Mogućnost da ostvarite neke druge životne ciljeve	609	1	5	3,09	1,01
	DQ1_ATT.4 Radost i zadovoljstvo koje dobivate od života	609	1	5	4,20	0,92
	DQ1_ATT.5 Vaše daljnje mogućnosti zapošljavanja	609	1	5	3,02	1,03
	DQ1_ATT.6 Vaš trenutni posao	609	1	6	3,31	1,07
	DQ1_ATT.7 Mogućnosti zapošljavanja Vašeg partnera	609	1	5	3,55	0,90
	DQ1_ATT.8 Skrb i sigurnost koju možete dobiti u starosti	609	1	5	3,42	0,97

	DQ1_ATT.9 Bliskost između vas i Vašeg partnera	609	1	5	3,77	1,08
Aritmetička sredina konstrukta Q1_ATT: 3,47 **Standardna devijacija konstrukta Q1_ATT: 0,77** **Aritmetička sredina konstrukta DQ1_ATT: 3,39** **Standardna devijacija konstrukta DQ1_ATT: 0,70** **Cronbachov alfa koeficijent: 0,886 i 0,854**						
Subjektivne norme	Q3_SN.1 Većina mojih prijatelja smatra da trebam imati dijete.	356	1	5	3,32	1,10
	Q3_SN.2 Moji roditelji smatraju da trebam imati dijete.	356	1	5	3,89	1,11
	Q3_SN.3 Moj partner smatra da trebamo imati dijete.	356	1	5	3,52	1,13
	Q3_SN.4 Članovi moje obitelji smatraju da trebam imati dijete.	356	1	5	3,73	1,08
	Q3_SN.5 Važno mi je mišljenje mojih prijatelja pri odluci o rađanju.	356	1	5	2,19	0,96
	Q3_SN.6 Važno mi je mišljenje mojih roditelja pri odluci o rađanju.	356	1	6	2,68	1,25
	Q3_SN.7 Važno mi je mišljenje mog partnera pri odluci o rađanju.	356	1	5	4,07	0,98
	Q3_SN.8 Važno mi je mišljenje članova moje obitelji pri odluci o rađanju.	356	1	5	2,54	1,12
	DQ3_SN.1 Većina mojih prijatelja smatra da trebam imati još jedno dijete.	621	1	5	2,46	1,14
	DQ3_SN.2 Moji roditelji smatraju da trebam imati još jedno dijete.	621	1	6	2,47	1,25
	DQ3_SN.3 Moj partner smatra da trebamo imati još jedno dijete.	621	1	5	2,64	1,29
	DQ3_SN.4 Članovi moje obitelji smatraju da trebam imati još jedno dijete.	621	1	5	2,47	1,19
	DQ3_SN.5 Važno mi je mišljenje mojih prijatelja pri odluci o rađanju.	621	1	5	1,89	0,91
	DQ3_SN.6 Važno mi je mišljenje mojih roditelja pri odluci o rađanju.	621	1	6	2,32	1,11
	DQ3_SN.7 Važno mi je mišljenje mog partnera pri odluci o rađanju.	621	1	5	4,08	0,98
	DQ3_SN.8 Važno mi je mišljenje članova moje obitelji pri odluci o rađanju.	621	1	5	2,38	1,14
Standardizirana vrijednost standardne devijacije Q3_SN:0,81 **Standardizirana vrijednost standardne devijacije DQ3_SN: 0,80** **Cronbachov alfa koeficijent: 0,801 i 0,78**						

Percipirana kontrola ponašanja	Q2_PBC.1 Moći ću si s financijskog aspekta priuštiti imati dijete.	363	1	5	3,60	1,208
	Q2_PBC.2 Imat ću odgovarajući smještaj koji će mi omogućiti da imam dijete.	363	1	5	3,97	1,102
	Q2_PBC.3 Bit ću dovoljno zdrava da mogu imati dijete.	363	1	5	3,80	,917
	Q2_PBC.4 Osjećat ću se spremnom da imam dijete.	363	1	5	3,58	1,308
	Q2_PBC.5 Imat ću partnera s kojim ću imati dijete.	363	1	5	4,17	1,033
	Q2_PBC.6 Moći ću uskladiti svoj poslovni i obiteljski život ako budem imala dijete.	363	1	5	3,62	1,097
	Q2_PBC.7 Imat ću pristup zadovoljavajućoj zdravstvenoj skrbi za djecu ako budem imala dijete.	363	1	5	4,00	,951
	Q2_PBC.8 Imat ću pristup vrtićima/jaslicama.	363	1	5	3,74	,922
	Q2_PBC.9 Imat ću mogućnost otići na roditeljski dopust.	363	1	5	4,17	1,004
	Q2_PBC.10 Imat ću potporu obitelji/bliskih ljudi u slučaju potrebe za čuvanjem djeteta/djece.	363	1	5	4,05	1,054
	DQ2_PBC.1 Moći ću si s financijskog aspekta priuštiti imati još jedno dijete.	673	1	5	3,28	1,288
	DQ2_PBC.2 Imat ću odgovarajući smještaj koji će mi omogućiti da imam još jedno dijete.	673	1	5	3,68	1,299
	DQ2_PBC.3 Bit ću dovoljno zdrava da mogu imati još jedno dijete.	673	1	5	3,42	1,078
	DQ2_PBC.4 Osjećat ću se spremnom da imam još jedno dijete.	673	1	5	2,98	1,353
	DQ2_PBC.5 Imat ću partnera s kojim ću imati još jedno dijete.	673	1	5	3,58	1,458
	DQ2_PBC.6 Moći ću uskladiti svoj poslovni i obiteljski život ako budem imala još jedno dijete.	673	1	5	3,24	1,242
	DQ2_PBC.7 Imat ću pristup zadovoljavajućoj zdravstvenoj skrbi za djecu ako budem imala još jedno dijete.	673	1	5	3,80	1,108
	DQ2_PBC.8 Imat ću pristup vrtićima/jaslicama.	673	1	5	3,61	1,109
	DQ2_PBC.9 Imat ću mogućnost otići na roditeljski dopust.	673	1	5	4,11	1,026
	DQ2_PBC.10 Imat ću potporu obitelji/bliskih ljudi u slučaju potrebe za čuvanjem djeteta/djece.	673	1	5	3,49	1,297

Aritmetička sredina konstrukta Q2_PBC: 3,89 **Standardna devijacija konstrukta Q2_PBC: 0,74** **Aritmetička sredina konstrukta DQ2_PBC: 3,56** **Standardna devijacija konstrukta Q2_PBC: 0,86** **Cronbachov alfa koeficijent: 0,883 i 0,883**

Izvor: izrada doktorandice

S aspekta Teorije planiranog ponašanja (tablica 23.), zanimljivo je promotriti rezultate provedenog istraživanja o stavovima prema rađanju, odnosno utjecaju djeteta na različite aspekte života žena. Rezultati deskriptivne statistike pokazuju da najvišu prosječnu ocjenu ima radost i zadovoljstvo koje žena dobiva od života kada ima dijete ($\bar{x}$ = 3,77 kod žena s djecom i $\bar{x}$ = 3,99 kod žena bez djece) te bliskost između žene i njezinog partnera ($\bar{x}$ = 3,78 kod žena s djecom i $\bar{x}$ = 4,02 kod žena bez djece) dok su ostali oblici neznačajno prisutni. Najmanju prosječnu ocjenu ima mogućnost da žena radi što želi ($\bar{x}$ = 2,86 i $\bar{x}$ = 2,91). Rezultati sugeriraju da žene bez djece mogu imati nešto veću percepciju slobode i mogućnosti u nekim aspektima života, dok žene s djecom mogu doživljavati veću radost i zadovoljstvo.

Nadalje, mjerenje subjektivnih normi provedeno je kroz izražavanje mišljenja i važnosti mišljenja drugih ljudi o tome da ispitanica ima dijete u sljedeće dvije godine. Iz dobivenih rezultata može se zaključiti da je mišljenje partnera najvažnije za obje skupine ($\bar{x}$ = 4,08 i $\bar{x}$ = 4,07), dok je mišljenje prijatelja najmanje važno ($\bar{x}$ = 1,89 i $\bar{x}$ = 2,19) pri odlučivanju o rađanju djece. Žene bez djece su najveći stupanj slaganja dale za izjavu da roditelji smatraju da trebaju imati dijete ($\bar{x}$ = 2,89), dok partneri žena koje imaju dijete smatraju da bi trebale imati dijete u sljedeće dvije godine ($\bar{x}$ = 2,64). Ovi rezultati pokazuju razlike u percepciji i važnosti društvenih normi između žena s djecom i bez djece. Općenito, žene bez djece osjećaju veći društveni pritisak i više cijene mišljenje drugih o pitanju rađanja djece.

Percipirana kontrola ponašanja odnosila se je na uvjete koje je potrebno ispuniti prije nego što pojedinci/parovi dobiju dijete, odnosno imaju još jedno dijete. Rezultati prikazuju da i žene s djecom i žene bez djece imaju najveću prosječnu vrijednost sigurnosti odlaska na roditeljski dopust ($\bar{x}$ = 4,11 i $\bar{x}$ = 4,17), dok su obje skupine ispitanica najmanje sigurne da će se osjećati spremnom da imaju dijete, odnosno još jedno dijete. Rezultati sugeriraju da žene bez djece općenito osjećaju veću sigurnost u ispunjenje uvjeta potrebnih za rađanje djece u odnosu na žene koje već imaju djecu.

Zaključno, sve vrijednosti koeficijenta Cronbachove alfe su iznad preporučene vrijednosti od 0,7 (Nunnally, 1978), odnosno oko 0,9 (koja se smatra izvrsnom prema Kline, 2011) te sugeriraju prihvatljivu pouzdanost mjernog instrumenta. Rezultati upućuju na zaključak da instrument ima dobru unutarnju konzistentnost te se može smatrati pouzdanim mjernim instrumentom.

Valjanost se odnosi na prikladnost korištenih mjera u skladu s njihovom namjenom te na točnost analize dobivenih rezultata. U ovom doktorskom radu valjanost je provjerena i osigurana putem sadržajne valjanosti, koja je postignuta kroz nekoliko aspekata. Za istraživanje namjere rađanja u Republici Hrvatskoj korišteni su, u najvećem obujmu, konstrukti iz najnovije verzije upitnika *Generation and Gender Survey (GGS) Questionnaire* (Gauthier i sur., 2022). GGS upitnik razvijen je od strane međunarodnog konzorcija stručnjaka iz različitih područja, uključujući demografiju, sociologiju, ekonomiju i psihologiju. Upitnik je kroz godine unaprjeđivan i testiran provođenjem pilot istraživanja. Pilot studije omogućile su da se identificiraju i isprave bilo kakve nejasnoće ili neprikladnosti u formulaciji pitanja, čime je dodatno osigurano da pitanja precizno mjere ciljne konstrukte. Konačno, zbog ovih pažljivih i sustavnih pristupa u razvoju upitnika, korištenje pitanja iz GGS-a u ovom istraživanju osigurava da se relevantni konstrukti mjere na valjan i pouzdan način. To znači da pitanja u ovom istraživanju pokrivaju sve ključne aspekte istraživanog fenomena, čime se doprinosi ukupnoj valjanosti rezultata istraživanja. Osim GGS upitnika, pojedina pitanja dodana su iz Eurobarometerovog istraživanja *Childbearing Preferences and Family Issues in Europe* (Testa, 2006).

5.6. Statističke metode analize

U cilju adekvatnog odabira statističkih testova provjerena je normalnost distribucije kriterijske varijable (namjera rađanja u sljedeće dvije godine, namjera_sljedece2_godine) koja je testirana provedbom Kolmogorov-Smirnov testa. Na temelju rezultata testa o normalnosti distribucije ($p < ,05$) odbačena je pretpostavka o normalnosti distribucije testirane varijable. Dodatno, mjera asimetrije (engl. *Skewness*, 0,539) i zaobljenosti (engl. *Kurtosis*, -1,036), kao i grafički prikaz histogramom i Q-Q dijagramom također potvrđuju narušenost normalnosti distribucije. Stoga navedenu varijablu nije moguće odabrati za parametrijske testove jer njezin

oblik narušava pretpostavku provedbe parametrijskih testova. Sukladno navedenom, u daljnjoj analizi primjenjuju se odabrani neparametrijski testovi u svrhu testiranja postavljenih hipoteza.

5.6.1. Deskriptivna analiza

Deskriptivna statistika koristi se za opisivanje, sažimanje i prikazivanje osnovnih značajki skupa podataka. Glavna svrha deskriptivne statistike je pružiti pregled podataka na razumljiv i sažet način, kako bi se lakše razumjele osnovne karakteristike skupa podataka. Neki od ključnih elemenata deskriptivne statistike uključuju:

1. mjere centralne (središnje) tendencije: srednja vrijednost (aritmetička sredina), medijan i mod
2. mjere disperzije (raspršenosti): raspon, varijanca, standardna devijacija
3. oblik distribucije: simetrija i zaobljenost
4. frekvencijske distribucije: tablice frekvencija, histogrami
5. vizualizaciju podataka: grafikoni i dijagrami.

Korištenjem deskriptivne statistike, istraživači i analitičari mogu dobiti uvid u osnovne karakteristike podataka prije nego što prijeđu na složenije analize, poput inferencijalne statistike koja uključuje donošenje zaključaka i predviđanja na temelju podataka. Rezultati deskriptivne statistike prikazani su u potpoglavlju 5.7.1.

5.6.2. Kruskal-Wallisov test i Mann-Whitney U test nezavisnih uzoraka

Neparametrijske metode zahtijevaju manje stroge pretpostavke od svojih parametrijskih ekvivalenata; s druge strane, koriste i manje informacija iz podataka (Ostertagova i sur., 2014).

Kada se uspoređuju sredine k populacija i poznato je da populacije nemaju jednake varijance ili da populacije nisu normalno distribuiranje, koristi se Kruskal-Wallisov neparametrijski test. Kruskal-Wallisov test koristan je kao opći neparametrijski test za usporedbu više od dva nezavisna uzorka. Može se koristiti za provjeru dolaze li takvi uzorci iz iste distribucije. Ovaj test snažna je alternativa jednosmjernoj analizi varijance (ANOVA)

(Ostertagova i sur., 2014). Ovaj test je u osnovi proširenje Wilcoxon-Mann-Whitney testa s dva uzorka (Mann i Whitney, 1947) za više od dva neovisna uzorka.

Kruskal-Wallisov test ne postavlja pretpostavke o postojanju normalnosti. Ipak, pretpostavlja da opažanja u svakoj skupini dolaze iz populacija s istim oblikom distribucije i da su uzorci nezavisni i slučajni. Kruskal-Wallisov test koristi isti postupak kao i test za jednosmjernu analizu varijance, ali kao i kod mnogih neparametrijskih testova, rangovi podataka koriste se umjesto sirovih podataka (Ostertagova i sur., 2014).

Test rangiranja zahtijeva da sva opažanja budu rangirana zajedno te da se izračuna zbroj rangova dobivenih za svaki uzorak. Matematički zapis Kruskal-Wallisovog testa koji se izračunava ako nema srednjih rangova ili ako ih ima ograničen broj (Kruskal i Wallis, 1952: 586) je sljedeći:

$$H = \left(\frac{12}{N(N+1)} \sum_{i=1}^{k} \frac{R_i^2}{n_i} \right) - 3(N+1)$$

gdje je n_i broj analiziranih uzorka *i* za *i* = 1, …, k; N je ukupan broj promatranja; R_i je zbroj rangova analiziranih uzorka *i,* gdje je *i* =1, …, k . Koeficijent $\frac{12}{N(N+1)}$ je faktor normalizacije. „Kruskal-Wallisovim testom odlučuje se jesu li zbrojevi rangova toliko različiti da nije vjerojatno da pripadaju uzorcima izabranim iz iste populacije“ (Horvat i Mijoč, 2019).

Kako je već ranije spomenuto, Mann-Whitney U test nezavisnih uzoraka vrlo je sličan Kruskal-Wallisovom testu, samo što se u Mann-Whitneyevu U testu zbroj rangova izračunava za dva uzorka prema sljedećem matematičkom zapisu:

$$U_1 = n_1 n_2 \frac{n_1(n_1+1)}{2} - R_1$$

$$U_2 = n_1 n_2 \frac{n_2(n_2+1)}{2} - R_2$$

gdje je R_1 zbroj rangova prvog uzorka, a R_2 zbroj rangova drugog uzorka.

Opisani neparametrijski testovi u doktorskom radu korišteni su za utvrđivanje razlike u broju živorođene djece s obzirom na određene demografske karakteristike ispitanica, kao i testiranje hipoteze H4, odnosno utvrđivanje razlike u namjeri rađanja u sljedeće dvije godine s obzirom na razvijenost jedinca područne (regionalne) samouprave prema indeksu razvijenosti.

5.6.3. Probit i logit regresijski model

Prije nego što se pristupi teorijskom objašnjenju *probit* i *logit* regresijskih modela, nužno je pojasniti pojam, ulogu i značaj kontrolnih varijabli u testiranju modela.

Kontrolne varijable razlikuju se po tome što se smatraju vanjskim varijablama koje nisu povezane s hipotezama i teorijama koje se testiraju. Istraživači jasno odvajaju neke varijable kao isključivo kontrolne ili varijable bez posebnog teorijskog interesa, čije je učinke potrebno nekako ukloniti iz istraživanja. Međutim, kontrolne varijable treba uvrstiti u analizu, uzimajući u obzir teorijske spoznaje (Spector i Brannick, 2011).

Hair i sur. (2013) navode da istraživači često zanemaruju činjenicu da se uključivanjem kontrolnih varijabli povećava složenost modela. Kontrolne varijable čimbenici su koje istraživači uključuju u svoj rad kako bi isključili alternativna objašnjenja svojih nalaza ili kako bi smanjili pogreške i povećali statističku snagu. Kada je učinak kontrolne varijable značajan, Hair i sur. (2013) sugeriraju da istraživač treba s posebnom pažnjom donositi zaključke i postupati s daljnjim analizama. Navedeno potvrđuje i Becker (2005) koji smatra da se matematički dobiveni rezultati mogu krivo protumačiti ako se u obzir ne uzmu i kontrolne varijable.

Spector i Brannick (2011) također smatraju da je upotreba kontrolnih varijabli učinkovitija kroz pristup alternativnog testiranja hipoteza. Ovi autori preporučuju da se umjesto pukog uključivanja kontrolnih varijabli u model usporede rezultati modela bez njih i s njima. Na taj način može se bolje sagledati utječu li kontrolne varijable na odnose među varijablama u modelu i koliko pridonose ukupnom objašnjenju modela. Uzimajući u obzir ovu važnu činjenicu, kriterijska varijabla kreirana je na tri različita načina M1, M2 i M3 (način kreiranja objašnjen je u potpoglavlju 5.7.1.) i testira se kroz tri različita pristupa: I. pristup (Blok 1): model se sastoji od kriterijske i prediktorske varijable; II. Pristup (Blok 2): model se sastoji od

kriterijske, prediktorske varijable i varijabli koje uključuju elemente Teorije planiranog ponašanja: stavove, subjektivne norme i percipiranu kontrolu ponašanja; III. pristup (Blok 3): model se sastoji od kriterijske, prediktorske varijable, kontrolnih varijabli i dodatnih varijabli koje uključuju elemente Teorije planiranog ponašanja: stavove, subjektivne norme i percipiranu kontrolu ponašanja. Cilj kreiranja blokova je uvidjeti utječe li dodavanje dodatnih varijabli na klasifikacijsku točnost modela te na zaključke o postavljenim hipotezama. U nastavku je objašnjena razlika između *probit* i *logit* modela.

Probit model koristi kumulativnu funkciju standardne normalne distribucije što znači da je pretpostavljena funkcija distribucije simetrična. S druge strane, *logit* model koristi logističku distribuciju. *Logit* model procjenjuje vjerojatnosti na temelju logističke funkcije, koja ima sličan S-oblik kao normalna distribucija, ali nešto deblje repove. Zbog tih repova, *logit* model može bolje opisati događaje s ekstremnim vjerojatnostima.

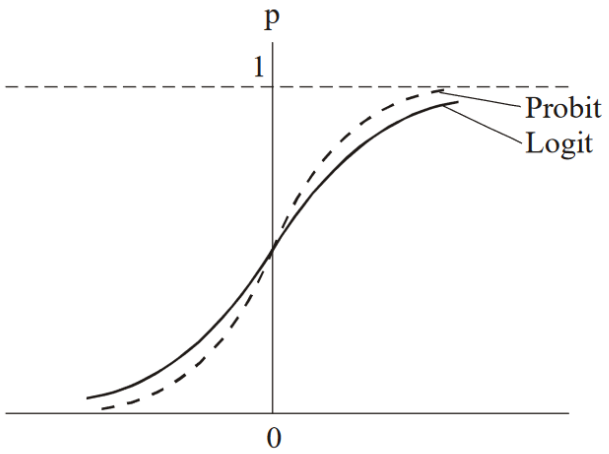

Slika 9. Funkcije raspodjele probit i logit modela
Izvor: Nojković (2019: n.p.)

Na slici 9. su prikazane krivulje za probit i logit modele. Oboje pokazuju odnos između vjerojatnosti događaja (označeno kao p na osi y) i vrijednosti prediktorske varijable (na osi x). Oba modela prikazuju vjerojatnost događaja u funkciji prediktorske varijable i imaju S-oblik (sigmoidna krivulja).

Logit model (puna linija) i *probit* model (isprekidana linija) vrlo su slični u središnjem dijelu grafikona, gdje se krivulje gotovo preklapaju. Međutim, u ekstremnim dijelovima (kada je vjerojatnost blizu 0 ili 1), *probit* krivulja ima nešto oštriji porast, dok *logit* krivulja ima nešto glatkiji prijelaz. Oba modela približno opisuju odnos između prediktorske varijable i vjerojatnosti, ali s blagim razlikama na krajevima ljestvice.

U nastavku su prikazane određene matematičke formulacije čije će vrijednosti biti prikazane u empirijskim rezultatima.

Šanse, u oznaci ξ predstavljaju količnik vjerojatnosti da se nešto dogodi (π) i vjerojatnosti da se događaj ne dogodi ($1 - \pi$).

$$\xi = \frac{\pi}{1 - \pi}$$

U empirijskim se istraživanjima vjerojatnost π ocjenjuje na osnovu relativne frekvencije, tj. proporcije dobivene na slučajnom uzorku. Prema tomu, ocjena šansi ili izgleda (Š) dobiva se sljedećim izrazom:

$$\check{S} = \frac{p}{1 - p}$$

Dakle, šanse nisu isto što i vjerojatnost. Naime, za razliku od vjerojatnosti, koja može poprimiti vrijednosti od 0 do 1, šanse se mogu kretati u intervalu od 0 do $+\infty$.
Vjerojatnost se može iskazati i preko šansi na sljedeći način:

$$\pi = \frac{\xi}{1 + \xi}$$

Slično tomu, ocjena vjerojatnosti (p) se može iskazati preko ocjena šansi na sljedeći način:

$$p = \frac{\check{S}}{1 + \check{S}}$$

Na temelju prethodnog opisa i iznesenih istraživačkih spoznaja za modeliranje namjere rađanja, a koje su predstavljene u teorijskom dijelu ovoga rada, za testiranje postavljenih istraživačkih hipoteza korištena je logistička regresija.

U logističkoj regresiji kriterijska varijabla je binarna. Analiza logističke regresije proučava povezanost između kategoričke kriterijske varijable i skupa prediktorskih (eksplanatornih) varijabli. U logističkoj regresiji koristi se matematički model skupa eksplanatornih varijabli za predviđanje *logit* transformacije kriterijske varijable. Pretpostavimo da su numeričke vrijednosti 0 i 1 dodijeljene dvama ishodima binarne varijable. Često 0 predstavlja negativan odgovor, a 1 pozitivan odgovor. Srednja vrijednost ove varijable bit će proporcija pozitivnih odgovora. Ako je p proporcija opažanja s ishodom 1, tada je 1-p vjerojatnost ishoda 0. Omjer $\left(\frac{p}{1-p}\right)$ naziva se izgledi (*odds*), a *logit* je logaritam izgleda (*log odds*). Matematički, logaritamska transformacija se zapisuje (NCSS, n.d.):

$$logit(p) = \ln\left(\frac{p}{1-p}\right)$$

Za razliku od linearne regresije, logistička regresija predviđa vjerojatnosti umjesto stvarnih vrijednosti. U nastavku je prikazana matematička formulacija logističke regresije, objašnjene su njezine temeljne pretpostavke te su definirane najčešće metode procjene. Opis logističke regresije temelji se na Wooldgridgeu (2012).

Logistička regresija ima za cilj modelirati vjerojatnost $P(Y = 1 \mid X)$, gdje je Y binarna ishodna (zavisna/kriterijska) varijabla, a X (nezavisna/prediktorska) varijabla prediktora. Logistička funkcija koristi se kako bi se osiguralo da se vjerojatnosti ishoda kreću u rasponu od 0 do 1. Model logističke regresije se može definirati kao:

$$P(Y = 1|X) = \sigma(\boldsymbol{X} \cdot \beta) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \cdots + \beta_n X_n)}}$$

gdje je σ sigmoidalna funkcija koja striktno poprima vrijednosti između 0 i 1: $0 < \sigma(z) < 1$, za svaki realni broj z. $\boldsymbol{X}$ predstavlja vektor n-prediktora, a β vektor n-parametara (koeficijenata) vezanih uz svaki prediktor uključen u analizu.

Kako bi se bolje razumjela obilježja sigmoidne funkcije na grafikonu 5. prikazana je sigmoidna funkcija koja povezuje vrijednosti prediktora X_1 te ishoda $P(Y = 1|X)$ za proizvoljno odabrane vrijednosti $-10 < X_1 < 10$.

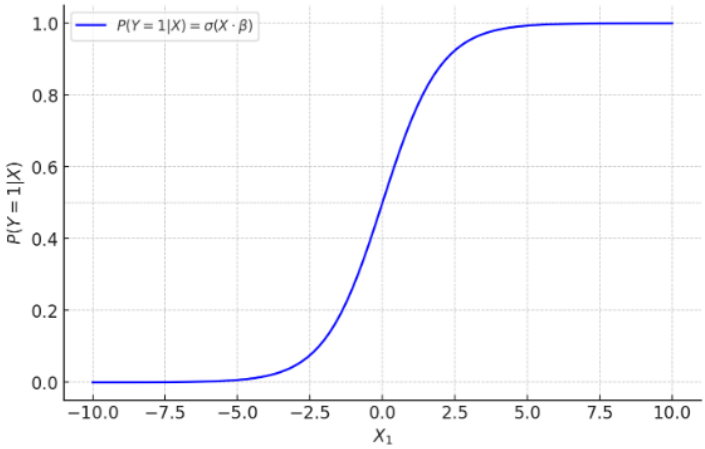

Grafikon 5. Sigmoidalna funkcija $P(Y = 1|X) = \frac{1}{1+e^{-(\beta_0+\beta_1 X_1+\cdots+\beta_n X_n)}}$

Izvor: izrada doktorandice

Prednost ove funkcije je u tome što je derivabilna, odnosno njezina derivacija je glatka i nema naglih skokova između izlaznih vrijednosti. Osim toga, izlazne vrijednosti su normalizirane u rasponu od 0 do 1, a dodatna prednost je i jasnoća predviđanja.

Logistička funkcija primjenom *logita* definira se kao:

$$\log\left(\frac{P(Y = 1|X)}{1 - P(Y = 1|X)}\right) = \beta_0 + \beta_1 X_1 + \cdots + \beta_n X_n$$

Ova transformacija ključna je u primjeni logističke regresije iz više razloga povezanih s interpretacijom, računanjem i uporabnom vrijednošću modela.

Prvo, nelinearna veza između kriterijske i prediktorske(ih) varijable(i) i ishoda otežava izravnu interpretaciju učinaka prediktora i izračun parametara. Primjenom *logita* dobiva se linearni oblik gdje svaki β_i odražava utjecaj jedinične promjene prediktora X_i na log-vjerojatnost ishoda Y.

Drugo, važno je naglasiti da je vjerojatnost kao veličina ograničena između 0 i 1. U standardnoj linearnoj regresiji predikcija može proizvesti bilo koju realnu vrijednost,

uključujući i one koje izlaze izvan tog raspona, što je neprihvatljivo za modeliranje vjerojatnosti.

Treće, ovaj postupak omogućava procjenu metodom maksimalne vjerojatnosti (engl. *Maximum Likelihood Estimation*, MLE). Logistička regresija najčešće koristi ovu metodu za pronalaženje optimalnih parametara. *Logit* transformacija linearizira odnos između prediktora i ishoda, čineći *log*-vjerojatnosnu funkciju konkavnom, što omogućuje lakšu i stabilniju optimizaciju. Ta stabilnost osigurava da iterativne metode (poput gradijentnog spusta) učinkovito konvergiraju prema optimalnom rješenju za parametre β.

Četvrto, kada lineariziramo funkciju parametri β_i postaju interpretabilni u smislu omjera izgleda, gdje svaki β_i odražava utjecaj jedinične promjene prediktora X_i na *log*-vjerojatnost ishoda Y (odnosno na omjer između vjerojatnosti da je Y=1 i vjerojatnosti da Y= 0). Primjerice, ako procjenjujemo vjerojatnost prolaska ispita autoškole na temelju broja sati vožnje i utvrdimo da je β = 0,17 za univarijantni *logit*, to znači da svaki dodatni sat vožnje povećava *log*(p/1-p) za *exp*(0,17). Konkretno, to iznosi 1,185, što znači da se vjerojatnost prolaska na ispitu autoškole povećava za 18,5 %.

Posljednje, ovaj postupak pruža veću fleksibilnost u analizama u kojima je uključeno više prediktora. Kod višestrukih prediktora linearizirani oblik $\beta_0 + \beta_1 X_1 + \cdots + \beta_p X_p$ omogućava aditivne kombinacije, što pojednostavljuje proširenje modela, interakcije i upravljanje s više varijabli uz očuvanje interpretabilnosti.

Za provođenje (logističke) regresije nužno je zadovoljiti nekoliko pretpostavki (Pallant, 2020: 176):

I. veličina uzorka: jedno od pitanja odnosi se na broj slučajeva u uzorku i broj prediktora (nezavisnih varijabli) koje istraživač želi uključiti u model. Problem u analizi može predstavljati mali uzorak s velikim brojem prediktora. U literaturi ne postoji konsenzus oko veličine uzorka za provođenje logističke regresije pa tako Bujang i sur. (2018) navode da je za studije s velikom populacijom koje uključuju logističku regresijsku analizu potrebna minimalna veličina uzorka od 500, dok Peduzzi i sur. (1996) navode da je potrebno minimalno 10 opažanja po varijabli.

Potrebna veličina uzorka za provođenje logističke regresije u ovom doktorskom radu je izračunata upotrebom programa G*Power 3.1. Rezultati ukazuju da je potrebna veličina uzorka od 786 ispitanika za statističku snagu od 80 %.

II. multikolinearnost: prije provođenja logističke regresije potrebno je provjeriti postoje li visoke međukorelacije u prediktorskim (nezavisnim) varijablama. Idealno bi bilo da su prediktorske varijable snažno povezane sa (kriterijskom) zavisnom varijablom, ali ne i snažno međusobno povezane (Pallant, 2020). Faktor inflacije varijance (engl. *Variance inflation factor,* VIF) u doktorskom radu je manji od 10 u sva tri načina mjerenja namjere rađanja pri čemu je zadovoljena pretpostavka o nepostojanju multikolinearnosti među prediktorskim varijablama.

III. izdvojenice: važno je provjeriti prisutnost izdvojenica ili slučajeva koji nisu dobro objašnjeni modelom. U terminima logističke regresije, model može snažno predvidjeti da će slučaj biti jedna kategorija, ali u stvarnosti biti klasificiran u drugu kategoriju. Ovi izvanredni slučajevi mogu se identificirati pregledom reziduala, što je osobito važan korak ako se pojavi problem s rezultatima *goodnes of fit* modela. Za identifikaciju izdvojenica u doktorskom radu primijenjen je Cookov test izdvojenica kojim je dobiveni rezultat manji od 1 čime se potvrđuje nepostojanje značajnih izdvojenica.

IV. nezavisnost opažanja: (logistička) regresija zahtijeva da promatranja budu neovisna jedno o drugom. Drugim riječima, opažanja ne bi trebala proizaći iz ponovljenih mjerenja ili podudarnih podataka (Schreiber-Gregory i Bader, 2018).

Vrijedi napomenuti da postoje još dvije pretpostavke koje je potrebno zadovoljiti u bilo kojoj vrsti regresijske analize. To su provjera pristranosti izostavljene varijable (engl. *Omitted variable bias*) i pristranosti istovremene uzročnosti (engl. *Simultaneous causality bias*). Pristranost izostavljene varijable, prema Stock i Watson (2006) javlja se kada su dva uvjeta istinita: 1) izostavljena varijabla je u korelaciji s uključenim regresorom; i 2) izostavljena varijabla je determinanta kriterijske varijable. Budući da je u logističkoj regresiji u ovom doktorskom radu uzet u obzir niz prediktorskih varijabli, odnosno društvenih, demografskih, ekonomskih, socio-ekonomskih i regionalnih čimbenika koji bi mogli utjecati na namjeru rađanja, navedena pretpostavka nije narušena. Pristranost istovremene uzročnosti javlja se kada

u regresijskoj analizi uz uzročnu vezu od prediktorske varijable do kriterijske varijable postoji i obrnuta uzročna veza. Prema načinu kreiranja modela u ovom doktorskom radu navedena pretpostavka ni u kom slučaju ne može biti narušena, odnosno, ne postoji uzročnost namjere rađanja prema odabranim prediktorima namjere rađanja.

Budući da su sve pretpostavke zadovoljene, u testiranju postavljenih hipoteza H1 i H3 primijenjena je logistička regresija. Analizirani su modeli binarne logističke regresije s različitim brojem prediktorskih i kontrolnih varijabli za koje se pretpostavlja, na temelju prethodnih istraživačkih spoznaja, da utječu na povezanost s namjerom rađanja.

Procijenjena snaga povezanosti prikazana je kao omjer izgleda (engl. *odds ratio*, *Exp* (B)). Za valjanost modela korišten je Omnibus test koeficijenata modela i Hosmer i Lemeshow test. Omnibus test koeficijenata modela daje opću indikaciju o tome koliko dobro model funkcionira, iznad i izvan rezultata dobivenih za Blok 0 – kada nijedan prediktor nije uključen u model. Ovo se naziva testom „prilagodbe modela“ (engl. *goodness of fit*). Za ovaj skup rezultata poželjna je visoko značajna vrijednost ($p < ,05$).

Rezultati Hosmer i Lemeshow testa također daju dodatno uporište valjanosti modela. Ovaj test, za koji IBM SPSS Statistics navodi da je najpouzdaniji test prilagodbe modela (Pallant, 2020:184), tumači se suprotno od gore spomenutog Omnibus testa. Za Hosmer i Lemeshow test prilagodbe loša prilagodba je naznačena vrijednošću značajnosti manjom od 0,05, pa da bi model bio podržan, poželjne su vrijednosti veće od 0,05.

Vrijednost klasifikacijske točnosti daje indikaciju o tome koliko je model sposoban točno predvidjeti ispravnu kategoriju (ima namjeru rađanja u sljedeće dvije godine / nema namjeru rađanja u sljedeće dvije godine) za svaki promatrani slučaj. Navedena vrijednost može se usporediti s klasifikacijskom točnošću modela u kojemu nisu uključene prediktorske varijable (Blok 0) kako bismo vidjeli koliko je poboljšanje kad su prediktorske varijable uključene u model. Dakako, poželjno je da je ova vrijednost što veća.

Za modele u kojima su uključene sve prediktorske varijable (Blok 3) prikazana je i ROC krivulja (engl. *Receiver Operating Characteristic,* ROC) i područje ispod ROC krivulje (engl. *Area under the ROC curve,* AUC).

ROC krivulja grafički je prikaz koji se koristi za evaluaciju prediktivne sposobnosti klasifikacijskog modela, posebice u binarnim klasifikacijama (gdje ishod može biti jedan od dva moguća). ROC krivulja prikazuje odnos između osjetljivosti (engl. s*ensitivity*) i 1 – specifičnosti (engl. *specificity*) modela za različite granične vrijednosti (engl. *cut-off* točke) korištene za klasifikaciju.

Osjetljivost prikazuje točnost pozitivnih slučajeva (engl. *true positive rate*), odnosno mjeri koliko je model učinkovit u ispravnom prepoznavanju pozitivnih slučajeva (kada je stvarni ishod 1). Specifičnost prikazuje točnost negativnih slučajeva (engl. *true negative rate*), odnosno mjeri učinkovitost modela u prepoznavanju negativnih slučajeva (kada je stvarni ishod 0). 1 – specifičnost predstavlja stopu lažno pozitivnih slučajeva (engl. *false positive rate*), odnosno pokazuje koliko često model pogrešno klasificira negativan slučaj kao pozitivan (Fawcett, 2006). Kada model postaje bolji u prepoznavanju pozitivnih slučajeva dolazi do povećanja osjetljivosti dok će se 1 – specifičnost povećati kada model ima veće pogreške u klasificiranju negativnih slučajeva kao pozitivnih.

$$stopa\ stvarno\ pozitivnih\ slučajeva\ = \frac{točno\ klasificirani\ pozitivni\ slučajevi}{ukupno\ pozitivni\ slučajevi}$$

$$stopa\ lažno\ pozitivnih\ slučajeva\ = \frac{pogrešno\ klasificirani\ negativni\ slučajevi}{ukupno\ negativni\ slučajevi}$$

Područje ispod ROC krivulje popularna je mjera povezana s ROC krivuljama. Područje ispod ROC krivulje kvantitativna je mjera učinkovitosti modela koja poprima vrijednosti između 0 i 1. „Budući da je AUC dio površine jediničnog kvadrata, njegova će vrijednost uvijek biti između 0 i 1,0. Međutim, budući da nasumično pogađanje proizvodi dijagonalnu liniju između točaka (0, 0) i (1, 1), koja ima površinu 0,5, niti jedan realističan klasifikator ne bi trebao imati AUC manji od 0,5“ (Fawcett, 2006: 868).

Veća vrijednost AUC ukazuje na bolje karakteristike testa, odnosno to znači da je test ispravno prepoznao sve pozitivne i negativne slučajeve. Hosmer i sur. (2013: 177) daju sljedeće smjernice za tumačenje AUC vrijednosti:

$$\text{Ako je} \quad \begin{cases} AUC = 0{,}5 & Slučajan\ rezultat \\ AUC = 0{,}7 - 0{,}8 & Prihvatljiv \\ AUC = 0{,}8 - 0{,}9 & Odličan \\ AUC \geq 0{,}9 & Izvrstan \end{cases}$$

Konkretno, u ovom doktorskom radu veće AUC vrijednosti ukazivat će na to da test bolje razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine od onih koje nemaju namjeru rađanja u sljedeće dvije godine.

5.6.4. Korelacijska analiza

Korelacijska analiza služi za određivanje jačine i smjera veze između dviju varijabli. Prema Horvat i Mijoč (2019), koeficijent korelacije najčešće se koristi kao mjera za opisivanje povezanosti među varijablama. Najpoznatiji među njima je Pearsonov koeficijent korelacije koji predstavlja parametrijski koeficijent. Pri odabiru varijabli nužno je koristiti varijable prikladnih mjernih ljestvica. Pearsonov koeficijent korelacije primjenjuje se kada su obje varijable mjerene na intervalnoj ili omjernoj ljestvici, dok se Spearmanov koeficijent korelacije ranga, kao neparametrijski test, preporučuje za varijable koje su mjerene ordinalnom razinom. U korelacijskoj analizi jedna je varijabla nezavisna, odnosno prediktorska (njome se objašnjavaju varijacije u zavisnoj varijabli), dok je druga varijabla zavisna, odnosno kriterijska (odnosi se na predmet istraživanja i njezine se varijacije objašnjavaju uz pomoć drugih varijabli). Istraživač u korelacijskoj analizi može odabrati više varijabli što znači da se provodi korelacijska analiza za svaki mogući par varijabla (Horvat i Mijoč, 2019: 438).

Koeficijent korelacije, koji mjeri jačinu povezanosti između varijabli, poprima vrijednosti u rasponu od 0 do 1. Vrijednost 0 upućuje na potpunu odsutnost korelacije, dok vrijednost 1 označava izrazito snažnu korelacijsku povezanost među promatranim varijablama. U statističkoj literaturi postoje različiti prijedlozi za određivanje granica za tumačenje povezanosti između varijabla, a Horvat i Mijoč (2019: 442) navode sljedeće smjernice prikazane na slici 10.

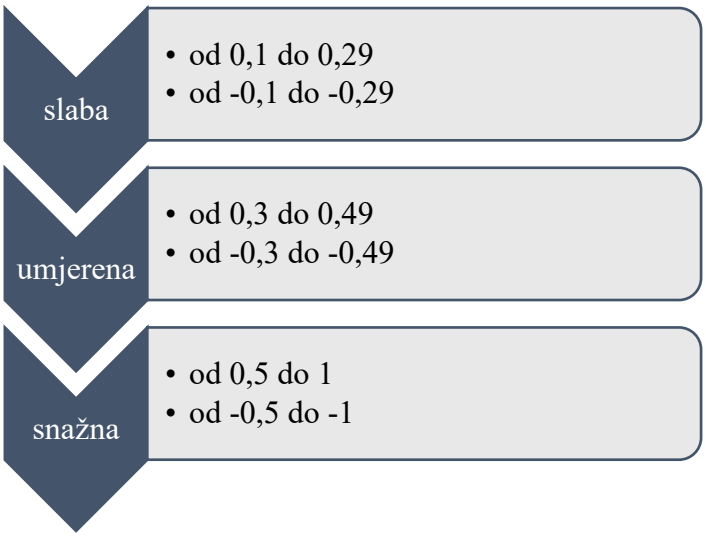

Slika 10. Smjernice za tumačenje koeficijenta korelacije
Izvor: Horvat i Mijoč (2019: 442)

Pozitivna korelacijska povezanost odnosi se na situaciju u kojoj porast jedne varijable rezultira porastom druge varijable. Ako porast jedne varijable rezultira smanjenjem druge varijable riječ je o negativnoj korelacijskoj povezanosti između varijabli.

Za provođenje Pearsonove korelacije, osim vrsta varijabli, nužno je zadovoljiti i određene pretpostavke vezane uz linearnost, neovisnost opažanja, veličinu uzorka, normalnost i izdvojenice. Ako navedene pretpostavke nisu zadovoljene moguće je provesti korelacijsku analizu korištenjem Spearmanovog koeficijenta korelacije. Budući da navedene pretpostavke nisu zadovoljene, pri testiranju druge hipoteze (H2) korišten je Spearmanov koeficijent korelacije. Korelacijska analiza korištena je za testiranje povezanosti između tri varijable koje mjere ekonomsku sigurnost (sigurnost posla, financijska sigurnost i potpuno vlasništvo nad nekretninom) i fertilnog jaza.

5.7. Rezultati istraživanja

U uvodnom i teorijskom dijelu objašnjen je istraživački jaz u promatranju namjere rađanja, kao i u prediktorima koji utječu na jaz između željenog i ostvarenog broja djece s ekonomskog aspekta. U cilju prevladavanja problematike postavljeni su ciljevi i hipoteze istraživanja. U okviru ovog poglavlja testirane su postavljene hipoteze (poglavlje 1.3.).

5.7.1. Rezultati deskriptivne analize

Prije provođenja multivarijatne statističke analize nužno je sagledati određene deskriptivne podatke dobivene empirijskim istraživanjem. Socio-demografske karakteristike uzorka koji se sastoji od ukupno 1036 žena prikazane su u tablici 24.

Tablica 24. Opis uzorka

		n	%
Dobna skupina		**1036**	**100**
	22 - 29	246	23,7
	30 - 39	384	37,1
	40 - 49	406	39,2
Završena izobrazba		**1036**	**100**
	Završena osnovna škola	1	0,1
	Zanat – trogodišnja srednja škola	84	8,1
	Četverogodišnja srednja škola / Gimnazija	345	33,3
	Viša škola (stručni ili strukovni studij, 6. stupanj, VŠS / stručni prvostupnik / baccalaureus)	214	20,7
	Fakultet (7. stupanj / VSS / magistar struke)	370	35,7
	Magisterij znanosti	15	1,4
	Doktor znanosti	5	0,5
	Specijalizacija	2	0,2
Bračni status		**1036**	**100**
	Samac (neudana)	176	17,0
	Udana	565	54,5
	Živim u zajednici	216	20,8
	Rastavljena	39	3,8
	Udana, ali živimo odvojeno	7	0,7
	Udovica	5	0,5
	Ne želim odgovoriti	28	2,7
Broj članova kućanstva		**1036**	**100**
	1 član	44	4,2
	2	201	19,4
	3	256	24,7
	4	347	33,5
	5	127	12,3
	6	45	4,3
	7	4	0,4
	8 ili više članova	2	0,2
	Ne želim odgovoriti	10	1,0
Tip naselja		**1036**	**100**

	Urbano	626	60,42
	Ruralno	389	37,55
	Ne znam / ne želim odgovoriti	21	2,03
Veličina naselja		**1036**	**100**
	manje od 1.000 stanovnika	224	21,6
	1.000 - 4.999 stanovnika	216	20,8
	5.000 - 24.999 stanovnika	169	16,3
	25.000 - 100.000 stanovnika	186	18,0
	100.000 ili više stanovnika	55	5,3
	grad Zagreb	174	16,8
	Ne znam / ne želim odgovoriti	12	1,16
Regija prema indeksu razvijenosti		**1036**	**100**
	I. skupina razvijenosti	147	14,2
	II. skupina razvijenosti	197	19,0
	III. skupina razvijenosti	226	21,8
	IV. skupina razvijenosti	466	45,0
Vlasništvo nad nekretninom		**1036**	**100**
	potpuno vlasništvo nad stanom	212	20,5
	potpuno vlasništvo nad kućom	269	26,0
	djelomično vlasništvo nad stanom	81	7,8
	djelomično vlasništvo nad kućom	188	18,1
	Najam	122	11,8
	Ostalo	164	15,8
Djeca		**1036**	**100**
	Da	657	63,4
	Ne	379	36,6
Broj živorođene djece		**1036**	**100**
	0	379	36,6
	1	232	22,4
	2	325	31,4
	3	80	7,7
	4	17	1,6
	5	3	0,3
Vrsta zaposlenja		**852**	**100**
	privatni sektor	427	50,1
	javni sektor	383	45
	samozaposlena	42	4,9
Vrsta ugovora o radu		**788**	**100**
	neodređeno	710	90,1
	određeno	78	9,9
Radno vrijeme		**788**	**100**
	puno radno vrijeme	763	98,8
	pola radnog vremena	25	3,2
Ukupni mjesečni prihod svih članova kućanstva		**1036**	**100**
	Bez prihoda kućanstva	5	0,5
	Do 200 EUR	7	0,7
	Više od 200 EUR do 400 EUR	10	1,0
	Više od 400 EUR do 600 EUR	18	1,7

	Više od 600 EUR do 800 EUR	24	2,3
	Više od 800 EUR do 1000 EUR	37	3,6
	Više od 1000 EUR do 1200 EUR	50	4,8
	Više od 1200 EUR do 1400 EUR	61	5,9
	Više od 1400 EUR do 1600 EUR	61	5,9
	Više od 1600 EUR do 1800 EUR	45	4,3
	Više od 1800 EUR do 2000 EUR	74	7,1
	Više od 2000 EUR do 2200 EUR	61	5,9
	Više od 2200 EUR do 2400 EUR	78	7,5
	Više od 2400 EUR do 2600 EUR	58	5,6
	Više od 2600 EUR do 2800 EUR	50	4,8
	Više od 2800 EUR do 3000 EUR	47	4,5
	Više od 3000 EUR do 3200 EUR	32	3,1
	Više od 3200 EUR do 3400 EUR	20	1,9
	Više od 3400 EUR do 3600 EUR	14	1,4
	Više od 3600 EUR do 3800 EUR	14	1,4
	Više od 3800 EUR do 4000 EUR	24	2,3
	Više od 4000 EUR	56	5,4
	Ne znam / ne želim odgovoriti	190	18,3

*originalni podatci uzorka prije ponderiranja

Izvor: izrada doktorandice

Tablica 24. prikazuje uzorak od 1036 ispitanica u originalnim podatcima prije provođenja ponderiranja. U uzorku su zastupljene tri dobne skupine s udjelom od 23,7 % žena starosti od 22 do 29 godina, 37,1 % žena od 30 do 39 godina starosti te 39,2 % žena starosti od 40 do 49 godina. U opisanom uzorku najveći udio čine fakultetski obrazovane žene (35,7 %), zatim slijede žene koje su završile četverogodišnju srednju školu (33,3 %), dok su najmanje zastupljene žene sa završenom osnovnom školom (0,1 %) i žene sa završenom specijalizacijom (0,2 %). Promatrajući bračni status ispitanica, više od polovice njih je udano, dok se je 20,8 % ispitanica izjasnilo da živi u zajednici. Neudane žene čine 17 % u uzorku, rastavljene 3,8 %, 0,12 % žena je udano, ali živi odvojeno od supruga ili su udovice. O bračnom statusu nije se htjelo izjasniti 2,7 % ispitanica. Najveći udio ispitanica živi u urbanom tipu naselja (60,4 %), dok promatrajući veličinu naselja, najveći broj ispitanica živi u naselju s manje od 1000 stanovnika (21,6 %), a najmanji broj ispitanica živi u naselju s više od 100 000 stanovnika (5,3 %). Sukladno podatcima o županiji stanovanja, ispitanicama su dodijeljene regije prema indeksu razvijenosti, stoga se iz uzorka može zaključiti da u I. skupini jedinica područne (regionalne) samouprave živi 14,2 % žena, u II. skupini jedinica područne (regionalne) samouprave 19 % žena, u III. skupini jedinica područne (regionalne) samouprave 21,8 % žena, dok je najveći broj ispitanica (45,0 %) iz IV. skupine jedinica područne (regionalne) samouprave. U IV. skupini prema indeksu razvijenosti, gotovo polovica žena (48,4 %) ima

završen viši stupanj obrazovanja (viša škola, fakultet, magisterij znanosti, doktor znanosti i specijalizacija), dok je najmanji udio visokoobrazovanih žena (11,8 %) u I. skupini jedinica područne (regionalne) samouprave prema indeksu razvijenosti.

U ukupnom uzorku od 1036 ispitanica, njih 63,4 % ima dijete/djecu, dok preostalih 36,6 % nema dijete. Najveći broj žena (325) ima dvoje djece, zatim slijede žene s jednim djetetom (232), dok najmanji broj žena (3) ima petero djece. Najzastupljenija su kućanstva s četiri člana (33,5 %), dok su u uzorku najmanje zastupljena kućanstva s osam ili više članova (0,2 %).

9,3 % ispitanica živi u kućanstvu s mjesečnim prihodom do 1000 EUR, dok 0,5 % žena živi u kućanstvu bez prihoda. Kućanstva s 1000 do 2000 EUR mjesečnih prihoda svih članova čine udio od 28 %, do 28,3 % ispitanica živi u kućanstvu s 2000 do 3000 EUR mjesečnih prihoda. Između 3000 i 4000 EUR mjesečnih prihoda čine kućanstva s udjelom od 10,1 %. Žene koje žive u kućanstvu s više od 4000 EUR ukupnih mjesečnih prihoda čine udio od 5,4 % dok se 18,3 % žena nije željelo izjasniti ili nije znalo odgovor na postavljeno pitanje.

Ukupno 502 žene je udano i pri tom ima dijete/djecu. Najveći broj udanih žena, njih 268, je u trenutku provođenja istraživanja imalo dvoje djece. Neudane žene i žene koje žive u zajednici uglavnom nemaju dijete (290 žena, odnosno 76,52 % od ukupnog broja žena koje nemaju dijete). Promatrajući dobne skupine žena, 74,39 % žena starosti 22 – 29 godina nema dijete, dok preostale žene iz navedene dobne skupine uglavnom imaju jedno dijete (15,86 %). 28,65 % žena starosti 30 – 39 godina nema dijete, dok najveći broj žena (31,51 %, odnosno njih 121) ima dvoje djece. Najmanji udio žena bez djece (22,69 %) starosti je između 40 i 49 godina, dok je, očekivano, najveći udio žena bez djece starosti od 20 do 29 godina (grafikon 6.). Najveći broj žena (184 žene, odnosno 45,32 %) najstarije dobne skupine u trenutku istraživanja je imalo dvoje djece.

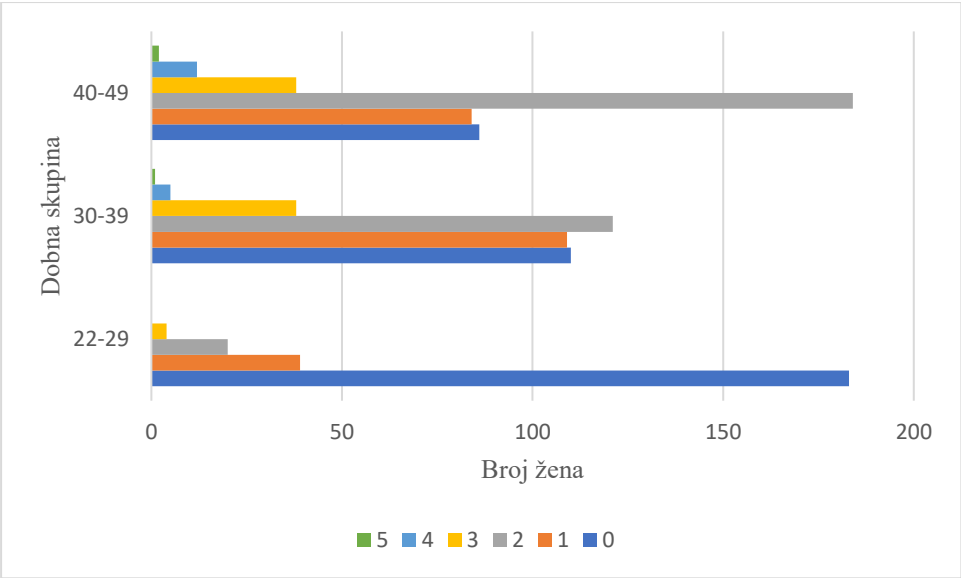

Grafikon 6. Broj djece po dobnim skupinama žena
Izvor: izrada doktorandice

Analizirajući stambene uvjete ispitanica, najveći broj ispitanica ima potpuno vlasništvo nad kućom ili stanom (46,5 %). Djelomično vlasništvo nad kućom ili stanom ima 25,9 % žena, dok 11,8 % žena živi u unajmljenoj nekretnini. Više od polovice (53,27 %) žena koje imaju potpuno vlasništvo nad nekretninom ima dijete/djecu. Najveći broj žena koje imaju potpuno vlasništvo nad kućom ili stanom ima dvoje djece (50,57 %). Promatrajući interakciju vlasništva nad nekretninom i indeks razvijenosti, od ukupnog broja žena koje imaju potpuno vlasništvo nad stanom ili kućom, njih 43,87 % stanuje u jedinicama regionalne (područne) samouprave IV. skupine razvijenosti prema indeksu razvijenosti. Nasuprot tomu, najmanji udio žena s potpunim vlasništvom nad nekretninom nalazi se u I. skupini prema indeksu razvijenosti (16,84 %).

Od ukupnog broja žena koje su sudjelovale u istraživanju, polovica njih je zaposlena kod poslodavca i ima dijete. Promatrajući vrstu ugovora o radu, veći je udio žena koje imaju dijete, a pritom imaju ugovor na neodređeno vrijeme (91,54 %) u odnosu na žene koje imaju ugovor na određeno vrijeme. Više od 90 % žena koje imaju potpuno vlasništvo nad nekretninom ujedno imaju i ugovor na neodređeno vrijeme. U ukupnom uzorku ispitanica koje su zaposlene, njih 50,1 % zaposleno je u privatnom sektoru s ugovorom na neodređeno vrijeme (90,1 %) s punim radnim vremenom (98,8 %). Više od polovice žena koje imaju dijete/djecu je zaposleno u privatnom sektoru. Žene koje su zaposlene u punom radnom vremenu imaju veći prosječan broj djece (1,34) u odnosu na žene koje rade na pola radnog vremena (1,32).

Uzimajući u obzir važnost usklađivanja privatnog i poslovnog života, ispitanice su bile upitane i je li im poslodavac omogućio fleksibilno radno vrijeme nakon povratka s rodiljnog/roditeljskog dopusta. Na postavljeno pitanje, od ukupnog broja žena koje imaju dijete/djecu (657), njih 41,2 % izjasnilo se je da im poslodavac nije omogućio fleksibilno radno vrijeme.

Ispitanice su se, između ostalog, trebale izjasniti i o financijskom stanju njihovog kućanstva, što je prikazano u Tablici 25.

Tablica 25. Financijsko stanje kućanstva

		n	**%**
Varijabla	**Čestice/Pitanje**	**1036**	**100**
Prihodi kućanstva	Prihodi našeg kućanstva su jedva dovoljni za hranu.	25	2,4
	Prihodi našeg kućanstva su dovoljni za hranu, ali teško si možemo priuštiti novu odjeću.	76	7,3
	Prihodi su dovoljni za kupovinu hrane i odjeće, ali trenutno bismo si teško mogli priuštiti novi televizor, hladnjak.	285	27,5
	Prihodi su dovoljni za kupovinu kućnih aparata, ali bismo si teško mogli priuštiti novi automobil.	455	43,9
	Prihodi su dovoljni za sve, osim za kupovinu novog stana ili vikendice.	170	16,4
	Ako bi bilo potrebno, mogli bismo si priuštiti kupovinu stana ili vikendice.	25	2,4
Varijabla	Pitanje	**1036**	**100**
Q8 i DQ9	Kućanstvo može imati više izvora prihoda i više od jednog člana kućanstva može pridonositi kućnom budžetu. Razmišljajući o ukupnom mjesečnom prihodu Vašeg kućanstva, može li Vaše kućanstvo podmiriti sve svoje obveze?		
	S velikim poteškoćama	42	4,1
	Uz određene poteškoće	396	38,2
	Prilično lako	349	33,7
	Lako	171	16,5
	Vrlo lako	78	7,5

Izvor: izrada doktorandice

Iz tablice 25. vidljivo je da više od 57 % ispitanica smatra da njihovo kućanstvo nema financijskih poteškoća s podmirivanjem obveza, ali također si ne mogu priuštiti pokretnu i nepokretnu imovinu veće vrijednosti.

Za potrebe provođenja multivarijatne statističke analize, varijable Q8 i DQ9 su prekodirane u binarnu varijablu, pri čemu 0 označava da kućanstvo ima financijske poteškoće (odgovori „S velikim poteškoćama“ i „Uz određene poteškoće“), a 1 da kućanstvo nema financijske poteškoće (odgovori „Prilično lako“, „Lako“ i „Vrlo lako“). Sukladno navedenom, više od polovice ispitanica se je izjasnilo da nema poteškoće u podmirivanju svojih mjesečnih obveza. Ispitanice koje vrlo lako podmiruju svoje financijske obveze u prosjeku imaju 1,74 djece, dok ispitanice koje lako podmiruju financijske obveze prosječno imaju 1,65 djece. Zaključno se uočava da žene koje podmiruju obveze s velikim poteškoćama imaju najveći prosječan broj djece, odnosno 2,13. Nadalje, 42,7 % ispitanica s djecom, zaposlenih u privatnom sektoru s velikim ili uz određene poteškoće podmiruje svoje obveze. Vrlo slična distribucija je i kod žena s djecom zaposlenih u javnom sektoru (42,1 % njih podmiruje svoje obveze s velikim ili uz određene poteškoće). Promatrajući visinu prihoda kućanstva, najveći broj ispitanica (14,9 %) koje imaju dijete/djecu nije željelo dati informaciju o visini prihoda kućanstva, a odgovorilo je da lako podmiruje svoje financijske obveze. Slično tomu, žene koje nemaju dijete, a lako podmiruju svoje financijske obveze u najvećem udjelu (22,9 %) nisu željele dati informaciju o visini prihoda kućanstva. Najveći broj ispitanica (20,9 %) bez djece vrlo lako podmiruje svoje obveze i prihod kućanstva im je veći od 4000 EUR. Gotovo isti udio (20%) je i žena s djecom koje vrlo lako podmiruju svoje obveze i imaju prihod kućanstva veći od 4000 EUR. Žene koje imaju djecu i s velikim poteškoćama podmiruju svoje obveze, u najvećem udjelu (22,6 %) raspolažu s ukupnim dohotkom od 1200 do 1400 EUR. Kod žena bez djece koje s velikim poteškoćama podmiruju obveze, najveći je udio žena s ukupnim prihodom kućanstva između 1400 i 1600 EUR. Zaključno, analiza pokazuje da žene koje s velikim poteškoćama podmiruju financijske obveze imaju najveći prosječan broj djece (2,13), dok one koje vrlo lako podmiruju obveze imaju najmanji prosjek (1,74). Ovi rezultati sugeriraju da financijske poteškoće mogu biti povezane s većim brojem djece, što može dodatno opteretiti kućni budžet i utjecati na kvalitetu obiteljskog života.

Prije samog testiranja postavljenih hipoteza i provođenja logističke regresijske analize, nužno je sagledati određene deskriptivne podatke provedenog empirijskog istraživanja. Prije svega razlike u broju živorođene djece s obzirom na dob, obrazovanje, tip naselja stanovanja,

indeks razvijenosti jedinice regionalne (područne) samouprave, uvjete stanovanja te vrstu ugovora o radu.

Kako bi se utvrdilo postoje li razlike u broju živorođene djece i različitih socio-demografskih karakteristika, u nastavku doktorskog rada analiziraju se potencijalne razlike u broju živorođene djece u odnosu na prethodno spomenute karakteristike uzorka.

Razlike u broju živorođene djece s obzirom na starosnu dob

Prethodno je već naglašena važnost starosti žene pri odluci o rađanju, ali i odgađanju rađanja, stoga su u nastavku testirane razlike u broju živorođene djece ovisno o starosnoj dobi žena koje su sudjelovale u istraživanju.

Tablica 26. Razlika u broju živorođene djece s obzirom na starosnu dob

	Dobna skupina	n	Prosjek rangova	Kruskal-Wallisov test
Živorođena djeca	22 – 29	246	289,70	$\chi^2 = 203{,}072$ df = 2 $p < ,001$
	30 – 39	384	551,64	
	40 – 49	406	620,33	
	Ukupno	**1036**		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa (tablica 26.) ukazuju na to da postoji statistički značajna razlika u broju živorođene djece ovisno o starosnoj dobi žene ($\chi^2 = 203{,}072$, $p < ,001$). Navedeno upućuje na postojanje razlike u fertilitetu među različitim dobnim skupinama, pri čemu je najveći prosjek rangova za dobnu skupinu žena starosti od 40 do 49 godina, a najmanji za dobnu skupinu u kojoj su žene od 22 do 29 godina. Promatrajući dobne kategorije, najmanji prosječan broj živorođene djece (0,37) imaju žene starosti od 22 do 29 godina. Žene starosti od 30 do 39 godina prosječno imaju 1,28 djece, dok najveći prosječan broj živorođene djece (1,54) imaju žene u dobnoj skupini od 40 do 49 godina. Navedeno je u skladu i s distribucijom koja je prikazana u potpoglavlju 2.4. (grafikon 1.).

Razlike u broju živorođene djece s obzirom na obrazovanje

Povećanje obrazovanja žena smatra se jednim od najvažnijih čimbenika koji utječu na razinu fertiliteta (Hoem, 2005; Basu, 2002; Axinn i Barber, 2001; Rindfuss i sur., 1980). Navedeno se očituje (prema Berrington i Pattaro, 2014) putem učinka odgađanja zbog produljenja godina obrazovanja (Blossfeld i Huinink, 1991), ekonomskih oportunitetnih troškova napuštanja tržišta rada radi brige o djeci (Rondinelli i Zizza., 2010; Becker, 1981; Willis, 1973) ili putem utjecaja obrazovanja na emancipaciju žena i želju za osobnim ispunjenjem (Lesthaeghe, 1998; Van de Kaa, 1987). Istraživanja pokazuju da je konačna veličina obitelji mjerena brojem djece povezana s razlikama u obrazovanju (De Wachter i Neels, 2011; Kravdal, 1992; Kreyenfeld, 2002). U skladu s prethodnim istraživačkim nalazima (Kneale i Joshi, 2008), Berrington i Pattaro (2014) navode da među ženama postoji jasan obrazovni gradijent u udjelu onih koje na kraju ostaju bez djece, od 25 % među onima s diplomom do samo 12 % među onima bez kvalifikacija. Istraživanja ukazuju na to kako sklonost žena s diplomom da ne ostvare namjeru da imaju dvoje ili troje djece ima veze s njihovom većom sklonošću za rad s punim radnim vremenom na bolje plaćenim poslovima te s kasnijim ulaskom u brak i stoga odgađanjem majčinstva. Na temelju prethodnih istraživanja provedena je analiza razlika Kruskal-Wallisovim testom kako bi se utvrdilo postoji li statistički značajna razlika u broju živorođene djece s obzirom na najviši završeni stupanj obrazovanja žene.

Tablica 27. Razlika u broju živorođene djece s obzirom na najviši završeni stupanj obrazovanja

Najviši završeni stupanj obrazovanja		n	Prosjek rangova	Kruskal-Wallisov test
Živorođena djeca	Završena osnovna škola	1	976,50	$\chi^2 = 36{,}395$ df = 7 p < ,001
	Zanat – trogodišnja srednja škola	84	611,25	
	Četverogodišnja srednja škola / Gimnazija	345	556,17	
	Viša škola (stručni ili strukovni studij, 6. stupanj, VŠS / stručni prvostupnik / baccalaureus)	214	519,07	
	Fakultet (7. stupanj / VSS / magistar struke)	370	461,40	
	Magisterij znanosti	15	427,20	
	Doktor znanosti	5	642,00	
	Specijalizacija	2	774,00	

	Ukupno	1036		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa ukazuju na postojanje razlika u broju živorođene djece s obzirom na završeni najviši stupanj obrazovanja žene ($\chi^2 = 36{,}396$, $p < ,001$). Vidljivo je da je najmanji prosjek rangova za broj živorođene djece kod žena s magisterijem znanosti, a najveći kod žena sa završenom osnovnom školom.

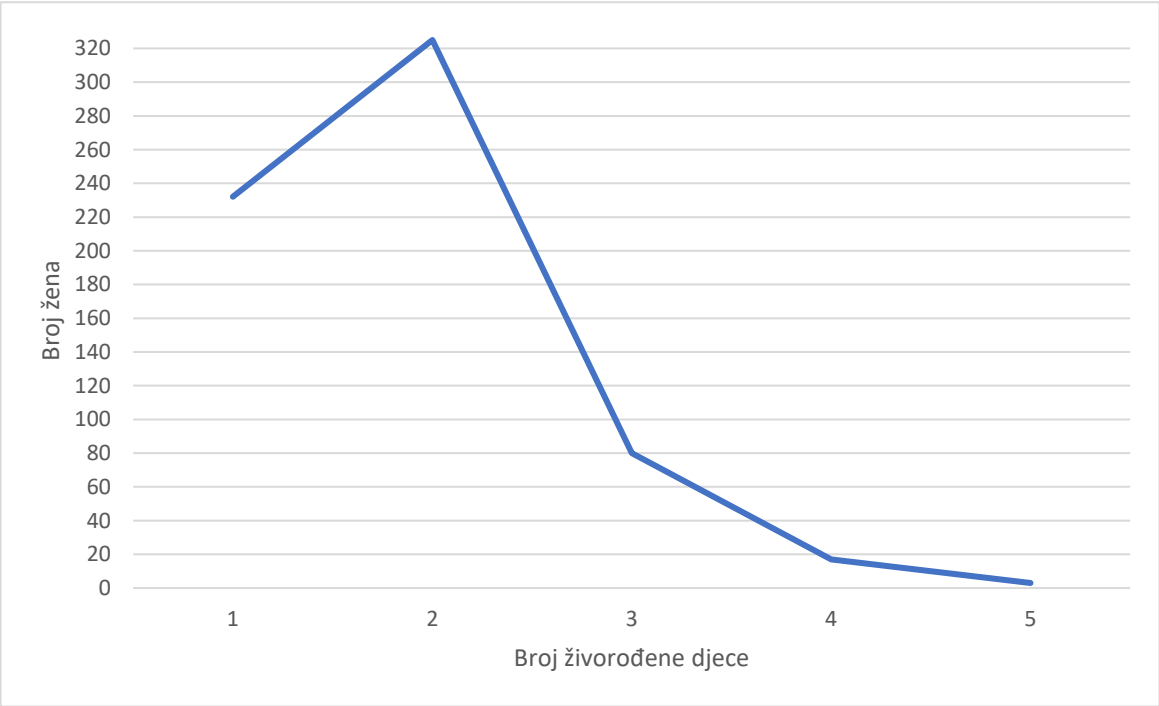

Grafikon 7. Broj živorođene djece
Izvor: izrada doktorandice

Grafikon 7. prikazuje broj žena prema broju živorođene djece te je iz istoga vidljivo da najveći broj žena ima dvoje djece (325 žena, odnosno 31,4 %), zatim slijede žene s jednim djetetom (22,4 % žena). Najmanji broj žena, odnosno samo njih tri ima petero djece. Od ukupnog broja žena s djecom koje su sudjelovale u istraživanju, njih 14,8 % ima troje ili četvero djece. S aspekta obrazovanja, najveći broj djece, odnosno petero djece imaju žene koje su završile trogodišnju (66,7 %) i četverogodišnju srednju školu (33,3 %). Četvero djece, također, najviše imaju žene koje su završile četverogodišnju srednju školu (52,9 %), zatim slijede žene sa završenom višom školom i fakultetom (po 17,6 % u svakoj obrazovnoj skupini), dok najmanji broj žena sa završenom trogodišnjom srednjom školom ima četvero djece (11,8 %). Najveći broj žena bez djece ima završen fakultet (43,89 %), dok troje ili više djece najviše

imaju žene (58 %) sa završenim nižim stupnjem obrazovanja (osnovna škola, trogodišnja i četverogodišnja škola). Zaključno, žene s nižim stupnjem obrazovanja, poput trogodišnje i četverogodišnje srednje škole, češće imaju četvero ili petero djece, dok žene s visokom stručnom spremom češće nemaju djece. Navedeno je u skladu s istraživanjima koja su prikazana u prethodnim poglavljima.

Razlike u broju živorođene djece s obzirom na tip naselja stanovanja

Proučavanje razlika u fertilitetu između ruralnih i urbanih područja predmet je brojnih istraživanja te ista ukazuju na statistički značajne razlike u broju rođene djece u ruralnim i urbanim sredinama (Lerch, 2019, Kulu, 2013). Doprinosi literaturi pokazuju sve veći interes za prostornim aspektima fertiliteta, uključujući razlike između fertiliteta u urbanim i ruralnim područjima (Hank, 2001; Thygesen i sur., 2005; De Beer i Deerenberg, 2007; Kulu i sur., 2007). Studije pokazuju da su se varijacije fertiliteta između urbanih i ruralnih područja smanjile tijekom vremena, ali značajne razlike između različitih naselja i dalje postoje. Razine fertiliteta su veće u ruralnim područjima i malim gradovima, dok su niže u velikim gradovima (Glusker i sur., 2000; Tromans i sur., 2009; Mulder i Wagner, 2001; De Beer i Deerenberg, 2007; Michielin, 2004; Kulu, 2006; Kulu i sur., 2007). Kako bi se utvrdilo postoje li razlike u broju živorođene djece s obzirom na tip naselja u kojemu žena stanuje proveden je Kruskal-Wallisov test.

Tablica 28. Razlika u broju živorođene djece s obzirom na tip naselja

	Tip naselja	n	Prosjek rangova	Kruskal-Wallisov test
Živorođena djeca	Urbano	626	494,38	$\chi^2 = 3{,}880$ df = 1 p = ,049
	Ruralno	389	529,92	
	Ne želim odgovoriti	21		
	Ukupno	1036		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa (tablica 28.) u skladu su s prethodnim istraživanjima i ukazuju na postojanje razlika u broju živorođene djece s obzirom na tip naselja u kojemu stanuje žena ($\chi^2 = 3{,}880$, $p < ,05$), pri čemu je veći prosječni rang za broj živorođene djece kod žena koje žive u ruralnim područjima Republike Hrvatske. Žene koje žive u urbanim

sredinama imaju prosječno manje djece (1,12) u odnosu na žene koje žive u ruralnim krajevima (1,25 djece). Uzimajući u obzir i veličinu naselja, troje ili više djece ima najveći broj žena (23 %) koje žive u naseljima s 1000 do 4999 stanovnika, dok najmanji broj žena (5 %) s troje ili više djece živi u naseljima sa 100 000 ili više stanovnika. U naseljima manjim od 1000 stanovnika najviše je žena s dvoje djece (36,16 %), kao i u naseljima s 5000 do 24 999 stanovnika (34,91 %). Nadalje, u naseljima koja imaju između 1000 i 4999 stanovnika najviše je žena bez djece (34,26 %). U naseljima sa 100 000 i više stanovnika najviše je žena koje u trenutku provedbe istraživanja nisu imale dijete (41,82 %). Dobiveni rezultati istraživanja u skladu su s prethodno prezentiranim istraživačkim spoznajama koje ukazuju na razlike u fertilitetu ovisno o tipu i veličini naselja.

Razlike u broju živorođene djece s obzirom na razvijenost jedinca područne (regionalne) samouprave prema indeksu razvijenosti

Prethodne istraživačke spoznaje upućuju na razlike u stopama fertiliteta na različitim razinama regionalne razvijenosti (Fox i sur., 2018; Hank, 2001; Basten i sur., 2012), stoga je u nastavku proveden Kruskal-Wallisov test kako bi se utvrdilo postoje li razlike u broju živorođene djece na temelju podjele regija prema indeksu razvijenosti (tablica 29).

Tablica 29. Razlika u broju živorođene djece s obzirom na regiju prema indeksu razvijenosti

Regija prema indeksu razvijenosti		n	Prosjek rangova	Kruskal-Wallisov test
Živorođena djeca	I. skupina razvijenosti	147	555,12	χ^2 = 10,327 df = 3 p = ,016
	II. skupina razvijenosti	197	556,05	
	III. skupina razvijenosti	226	519,65	
	IV. skupina razvijenosti	466	490,52	
	Ukupno	1036		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa ukazuju na postojanje razlika u broju živorođene djece s obzirom na razvijenost jedinca područne (regionalne) samouprave prema indeksu razvijenosti (χ^2 = 10,327, p = 0,016) u kojoj stanuje žena. Vidljivo je da je najmanji prosjek rangova za broj živorođene djece kod žena koje stanuju u jedinicama regionalne (područne) samouprave IV. skupine razvijenosti, a najveći u jedinicama regionalne (područne)

samouprave II. skupine razvijenosti. Prosječan broj živorođene djece u prvoj skupini razvijenosti je 1,32, u drugoj skupini 1,31, u trećoj je prosječan broj djece 1,17, dok je u jedinicama regionalne (područne) samouprave koje pripadaju četvrtoj skupini razvijenosti taj prosjek 1,05 djece. Iz navedenog se zaključuje da prosječan broj djece opada s povećanjem razvijenosti jedinice regionalne (područne) samouprave. Nadalje, najveći broj žena bez djece (48 %) dolazi iz najrazvijenijih jedinica regionalne (područne) samouprave, dok je najveći broj djece (petero) rođeno u jedinicama regionalne (područne) samouprave koje se svrstavaju u drugu i treću skupinu prema indeksu razvijenosti.

Razlike u broju živorođene djece s obzirom na stambene uvjete

Prethodna istraživanja pokazuju da stambeni uvjeti objašnjavaju značajan dio varijacije u fertilnosti između urbanih i ruralnih područja (Kulu, 2013). Međutim, neka od istraživanja proučavala su i obrasce rađanja prema vrsti i veličini stambenog prostora (Tocchioni i sur., 2021; Kulu i Vikat, 2007; Ström, 2010). Empirijska istraživanja ukazuju na pozitivnu povezanost između vlasništva nad nekretninom i fertiliteta (Castiglioni i Dalla Zuanna, 1994; Krishnan i Krotki, 1993; Mulder i Wagner, 2001). U većini društava vlasništvo nad nekretninom predstavlja ključnu imovinu i izvor stabilnosti, pružajući sigurnost stanovanja (Vignoli i sur. 2016). U usporedbi s unajmljenim domovima, vlasnički stanovi obično su prostraniji i prilagodljiviji potrebama kućanstva, pružajući bolje stambene uvjete za osnivanje obitelji (Mulder i Smits, 1999; Ricci 1997). Postoji značajna empirijska podrška za povezanost između vlasništva nad nekretninom i formiranja obitelji (Clark i Mulder, 2000; Clark i Withers 2007; Fiori i sur., 2014; Mulder i Wagner, 1993; Feijten i Mulder, 2002; Mulder i Wagner, 2001; Deurloo i sur., 1994). Testiranje razlike u broju živorođene djece ovisno o uvjetima stanovanja žene provedeno je Kruskal-Wallisovim testom (tablica 30.).

Tablica 30. Razlika u broju živorođene djece s obzirom na stambene uvjete

	Stambeni uvjeti	n	Prosjek rangova	Kruskal-Wallisov test
Živorođena djeca	potpuno vlasništvo nad stanom	212	520,98	$\chi^2 = 75{,}703$ df = 5 p < ,001
	potpuno vlasništvo nad kućom	269	602,93	
	djelomično vlasništvo nad stanom	81	530,54	
	djelomično vlasništvo nad kućom	188	564,54	
	Najam	122	388,09	

	Ostalo	164	415,10	
	Ukupno	1036		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa ukazuju na značajne razlike u broju živorođene djece s obzirom na stambene uvjete žena (χ^2 = 75,703, p < ,001). Na temelju rezultata neparametrijskog testa može se zaključiti da žene koje žive u različitim stambenim uvjetima imaju različite prosječne brojeve živorođene djece, pri čemu je najmanji prosjek rangova u kategoriji najma, a najveći potpunog vlasništva nad kućom.

Žene koje imaju potpuno vlasništvo nad stanom prosječno imaju 1,17 djece, dok je taj prosjek za žene koje imaju potpuno vlasništvo nad kućom 1,46. Promatrajući žene koje imaju djelomično vlasništvo nad stanom i kućom zaključuje se da žene s djelomičnim vlasništvom nad stanom imaju prosječno manje djece (1,20) u odnosu na žene s djelomičnim vlasništvom nad kućom (1,33). Žene koje žive u iznajmljenoj nekretnini prosječno imaju 0,70 djece, dok je taj prosjek kod žena koje žive u nekom drugom obliku vlasništva nekretnine 0,80. Najviše žena bez djece (23,48 %) živi u nekim drugim oblicima vlasništva nad nekretninom izuzev onih koji su bili ponuđeni. Troje ili više djece u najvećem udjelu imaju žene koje imaju potpuno vlasništvo nad kućom (32 %). Ovi podatci sugeriraju da stabilnost stambenog prostora može pozitivno utjecati na odluku o većem broju djece.

Razlike u broju živorođene djece s obzirom na vrstu ugovora o radu

Istraživanje utjecaja stabilnosti zaposlenja u središtu je pozornosti brojnih znanstvenika. Alderotti i sur. (2021) i De Paola i sur. (2020) navode da žene koje imaju ugovor na određeno vrijeme odgađaju ulazak u majčinstvo. Do istog zaključka došli su i Barbieri i sur. (2015) na temelju istraživanja u južnim europskim zemljama. Između ostalog, istraživanja pokazuju da žene koje su karijerno usmjerene i više ulažu u svoj ljudski kapital imaju veće povrate u smislu plaća i ekonomske sigurnosti pa je i veća vjerojatnost da će odgoditi odluku o rađanju kada imaju ugovore na određeno vrijeme (Wijk i sur., 2021; Beaujouan i Berghammer, 2019; Auer i Danzer, 2015). Osim samog odgađanja rađanja, vrsta ugovora o radu utječe i na razinu fertiliteta, pa će tako žene koje imaju nestabilan posao imati i smanjen fertilitet (Doepke i sur., 2022; Vignoli i sur., 2012; Santarelli, 2011).

Kako bi se utvrdila postoji li značajna razlika u broju živorođene djece između žena s različitim vrstama ugovora o zaposlenju (ugovor na određeno i ugovor na neodređeno vrijeme) provodi se Mann - Whitney U test (tablica 31.).

Tablica 31. Razlika u broju živorođene djece s obzirom na vrstu ugovora o radu

Vrsta ugovora o radu		n	Prosjek rangova	Zbroj rangova	Mann-Whitney U test
Živorođena djeca	neodređeno	710	399,33	283.527	U = 24.258
	određeno	78	350,50	27.339	z = -1,885
	Ukupno	788			p = ,059 r = -,067

Izvor: izrada doktorandice

Za izračun efekta veličine (r) u Mann-Whitneyevom testu, primjenjuje se sljedeća formula:

$$r = \frac{z}{\sqrt{N}} = \frac{-1{,}885}{\sqrt{788}} = -{,}067$$

Izračunata vrijednost r = -,067 predstavlja efekt veličine i u ovom kontekstu označava vrlo mali negativan efekt, što znači da su razlike između skupina vrlo male (Cohen, 1988). Negativan predznak nema interpretativnu vrijednost u kontekstu Mann-Whitneyjevog U testa, već samo ukazuje smjer razlike u rangovima.

Rezultati Mann-Whitneyjevog U testa ne ukazuju na statistički značajnu razliku u broju živorođene djece među ženama s ugovorom o radu na određeno (n = 78) i ugovorom o radu na neodređeno vrijeme (n = 710), U = 24258,00, z = -1,885, p = -,059, r = -,067.

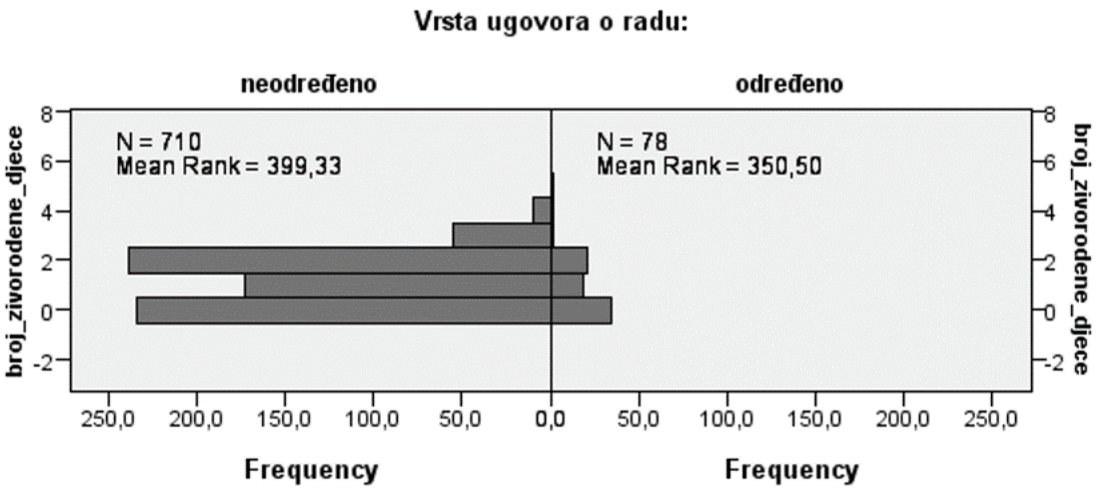

Grafikon 8. Razlika u broju živorođene djece s obzirom na vrstu ugovora o radu
Izvor: izrada doktorandice

Iz grafikona 8. vidljivo je da najveći udio žena bez djece (87,31 %) ima ugovor na neodređeno vrijeme. Nadalje, žene koje imaju ugovor na neodređeno vrijeme prosječno imaju više djece (1,20) u odnosu na žene koje imaju ugovor na određeno vrijeme (1,01).

Prema Teoriji planiranog ponašanja (Ajzen, 1991) namjera za poduzimanjem određenog ponašanja smatra se najboljim prediktorom stvarnog ponašanja. Novije studije u segmentu plodnosti pokazuju da namjere da se ima dijete (u formalnom smislu, namjera da se postigne cilj ponašanja da se dobije dijete) može se predvidjeti iz stavova, subjektivnih normi i percipirane kontrole u pogledu rađanja djeteta (Ajzen i Klobas, 2013). Namjera je pod utjecajem triju čimbenika:

1. Stavovi koji se formiraju na temelju uvjerenja o ponašanju, što uključuje percipirane pozitivne ili negativne posljedice određenog ponašanja, kao i subjektivne procjene tih posljedica. Kada je riječ o imanju djece, osoba može razmišljati o različitim ishodima, poput osobnog zadovoljstva ili financijskog tereta. Zajedno, ova uvjerenja oblikuju ukupan stav prema imanju djeteta, bilo pozitivan ili negativan.
2. Subjektivne norme uključuju percepciju o tome što pojedincima važni ljudi iz okoline misle da bi trebao učiniti. Također uključuju deskriptivne norme, koje se odnose na percepciju o tome kako se bliski ljudi pojedinca ponašaju u sličnim situacijama. Na temelju teorijskih spoznaja, varijabla subjektivne norme u ovom radu kreirana je kao

prosjek vrijednosti mišljenja pojedincu važnih ljudi o tome treba li imati dijete/još jedno dijete i percepcije pojedinca o važnosti mišljenja tih ljudi.

3. Percipirana kontrola ponašanja odnosi se na percepciju pojedinca o tome koliko ima kontrolu nad izvođenjem određenog ponašanja, u ovom slučaju, imanja djece. Percipirana kontrola uključuje vjeru u vlastite sposobnosti i dostupne resurse, kao i prepreke koje bi mogle ometati ili olakšati ostvarenje namjere. Na primjer, osoba može procijeniti svoje financijske mogućnosti ili zdravstveno stanje kao faktore koji utječu na njenu sposobnost da ima dijete.

Kombinacija ovih faktora utječe na formiranje namjere da se ima ili nema dijete. Općenito, što su stavovi i subjektivne norme povoljniji prema imanju djece te što je veća percipirana kontrola, to je veća vjerojatnost da će osoba formirati namjeru imati dijete. Konačno, stvarna sposobnost ostvarivanja ove namjere ovisi o stvarnoj kontroli nad situacijom, iako se u često primjenjuje percipirana kontrola kao zamjena za stvarnu kontrolu.

Sukladno navedenom, za potrebe istraživanja kreirani su konstrukti koji su se sastojali od čestica mjerenih Likertovom ljestvicom od 1 do 5. Ljestvica od 1 do 5 izabrana je na temelju preporuke Mejovšeka (2003: 42) koji navodi kako je za razliku od dihotomne ljestvice koja se često koristi u društvenim i humanističkim znanostima, Likertova ljestvica omogućava bolje diferenciranje ispitanika te je posebno prikladna u tradicionalnim sustavima u kojima se primjenjuje obrazovni sustav ocjenjivanja ocjenama od 1 do 5.

Deskriptivna statistika u nastavku predstavlja opis zavisne (kriterijske) varijable i nezavisnih (prediktorskih) varijabli pri čemu je kriterijska varijabla namjera rađanja u sljedeće dvije godine prilikom testiranja H1, H3 i H4, a fertilni jaz predstavlja kriterijsku varijablu prilikom testiranja H2. Prediktorske varijable u modelu su sigurnost posla, financijska sigurnost, potpuno vlasništvo nad nekretninom, izravni novčani transferi, neizravni novčani transferi, transferi u naravi i regije prema indeksu razvijenosti.

Namjera rađanja je mjerena Likertovom ljestvicom od 1 do 5 pri čemu su ispitanice trebale iskazati stupanj slaganja s navedenom izjavom koristeći sljedeću ljestvicu: 1 – definitivno ne, 2 – vjerojatno ne, 3 – nisam sigurna, 4 – vjerojatno da, 5 – definitivno da. Izjava za mjerenje namjere rađanja u sljedeće dvije godine je glasila: „Namjeravam imati još jedno dijete u sljedeće 2 godine (biološko dijete/djeca)“, za žene koje već imaju dijete/djecu;

odnosno: „Namjeravam imati dijete u sljedeće 2 godine (biološko dijete/djecu)“, za žene koje nemaju dijete.

Na temelju dobivenih rezultata korištena su tri načina mjerenja namjere rađanja (M1, M2, M3), a uzimajući u obzir da su ispitanice na postavljenu izjavu dale odgovor kako nisu sigurne u svoju namjeru rađanja u sljedeće dvije godine (3 – nisam sigurna). Binarna kriterijska varijabla za mjerenje namjere rađanja u sljedeće dvije godine kodirana je kako slijedi, a iz iste su proizašla i tri alternativna mjerenja kriterijske varijable M1, M2, M3:

M1: odgovori 1, 2 i 3 = 0
odgovori 4 i 5 = 1
M2: odgovori 1 i 2 = 0
odgovori 4 i 5 = 1
M3: odgovori 1 i 2 = 0
odgovori 3, 4 i 5 = 1

pri čemu se 0 odnosi na stav „nemam namjeru rađanja u sljedeće dvije godine“, a 1 na stav „imam namjeru rađanja u sljedeće dvije godine“.

Kreiranje različitih načina mjerenja namjere rađanja i blokova u mjerenju namjera rađanja u skladu je s prethodnim istraživačkim spoznajama (Chen i sur., 2024), a imaju za cilj procijeniti učinke različitih kategorija prediktorskih varijabli. U nastavku je prikazana deskriptivna analiza kriterijskih i prediktorskih varijabli koje su korištene za testiranje postavljenih hipoteza (tablica 32.).

Tablica 32. Deskriptivna analiza kriterijskih i prediktorskih varijabli

Varijabla	**N**	**x̄**	**s**
Namjera rađanja M1	1.036	0,25	0,43
Namjera rađanja M2	843	0,30	0,46
Namjera rađanja M3	1.036	0,43	0,50
Fertilni jaz	673	1,41	1,12
Sigurnost posla	1.036	2,98	1,17
Financijska sigurnost	1.036	3,25	1,08
Potpuno vlasništvo nad nekretninom	1.036	0,55	0,50

Izravni novčani transferi	864	3,39	1,21
Neizravni novčani transferi	970	3,40	1,36
Transferi u naravi	941	3,49	1,21
Indeks regije	1.036	2,91	1,10

Izvor: izrada doktorandice

U tablici 32. prikazane su osnovne deskriptivne statistike za niz varijabli, uključujući kriterijske varijable koje se odnose na namjeru rađanja (M1, M2, M3) i fertilni jaz, kao i prediktorske varijable kao što su sigurnost posla, financijska sigurnost, stambeni uvjeti, razni oblici transfera i regije prema indeksu razvijenosti.

Prosječna vrijednost varijable namjere rađanja u sljedeće dvije godine najveća je u alternativnom načinu mjerenja namjere rađanja M3 ($\bar{x}$ = 0,43), dok je najmanja vrijednost u načinu mjerenja M1 ($\bar{x}$ = 0,25). Navedeno pokazuje da ocjena 3 značajno utječe na kriterijsku varijablu, odnosno namjeru rađanja u sljedeće dvije godine. U alternativnom načinu mjerenja namjere rađanja M2 prosječna vrijednost kriterijske varijable je 0,30. Izostavljanje ocjene 3 u kreiranju kriterijske varijable utječe na povećanje njezine prosječne vrijednosti. Standardna devijacija ukazuje na konzistentnost odgovora ispitanica u modelu M1 (s = 0,43), dok je značajnija varijabilnost među odgovorima u alternativnom mjerenju namjere rađanja M3 (s = 0,50) i M2 (s = 0,46). Žene koje imaju djecu prosječno imaju manju namjeru rađanja u sljedeće dvije godine (M1: $\bar{x}$ = 0,16, M2: $\bar{x}$ = 0,17, M3: $\bar{x}$ = 0,32) u odnosu na žene koje nemaju dijete (M1: $\bar{x}$ = 0,41, M2: $\bar{x}$ = 0,54 , M3: $\bar{x}$ = 0,65).

Varijabla „fertilni jaz“ (DQ4eDQ4c) izračunata je kao razlika željenog broja djece i stvarnog broja živorođene djece kod žena koje su već imale djecu u vrijeme provedbe istraživanja. Dobivene pozitivne vrijednosti ukazuju na neispunjenje reproduktivne želje, odnosno da je veći broj željene djece u odnosu na stvarni broj živorođene djece. Negativne vrijednosti fertilnog jaza ukazuju na veći broj živorođene djece u odnosu na željeni broj djece u ranim dvadesetim godinama starosti žene. Nulti fertilni jaz javlja se u situaciji kada je stvarni broj živorođene djece jednak željenom broju djece.

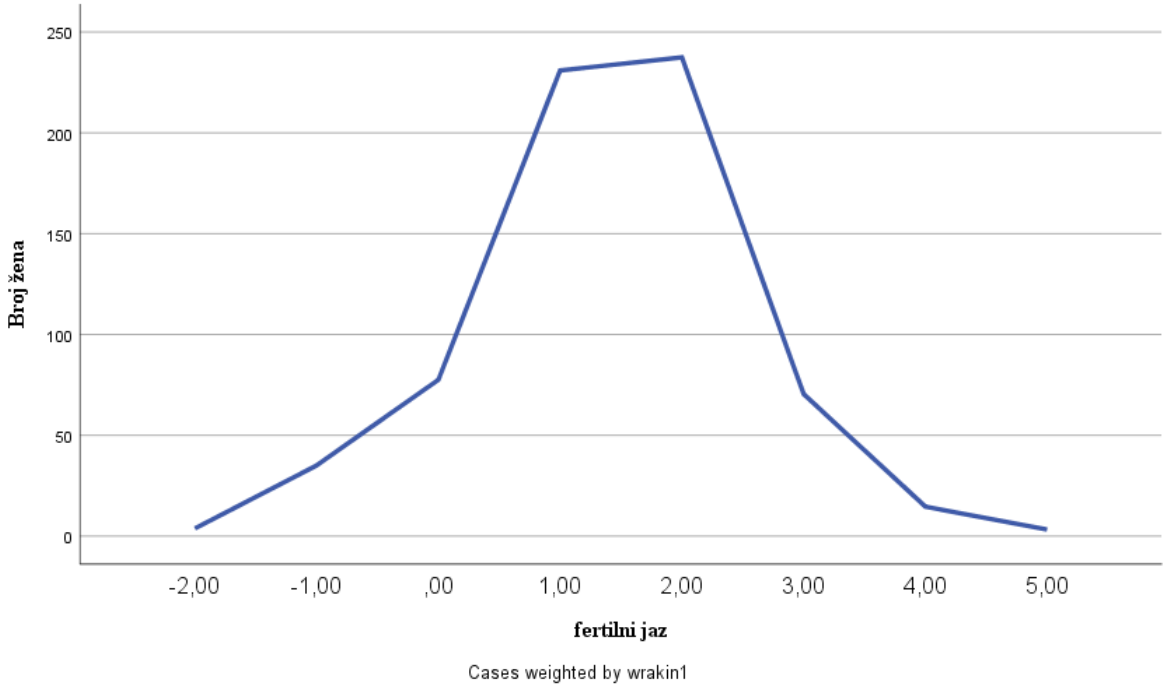

Grafikon 7. Veličina fertilnog jaza
Izvor: izrada doktorandice

Iz grafikona 7. vidljivo je da samo 5,8 % žena ima pozitivan fertilni jaz, odnosno veći stvarni broj djece od željenog. Stvarni broj djece jednak željenom, odnosno nulti fertilni jaz ima 11,5 % ispitanica. Preostale ispitanice (82,7 %) nisu ostvarile željeni broj djece te je kod njih prisutan negativan fertilni jaz.

5.7.2. Istraživanje povezanosti ekonomske sigurnosti, fertilnog jaza i namjere rađanja

Ovo potpoglavlje posvećeno je testiranju hipoteze H1 i pripadajućih pomoćnih hipoteza H1a, H1b i H1c, kao i testiranju hipoteze H2. Istraživanje povezanosti između ekonomske sigurnosti i namjere rađanja korišteno je u cilju donošenja zaključka jesu li žene koje imaju siguran posao, financijsku sigurnost i potpuno vlasništvo nad nekretninom sklonije namjeri rađanja u sljedeće dvije godine (H1a, H1b i H1c). Istraživanje povezanosti ekonomske sigurnosti i fertilnog jaza (H2) provedeno je u svrhu ustanovljenja razlike u jazu između željenog i ostvarenog broja djece ovisno o ekonomskoj sigurnosti. Postavljenom hipotezom pretpostavljalo se je da ekonomska sigurnost dovodi do manjeg jaza između željenog i ostvarenog broja djece. Veličina jaza (fertilni_jaz_DQ4eDQ4c) izračunata je kao razlika željenog broja djece u 20-im godinama starosti (DQ4E) i broja živorođene djece (DQ4C).

Za testiranje hipoteze H1 primijenjena je binarna logistička regresija, dok je za testiranje hipoteze H2 korišten Spearmanov koeficijent korelacije.

Kako je već ranije navedeno (potpoglavlje 5.6.3.), H1 testirana je kroz tri različita načina izražavanja namjere i tri bloka. Kontrolne varijable uključene su u modele na temelju prethodnih istraživačkih spoznaja, a odnose se na:

- vrstu ugovora o radu (Pieroni i sur., 2023; Alderotti i sur., 2021, Modena i sur., 2014)
- sektor zaposlenja (Wijk i sur., 2021), radni status (Modena i sur., 2014; Gatta i sur., 2021)
- bračni status (Modena i sur., 2014), tip naselja (Fahlen i Olah, 2015)
- broj djece (Hu i sur., 2022; Modena i sur., 2014; Mansour, 2018)
- razina obrazovanja (Modena i sur., 2014; Gatta i sur., 2021; Fahlen i Olah, 2015; Hu i sur., 2022)
- starosnu dob (Modena i sur., 2014; Gatta i sur., 2021; Fahlen i Olah, 2015; Wijk i sur., 2021; Hu i sur., 2022)
- prihode kućanstva (Gatta i sur., 2021; Wijk i sur., 2021; Mansour, 2018; Modena i sur., 2014; Hu i sur., 2022)
- regionalnu razvijenost (Ciritel i sur., 2019; Fox i sur., 2018; Myrskylä i sur., 2009)
- mogućnost podmirivanja financijskih obveza (Gauthier i sur., 2022).

U nastavku su prikazani rezultati testiranja.

Tablica 33. Povezanost sigurnosti posla i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Sigurnost posla	,312*** (,089)	,533*** (,107)	,431** (,129)	,326*** (,091)	,606*** (,121)	,382* (,152)	,230** (,075)	,436*** (,096)	,308** (,107)
Stavovi		-,097 (,238)	-,101 (,306)		-,005 (,253)	,219 (,350)		,048 (205)	,227 (235)
Subjektivne norme		,651*** (,161)	,788*** (,199)		,948*** (,200)	1,153*** (,277)		,990*** (,158)	1,140*** (186)
Percipirana kontrola ponašanja		1,792*** (,276)	1,682*** (,353)		1,943*** (,301)	1,646*** (397)		1,278*** (,210)	1,079*** (,242)
Broj djece			-2,026*** (,414)			-2,077*** (,445)			-,842*** (,221)
Djeca (DA) * Godine starosti			-,193*** (,038)			-,226*** (,043)			-,100*** (,024)
Djeca (DA) * Obrazovanje(srednje ili niže obrazovanje) * Indeks_regije (ispodprosječno rangirane, I. i II. skupina)			-1,435** (,535)			-1,508* (,601)			-,234 (,330)
Djeca (DA) * Podmirivanje financ. obveza (poteškoće) * Vrsta ugovora o radu (određeno)			2,126* (,949)			2,373* (1,009)			,648 (,737)
Sektor zaposlenja (privatni) * Vrsta ugovora o radu (određeno)			-1,561* (,733)			-1,440 (,929)			,205 (541)
Godine starosti * Tip naselja (urbano) * Bračni status (sama/neudana)			,018* (,009)			,023* (0,11)			,009 (,007)
Konstanta	-2,148*** (,296)	-9,626*** (1,173)	-7,854*** (1,369)	-1,930*** (,300)	-10,386*** (1,350)	-7,888*** (1,543)	-1,065*** (,237)	-6,738*** (,897)	-4,923*** (,985)

Omnibus test koeficijenata modela	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,01	p < ,001	p < ,001
Hosmer i Lemeshow test	χ^2 = 16,419 df = 7 p = ,022	χ^2 = 13,552 df = 8 p = ,094	χ^2 = 3,702 df = 8 p = ,883	χ^2 = 15,225 df = 7 p = ,033	χ^2 = 10,964 df = 8 p = ,204	χ^2 = 4,371 df = 8 p = ,822	χ^2 = 9,912 df = 7 p = ,194	χ^2 = 6,909 df = 8 p = ,547	χ^2 = 9,991 df = 8 p = ,266
Klasifikacijska točnost	77,1 %	80,2 %	87,1 %	72,3 %	82,1 %	89,4 %	58,5 %	74,5 %	81,4 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Tablica 33. prikazuje rezultate logističke regresije za sva tri načina mjerenja kriterijske varijable (M1, M2 i M3). Rezultati ukazuju na statistički značajnu (p < ,001, p < ,01 i p < ,05) pozitivnu povezanost sigurnosti posla i namjere rađanja u sljedeće dvije godine kada je namjera rađanja eksplicitno izražena s „vjerojatno“ ili „definitivno da“ (M1 i M2), odnosno „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3). Sigurnost posla povećava izglede za namjeru rađanja za 1,83 puta (M2, Blok 2: Exp(B) = 1,834[18]). Omnibus test koeficijenata modela u kojemu je kriterijska varijabla M1 ukazuje na valjanost modela u sva tri bloka (p < ,001). Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test (p > ,05). Dodavanjem varijabli iz Teorije planiranog ponašanja (Blok 2) povećala se klasifikacijska točnost sa 77,1 % na 87,1 %. Uključivanjem kontrolnih varijabli u model (Blok 3) dodatno je povećana klasifikacijska točnost modela na 87,1 % čime je potvrđeno teorijsko uporište o važnosti uključivanja kontrolnih varijabli u testirane modele. Veći broj djece koji žena već ima smanjuje šansu za namjerom rađanja u sljedeće dvije godine. Promatrajući interakcijske efekte, dolazi se do zaključka da se s povećanjem starosti žena koje imaju djecu smanjuju izgledi (Exp(B) = ,824) za namjeru rađanja u sljedeće dvije godine. Nadalje, žene sa srednjim ili nižim obrazovanjem koje imaju dijete/djecu i žive u jedinicama područne (regionalne) samouprave koje su prema indeksu razvijenosti svrstane u I. ili II. skupinu imaju manje izglede (Exp(B) = ,238)

[18] Prikazana je najveća vrijednost Exp(B) varijable „sigurnost posla“ promatrajući sve blokove (Blok 1, Blok 2, Blok 3) ovisno o načinu izražavanja namjere rađanja (M1, M2, M3).

za namjeru rađanja u odnosu na referentnu skupinu (žene bez djece, više obrazovane ili iz regija III. i IV. skupine prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme pokazuju veću spremnost (Exp(B) = 8,38) za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Žene s ugovorom na određeno vrijeme koje su zaposlene u privatnom sektoru pokazuju manje izglede (Exp(B) = ,21) za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje imaju stalno zaposlenje i zaposlene su u javnom sektoru. Konačno, sa svakom dodatnom godinom starosti, šansa za namjeru rađanja raste za 1,8 % unutar grupe neudanih žena koje žive u urbanim naseljima. Kada je u regresijski model uključena kriterijska varijabla M2 ne uočavaju se značajnija odstupanja u odnosu na rezultate logističke regresije s kriterijskom varijablom M1. U Bloku 3 izostaje statistička značajnost interakcijskog djelovanja žena koje su zaposlene u privatnom sektoru i imaju ugovor na određeno vrijeme. Nadalje, posljednji alternativni način mjerenja namjere rađanja u sljedeće dvije godine (M3) pokazuje značajnije razlike u odnosu na prethodna dva pristupa. Navedeno dodatno potvrđuje već prethodne zaključke da odgovor 3 („nisam sigurna“) prilikom mjerenja namjere rađanja u sljedeće dvije godine značajno utječe na konačan ishod. Naime, kada je kriterijska varijabla eksplicitno izražena s „nisam sigurna“, „definitivno“ ili „vjerojatno da“, izostaje statistička značajnost interakcije između varijabli starosti žena koje žive u urbanim sredinama i nisu udane, sektora u kojemu je žena zaposlena i ugovora o radu na određeno vrijeme, kao i ugovora o radu na određeno vrijeme kod žena koje imaju dijete/djecu te ujedno imaju i poteškoće u podmirivanju svojih financijskih obveza. Osim toga, nije statistički značajna interakcija niti između varijabli obrazovanja, regije prema indeksu razvijenosti i imanja djece. U *Prilogu 2* prikazane su opcije koje uključuju dodatne kategorije varijabli, nove varijable ili drugačije određenu referentnu kategoriju unutar postojeće varijable.

ROC krivulja i područje ispod nje ključni su alati za procjenu učinkovitosti klasifikacijskog modela, omogućujući detaljan uvid u sposobnost modela da razlikuje između različitih kategorija te pomažu u optimizaciji klasifikacijskih odluka.

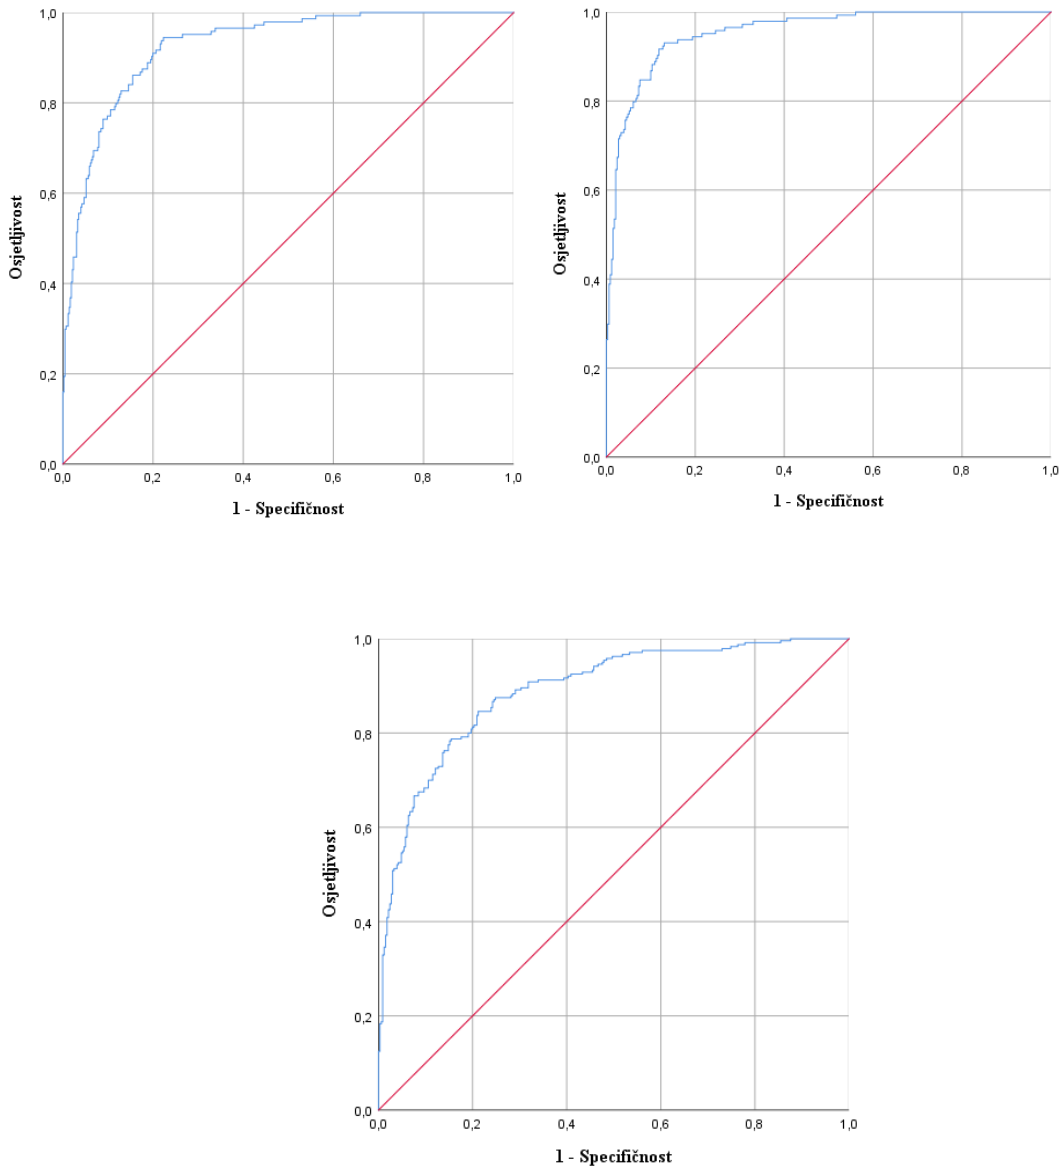

Grafikon 8. ROC krivulja M1, M2, M3 (Blok 3)
Izvor: izrada doktorandice

ROC krivulja omogućuje usporedbu različitih modela. Tako model s višom AUC vrijednošću bolje razlikuje između pozitivnih i negativnih klasa. Ovo je osobito korisno kada se treba odabrati najbolji model za predviđanje, stoga su izračunate AUC vrijednosti za sva tri načina izražavanja namjere rađanja u sljedeće dvije godine M1, M2 i M3 na temelju rezultata logističke regresije u Bloku 3.

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju

namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,926. Ova visoka vrijednost, uz standardnu pogrešku od ,012, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,904 i ,949 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,954, uz standardnu pogrešku od ,009 te $p < ,001$. Interval pouzdanosti od 95 % je između ,936 i ,972. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3) AUC vrijednost je ,891, dok je standardna greška ,014 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,864 do ,917. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

Tablica 34. Povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Financijska sigurnost	,216* (,107)	,643*** (,140)	,435* (,170)	,217* (,108)	,670*** (,154)	,355 (,199)	,146 (,089)	,519*** (,122)	,306* (,140)
Stavovi		-,079 (,270)	-,164 (,346)		-,010 (,288)	,222 (,390)		,152 (,225)	,412 (,267)
Subjektivne norme		,732*** (,176)	1,027*** (,231)		1,082*** (,220)	1,379*** (,314)		1,031*** (,171)	1,247*** (,205)
Percipirana kontrola ponašanja		2,011*** (1,492)	1,900*** (,403)		2,028*** (,349)	1,716*** (,435)		1,308*** (,237)	1,046*** (,274)
Broj djece			-1,639*** (,429)			-1,747*** (,461)			-,677** (,232)
Djeca (DA)			10,732*** (2,082)			10,776*** (2,341)			3,037*** (1,179)
Djeca (Da) * Godine starosti			-,235*** (,045)			-,262*** (,051)			-,114*** (,027)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije(ispodprosječno rangirane, I. i II. skupina)			-1,667** (,639)			-1,608* (,739)			,113 (,373)
Djeca (DA) * Podmirivanje financ. obveza (poteškoće) * Vrsta ugovora o radu (određeno)			2,637** (1,020)			2,396* (1,092)			1,348 (,838)
Sektor zaposlenja (privatni) * Vrsta ugovora o radu (određeno)			-1,732* (,792)			-1,188 (1,011)			,401 (,614)

Godine starosti * Tip naselja (urbano) * Bračni status (udana/udana, ali žive odvojeno)			,011 (,010)			,017 (,012)			,005 (,008)
Djeca (DA) * ukupni prihod kućanstva			-,729* (,367)			-,548 (,411)			,104 (,243)
Konstanta	-1,921*** (,366)	-11,035*** (1,492)	-8,496*** (1,714)	-1,672*** (,368)	-11,062*** (1,617)	-7,989*** (1,836)	-,873** (,297)	-7,575*** (1,121)	-5,322*** (1,260)
Omnibus test koeficijenata modela	p = ,041	p < 0,001	p < 0,001	p = ,042	p < 0,001	p < 0,001	p = ,101	p < 0,001	p < 0,001
Hosmer i Lemeshow test	χ^2 = 2,643 df = 8 p = ,955	χ^2 = 4,401 df = 8 p = ,819	χ^2 = 10,849 df = 8 p = ,210	χ^2 = 2,337 df = 8 p = ,969	χ^2 = 6,701 df = 8 p = ,569	χ^2 = 5,654 df = 8 p = ,686	χ^2 = 4,649 df = 8 p = ,794	χ^2 = 7,732 df = 8 p = ,460	χ^2 = 8,596 df = 8 p = ,378
Klasifikacijska točnost	77,5 %	82,5 %	89,3 %	72,8 %	81,3 %	90,2 %	60,3 %	77,2 %	80,9 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Rezultati logističke regresije prikazani u tablici 34. ukazuju na statistički značajnu (p < ,001, p < ,01 i p < ,05) pozitivnu povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine kada je namjera rađanja eksplicitno izražena s „vjerojatno“ ili „definitivno da“ (M1 i M2), odnosno „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3). Financijska sigurnost povećava šansu za namjeru rađanja za 1,681 do 1,954 puta (M1, Blok 2: Exp(B) = 1,902; M2, Blok 2: Exp(B) = 1,954; M2, Blok 2: Exp(B) = 1,681)[19].

Omnibus test koeficijenata modela u kojemu je kriterijska varijabla M1 ukazuje na valjanost modela u Bloku 2 i Bloku 3 (p < ,001). Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test (p > ,05). Dodavanjem varijabli iz Teorije planiranog ponašanja (Blok 2)

[19] Prikazane su najveće vrijednosti Exp(B) varijable „financijska sigurnost“ za svaki od načina kreiranja kriterijske varijable (M1, M2, M3).

povećala se klasifikacijska točnost sa 82,5 % na 89,3 %. Uključivanjem kontrolnih varijabli u model (Blok 3) dodatno je povećana klasifikacijska točnost modela čime je ponovno potvrđeno teorijsko uporište o važnosti uključivanja kontrolnih varijabli u testirane modele. Paritet je statistički značajna varijabla u modelu, neovisno o načinu kreiranja kriterijske varijable. Ista je negativno povezana s namjerom rađanja, stoga se može zaključiti da veći broj djece koji žena ima smanjuje njezinu šansu (M1: Exp(B) =,194; M2: Exp(B) = ,174; M3: Exp(B) = ,508) za namjeru rađanja u sljedeće dvije godine. Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 10,8 % do 23 % (M1: Exp(B) =,790; M2: Exp(B) = ,770; M3: Exp(B) = ,892) u odnosu na mlađe žene koje još uvijek nemaju dijete. Nadalje, izgledi za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu i žive u manje razvijenim regijama manji su za oko 80 % (M1: Exp(B) = ,189; M2: Exp(B) = ,200) u odnosu na žene suprotnih karakteristika (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme imaju za otprilike 11 do 13 puta veću šansu (M1: Exp(B) = 13,976, M2: Exp(B) = 10,977) za namjeru rađanja u sljedeće dvije u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Signifikantnost prethodno navedenih interakcijskih varijabli izostaje u logističkom modelu u kojemu je namjera rađanja iskazana kao M3. Žene s ugovorom na određeno vrijeme koje su zaposlene u privatnom sektoru pokazuju manje izglede (M1: Exp(B) = ,177) za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje imaju stalno zaposlenje i zaposlene su u javnom sektoru. Konačno, žene s djecom i većim ukupnim prihodom kućanstva imaju veće izglede za namjeru rađanja (M2: Exp(B) = 1,110). U *Prilogu 3* prikazane su opcije koje uključuju dodatne interakcijske efekte.

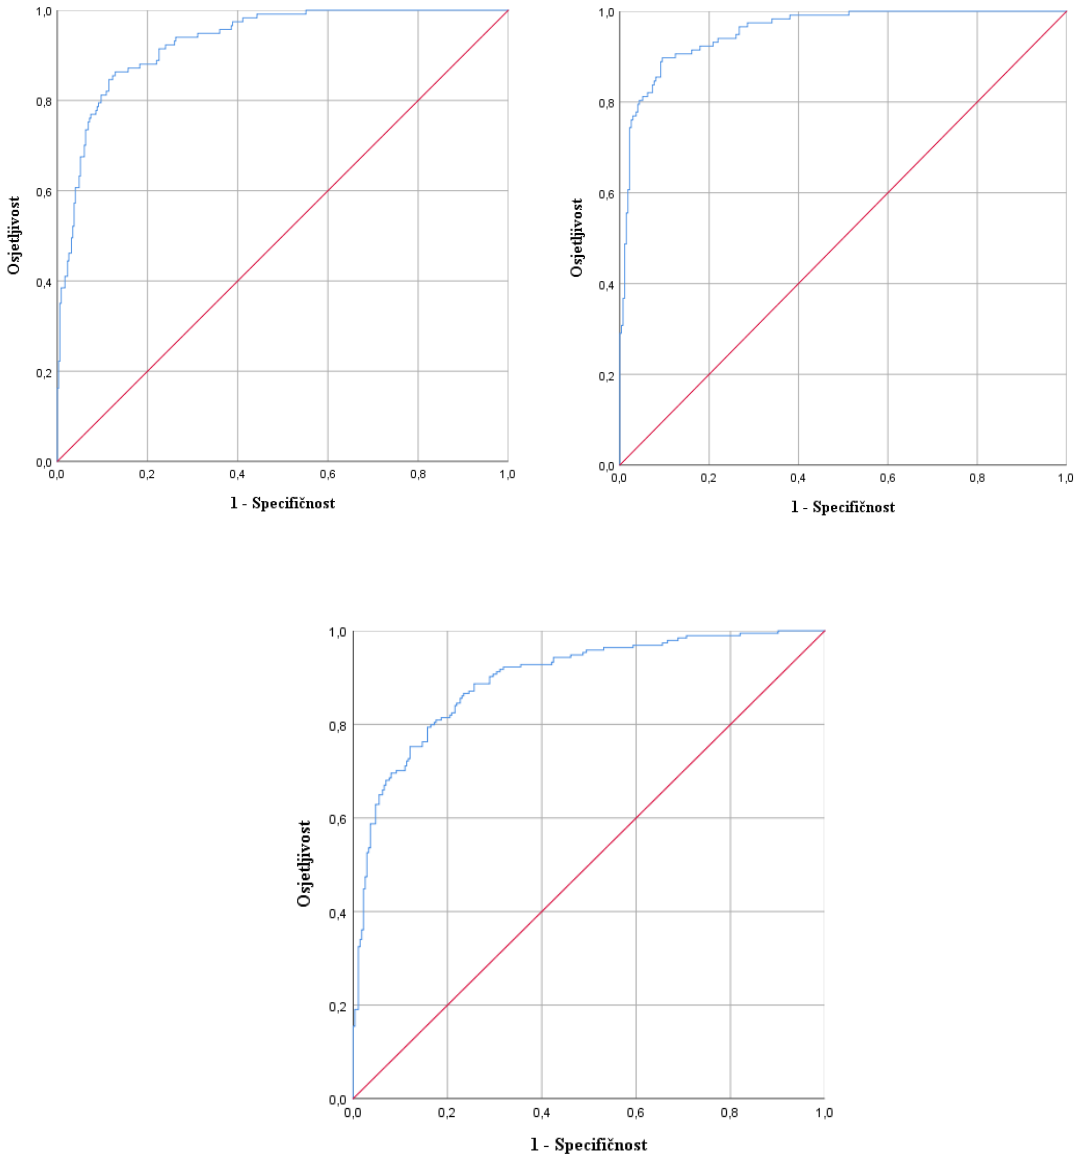

Grafikon 9. ROC krivulja M1, M2 i M3 (Blok 3)
Izvor: izrada doktorandice

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,931. Ova visoka vrijednost, uz standardnu pogrešku od ,012, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,907 i ,955 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,956, uz standardnu pogrešku od ,010 te $p < ,001$. Interval

pouzdanosti od 95 % je između ,937 i ,976. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3) AUC vrijednost je ,897, dok je standardna greška ,015 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,868 do ,926. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

Tablica 35. Povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Potpuno vlasništvo	-,141 (,172)	-,580** (,202)	,019 (,249)	-,226 (,179)	-,725** (,225)	-,243 (,298)	-,276 (,153)	-,709*** (,187)	-,288 (,213)
Stavovi		-,073 (,197)	,046 (,242)		-,008 (,208)	,281 (,277)		.035 (,175)	,319 (,202)
Subjektivne norme		,651*** (,137)	,686*** (,164)		,927*** (,164)	,961*** (,217)		,930*** (,137)	1,031*** (,160)
Percipirana kontrola ponašanja		1,701*** (,226)	1,585*** (,280)		1,795*** (,241)	1,674*** (,322		1,231*** (,176)	,952*** (,204)
Broj djece			-2,169*** (,371)			-2,350*** (,401)			-,959*** (,203)
Djeca (DA) * Godine starosti			-,147*** (,029)			-,160*** (,032)			-,079*** (,020)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije (ispodprosječno, I. i II. skupina)			-1,152* (,451)			-1,371** (,515)			-,345 (,304)
Djeca (DA) * Podmirivanje financ. obveza (teškoće) * Vrsta ugovora o radu (određeno)			2,061* (,879)			1,924* (,937)			,470 (,704)
Sektor zaposlenja (privatni) * Vrsta ugovora o radu (određeno)			-,942 (,528)			-,466 (,692)			,229 (,481)
Godine starosti * Tip naselja (urbano) *			-,016			-,019			-,012

Bračni status (sama, neudana)			(,008)			(,010)			(008)
Konstanta	-,957*** (,117)	-7,325*** (,833)	-6,249*** (,987)	-,639*** (,123)	-7,475*** (,914)	-6,464*** (1,115)	-,102 (,105)	-4,750*** (,636)	-3,374*** (,729)
Omnibus test koeficijenata modela	p = ,411	p < 0,001	p < 0,001	p = ,207	p < 0,001	p < 0,001	p = ,070	p < 0,001	p < 0,001
Hosmer i Lemeshow test	χ^2 = ,000 df = 0	χ^2 = 4,401 df = 8 p = ,819	χ^2 = 2,148 df = 8 p = ,976	χ^2 = ,000 df = 7	χ^2 = 5,707 df = 8 p = ,680	χ^2 = 5,654 df = 8 p = ,686	χ^2 = 000 df = 0	χ^2 = 8,365 df = 8 p = ,399	χ^2 = 14,383 df = 8 p = ,072
Klasifikacijska točnost	73,6 %	77,4 %	84,9 %	67,9 %	78,7 %	87,7 %	55,8 %	73 %	78,7 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Rezultati logističke regresije u tablici 35. ukazuju na statistički značajnu (p < ,05) povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine samo u Bloku 2, dodavanjem kontrolnih varijabli u Bloku 3 statistička značajnost izostaje, kao i u Bloku 1. Potpuno vlasništvo nad nekretninom smanjuje izglede za namjeru rađanja (M1, Blok 2: Exp(B) = ,560; M2, Blok 2: Exp(B) = ,484; M3, Blok 2: Exp(B) = ,492)[20].

Omnibus test koeficijenata modela ukazuje na valjanost modela u Bloku 2 i 3 (p < 0,05) u sva tri načina prikazivanja kriterijske varijable. Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test (p > 0,05). Statistički značajne varijable su subjektivne norme i percipirana kontrola ponašanja, dok stavovi nisu statistički značajni niti u jednom slučaju. Promatrajući Blok 3 u sva tri načina kreiranja kriterijske varijable,

[20] Prikazane su statistički značajne vrijednosti Exp(B) varijable „potpuno vlasništvo nad nekretninom“ za svaki od načina kreiranja kriterijske varijable (M1, M2, M3).

paritet je statistički značajna varijabla te je ista je negativno povezana s namjerom rađanja, stoga se može zaključiti da veći broj djece koji žena ima smanjuje izglede (M1: Exp(B) =,114; M2: Exp(B) = ,09; M3: Exp(B) = ,383) za namjeru rađanja u sljedeće dvije godine. Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 7,6 % do 14,8 % (M1: Exp(B) =,863; M2: Exp(B) = ,852; M3: Exp(B) = ,924) u odnosu na mlađe žene koje još uvijek nemaju dijete. Nadalje, izgledi za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu i žive u manje razvijenim regijama su manji za oko 68 % do 75 % (M1: Exp(B) = ,316; M2: Exp(B) = ,254) u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme imaju za otprilike 7 do 8 puta veće izglede (M1: Exp(B) = 7,858, M2: Exp(B) = 6,848) za namjeru rađanja u sljedeće dvije u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Preostale varijable i njihove interakcije nisu statistički značajne. U *Prilogu 4* prikazane su dodatne opcije testiranja povezanosti potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine.

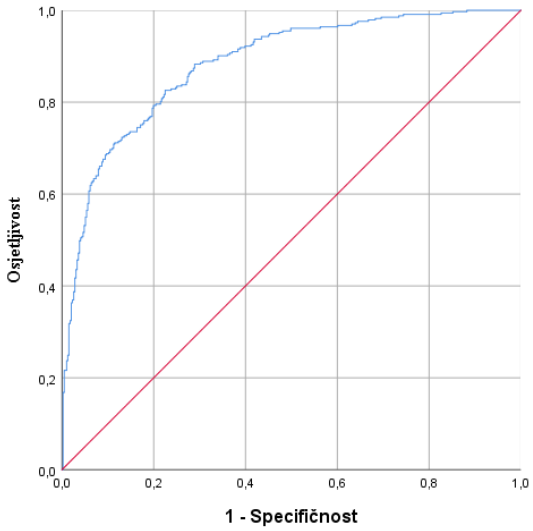

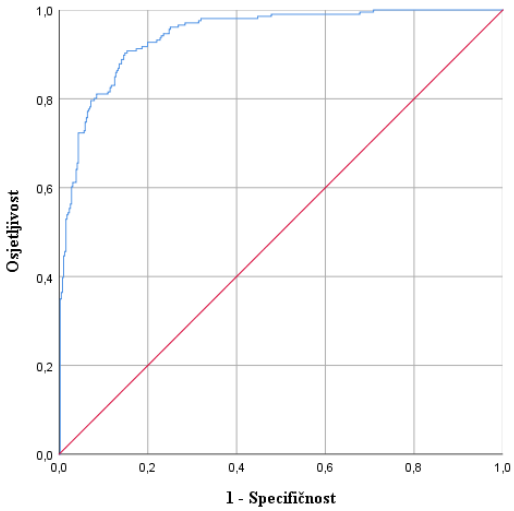

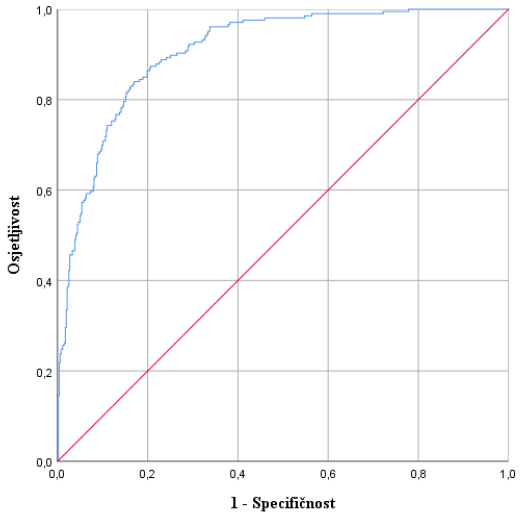

Grafikon 10. ROC krivulja M1, M2 i M3 (Blok 3)
Izvor: izrada doktorandice

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,908. Ova visoka vrijednost, uz standardnu pogrešku od ,011, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,886 i ,930 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,943, uz standardnu pogrešku od ,009 te $p < ,001$. Interval pouzdanosti od 95 % je između ,925 i ,961. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3) AUC vrijednost je ,883, dok je standardna greška ,012 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,858 do ,907. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

Na temelju prethodno prikazanih rezultata može se zaključiti kako dodavanje kontrolnih varijabli u model može imati utjecaj na statističku značajnost promatranih varijabli. Osim toga, tri različita načina izražavanja kriterijske varijable pokazala su se utemeljenim

budući da se klasifikacijska točnost modela značajno razlikuje ovisno o modelu, kao i statistička značajnost promatranih varijabli.

U nastavku je potrebno utvrditi postoji li statistički značajna negativna povezanost između ekonomske sigurnosti i fertilnog jaza (hipoteza H2).

Testiranje povezanosti provedno je Spearmanovim koeficijentom korelacije te su u nastavku prikazani rezultati korelacijske analize koja uključuje četiri varijable: fertilni jaz kao kriterijsku varijablu te prediktorske varijable: sigurnost posla, financijsku sigurnost te potpuno vlasništvo nad nekretninom.

Tablica 36. Testiranje povezanosti ekonomske sigurnosti i fertilnog jaza

		Fertilni jaz	Sigurnost posla	Financijska sigurnost	Potpuno vlasništvo
Fertilni jaz	r_s		,022	-,040	,074*
	p	.	,545	,279	,047
	N	725	725	725	725
Sigurnost posla	r_s	,022		,663**	,097**
	p	,545	.	,000	,009
	N	725	725	725	725
Financijska sigurnost	r_s	-,040	,663**		,091*
	p	,279	,000	.	,015
	N	725	725	725	725
Potpuno vlasništvo	r_s	,074*	,097**	,091*	
	p	,047	,009	,015	.
	N	725	725	725	1132

*p < ,05, **p < ,01 (dvosmjerni test)

Izvor: izrada doktorandice

Spearmanov koeficijent korelacije (tablica 36.) pokazuje pozitivnu povezanost između fertilnog jaza i potpunog vlasništva nad nekretninom (r_s = ,74) uz statističku razinu značajnosti manju od ,05. S druge strane, ne postoji statistički značajna povezanost između fertilnog jaza i sigurnosti posla, kao niti fertilnog jaza i financijske sigurnosti, stoga nije moguće daljnje tumačenje rezultata korelacijske analize.

Zanimljivo je razmotriti razloge koje su ispitanice u provedenom empirijskom istraživanju navele kao najveće uzroke fertilnog jaza. Najveći broj ispitanica koji nije ostvario željeni broj djece izjasnio se je da nije bilo pravo vrijeme (43,6 %). Kao sljedeći razlog navode visoke troškove koji su povezani s uzdržavanjem djece (39,8 %), promjene prioriteta (38,9 %), dok je 38,7 % ispitanica navelo kao uzrok fertilnog jaza problem usklađivanja poslovnog i obiteljskog života. Značajan uzrok pronalaze i u financijskim problemima i u nemogućnosti podmirivanja neočekivanih troškova. Problem neposjedovanja vlastite nekretnine i neadekvatni stambeni uvjeti također su važni uzročnici fertilnog jaza. 32,6 % ispitanica kao uzrok neostvarenja željenog broja djece navodi nesiguran posao. Iz navedenog se može zaključiti kako rezultati istraživanja ne odstupaju značajno od prethodnih istraživačkih spoznaja koje su prezentirane u potglavlju 4.3.3.

5.7.3. Istraživanje povezanosti fiskalnih instrumenata javnih politika i namjere rađanja

Ovo potpoglavlje bavi se analizom utjecaja fiskalnih mjera na reproduktivne odluke žena starosti od 22 do 49 godina. Fiskalni instrumenti koji uključuju izravne novčane transfere, neizravne novčane transfere i naknade u naravi, ključni su alati kojima država može poticati ili podržavati obitelji u donošenju odluka o rađanju djece. Ove mjere imaju značajnu ulogu u ublažavanju financijskih pritisaka povezanih s roditeljstvom, a njihova učinkovitost ovisi o tome u kojoj mjeri doprinose smanjenju ekonomskih barijera i povećanju sigurnosti za obitelji. Cilj ovog istraživanja je utvrditi utječu li fiskalni instrumenti javnih politika na namjeru rađanja u sljedeće dvije godine stoga se u nastavku pristupa testiranju hipoteze H3 s pripadajućim pomoćnim hipotezama H3a, H3b i H3c.

Kako je već ranije navedeno, H3 je testirana na temelju tri različita načina kreiranja kriterijske varijable te tri bloka. Kontrolne varijable uključene su u modele na temelju prethodnih istraživačkih spoznaja, a odnose se na: starosnu dob žene (Andersen i sur., 2018; Raute, 2019; Cowan i Wyndham Douds, 2022), bračni status (Cowan i Wyndham Douds, 2022), broj djece (Cowan i Wyndham Douds, 2022; Cohen i sur., 2013), stupanj obrazovanja (Andersen i sur., 2018; Raute, 2019; Cohen i sur., 2013; Cowan i Wyndham Douds, 2022), prihode kućanstva (Andersen i sur., 2018; Raute, 2019; Laroquea i Salanié, 2014; Cohen i sur., 2013), mogućnost podmirivanja financijskih obveza (Gauthier i sur., 2022), radno vrijeme (Andersen i sur., 2018), regionalnu razvijenost (Ciritel i sur., 2019; Fox i sur., 2018; Myrskylä

i sur., 2009) i vrsta ugovora o radu (Pieroni i sur., 2023; Alderotti i sur., 2021, Modena i sur., 2014).

U nastavku su prikazani rezultati testiranja postavljenih hipoteza.

Tablica 37. Povezanost izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Izravni novčani transferi	,441*** (,111)	,521*** (,127)	,589*** (,160)	,493*** (,116)	,571*** (,141)	,608** (,198)	,339*** (,085)	,332** (,103)	,401** (,125)
Stavovi		-,226 (,267)	-,401 (,670)		-,176 (,284)	-,018 (,401)		,010 (,221)	,271 (,269)
Subjektivne norme		,718*** (,175)	1,062*** (,236)		1,116*** (,219)	1,426*** (,323)		1,010*** (,169)	1,236*** (,209)
Percipirana kontrola ponašanja		1,832*** (,315)	2,095*** (,431)		1,860*** (,337)	1,891*** (,464)		1,162*** (,227)	1,106*** (,275)
Broj djece			-1,300** (,443)			-1,669** (,511)			-,721** (,250)
Djeca (DA)			9,209*** (1,808)			9,198*** (2,060)			2,926** (1,084)
Djeca (Da) * Godine starosti			-,214*** (,045)			-,225*** (,050)			-,102*** (,027)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije (ispodprosječno rangirane, I. i II. skupina)			-1,896** (,640)			-1,789* (,734)			-,076 (,375)
Djeca (DA) * Podmirivanje financ. obveza (poteškoće) * Vrsta ugovora o radu (određeno)			2,714* (1,067)			2,379* (1,175)			1,359 (,845)
Sektor zaposlenja (privatni) * Vrsta			-1,506 (,814)			-1,293 (1,062)			,360 (,596)

ugovora o radu (određeno)									
Godine starosti * Tip naselja (ruralno) * Bračni status (udana/udana, ali žive odvojeno)			-,014 (011)			-,024 (,013)			-,015 (,008)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (1301 – 2700 EUR)			-,388* (,160)			-,178 (,178)			-,004 (,106)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (> 2700 EUR)			-,462* (,183)			-,405 (,208)			,011 (,116)
Konstanta	-2,826*** (,432)	-9,672*** (1,358)	-8,883*** (1,686)	-2,750*** (,448)	-9,789*** (1,483)	-8,486*** (1.825)	-1,600*** (,318)	-6,079*** (,961)	-5,239*** (1,129)
Omnibus test koeficijenata modela	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001
Hosmer i Lemeshow test	$\chi2$ = 14,879 df = 8 p = ,062	$\chi2$ = 10,202 df = 8 p = ,251	$\chi2$ = 9,535 df = 8 p = ,299	$\chi2$ = 15,612 df = 8 p = ,048	$\chi2$ = 9,781 df = 8 p = ,281	$\chi2$ = 3,776 df = 8 p = ,877	$\chi2$ = 11,083 df = 8 p = ,197	$\chi2$ = 7,792 df = 8 p = ,454	$\chi2$ = 4,864 df = 8 p = ,772
Klasifikacijska točnost	77,6 %	81,4 %	89,2 %	72,9 %	79,9 %	89,9 %	61,2 %	73,6 %	82,1 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Rezultati logističke regresije u tablici 37. ukazuju na statistički značajnu ($p < ,05$) pozitivnu povezanost izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine u svim blokovima bez obzira na način izražavanja kriterijske varijable. Mogućnost dobivanja izravnih novčanih transfera povećava izglede (M1, Blok 3: Exp(B) = 1,801; M2, Blok 3: Exp(B) = 1,837; M3, Blok 3: Exp(B) = 1,494[21]) za namjeru rađanja u sljedeće dvije godine.

Omnibus test koeficijenata modela ukazuje na valjanost modela u svim logističkim modelima. Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test ($p > ,05$), izuzev u Bloku 1 kada je iz kreiranja kriterijske varijable izuzet odgovor onih žena koje nisu sigurne u svoju namjeru (M2). Statistički značajne varijable iz Teorije planiranog ponašanja su subjektivne norme i percipirana kontrola ponašanja, dok stavovi nisu statistički značajni niti u jednom slučaju. Promatrajući Blok 3 u sva tri načina kreiranja kriterijske varijable, paritet je statistički značajna varijabla te je ista negativno povezana s namjerom rađanja, stoga se može zaključiti da veći broj djece koji žena ima smanjuje izglede (M1: Exp(B) = ,273; M2: Exp(B) = ,118; M3: Exp(B) = ,486) za namjeru rađanja u sljedeće dvije godine. Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 10 % do 20 % (M1: Exp(B) = ,807; M2: Exp(B) = ,798; M3: Exp(B) = ,903) u odnosu na mlađe žene koje još uvijek nemaju dijete. Nadalje, šansa za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu i žive u manje razvijenim regijama je manja (M1: Exp(B) = ,150; M2: Exp(B) = ,167) u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme imaju za otprilike 10 do 15 puta veće izglede (M1: Exp(B) = 15,091, M2: Exp(B) = 10,791) za namjeru rađanja u sljedeće dvije u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Žene koje imaju djecu, veći broj članova kućanstva i ukupan prihod kućanstva veći od 1.301 EUR imaju manju šansu za namjeru rađanja u odnosu na žene koje nemaju djecu, žive u kućanstvu s manjim brojem članova i imaju manje prihode. Preostale varijable i njihove interakcije nisu statistički značajne. U *Prilogu 5* prikazane su dodatne opcije testiranja povezanosti izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine.

[21] Najveća vrijednost Exp(B) varijable „izravni novčani transferi“ promatrajući sve blokove (Blok 1, Blok 2, Blok 3) ovisno o načinu izražavanja namjere rađanja (M1, M2, M3).

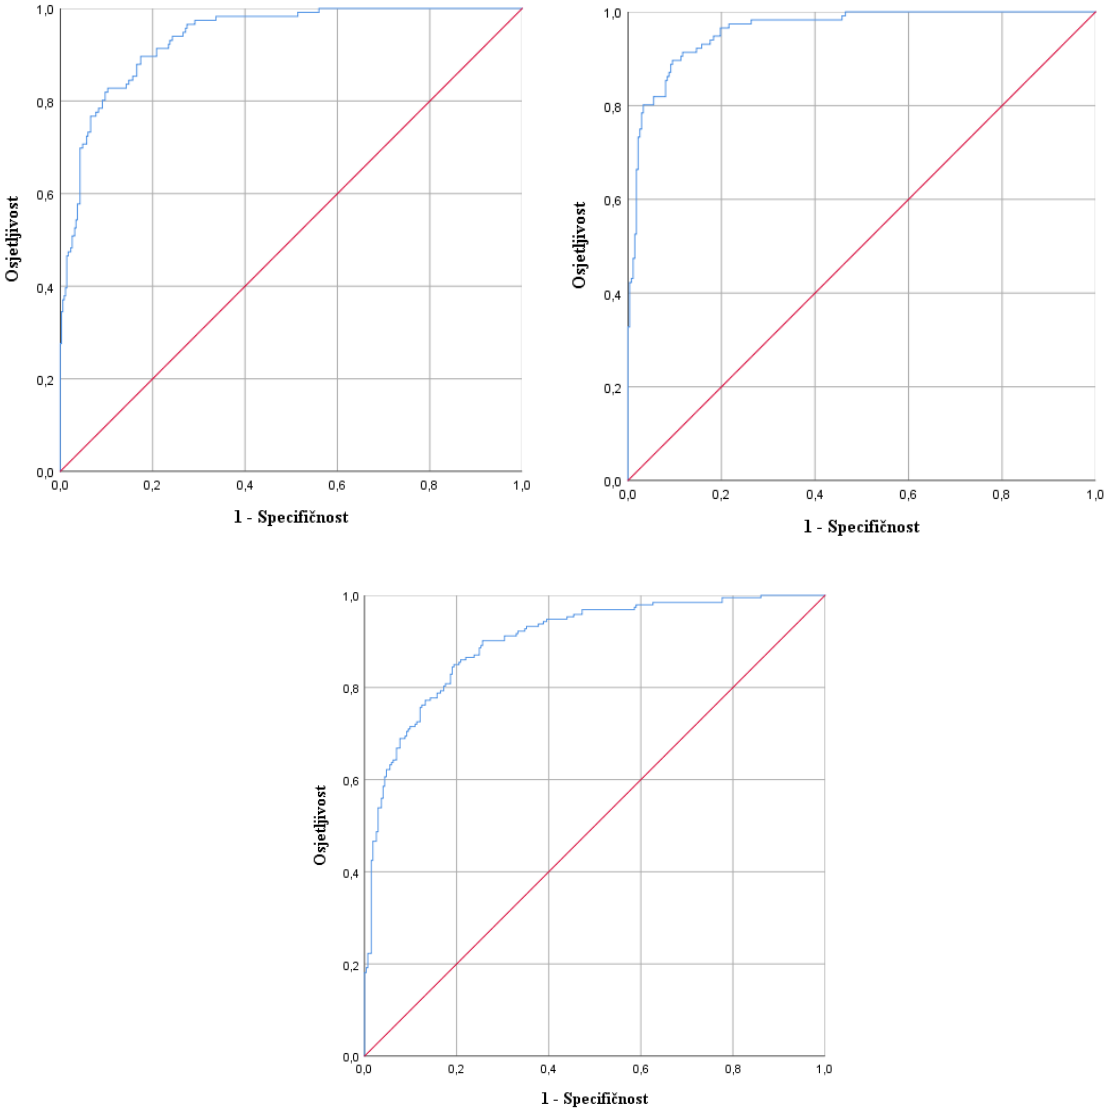

Grafikon 11. ROC krivulja M1, M2 i M3 (Blok 3)
Izvor: izrada doktorandice

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,938. Ova visoka vrijednost, uz standardnu pogrešku od ,011, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,915 i ,960 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,961, uz standardnu pogrešku od ,009 te $p < ,001$. Interval

pouzdanosti od 95 % je između ,944 i ,979. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s nisam sigurna, vjerojatno ili definitivno da (M3) AUC vrijednost je ,903, dok je standardna greška ,014 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,875 do ,930. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

Tablica 38. Povezanost neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Neizravni novčani transferi	**,483*** (,104)**	**,596*** (,120)**	**,675*** (,155)**	**,522*** (,109)**	**,661*** (,135)**	**,744*** (.193)**	**,322*** (,078)**	**,360*** (,094)**	**,355** (,111)**
Stavovi		-,175 (,268)	-,361 (,361)		-,124 (,286)	-,021 (,409)		,042 (,222)	,322 (,266)
Subjektivne norme		,719*** (,178)	1,100*** (,243)		1,160*** (,227)	1,504*** (,332)		1,017*** (,171)	1,237*** (,209)
Percipirana kontrola ponašanja		1,853*** (,318)	2,215*** (,450)		1,856*** (,339)	2,057*** (,494)		1,169*** (,227)	1,083*** (,271)
Broj djece			-1,263** (,448)			-1,575** (,514)			-,686** (,252)
Djeca (DA)			9,171*** (1,840)			9,229*** (2,090)			2,839** (1,089)
Djeca (Da) * Godine starosti			-,212*** (,045)			-,229*** (,050)			-,100*** (,027)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije (ispodprosječno rangirane, I. i II. skupina)			-2,037** (,650)			-1,974** (,754)			-,043 (,377)
Djeca (DA) * Podmirivanje financ. obveza (poteškoće) * Vrsta ugovora o radu (određeno)			3,083** (1,066)			2,768* (1,194)			1,404 (,833)
Sektor zaposlenja (privatni) * Vrsta			-1,665* (,826)			-1,423 (1,111)			,306 (,603)

ugovora o radu (određeno)									
Godine starosti * Tip naselja (ruralno) * Bračni status (udana/udana, ali žive odvojeno)			-,017 (,011)			-,027* (,014)			-,015 (,008)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (1301 – 2700 EUR)			-,432** (,163)			-,241 (,180)			-,009 (,106)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (> 2700 EUR)			-,467* (,183)			-,419* (,207)			,004 (,115)
Konstanta	-3,000*** (,419)	-10,232*** (1,373)	-9,828*** (1,783)	-2,884*** (,434)	-10,314*** (1,493)	-9,588*** (1,972)	-1,546*** (,295)	-6,320*** (,965)	-5,185*** (1,116)
Omnibus test koeficijenata modela	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001
Hosmer i Lemeshow test	$\chi2$ = 14,380 df = 8 p = ,026	$\chi2$ = 5,163 df = 8 p = ,740	$\chi2$ = 6,450 df = 8 p = ,597	$\chi2$ = 15,901 df =6 p = ,014	$\chi2$ = 7,706 df = 8 p = ,463	$\chi2$ = 2,832 df = 8 p = ,944	$\chi2$ = 10,856 df = 6 p = ,093	$\chi2$ = 10,183 df = 8 p = ,252	$\chi2$ = 11,797 df = 8 p = ,161
Klasifikacijska točnost	77,6 %	81,7 %	88,6 %	72,9 %	81,2 %	89,2 %	63,2 %	74,7 %	82,5 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Rezultati logističke regresije u tablici 38. ukazuju na statistički značajnu ($p < ,05$) pozitivnu povezanost neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine u svim blokovima bez obzira na način izražavanja kriterijske varijable. Mogućnost korištenja neizravnih novčanih transfera povećavaju izglede (M1, Blok 3: Exp(B) = 1,963; M2, Blok 3: Exp(B) = 2,105; M3, Blok 2: Exp(B) = 1,434[22]) za namjeru rađanja u sljedeće dvije godine za 1,4 do 2,1 puta.

Omnibus test koeficijenata modela ukazuje na valjanost modela u svim logističkim modelima. Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test ($p > ,05$), izuzev u Bloku 1 i Bloku 2 kada se ne uzimaju u obzir odgovori onih žena koje nisu sigurne u svoju namjeru rađanja (M2), odnosno, kada su takvi odgovori označeni s 0 – stav da nema namjeru rađanja u sljedeće dvije godine (M1). Statistički značajne varijable iz Teorije planiranog ponašanja su subjektivne norme i percipirana kontrola ponašanja, dok stavovi nisu statistički značajni niti u jednom slučaju. Promatrajući Blok 3 u sva tri načina kreiranja kriterijske varijable, paritet je statistički značajna varijabla te je ista negativno povezana s namjerom rađanja, stoga se može zaključiti da veći broj djece koji žena ima značajno smanjuje izglede (M1: Exp(B) = ,283; M2: Exp(B) = ,207; M3: Exp(B) = ,504) za namjeru rađanja u sljedeće dvije godine. Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 10 % do 20 % (M1: Exp(B) = ,809; M2: Exp(B) = ,795; M3: Exp(B) = ,904) u odnosu na mlađe žene koje još uvijek nemaju dijete. Nadalje, šansa za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu, i žive u manje razvijenim regijama je smanjena (M1: Exp(B) = ,130; M2: Exp(B) = ,139) u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme imaju za otprilike 16 do 22 puta veću šansu (M1: Exp(B) = 21,831, M2: Exp(B) = 15,934) za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Interakcija sektora zaposlenja i vrste ugovora o radu statistički je značajna ($p < ,05$) kada je namjera rađanja iskazana kao M1. Naime, žene zaposlene u privatnom sektoru s ugovorom na određeno vrijeme imaju manje izglede (M1: Exp(B) = ,189) za namjeru rađanja u sljedeće dvije godine u odnosu

[22] Najveća vrijednost Exp(B) varijable „neizravni novčani transferi“ promatrajući sve blokove (Blok 1, Blok 2, Blok 3) ovisno o načinu izražavanja namjere rađanja (M1, M2, M3).

na žene zaposlene u javnom sektoru s ugovorom na neodređeno vrijeme. Žene koje imaju djecu, veći broj članova kućanstva i ukupan prihod kućanstva veći od 1301 EUR, a manji od 2700 EUR imaju manju šansu (M1: Exp(B) = ,650) za namjeru rađanja u odnosu na žene koje nemaju djecu, žive u kućanstvu s manjim brojem članova i imaju manje prihode. Isto vrijedi i kada su ukupni prihodi kućanstva veći od 2700 EUR (M1: Exp(B) = ,627; M2: Exp(B) = 658). Preostale varijable i njihove interakcije nisu statistički značajne. U *Prilogu 6* prikazane su dodatne opcije testiranja povezanosti neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine.

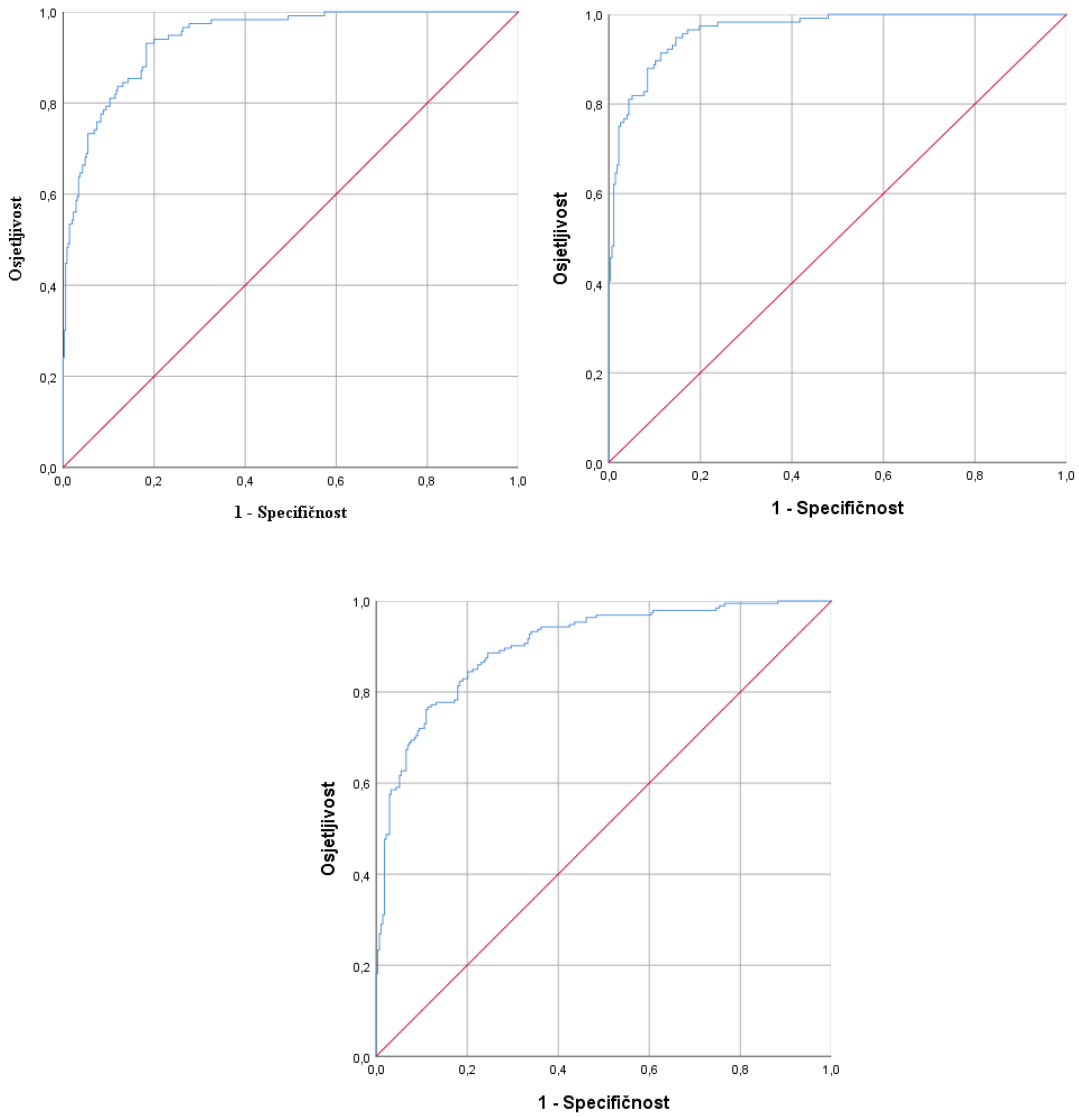

Grafikon 12. ROC krivulja M1, M2 i M3
Izvor: izrada doktorandice

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,942. Ova visoka vrijednost, uz standardnu pogrešku od ,011, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,920 i ,963 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,965, uz standardnu pogrešku od ,008 te $p < ,001$. Interval pouzdanosti od 95 % je između ,948 i ,981. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3) AUC vrijednost je ,902, dok je standardna greška ,014 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,875 do ,930. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

Tablica 39. Povezanost transfera u naravi i namjere rađanja u sljedeće dvije godine

	M1			M2			M3		
	Blok 1	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**	**Blok 1**	**Blok 2**	**Blok 3**
Transferi u naravi	,280** (,106)	,363** (,125)	,475** (,158)	,298** (,111)	,379** (,141)	,522* (,210)	,184* (,085)	,175 (,104)	,185 (,126)
Stavovi		-,186 (,260)	-,316 (,351)		-,124 (,277)	,078 (,396)		,048 (,218)	,351 (,265)
Subjektivne norme		,729*** (,172)	1,075*** (,235)		1,121*** (,277)	1,459*** (,322)		1,034*** (,168)	1,265*** (,209)
Percipirana kontrola ponašanja		1,729*** (,303)	2,003*** (,415)		1,746*** (,322)	1,866*** (,456)		1,098*** (,221)	1,011*** (,267)
Broj djece			-1,395** (,444)			-1,733** (,513)			-,721** (,249)
Djeca (DA)			9,664*** (1,803)			9,836*** (2,061)			3,186** (1,082)
Djeca (Da) * Godine starosti			-,223*** (,044)			-,240*** (,050)			-,109*** (,027)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije (ispodprosječno rangirane, I. i II. skupina)			-1,946** (,642)			-1,948** (,732)			-,053 (,372)
Djeca (DA) * Podmirivanje financ. obveza (poteškoće) * Vrsta ugovora o radu (određeno)			2,817** (1,044)			2,477* (1,158)			1,383 (,829)
Sektor zaposlenja (privatni) * Vrsta ugovora o radu (određeno)			-1,819* (,811)			-1,436 (1,111)			,303 (,609)

Godine starosti * Tip naselja (ruralno) * Bračni status (udana/udana, ali žive odvojeno)			-,013 (,011)			-,023 (,013)			-,013 (,008)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (1301 – 2700 EUR)			-,364* (,160)			-,176 (,179)			,014 (,106)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (> 2700 EUR)			-,455* (,183)			-,407* (,206)			,007 (,115)
Konstanta	-2,255*** (,413)	-8,837*** (1,302)	-8,456*** (1,640)	-2,069*** (,426)	-8,843*** (1,419)	-8,482*** (1,849	-1,077** (,318)	-5,420*** (,944)	-4,476*** (1,122)
Omnibus test koeficijenata modela	p < ,01	p < ,001	p < ,001	p < ,001	p < ,001	p < ,001	p < 0,05	p < ,001	p < ,001
Hosmer i Lemeshow test	$\chi2$ = 8,654 df = 8 p = ,372	$\chi2$ = 21,505 df = 8 p = ,006	$\chi2$ = 11,702 df = 8 p = ,164	$\chi2$ = 15,901 df =6 p = ,014	$\chi2$ = 13,163 df = 8 p = ,106	$\chi2$ = 2,500 df = 8 p = ,962	$\chi2$ = 8,347 df = 8 p = ,400	$\chi2$ = 10,183 df = 8 p = ,252	$\chi2$ = 13,309 df = 8 p = ,102
Klasifikacijska točnost	77,6 %	80,9 %	89,4 %	72,9 %	78,7 %	90,3 %	60,4 %	74,1 %	81,2 %

* p < ,05, ** p < ,01, *** p < ,001

Izvor: izrada doktorandice

Statistički značajnost (p < ,05) povezanosti transfera u naravi i namjere rađanja u sljedeće dvije godine prikazana je u tablici 39. Prediktorska varijabla statistički je značajna u svim blokovima kada je namjera rađanja izražena vjerojatno ili definitivno da (M1 i M2), dok u slučaju kada je ista eksplicitno izražena nisam sigurna, vjerojatno ili definitivno da (M3), izostaje statistička značajnost prilikom uključivanja varijabli povezanih s Teorijom planiranog ponašanja (Blok 2) i kontrolnih varijabli (Blok 3). Transferi u naravi povećavaju izglede (M1, Blok 3: Exp(B) = 1,608; M2, Blok 3: Exp(B) = 1,685; M3, Blok 1: Exp(B) = 1,203[23]) za namjeru rađanja u sljedeće dvije godine za 1,2 do 2,7 puta.

Omnibus test koeficijenata modela ukazuje na valjanost modela u svim logističkim modelima. Dodatno uporište valjanosti modela daje i Hosmer i Lemeshow test (p > ,05), izuzev u Bloku 1 i Bloku 2 kada je namjera rađanja izražena s vjerojatno ili definitivno da. Statistički značajne varijable iz Teorije planiranog ponašanja su subjektivne norme i percipirana kontrola ponašanja, dok stavovi nisu statistički značajni niti u jednom slučaju. Promatrajući Blok 3 u sva tri načina kreiranja kriterijske varijable, paritet je statistički značajna varijabla te je ista negativno povezana s namjerom rađanja, stoga se može zaključiti da veći broj djece koji žena ima značajno smanjuje izglede (M1: Exp(B) = ,248; M2: Exp(B) = ,177; M3: Exp(B) = ,486) za namjeru rađanja u sljedeće dvije godine. Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 10 % do 20 % (M1: Exp(B) = ,800; M2: Exp(B) = ,787; M3: Exp(B) = ,897) u odnosu na mlađe žene koje još uvijek nemaju dijete. Nadalje, šansa za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu, i žive u manje razvijenim regijama je manja (M1: Exp(B) = ,143; M2: Exp(B) = ,143) u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme imaju za otprilike 12 do 17 puta veće izglede (M1: Exp(B) = 16,721, M2: Exp(B) = 11,908) za namjeru rađanja u sljedeće dvije u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme. Interakcija sektora zaposlenja i vrste ugovora o radu statistički je značajna (p < ,05) kada je namjera rađanja iskazana kao M1. Naime, žene zaposlene u privatnom sektoru s ugovorom na

[23] Najveća vrijednost Exp(B) varijable „neizravni novčani transferi“ promatrajući sve blokove (Blok 1, Blok 2, Blok 3) ovisno o načinu izražavanja namjere rađanja (M1, M2, M3).

određeno vrijeme imaju manje izglede (M1: Exp(B) = ,162) za namjeru rađanja u sljedeće dvije godine u odnosu na žene zaposlene u javnom sektoru s ugovorom na neodređeno vrijeme. Žene koje imaju djecu, veći broj članova kućanstva i ukupan prihod kućanstva veći od 1301 EUR, a manji od 2700 EUR imaju manju šansu (M1: Exp(B) = ,695) za namjeru rađanja u odnosu na žene koje nemaju djecu, žive u kućanstvu s manjim brojem članova i imaju manje prihode. Isto vrijedi i kada su ukupni prihodi kućanstva veći od 2700 EUR (M1: Exp(B) = ,634; M2: Exp(B) = 666). Preostale varijable i njihove interakcije nisu statistički značajne. U *Prilogu 7* su prikazane dodatne opcije testiranja povezanosti transfera u naravi i namjere rađanja u sljedeće dvije godine.

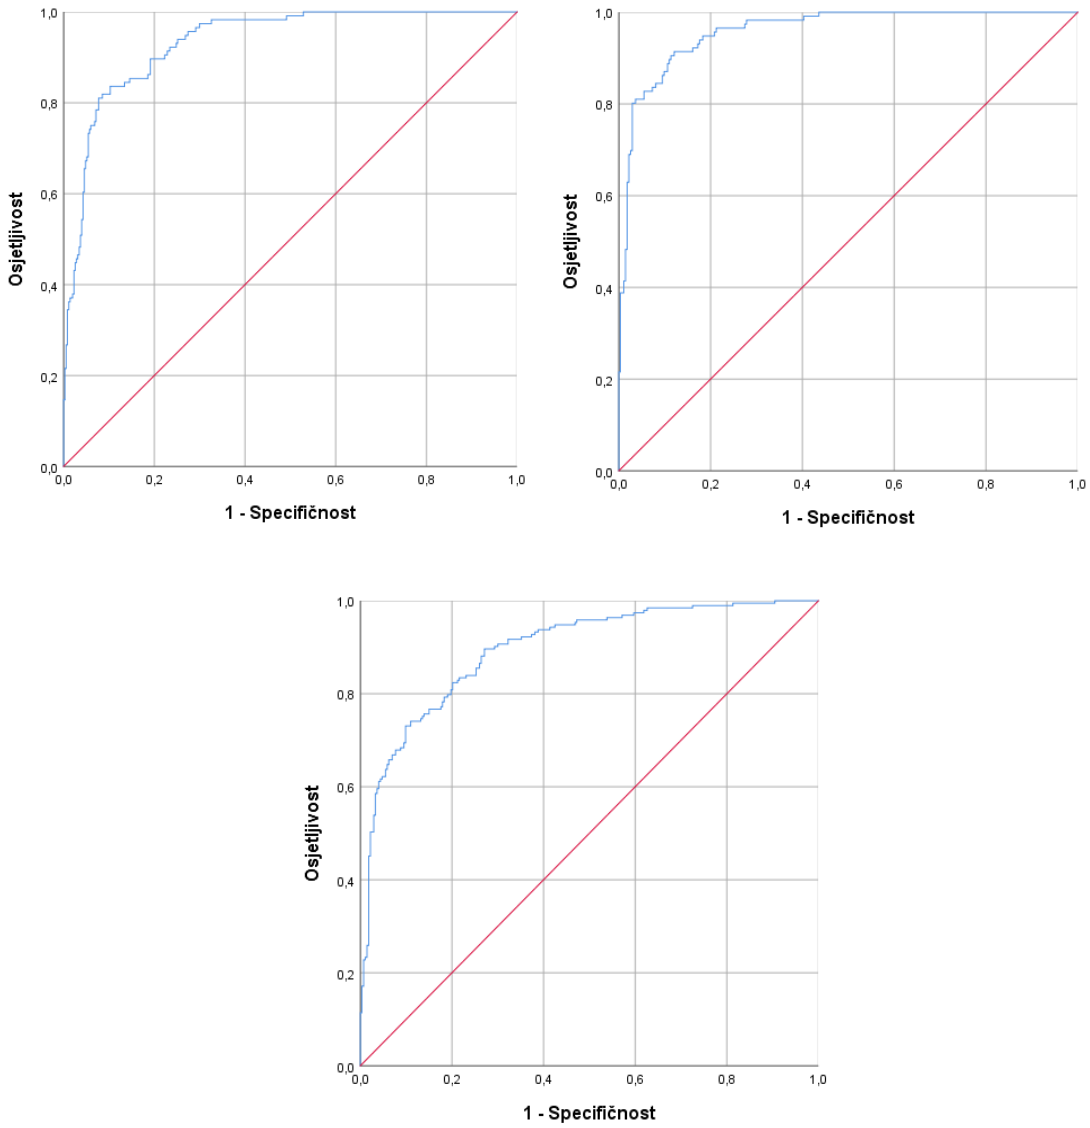

Grafikon 13. ROC krivulja M1, M2 i M3
Izvor: izrada doktorandice

Rezultati analize AUC kada je kriterijska varijabla M1 ukazuju na izuzetnu sposobnost modela da razlikuje žene koje imaju namjeru rađanja u sljedeće dvije godine i one koje nemaju namjeru rađanja u sljedeće dvije godine, s AUC vrijednošću od ,934. Ova visoka vrijednost, uz standardnu pogrešku od ,012, sugerira da je procjena AUC vrlo precizna. Statistička značajnost rezultata potvrđena je s $p < ,001$, što ukazuje na značajnu diskriminacijsku sposobnost modela. Interval pouzdanosti od 95 % između ,911 i ,957 dodatno osigurava da je sposobnost modela da razlikuje između klasa pouzdana i dosljedna. AUC vrijednost u slučaju kada je kriterijska varijabla M2 iznosi ,959, uz standardnu pogrešku od ,009 te $p < ,001$. Interval pouzdanosti od 95 % je između ,941 i ,977. Na temelju navedenog može se zaključiti da kreirani model ima izvrsnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine. U slučaju kada je namjera rađanja eksplicitno izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3), za AUC vrijednost je ,896, dok je standardna greška ,015 uz statističku značajnost $p < ,001$. Interval 95 %-tne pouzdanosti je u rasponu od ,867 do ,925. Iz navedenog se zaključuje da modeli imaju izuzetnu sposobnost razlikovanja žena u namjeri rađanja u sljedeće dvije godine.

5.7.4. Istraživanje razlike u namjeri rađanja ovisno o indeksu razvijenosti jedinica područne (regionalne) samouprave

Kako je već prethodno spomenuto, važno je utvrditi razliku u namjeri rađanja s obzirom na ekonomsku razvijenost regionalne samouprave jer ekonomski uvjeti značajno utječu na reproduktivne odluke pojedinaca i obitelji. Ekonomski razvijenije regije obično nude bolje uvjete za život, pristup obrazovanju, zapošljavanju, socijalnim i zdravstvenim uslugama, što može poticati veću sigurnost i optimizam u pogledu budućnosti, a time i veću sklonost rađanju djece. S druge strane, u manje razvijenim regijama, gdje su ekonomske prilike ograničenije, namjera rađanja može biti niža zbog nesigurnosti i ograničenih resursa. Razumijevanje tih razlika ključno je za kreiranje ciljane demografske i socijalne politike, kako bi se u manje razvijenim područjima pružila podrška obiteljima i potaknule mjere koje će pozitivno utjecati na fertilitet.

Za testiranje hipoteze H4, koja glasi da se odluke o namjeri rađanja statistički značajno razlikuju s obzirom na ekonomsku razvijenost lokalne i regionalne samouprave, odnosno

indeks razvijenosti, korišten je Kruskal-Wallisov test. Ovaj neparametrijski test primijenjen je zbog usporedbe više nezavisnih grupa, u ovom slučaju različitih razina ekonomske razvijenosti, kako bi se utvrdilo postoje li statistički značajne razlike u namjeri rađanja u sljedeće dvije godine među tim grupama. Kruskal-Wallisov test prikladan je kada varijable ne zadovoljavaju pretpostavke normalne raspodjele, a koristi se za ispitivanje razlika u rangovima između više od dvije skupine. Rezultati provedenog testa prikazani su u tablici 40.

Tablica 40. Testiranje razlike u namjeri rađanja (M1) ovisno o indeksu razvijenosti

Regija prema indeksu razvijenosti		n	Prosjek rangova	Kruskal-Wallisov test
Namjera rađanja u sljedeće dvije godine M1	I. skupina razvijenosti	147	538,74	χ^2 = 4,151 df = 3 p = ,246
	II. skupina razvijenosti	293	546,67	
	III. skupina razvijenosti	226	569,44	
	IV. skupina razvijenosti	466	586,30	
	Ukupno	1036		

Izvor: izrada doktorandice

Rezultati Kruskal-Wallisovog testa (tablica 40.) ukazuju na to da ne postoji statistički značajna razlika u namjeri rađanja u sljedeće dvije godine u odnosu na razvijenost jedinca područne (regionalne) samouprave prema indeksu razvijenosti ($\chi2$ = 4,151, p = ,246). Drugim riječima, prema ovim rezultatima, ekonomska razvijenost nije imala značajan utjecaj na odluku o namjeri rađanja u promatranim grupama.

Zapažanja i osvrt na rezultate cijelog provedenog istraživanja pojašnjeni su u poglavlju 6. (rasprava) koje slijedi u nastavku.

6. RASPRAVA O REZULTATIMA ISTRAŽIVANJA I USPOREDBA S PRETHODNIM ISTRAŽIVANJIMA

Republika Hrvatska suočava se s dugoročnim negativnim demografskim izazovima poput niskog nataliteta i starenja populacije što utječe na budući ekonomski i socijalni razvoj zemlje. Razumijevanje namjere rađanja može pomoći u predviđanju demografskih trendova i omogućiti kreiranje ciljane javne politike usmjerene na poticanje rađanja. Također, istraživanje ovih namjera rađanja pruža uvid u čimbenike koji utječu na odluke o rađanju, poput ekonomske sigurnosti, dostupnosti socijalnih usluga te stavova o obitelji i roditeljstvu. Ovi podatci mogu poslužiti kao temelj za prilagodbu fiskalnih i socijalnih mjera koje bi poticale veći broj rađanja i doprinosile rješavanju negativnih demografskih trendova.

Namjera rađanja u sljedeće dvije godine (namjera_binarnaM1, namjera_binarnaM2, namjera_binarnaM3) uzeta je kao binarna kriterijska varijabla u testiranju hipoteza H1, H3, dok je namjera rađanja u sljedeće dvije godine mjerena Likertovom ljestvicom korištena kao kriterijska varijabla za testiranje hipoteze H4 budući da se prema Teoriji planiranog ponašanja (Ajzen, 1991) namjera smatra najboljim prediktorom stvarnog ponašanja. U prethodnim istraživanjima testirana je i dokazana povezanost namjere rađanja i ekonomskih prediktora (sigurnost posla, financijska sigurnost i potpuno vlasništvo nad nekretninom), fiskalnih instrumenata javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi) te regionalne razvijenosti. Navedene varijable uvrštene su u istraživački okvir doktorskog rada s definiranom ulogom prediktorskih varijabla. U namjeri za premošćivanjem istraživačkog jaza u ovom doktorskom radu testirana je i povezanost ekonomske sigurnosti i fertilnog jaza (H2). Slijedom prikazanih rezultata istraživanja u nastavku su prikazani zaključci o postavljenim hipotezama.

Tablica 41. Sažetak statusa hipoteza

Hipoteza	**M1**			**M2**			**M3**			**Metoda**
	Blok 1	Blok 2	Blok 3	Blok 1	Blok 2	Blok 3	Blok 1	Blok 2	Blok 3	
H1										
H1a	+	+	+	+	+	+	+	+	+	Logistička regresija
H1b	+	+	+	+	+	-	-	+	+	
H1c	-	-	-	-	-	-	-	-	-	
H2	-									Spearmanov koeficijent korelacije
	M1			**M2**			**M3**			

	Blok 1	Blok 2	Blok 3	Blok 1	Blok 2	Blok 3	Blok 1	Blok 2	Blok 3	
H3										
H3a	+	+	+	+	+	+	+	+	+	Logistička regresija
H3b	+	+	+	+	+	+	+	+	+	
H3c	+	+	+	+	+	+	+	-	-	
H4	-									Kruskal-Wallis

Izvor: izrada doktorandice

Nakon testiranja proširenog konceptualnog modela i uvođenja kontrolnih varijabli, konačni model empirijskog istraživanja prikazan je slikom 11.

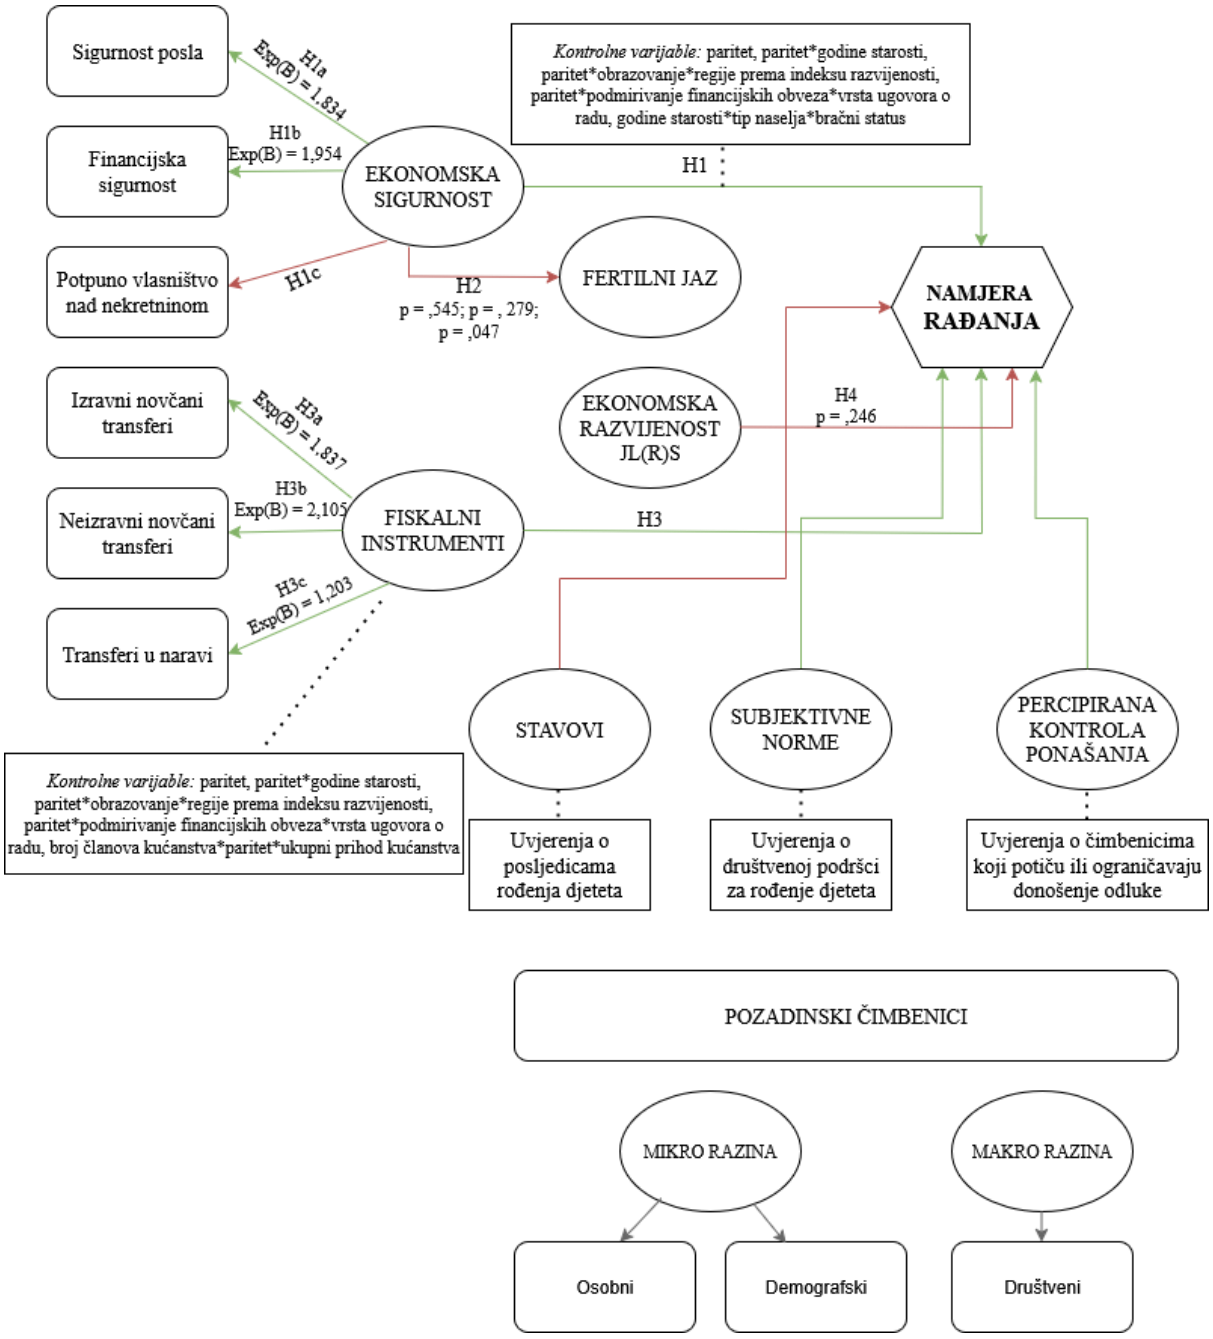

Slika 11. Konačni model namjere rađanja u sljedeće dvije godine
Izvor: izrada doktorandice

Rezultati prethodnih empirijskih istraživanja koji su prikazani u teorijskom dijelu doktorskog rada (poglavlje 4.) značajno podržavaju hipotezu H1a, koja sugerira da sigurnost posla ima pozitivan učinak na kratkoročne namjere rađanja. U provedenom empirijskom istraživanju u ovom doktorskom radu, hipoteza **H1a se ne odbacuje**. Rezultati u sva tri načina izražavanja namjere rađanja u sljedeće dvije godine i sva tri bloka ukazuju na statistički značajnu pozitivnu povezanost između sigurnosti posla i namjere rađanja u sljedeće dvije godine ($p < ,05$). Najveću klasifikacijsku točnost prilikom testiranja hipoteze H1a ima model u kojemu je namjera rađanja izražena s M2, u Bloku 3 (89,4 %).

Koeficijenti Exp(B) ili omjeri izgleda s 95 %-tnim intervalom pouzdanosti kada je namjera rađanja iskazana s „vjerojatno“ ili „definitivno da“ M1 (Blok 1: Exp(B) = 1,366; Blok 2: Exp(B) = 1,705; Blok 3: Exp(B) = 1,539) pokazuju da povećanje sigurnosti posla povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,37 do 1,71 puta, ovisno o promatranom bloku. U slučaju kada je namjera rađanja iskazana kao M2, omjeri izgleda (Blok 1: Exp(B) = 1,385; Blok 2: Exp(B) = 1,834; Blok 3: Exp(B) = 1,466) veći su u odnosu na iskazivanje namjere M1, što ukazuje da povećanje sigurnosti posla povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,39 do 1,83 puta. Kada se u izražavanje namjere uključi i odgovor žena koje nisu sigurne u svoju namjeru rađanja (M3), omjeri izgleda kreću se od 26 % do 55 % (Blok 1: Exp(B) = 1,258; Blok 2: Exp(B) = 1,546; Blok 3: Exp(B) = 1,361), što također ukazuje na značaj sigurnosti posla u oblikovanju namjere o rađanju. Promatrajući cijeli logistički model (Blok 3) prema načinu izražavanja namjere rađanja (M1, M2 i M3), najveći omjer izgleda ima varijabla koja se odnosi na imanje djece. Žene s djecom imaju veću šansu za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje u trenutku istraživanja nisu imale dijete.

U skladu s prethodnim istraživanjima (Peng i sur. 2023; Hu i sur., 2022; Gatta i sur., 2021; Fahlen i Olah, 2015; Modena i sur., 2014) broj djece koji žene imaju statistički su značajni prediktori namjere rađanja. U sva tri načina izražavanja namjere rađanja (M1, M2 i M3) prilikom testiranja hipoteze H1a omjeri šansi su negativni što ukazuje na zaključak da veći broj djece koji žena već ima smanjuje izglede za namjerom rađanja u sljedeće dvije godine. Također, promatrajući interakcijske efekte, dolazi se do zaključka da se s povećanjem starosti

žena koje imaju djecu smanjuju izgledi za namjeru rađanja u sljedeće dvije godine (u sva tri slučaja).

U provedenom empirijskom istraživanju korištenjem Kruskal-Wallisovog testa hipoteza **H4 se odbacuje** ($\chi 2$ = 4,151, df = 3, p = ,246) i ukazuje na zaključak da u Republici Hrvatskoj razvojne regije prema indeksu razvijenosti nisu značajan prediktor namjere rađanja u sljedeće dvije godine kod žena koje su bile obuhvaćene istraživanjem kada se promatraju kao samostalna varijabla u modelu. Međutim, prilikom testiranja hipoteze H1a promatrajući regije prema indeksu razvijenosti u interakciji sa stupnjem obrazovanja i imanjem djece, rezultati ukazuju na to da žene sa srednjim ili nižim obrazovanjem koje imaju dijete/djecu i žive u jedinicama područne (regionalne) samouprave koje su prema indeksu razvijenosti svrstane u I. ili II. skupinu imaju manje izglede (kada je namjera izražena M1 i M2) za namjeru rađanja u odnosu na referentnu skupinu (žene bez djece, više obrazovane ili iz regija III. i IV. skupine prema indeksu razvijenosti). Do istih zaključaka dolazi se i prilikom testiranja hipoteza H1b, H1c, H3a, H3b i H3c, stoga je slijedom navedenog vidljivo da odabir statističke metode, kao i uključivanje dodatnih varijabli u modele može upućivati na potpuno različite zaključke o utjecaju i statističkoj značajnosti.

Žene s djecom koje imaju poteškoće s podmirivanjem svojih financijskih obveza, a ujedno imaju ugovor o radu na određeno vrijeme pokazuju veću spremnost za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje nemaju dijete, nemaju financijskih poteškoća i koje imaju ugovor na neodređeno vrijeme (kada je namjera rađanja M1 i M2). Interakcijski efekt varijabli vrste ugovora o radu i sektora zaposlenja statistički je značajan samo u slučaju kada je namjera rađanja izražena s M1 i ukazuje na zaključak da žene s ugovorom na određeno vrijeme (u skladu s Alderotti i sur., 2021; Vignoli i sur., 2012; Rica i Iza, 2005) koje su zaposlene u privatnom sektoru pokazuju manje izglede za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje imaju stalno zaposlenje i zaposlene su u javnom sektoru. Konačno, sa svakom dodatnom godinom starosti (u slučaju M1 i M2), izgledi za namjeru rađanja rastu za 1,8 % unutar grupe neudanih žena koje žive u urbanim naseljima.

Rezultati logističke regresije prilikom testiranja hipoteze H1b provedenog empirijskog istraživanja u skladu su s prethodnim istraživanjima (Fiori i sur., 2013). Naime, rezultati logističke regresije ukazuju na pozitivnu i statistički značajnu povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine, uz izuzetak Bloka 3 kada je namjera rađanja M2 i

Bloka 1 kada je namjera rađanja M3. Najveću klasifikacijsku točnost prilikom testiranja hipoteze H1b ima model u kojemu je namjera rađanja izražena s M2, u Bloku 3 (90,2 %). Budući da je u sedam od devet slučajeva financijska sigurnost statistički značajna ($p < ,05$) i pozitivno povezana s namjerom rađanja u sljedeće dvije godine može se zaključiti da se postavljena hipoteza **H1b ne odbacuje**.

Koeficijenti Exp(B) ili omjeri izgleda s 95 %-tnim intervalom pouzdanosti kada je namjera rađanja iskazana s „vjerojatno“ ili „definitivno da“ M1 (Blok 1: Exp(B) = 1,241; Blok 2: Exp(B) = 1,902; Blok 3: Exp(B) = 1,544) pokazuju da povećanje financijske sigurnosti povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,24 do 1,90 puta, ovisno o promatranom bloku. U slučaju kada je namjera rađanja iskazana kao M2, omjeri izgleda (Blok 1: Exp(B) = 1,242; Blok 2: Exp(B) = 1,954; Blok 3: Exp(B) = 1,426) ukazuju na to da se s povećanjem financijske sigurnosti povećava šansa da žena ima namjeru rađanja u sljedeće dvije godine za 1,24 do 1,95 puta. Kada se u izražavanje namjere uključi i odgovor žena koje nisu sigurne u svoju namjeru rađanja (M3), omjeri izgleda kreću se od 16 % do 68 % (Blok 1: Exp(B) = 1,157; Blok 2: Exp(B) = 1,681; Blok 3: Exp(B) = 1,358), što također ukazuje na značaj financijske sigurnosti u oblikovanju namjere o rađanju. Promatrajući cijeli logistički model (Blok 3) prema načinu izražavanja namjere rađanja (M1, M2 i M3), najveći omjer izgleda ima varijabla koja se odnosi na imanje djece. Žene s djecom imaju veću šansu za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje u trenutku istraživanja nisu imale dijete.

U skladu s prethodnim istraživanjima (Peng i sur. 2023; Hu i sur., 2022; Gatta i sur., 2021; Fahlen i Olah, 2015; Modena i sur., 2014) broj djece koji žene imaju statistički su značajni prediktori namjere rađanja. U sva tri načina izražavanja namjere rađanja (M1, M2 i M3) prilikom testiranja hipoteze H1b omjeri izgleda su negativni što ukazuje na zaključak da veći broj djece koji žena već ima smanjuje izglede za namjerom rađanja u sljedeće dvije godine. Također, promatrajući interakcijske efekte, dolazi se do zaključka da se s povećanjem starosti žena koje imaju djecu smanjuju izgledi za namjeru rađanja u sljedeće dvije godine (u sva tri slučaja). Kao i prilikom testiranja H1a, rezultati upućuju na jednake zaključke u slučaju interakcijskih efekata Djeca (DA) * Obrazovanje * Indeks regije, Djeca (DA) * Podmirivanje financijskih obveza * Vrsta ugovora o radu, Sektor zaposlenja * Vrsta ugovora o radu. U Bloku 3, kada je namjera rađanja eksplicitno izražena s „vjerojatno“ i „definitivno da“ (M1) rezultati pokazuju da žene s djecom i većim ukupnim prihodom kućanstva imaju veće izglede za

namjeru rađanja u sljedeće dvije godine u odnosu na žene koje nemaju dijete i imaju manji ukupan prihod kućanstva (u skladu s Andersson, 2000; Vikat, 2004; Vignoli i sur., 2012; Ermisch, 1989; Becker, 1993; Becker i Barro, 1988).

Mjerenje ekonomske sigurnosti u ovom doktorskom radu obuhvatilo je i potpuno vlasništvo nad nekretninom budući da su prethodna istraživanja ukazala na statistički značajan pozitivan utjecaj potpunog vlasništva nad nekretninom i namjere rađanja. Provedenim istraživanjem i primjenom logističke regresije, postavljena hipoteza **H1c se odbacuje** jer postoji statistički značajna ($p < ,05$), ali negativna povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine (Blok 2 u M1, M2 i M3). Iako ovaj rezultat nije u skladu s prethodno prikazanim istraživačkim spoznajama, najnovije istraživanje koje su proveli Chen i sur. (2024) pokazalo je da su ispitanici koji su vlasnici nekretnina iskazali niže namjere za proširenjem obitelji u usporedbi s podstanarima. Prema Zhou i Guo (2020) vlasništvo nad nekretninom može smanjiti raspoložive resurse za odgoj djece kada obitelj raspolaže ograničenim ekonomskim sredstvima. Osobito je navedeno izraženo u mjestima gdje su cijene privatnih nekretnina nepristupačne. U tom slučaju stanovanje predstavlja ozbiljan problem za obitelji te dovodi do odricanja, stoga obitelji mogu biti prisiljene birati između imanja djeteta i posjedovanja nekretnine.

Kao i prilikom testiranja H1a i H1b, rezultati upućuju na jednake zaključke u slučaju interakcijskih efekata Djeca (DA) * Obrazovanje * Indeks regije, Djeca (DA) * Podmirivanje financijskih obveza * Vrsta ugovora o radu, dok preostale kontrolne varijable i njihove interakcije u slučaju oblikovanja namjere rađanja nisu statistički značajne.

Zaključno, na temelju analize prediktorskih varijabli ekonomske sigurnosti, rezultati pokazuju da sigurnost posla i financijska stabilnost značajno povećavaju izglede namjere rađanja. Sigurnost posla povećava izglede za namjeru rađanja za 1,834 puta (M2, Blok 2: Exp(B) = 1,834), dok financijska sigurnost povećava izglede za 1,954 puta (M2, Blok 2: Exp(B) = 1,954). S druge strane, potpuno vlasništvo nad nekretninom dovodi do smanjenja izgleda za namjeru rađanja (M1, Blok 2: Exp(B) = ,560; M2, Blok 2: Exp(B) = ,484; M3, Blok 2: Exp(B) = ,492).

Ovi rezultati upućuju na to da ekonomska stabilnost kroz zaposlenje i financijsku sigurnost potiče planiranje potomstva, dok vlasništvo nad nekretninom može imati suprotan učinak.

Korelacijskom analizom utvrđena je statistički značajna pozitivna povezanost fertilnog jaza i potpunog vlasništva nad nekretninom (r_s = ,74, p = ,047), dok je statistička značajnost izostala kod varijabli sigurnost posla i financijska sigurnost, stoga se postavljena **hipoteza H2 odbacuje**. Zaključci o odbacivanju hipoteze u skladu su s prethodnim istraživačkim spoznajama (Golub i sur., 2023; Norling, 2021; Beaujouan i Berghammer, 2019; Spéder i Kapitány, 2009) koji uzroke fertilnog jaza pronalaze u nemogućnosti pronalaženja odgovarajućeg partnera ili drugim okolnostima koje mogu spriječiti osobu koja namjerava imati dijete da to i učini, a ne primarno u ekonomskoj sigurnosti para. Prema izvješću UNFPA (2025), u europskim zemljama obuhvaćenima istraživanjem o uzrocima fertilnog jaza, s ekonomskog aspekta najizraženiji uzroci odnose se na financijska ograničenja i stambene uvjete. Financijska ograničenja kao čimbenik koji utječe na mogućnost ostvarenja željenog broja djece navelo je 29 % ispitanika u Italiji, 34 % u Mađarskoj, 25 % u Njemačkoj te 19 % u Švedskoj. Ograničenja vezana uz stambene uvjete zabilježena su u Italiji (14 %), Mađarskoj (20 %), Njemačkoj (18 %) i Švedskoj (6 %). Nedostatak adekvatnih i kvalitetnih usluga skrbi za djecu najizraženiji je u Italiji i Njemačkoj (po 12 %), zatim u Mađarskoj (11 %), dok 6 % ispitanika u Švedskoj navodi isti razlog. Nesigurnost zaposlenja kao uzrok fertilnog jaza najčešće je prijavljena u Italiji (30 %), zatim u Mađarskoj (16 %), Njemačkoj (10 %) te u Švedskoj (5 %). Zaključno, razlozi fertilnog jaza su višestruki, no kao daleko najznačajnija prepreka izdvajaju se ekonomski čimbenici. Od 10 000 ispitanika koji su imali djecu ili su izražavali želju za roditeljstvom, 39 % je navelo da su financijska ograničenja utjecala ili bi mogla utjecati na ostvarenje željenog broja djece. Drugi najčešće prijavljeni čimbenik, s udjelom od 21 %, bila je nezaposlenost ili nesigurnost zaposlenja. Treći najčešće navođeni čimbenik, s udjelom od 19 %, odnosio se na stambena pitanja, poput nedostatka prostora ili visoke cijene stanovanja. Kada su navedeni razlozi svrstani u šire kategorije – npr. zdravstveni problemi, ekonomski razlozi, strahovi vezani uz budućnost te nedostatak podržavajućeg partnera ili potpuno odsustvo partnera – više od polovice ispitanika navelo je da ekonomske prepreke utječu na njihovu mogućnost ostvarivanja željenog broja djece.

Rezultati prethodnih empirijskih istraživanja koji su prikazana u poglavlju 4. značajno podržavaju hipotezu H3a, koja sugerira da izravni novčani transferi imaju pozitivan učinak na

kratkoročne namjere rađanja, kako na makrorazini (kroz povećanje ukupne stope fertiliteta na razini populacije), tako i na mikrorazini (kroz povećanje vjerojatnosti namjere rađanja, odnosno donošenja odluke o rađanju). U provedenom empirijskom istraživanju u ovom doktorskom radu, hipoteza **H3a se ne odbacuje**. Rezultati u sva tri načina izražavanja namjere rađanja u sljedeće dvije godine i sva tri bloka ukazuju na statistički značajnu pozitivnu povezanost između izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine ($p <$,01). Najveću klasifikacijsku točnost prilikom testiranja hipoteze H3a ima model u kojemu je namjera rađanja izražena s M2, u Bloku 3 (89,9 %)

Koeficijenti Exp(B) ili omjeri izgleda s 95 %-tnim intervalom pouzdanosti kada je namjera rađanja iskazana s „vjerojatno“ ili „definitivno da“ M1 (Blok 1: Exp(B) = 1,555; Blok 2: Exp(B) = 1,684; Blok 3: Exp(B) = 1,801) pokazuju da mogućnost dobivanja izravnih novčanih transfera povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,55 do 1,80 puta, ovisno o promatranom bloku. U slučaju kada je namjera rađanja iskazana kao M2, omjeri izgleda (Blok 1: Exp(B) = 1,538; Blok 2: Exp(B) = 1,769; Blok 3: Exp(B) = 1,837) ukazuju da korištenje izravnih novčanih transfera povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,53 do 1,84 puta. Kada se u izražavanje namjere uključi i odgovor žena koje nisu sigurne u svoju namjeru rađanja (M3), omjeri izgleda kreću se od 40 % do 49 % (Blok 1: Exp(B) = 1,403; Blok 2: Exp(B) = 1,393; Blok 3: Exp(B) = 1,494), što također ukazuje na značaj fiskalnih instrumenata u oblikovanju namjere o rađanju.

Promatrajući cijeli logistički model (Blok 3) prema načinu izražavanja namjere rađanja (M1, M2 i M3), najveći omjer izgleda ima varijabla koja se odnosi na imanje djece. Žene s djecom imaju veće izglede za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje u trenutku istraživanja nisu imale dijete. Nadalje, u oblikovanju namjere rađanja vrlo značajna je interakcija varijabli imanja djece, mogućnosti podmirivanja financijskih obveza i vrste ugovora o radu. Naime, žene s djecom koje imaju ugovor o radu na određeno vrijeme i poteškoće u podmirivanju financijskih obveza imaju veće izglede za namjeru rađanja u sljedeće dvije godine u odnosu na žene iz referentne skupine (žene bez djece, ugovor na neodređeno vrijeme i bez financijskih poteškoća).

U skladu s prethodnim istraživanjima godine starosti žene i broj djece koji imaju statistički su značajni prediktori namjere rađanja. Prilikom testiranja hipoteze H3a omjeri šansi su negativni što ukazuje na zaključak da žene starije životne dobi koje već imaju dijete/djecu

imaju manju šansu za namjeru rađanja u sljedeće dvije godine u odnosu na žene mlađe životne dobi koje u trenutku istraživanja nisu imale dijete. Također, veći broj djece koji žena već ima smanjuje izglede za namjerom rađanja u sljedeće dvije godine. Kao i prilikom testiranja H1, rezultati upućuju na jednake zaključke u slučaju interakcijskih efekata Djeca (DA) * Obrazovanje * Indeks regije, Djeca (DA) * Podmirivanje financijskih obveza * Vrsta ugovora o radu. U Bloku 3, kada je namjera rađanja eksplicitno izražena s „vjerojatno“ i „definitivno da“ (M1) rezultati pokazuju da žene s djecom i većim ukupnim prihodom kućanstva imaju veće izglede za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje nemaju dijete i imaju manji ukupan prihod kućanstva.

Rezultati logističke regresije provedenog empirijskog istraživanja potvrdili su prethodna istraživanja prezentirana u poglavlju 4. o pozitivnom učinku neizravnih novčanih transfera. Rezultati u svim modelima ukazuju na statistički značajnu pozitivnu povezanost između neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine ($p < ,001$), stoga se postavljena hipoteza **H3b ne odbacuje**. Najveću klasifikacijsku točnost prilikom testiranja hipoteze H3b ima model u kojemu je namjera rađanja izražena s M2, u Bloku 3 (89,2 %)

Koeficijenti Exp(B) ili omjeri izgleda s 95 %-tnim intervalom pouzdanosti kada je namjera rađanja iskazana s „vjerojatno“ ili „definitivno da“ M1 (Blok 1: Exp(B) = 1,620; Blok 2: Exp(B) = 1,815; Blok 3: Exp(B) = 1,963) pokazuju da mogućnost korištenja neizravnih novčanih transfera povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,62 do 1,96 puta, ovisno o promatranom bloku. U slučaju kada je namjera rađanja iskazana kao M2, omjeri izgleda (Blok 1: Exp(B) = 1,686; Blok 2: Exp(B) = 1,936; Blok 3: Exp(B) = 2,105) ukazuju na to da korištenje neizravnih novčanih transfera povećava šansu da žena ima namjeru rađanja u sljedeće dvije godine za 1,68 do 2,05 puta. Kada se u izražavanje namjere uključi i odgovor žena koje nisu sigurne u svoju namjeru (M3), omjeri izgleda kreću se od 38 % do 43 % (Blok 1: Exp(B) = 1,381; Blok 2: Exp(B) = 1,434; Blok 3: Exp(B) = 1,427), što također ukazuje na značaj fiskalnih instrumenata u oblikovanju namjere o rađanju.

Uzimajući u obzir kontrolne varijable, statistički su značajne varijable i interakcije varijabli kao i prilikom testiranja hipoteze H3a. Međutim, prilikom testiranja hipoteze H3b dodatno je statistički značajna i negativno povezana interakcija sektora zaposlenja i vrste ugovora o radu s namjerom rađanja u sljedeće dvije godine. Žene zaposlene u privatnom

sektoru s ugovorom na određeno vrijeme imaju manje izglede (M1, Blok 3: Exp(B) = ,189) za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje imaju ugovor na neodređeno vrijeme i zaposlene su u javnom sektoru (u skladu s Pieroni i sur., 2023; Alderotti i sur., 2021, Modena i sur., 2014). Zanimljivo je uočiti i da starije žene koje žive u ruralnom području i udane su imaju 2,6 % manje izglede (M2, Blok 3: Exp(B) = ,974) za namjeru rađanja u odnosu na žene mlađe životne dobi koje su same/neudane i žive u urbanim naseljima. Ukupan prihod kućanstva u interakciji s brojem članova kućanstva i djecom ukazuje na zaključak (u M1 i M2) da žene koje imaju veći ukupan prihod kućanstva, dijete/djecu i veći broj članova kućanstva imaju manje izglede za namjeru rađanja u sljedeće dvije godine u odnosu na referentnu skupinu (žene bez djece, manji ukupan prihod kućanstva i manji broj članova kućanstva).

Fiskalni instrumenti javnih politika u ovom doktorskom radu obuhvatili su i transfere u naravi čija se je povezanost s namjerom rađanja u sljedeće dvije godine testirala hipotezom H3c. Provedenim istraživanjem i primjenom logističke regresije, postavljena hipoteza **H3c se ne odbacuje** jer postoji statistički značajna ($p < ,05$) pozitivna povezanost transfera u naravi i namjere rađanja u sljedeće dvije godine u sedam od devet testiranih slučajeva. Najveću klasifikacijsku točnost prilikom testiranja hipoteze H3a ima model u kojemu je namjera rađanja izražena s M2, u Bloku 3 (90,3 %)

Koeficijenti Exp(B) ili omjeri izgleda s 95 %-tnim intervalom pouzdanosti kada je namjera rađanja iskazana s „vjerojatno“ ili „definitivno da“ M1 (Blok 1: Exp(B) = 1,323; Blok 2: Exp(B) = 1,437; Blok 3: Exp(B) = 1,608) pokazuju da korištenje transfera u naravi povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,32 do 1,61 puta, ovisno o promatranom bloku. U slučaju kada je namjera rađanja iskazana kao M2, omjeri izgleda (Blok 1: Exp(B) = 1,347; Blok 2: Exp(B) = 1,461; Blok 3: Exp(B) = 1,685) ukazuju na to da korištenje transfera u naravi povećava izglede da žena ima namjeru rađanja u sljedeće dvije godine za 1,35 do 1,69 puta. Kada se u izražavanje namjere uključi i odgovor žena koje nisu sigurne u svoju namjeru (M3), omjeri izgleda kreću se od 19 % do 20 % (Blok 1: Exp(B) = 1,203; Blok 2: Exp(B) = 1,191; Blok 3: Exp(B) = 1,203), što također ukazuje na značaj ovakve vrste transfera u oblikovanju namjere o rađanju. Promatrajući cijeli logistički model (Blok 3) prema načinu izražavanja namjere rađanja (M1, M2 i M3), najveći omjer izgleda ima varijabla koja se odnosi na imanje djece. Žene s djecom imaju veću šansu za namjeru rađanja u sljedeće dvije godine u odnosu na žene koje u trenutku istraživanja nisu imale dijete. Nadalje, u oblikovanju namjere rađanja vrlo značajna je interakcija varijabli imanja djece, mogućnosti podmirivanja

financijskih obveza i vrste ugovora o radu. Naime, žene s djecom koje imaju ugovor na određeno vrijeme i poteškoće u podmirivanju financijskih obveza imaju veće izglede za namjeru rađanja u sljedeće dvije godine u odnosu na žene iz referentne skupine (žene bez djece, ugovor na neodređeno vrijeme i bez financijskih poteškoća). Statistička značajnost ostalih varijabli i interakcija jednaka je kao i prilikom testiranja hipoteze H3b.

Prilikom testiranja hipoteza H1 i H3 elementi Teorije planiranog ponašanja – subjektivne norme i percipirana kontrola ponašanja su statistički značajni prediktori namjere rađanja u sljedeće dvije godine, dok stavovi nisu.

Zaključno, izravni novčani transferi povećavaju izglede za namjeru rađanja u sljedeće dvije godine za 1,83 puta (M2, Blok 3: Exp(B) = 1,837), dok neizravni novčani transferi izglede povećavaju za 2,1 puta (M2, Blok 3: Exp(B) = 2,105). Najmanje izglede za namjeru rađanja imaju transferi u naravi, koji je povećavaju za 1,2 puta (M3, Blok 1: Exp(B) = 1,203). Važno je napomenuti da značajnu ulogu u rezultatima omjera izgleda ima odabir kreiranog modela. Ovi rezultati dodatno potvrđuju opravdanost korištenja različitih pristupa u izražavanju namjere rađanja u sljedeće dvije godine, ovisno o specifičnim odgovorima ispitanica.

U prethodnom poglavlju ovog doktorskog rada prikazani su rezultati testiranja postavljenih hipoteza u kojima su se zasebno promatrale varijable ekonomskih prediktora i njihova povezanost s namjerom rađanja u sljedeće dvije godine. No, za daljnji tijek rasprave u logistički model uključene su sve prediktorske varijable koje se odnose na ekonomsku sigurnost i fiskalne instrumente te kontrolne varijable koje su se u logističkim modelima u potpoglavljima 5.7.2. i 5.7.3. pokazale statistički značajnima.

Tablica 42. Logistička regresija namjere rađanja u sljedeće dvije godine

Varijable/namjera rađanja u sljedeće dvije godine	**M1**	**M2**	**M3**
Sigurnost posla	,697*** (,160)	,839*** (,191)	,534*** (,131)
Financijska sigurnost	-,500** (,188)	-,763** (,241)	-,356* (,158)
Potpuno vlasništvo	,003 (,279)	-,199 (,340)	-,118 (.234)
Izravni novčani transferi	,312 (,234)	-,033 (,384)	,368 (,253)

Neizravni novčani transferi	,324 (,234)	,465 (,273)	,135 (,183)
Transferi u naravi	-,166 (,230)	,100 (,285)	-,235 (,184)
Subjektivne norme	,716*** (,180)	1,031*** (,238)	1,058*** (,170)
Percipirana kontrola ponašanja	2,184*** (,301)	2,257*** (,340)	1,169*** (,197)
Djeca (DA)	7,230*** (1,366)	7,460*** (1,625)	2,535** (,895)
Broj djece	-1,575*** (,397)	-1,945*** (,440)	-,832*** (,229)
Djeca (Da) * Godine starosti	-,157*** (,034)	-,176*** (,039)	-,085*** (,022)
Djeca (DA) * Obrazovanje (srednje ili niže) * Indeks regije (ispodprosječno rangirane, I. i II. skupina)	-1,272* (,514)	-1,417* (,613)	-,333 (,334)
Djeca (DA) * Podmirivanje financijskih obveza (poteškoće) * Vrsta ugovora o radu (određeno)	1,858* (,937)	1,570 (,996)	,720 (,724)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (1301 – 2700 EUR)	-,256 (,139)	-,125 (,158)	,017 (,097)
Broj članova kućanstva * Djeca (DA) * Ukupni prihod kućanstva (> 2700 EUR)	-,375* (,157)	-,340 (,180)	,002 (,103)
Konstanta	-11,010*** (1,547)	-9,978*** (1,734)	-4,629*** (1,040)
Omnibus test koeficijenata modela	p < ,001	p < ,001	p < ,001
Hosmer i Lemeshow test	$\chi2$ = 9,397 df = 8 p = ,310	$\chi2$ = 7,179 df = 8 p = ,517	$\chi2$ = 6,030 df = 8 p = ,644
Klasifikacijska točnost	88,4 %	90,9 %	83,3 %

Izvor: izrada doktorandice

Iz tablice 42. vidljivo je da je došlo do promjene statističke značajnosti pojedinih varijabli. Sigurnost posla je i u ovom modelu statistički značajna i pozitivno povezana s namjerom rađanja, pa se može zaključiti da žene koje imaju siguran posao imaju veće izglede za namjerom rađanja u sljedeće dvije godine za 1,7 do 2,3 puta (M1: Exp(B) = 2,008; M2: Exp(B) = 2,315; M3: Exp(B) = 1,706). Financijska sigurnost u ovom modelu smanjuje šansu za namjeru rađanja u sljedeće dvije godine (M1: Exp(B) = ,606; M2: Exp(B) = ,466; M3: Exp(B) = ,024). Subjektivne norme i percipirana kontrola ponašanja kao elementi Teorije planiranog ponašanja su i u ovom slučaju statistički značajne i pozitivno povezane varijable s namjerom rađanja u sljedeće dvije godine te povećavaju šansu za namjeru rađanja neovisno o načinu izražavanja namjere (M1, M2, M3). Žene koje imaju dijete/djecu imaju značajno veću šansu za namjeru rađanja u odnosu na žene koje nemaju dijete (M1: Exp(B) = 1379,595; M2: Exp(B) = 1737,856; M3: Exp(B) = 12,613). Paritet je i u ovom slučaju statistički značajna

varijabla i veći broj djece koji žena već ima smanjuje šansu za namjerom rađanja u sljedeće dvije godine (M1: Exp(B) = ,207; M2: Exp(B) = ,143; M3: Exp(B) = ,435). Žene starije životne dobi koje već imaju dijete/djecu imaju manje izglede za namjeru rađanja u sljedeće dvije godine za 8 % do 16 % (M1: Exp(B) = ,854; M2: Exp(B) = ,839; M3: Exp(B) = ,918) u odnosu na mlađe žene koje još uvijek nemaju dijete.

Nadalje, šansa za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu i žive u manje razvijenim regijama je manja (M1: Exp(B) = ,280; M2: Exp(B) = ,242) u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti). Ova interakcija varijabli nije statistički značajna u slučaju kada je namjera rađanja izražena s „nisam sigurna“, „vjerojatno“ ili „definitivno da“ (M3). Žene koje žive u kućanstvu s većim brojem članova, imaju dijete/djecu i ukupan prihod kućanstva veći od 2700 EUR imaju manju šansu (Exp(B) = ,687) za namjeru rađanja u odnosu na žene koje nemaju dijete, imaju manji ukupan prihod kućanstva i manji broj članova kućanstva. Interakcija ovih varijabli statistički je značajna samo kada je namjera rađanja izražena s „vjerojatno“ i „definitivno da“ (M1). Ostale varijable i interakcije varijabli nisu statistički značajne kada se promatra objedinjeni model. Kao i u prethodnim analizama, najveću klasifikacijsku točnost ima model u kojemu je namjera rađanja izražena s M2 (90,9 %)

Zaključno, utjecaj prediktorskih varijabli na kriterijsku varijablu značajno varira ovisno o načinu izražavanja namjere rađanja u sljedeće dvije godine (M1, M2, M3), ali i o samom izboru prediktorskih varijabli te njihovim međusobnim interakcijama unutar modela. Ovi rezultati upućuju na važnost pažljivog definiranja modela i odabira varijabli kako bi se preciznije razumjeli čimbenici koji utječu na reproduktivne odluke.

7. ZAKLJUČAK

Demografsku sliku Republike Hrvatske prvenstveno karakterizira depopulacija i starenje stanovništva. Popisi stanovništva ukazuju na neujednačenost depopulacije po regijama, koja je u novije vrijeme u najvećoj mjeri potaknuta iseljavanjem nakon pristupanja Europskoj uniji. Depopulacija je osobito prisutna među mlađom populacijom, što je dovelo i do smanjenja broja rađanja. Broj živorođene djece od 2013. godine je u znatnom padu, čak i u većoj mjeri nego što su ranije projekcije predviđale. Osim toga, starenje stanovništva postaje sve veći izazov, uzrokovano ne samo niskom stopom nataliteta i iseljavanjem mladih, već i produljenjem očekivanog životnog vijeka. Ipak, hrvatsko stanovništvo i dalje pokazuje visoke razine smrtnosti koje je moguće spriječiti ili liječiti, a uglavnom su rezultat rizičnih zdravstvenih ponašanja. Što se tiče imigracije, posljednjih godina raste broj stranih radnika, osobito muškaraca, koji dolaze raditi u različite sektore, ali ne ostaju trajno niti dovode obitelji. Struktura obitelji u Hrvatskoj također prolazi promjene. Raste broj djece rođene izvan braka, odgađa se stupanje u brak i rađanje prvog djeteta, parovi sve češće raskidaju. Istovremeno, sve više parova suočava se s problemima neplodnosti, što povećava udio djece rođene uz pomoć medicinski potpomognute oplodnje. Mlade žene sve češće biraju tercijarno obrazovanje, a stopa nezaposlenosti se smanjila, djelomično zahvaljujući iseljavanju nakon ulaska u Europsku uniju, ali i poboljšanju gospodarskog stanja. Prema svim projekcijama, očekuje se daljnji pad broja stanovnika i starenje populacije u nadolazećim desetljećima. Zbog toga je ključno da Republika Hrvatska razvije i provede djelotvorne politike koje će osigurati demografsku održivost s naglaskom na ublažavanje smanjenja stanovništva i poboljšanje dobne strukture, osobito u slabije razvijenim dijelovima zemlje.

Suvremeni stil života i rada, koji otežava usklađivanje poslovnih i obiteljskih obveza, doveo je do nižih stopa fertiliteta u razvijenim zemljama, uključujući i Hrvatsku. Činjenica da mnogi pojedinci i parovi žele imati više djece nego što ih stvarno imaju sugerira prisutnost prepreka u ostvarivanju roditeljstva. Primjetan je trend odgađanja rađanja u kasniju dob, što može negativno utjecati na plodnost parova ako se planiranje obitelji ne uskladi s reproduktivnim razdobljem života. Suvremeno roditeljstvo suočava se s brojnim društvenim promjenama i izazovima u preuzimanju odgovornosti za odgoj djece. Ključna je bolja suradnja između tijela državne uprave, lokalnih i regionalnih vlasti te organizacija civilnog društva kako bi se omogućila pravovremena podrška u ranom djetinjstvu. Društvo ima obvezu stvoriti uvjete za cjelovitu skrb o djeci i promicanje odgovornog roditeljstva. Sustavi podrške i sinergija

različitih oblika javnih politika ključni su za unapređenje kvalitete života obitelji i stvaranje poticajnog okruženja za povratak ili doseljavanje mladih obitelji iz inozemstva.

U kontekstu ovog doktorskog rada, nizak natalitet ugrožava održivost države blagostanja, jer dolazi do smanjenja radne snage i povećanja opterećenja na postojeće radno aktivno stanovništvo koje mora podržavati neaktivne stanovnike, uključujući umirovljenike i osobe koje ne mogu raditi iz različitih razloga. To može dovesti do smanjenja produktivnosti i rasta gospodarstva zbog opterećenosti proračuna uslijed povećanih socijalnih potreba stanovništva (mirovine i zdravstvena skrb). Osim toga, smanjeni natalitet u dugom roku dovodi do manjeg broja poreznih obveznika, a posljedično i manjih prihoda od poreza čime se otežava financiranje javnih usluga i infrastrukture.

Na temelju iznesenih teorijskih i istraživačkih spoznaja uočen je istraživački jaz (poglavlje 1.1.) koji se je pokušao premostiti provođenjem sveobuhvatnog istraživanja o namjeri rađanja u sljedeće dvije godine na populaciji žena starosti od 22 do 49 godina. Kako bi se dobio što cjelovitiji model u istraživanje su uključene varijable ekonomske sigurnosti, fiskalnih instrumenata javnih politika, Teorije planiranog ponašanja i socio-demografske karakteristike ispitanica. Identificirani istraživački jaz poslužio je kao temelj za formuliranje sljedećih hipoteza:

H1: Postoji statistički značajna pozitivna povezanost između ekonomske sigurnosti i namjere rađanja.

H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja.

H1b: Postoji statistički značajna pozitivna povezanost financijske sigurnosti i namjere rađanja.

H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja.

H2: Postoji statistički značajna negativna povezanost ekonomske sigurnosti i jaza između željenog i ostvarenog broja djece.

H3: Postoji statistički značajna pozitivna povezanost između fiskalnih instrumenata javnih politika i namjere rađanja.

H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja.
H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja.
H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja.

H4: Odluke o namjeri rađanja statistički značajno se razlikuju ovisno o ekonomskoj razvijenosti lokalne i regionalne samouprave, odnosno indeksu razvijenosti.

Svrha istraživanja bila je razviti cjeloviti model ekonomskih prediktora koji utječu na namjeru rađanja u sljedeće dvije godine kod žena koje imaju djecu i onih koje nemaju, kao i prediktora koji su povezani s fertilnim jazom. Sukladno tomu, postavljeni su ciljevi metodološkog i empirijskog dijela. Prvi cilj je bio testirati povezanost odabranih ekonomskih prediktora i namjere rađanja te je isti ostvaren u poglavlju 5.7. prikazom rezultata istraživanja kroz testiranje postavljenih hipoteza H1 i H3 primjenom logističke regresije te prilikom testiranja H4 primjenom Kruskal-Wallisovog testa. Drugi cilj bio je testirati povezanost ekonomske nesigurnosti i fertilnog jaza te je isti prikazan u poglavlju 5.7. testiranjem hipoteze H2 primjenom Spearmanovog koeficijenta korelacija. Posljednji cilj odnosio se je na usporedbu dobivenih empirijskih rezultata s rezultatima prethodnih istraživanja te je postavljeni cilj ostvaren u poglavlju 6. (Rasprava o rezultatima istraživanja).

U teorijskom dijelu rada (prva četiri poglavlja doktorskog rada) ostvareni su ključni ciljevi postavljeni na početku rada (potpoglavlje 1.2.). Prvo, detaljno su opisani procesi demografske tranzicije ključni za razumijevanje promjena u obrascima rađanja tijekom vremena. Definirane su i opisane ekonomske teorije fertiliteta koje pružaju temelj za razumijevanje ekonomskih aspekata reproduktivnog ponašanja. Uloga i značaj javnih politika u funkciji demografske revitalizacije, s naglaskom na povećanje fertiliteta, također su detaljno prikazani i objašnjeni. U teorijskom dijelu rada prikazani su i analizirani rezultati prethodnih istraživanja, čime se osigurao uvid u postojeće spoznaje.

Za potrebe provođenja empirijskog istraživanja kreiran je sveobuhvatni model namjere rađanja temeljen na Teoriji planiranog ponašanja, koji je proširen ekonomskim prediktorima kao što su ekonomska sigurnost, fiskalni instrumenti javnih politika i regionalna razvijenost (slika 1.). Konačno, pridonijelo se razvoju teorijskog okvira koji ukazuje na interakciju između

ekonomskih prediktora i namjere rađanja, obogaćujući postojeće razumijevanje ovog važnog društvenog i demografskog fenomena. Proširenje konceptualnog modela Teorije planiranog ponašanja varijablama ekonomske sigurnosti (sigurnost posla, financijska sigurnost i potpuno vlasništvo nad nekretninom), fiskalnih instrumenata javnih politika (izravni novčani transferi, neizravni novčani transferi i transferi u naravi) i regionalne razvijenosti u modeliranju namjere rađanja rezultiralo je kreiranjem sveobuhvatnog modela namjere rađanja u sljedeće dvije godine što predstavlja **metodološki znanstveni doprinos doktorskog rada**.

Kreirani model predstavljao je podlogu za provođenje empirijskog istraživanja na uzorku žena od 22 do 49 godina starosti, prostorno obuhvaćajući cijelu Republiku Hrvatsku. Rezultati istraživanja ukazuju da je ekonomska sigurnost djelomično pozitivno i statistički značajno povezana s namjerom rađanja u sljedeće dvije godine. Naime, sigurnost posla i namjera rađanja su statistički značajni i pozitivno povezani u svim testiranim modelima logističke regresije. Financijska sigurnost je statistički značajna i pozitivno povezana s namjerom rađanja u sedam od devet testiranih slučajeva. Potpuno vlasništvo nad nekretninom u slučajevima u kojima je statistički značajno je negativno povezano s namjerom rađanja u sljedeće dvije godine. Kako je već prethodno navedeno u potpoglavlju 4.3.1.1. dosadašnji literaturni navodi izučavali su ekonomsku nesigurnost samo neizravno, a mjerenje iste je nedovoljno razvijeno. Ovim doktorskim radom dan je znanstveni doprinos u mjerenju ekonomske sigurnosti, ali i njezinoj povezanosti s budućim fertilitetnim namjerama.

Rezultati provedenog istraživanja dovode do zaključka da ekonomska sigurnost nije povezana s fertilnim jazom kod ispitanica koje već imaju dijete/djecu. Značajnijim su se pokazali čimbenici koji se odnose na druge životne okolnosti.

Nadalje, u Republici Hrvatskoj razvojne regije prema indeksu razvijenosti nisu značajan prediktor namjere rađanja u sljedeće dvije godine kod žena koje su bile obuhvaćene istraživanjem kada se promatraju kao samostalna varijabla u modelu primjenom Kruskal-Wallisovog testa. Međutim, regionalni kontekst se je pokazao statistički značajnim prediktorom namjere rađanja primjenom logističke regresije u interakciji s drugim varijablama. Prema ovoj statističkoj metodi, izgledi za namjeru rađanja kod žena koje imaju srednje ili niže obrazovanje, imaju djecu, i žive u manje razvijenim regijama su manji u odnosu na žene iz referentne kategorije (žene s višim stupnjem obrazovanjem, bez djece i koje žive u razvijenijim regijama prema indeksu razvijenosti).

Fiskalni instrumenti javnih politika (izravni novčani transferi, neizravni novčani transferi i naknade u naravi i subvencije) statistički su značajan prediktor namjere rađanja u sljedeće dvije godine. Korištenje ovih transfera povećava izglede za namjeru rađanja u sljedeće dvije godine kod žena u Republici Hrvatskoj.

Teorijski znanstveni doprinos doktorskog rada očituje se u sveobuhvatnoj sistematizaciji i reinterpretaciji postojećih znanstvenih i teorijskih spoznaja koje se odnose na determinante namjere rađanja. Rad nudi sintezu recentne domaće i međunarodne znanstvene literature s naglaskom na ekonomske prediktore koji oblikuju namjeru rađanja, uključujući sigurnost posla, financijsku sigurnost, potpuno vlasništvo nad nekretninom, kao i ulogu javnih fiskalnih instrumenata usmjerenih obiteljima s djecom. Time se omogućuje interdisciplinarni uvid koji povezuje različita polja unutar područja društvenih znanosti (ekonomija i demografija). Nadalje, pregled i klasifikacija postojećih mjera javnih politika usmjerenih obiteljima s djecom omogućuje jasnije razumijevanje institucionalnog okvira koji oblikuje reproduktivno ponašanje pojedinaca. Takav teorijski pristup doprinosi razvoju proširenog konceptualnog modela temeljenog na Teoriji planiranog ponašanja, čime se unosi nova dimenzija u istraživanje demografskog ponašanja u suvremenom kontekstu.

Aplikativni znanstveni doprinos rada ogleda se u operacionalizaciji istraživačkih rezultata kroz izradu konkretnih smjernica za oblikovanje učinkovitijih javnih politika usmjerenih na poboljšanje demografskih trendova. U potpoglavlju 7.2. predložene su ciljane mjere koje proizlaze iz identificiranih statistički značajnih čimbenika namjere rađanja, a koje uključuju intervencije s ciljem poboljšanja demografskih trendova. Na taj se način omogućuje izravna primjena znanstvenih spoznaja u praksi, osobito na razini lokalne i regionalne samouprave, ali i u nacionalnim strateškim dokumentima. Time rad doprinosi stvaranju pristupa utemeljenog na dokazima u oblikovanju obiteljske politike, s ciljem stvaranja povoljnijih uvjeta za obiteljski život i povećanje fertiliteta u Hrvatskoj.

7.1. Ograničenja provedenog istraživanja i preporuke za buduća istraživanja

Svako istraživanje, pa tako i ovo, nastoji analizirati određenu problematiku te se u okviru toga neizbježno javljaju i određena ograničenja.

Prije svega, istraživanje u ovom doktorskom radu obuhvatilo je samo žene. Stoga je preporuka u buduća istraživanja uključiti i muškarce kako bi se dobio uvid i u njihov utjecaj na donošenje odluka o rađanju jer su i oni važni sudionici u planiranju obitelji. Nadalje, širok raspon dobi, odnosno uključivanje žena u različitim fazama života, od mladih žena koje tek ulaze u fertilno razdoblje do onih koje se bliže kraju reproduktivne dobi, može rezultirati značajnim varijacijama u motivacijama, iskustvima i namjerama rađanja. To otežava izoliranje specifičnih prediktora za svaku dobnu skupinu. Osim toga, za žene u starijim dobnim skupinama (npr. blizu 49 godina), namjera rađanja u sljedeće dvije godine može biti ograničena biološkim faktorima, što može distorzirati rezultate u odnosu na mlađe sudionice. S metodološkog aspekta, za statističku obradu podataka primijenjena je logistička regresija, čime je osigurana usporedivost s prethodnim relevantnim istraživanjima. Ova metoda prepoznata je kao robusna i pouzdana u analizi namjere rađanja u kontekstu demografskih istraživanja. Ipak, u svrhu dubljeg razumijevanja složenijih odnosa među varijablama, uključujući direktne i indirektne učinke, buduća istraživanja mogla bi se usmjeriti prema primjeni strukturalnog modeliranja. Nadalje, jedno od ograničenja ovog istraživanja odnosi se na činjenicu da kvaliteta stambenog prostora, odnosno nekretnine u vlasništvu, nije detaljno ispitivana. Konkretno, analiza ne obuhvaća informacije o veličini, lokaciji, uvjetima stanovanja ni prikladnosti stambenog prostora za podizanje većeg broja djece, što može imati značajan utjecaj na odluke o proširenju obitelji.

Kako bi se premostila navedena ograničenja u budućim istraživanjima, preporučuju se sljedeće smjernice:

- dobna segmentacija uzorka kroz podjelu sudionica na dobne skupine
- usmjeravanje na specifične faze reproduktivnog života kroz odabir uske skupine žena koje su u sličnim životnim fazama kako bi se smanjile varijacije u motivaciji i omogućilo dublje razumijevanje specifičnih prediktora namjere rađanja unutar tih skupina
- prilagodba anketnog instrumenta za žene koje su blizu kraja reproduktivnog razdoblja (npr. umjesto namjere rađanja u sljedeće dvije godine može se postaviti pitanje o stavu prema rađanju ili prošlim odlukama koje su dovele do sadašnjeg stanja)
- uključivanje bioloških i zdravstvenih podataka
- uključivanje procjene adekvatnosti stambenog prostora kao potencijalnog faktora koji može utjecati na odluke o proširenju obitelji. Posebna pažnja može se usmjeriti na

karakteristike poput veličine stambene jedinice, broja soba, kvalitete stanovanja i lokacije, koje mogu imati važnu ulogu u oblikovanju reproduktivnih namjera
- provođenje longitudinalnog istraživanja kako bi se preciznije razumjele promjene u motivacijama i namjerama rađanja kroz različite faze života
- kombinacija kvantitativnih i kvalitativnih metoda poput intervjua ili fokus grupa kako bi se dobio bogatiji uvid u motive i prepreke vezane za rađanje.

Implementacijom ovih preporuka, buduća istraživanja mogla bi preciznije obuhvatiti specifične čimbenike koji utječu na namjere rađanja unutar različitih dobnih i životnih faza te smanjiti distorzije u rezultatima.

Budući da je istraživanje temeljeno na anketi, postoji rizik da sudionice nisu bile potpuno iskrene u odgovaranju na postavljena pitanja o stavovima, normama, percipiranoj kontroli ponašanja te namjeri rađanja, posebno s obzirom na društvene ili kulturne pritiske, stoga je preporuka u buduća istraživanja uključiti i dodatne kvalitativne metode kako je gore navedeno. Kao posljednje ograničenje može se istaknuti segment predviđanja. Iako je istraživanje usmjereno na namjeru rađanja u sljedeće dvije godine, namjera ne mora nužno rezultirati stvarnim ponašanjem te može varirati tijekom vremena pod utjecajem različitih životnih događaja.

7.2. Preporuke koje proizlaze iz rezultata istraživanja

S obzirom na ključnu ulogu fertiliteta u funkcioniranju ne samo gospodarstva, već i cjelokupnog društva, svako istraživanje društvenog ili humanističkog pristupa ovoj temi treba ponuditi preporuke za poboljšanje javnih politika u kontekstu identificiranih problema. Slijedom toga i ovaj rad je osmišljen kako bi svojim istraživanjem i testiranjem postavljenih hipoteza pridonio daljnjem unapređenju demografske slike Republike Hrvatske. Na temelju rezultata istraživanja moguće je donijeti niz preporuka za nositelje javnih politika.

Iako je rađanje obiteljska odluka u koju se državne vlasti ne bi trebale previše miješati, one mogu različitim mjerama ukloniti prepreke koje negativno utječu na odluku o rađanju djece i staviti naglasak na poticanje namjere za roditeljstvom i proširenje obitelji.

Kako bi se smanjio jaz između željenog i ostvarenog broja djece te pozitivno djelovalo na stvaranje poticajnog okruženja za donošenje fertilitetnih odluka, mogu se predložiti sljedeće potencijalne strategije i mjere:

- dodatno povećanje izravnih novčanih transfera kako bi se utjecalo na smanjenje ekonomskih prepreka za roditeljstvo i postizanje željenog broja djece
- preporučuje se razmatranje zamjene postojećeg sustava poreznih olakšica za djecu sustavom poreznog odbitka za uzdržavanu djecu, s naglaskom na uvođenje poreznog odbitka s povratom (engl. *Refundable tax credit*)
- unaprjeđenje zdravstvene zaštite trudnica i majki
- proširenje naknada namijenjenih djeci s invaliditetom
- povećanje naknada za prijevoz u svrhu liječenja djeteta
- povećanje broja ustanova za rani i predškolski odgoj i obrazovanje i dostupnost istima svoj djeci
- fleksibilni radni uvjeti, uključujući rad od kuće i skraćeno radno vrijeme omogućilo bi roditeljima bolju ravnotežu između poslovnih i obiteljskih obveza
- produženje i fleksibilnosti roditeljskog dopusta
- pružanje subvencija za kupnju ili najam stana obiteljima s djecom kako bi se smanjili ekonomski pritisci
- ulaganja u socijalno stanovanje i poticanje izgradnje obiteljskih stanova učinilo bi stanovanje dostupnijim za mlade obitelji
- regionalni razvoj i stimulacija mladih obitelji u ruralnim područjima kroz poticanje naseljavanja mladih obitelji u ruralne i slabije razvijene regije kroz financijske poticaje, subvencije ili olakšice
- promicanje ravnopravnosti spolova
- informativne kampanje koje promiču aktivnu ulogu očeva u odgoju djece kako bi se doprinijelo smanjenju opterećenja na majke i poboljšanju opće klime za rađanje više djece
- promocija obiteljskih vrijednosti i roditeljstva kroz javnozdravstvene i društvene kampanje koje naglašavaju važnost obitelji i roditeljstva
- edukacija i informiranje javnosti o demografskim izazovima i dugoročnim posljedicama niskih stopa fertiliteta kako bi se promicala veća društvena odgovornost i svijest o potrebi za većim obiteljima.

Uz sve prethodno navedeno, predlaže se proširenje sustava demografskih i ostalih mjera koje su ispitanice navele u upitniku (uz postojeće mjere), a koje bi mogle imati pozitivan utjecaj na odluku o rađanju:

SKUPINA MJERA	MJERE
Roditeljske i obiteljske naknade i potpore	• mjera majka odgojiteljica • dječji doplatak za svu djecu (bez cenzusa) • povećanje roditeljskih naknada • veće naknade za vrijeme roditeljskog dopusta • puni iznos plaće za vrijeme bolovanja zbog djece • povećanje dječjeg doplatka • povećanje financijske potpore za vrijeme komplikacija u trudnoći
Stambena sigurnost i fiskalne olakšice	• poboljšanje uvjeta za stjecanje prve nekretnine • ukidanje poreza na veću nekretninu • pomoć roditeljima pri izgradnji prve nekretnine • subvencioniranje kamatnih stopa kod stambenih kredita
Predškolska skrb i usluge za djecu	• sufinanciranje vrtića u većem iznosu • dostupnost vrtića za svu djecu • rad svih vrtića u dvije smjene • mogućnost da sva djeca istog roditelja pohađaju isti vrtić • dodatna školska oprema • veći broj pedijatara • veći broj institucija za djecu s poteškoćama u razvoju
Radna prava i radno okruženje roditelja	• duži očinski dopust • uvođenje fleksibilnog radnog vremena • skraćeni radni tjedan za roditelje s više djece • rad na pola radnog vremena do 3. godine djeteta • provedba mjera protiv diskriminacije majki, trudnica i dojilja

SKUPINA MJERA	MJERE
	• povećanje razumijevanja poslodavaca u slučaju bolesti djeteta
	• pomoć u kući neposredno nakon poroda
	• besplatna psihološka potpora za roditelje
Zdravstvena i psihološka podrška	• dostupniji lijekovi za bolesnu djecu
	• veće naknade za pokriće troškova liječenja
	• mogućnost potpomognute oplodnje nakon 42. godine života
Međugeneracijska solidarnost i zajednica	• potpore za bake i djedove koji čuvaju djecu
	• sufinanciranje športskih aktivnosti u okviru škole/vrtića.

Ove mjere usmjerene su na stvaranje povoljnijih ekonomskih i socijalnih uvjeta za rađanje, smanjenje jaza između željenog i ostvarenog broja djece te na dugoročno povećanje stope fertiliteta. Kroz kombinaciju fiskalnih instrumenata, javnih politika i poticanje ravnoteže između poslovnog i obiteljskog života moguće je postići značajnije pozitivne promjene u demografskim kretanjima.

8. LITERATURA

1. Abbasi-Shavazi, M. J., Khani, S. (2014). Economic Insecurity and Fertility: Case Study of Married Women in Sanandaj District. *Journal of Population Association of Iran*, *9*(17), str. 37–76.
2. Adhikari, R. (2010). Demographic, socio-economic, and cultural factors affecting fertility differentials in Nepal. *BMC Pregnancy and Childbirth* 10(1), str. 1–11.
3. Adsera, A. (2004). Changing Fertility Rates in Developed Countries. The Impact of Labor Market Institutions. *Journal of Population Economics*, 17(1), str. 17–43.
4. Adsera, A. (2006). An Economic Analysis of the Gap Between Desired and Actual Fertility: The Case of Spain. *Review of Economics of the Household,* 4(1), str. 75–95, doi: 10.1007/s11150-005-6698-y
5. Ahn, N., Mira, P. (2001). Job bust, baby bust?: Evidence from Spain. *Journal of Population Economics,* 14(3), str. 505–521, doi: 10.1007/s001480100093
6. Ahn, N., Mira, P. (2002). A Note on the Changing Relationship between Fertility and Female Employment Rates in Developed Countries. *Journal of Population Economics*, 15(4), str. 667–682. Dostupno na: http://www.jstor.org/stable/20007839
7. Aitken, R.J. (2022). The changing tide of human fertility. *Human Reproduction,* 37(4), str. 629–638.
8. Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), str. 179–211, doi: 10.1016/0749-5978(91)90020-t
9. Ajzen, I., Klobas, J. (2013). Fertility intentions: An approach based on the theory of planned behavior. *Demographic Research*, 29(8), str. 203–232, doi: 10.4054/DemRes.2013.29.8
10. Akrap, A. (2003). Promjene u strukturama fertinoga kontingenta u Hrvatskoj 1971.-2001. *Zbornik Ekonomskog fakulteta u Zagrebu,* 1(1), str. 105–128. Dostupno na: https://hrcak.srce.hr/26177
11. Akrap, A. (2005). Demografsko stanje, trendovi, perspektive i nužnost provođenja populacijske politike u Republici Hrvatskoj. *Hrvatski časopis za javno zdravstvo*, 1(2). Dostupno na: https://hrcak.srce.hr/298067
12. Akrap, A. (2019). Stanovništvo u Hrvatskoj: čimbenici silaznih trendova (Population in Croatia: factors of the downward trend). *Obnovljeni Život,* 74(3), str. 335–349, doi: https://doi.org/10.31337/oz.74.3.4

13. Akrap, A., Čipin, I. (2008). Stambeni problemi, produženi život s roditeljima i odgoda ulaska u brak u Hrvatskoj, *Revija za socijalnu politiku*, 15(3), str. 415–434, doi: https://doi.org/10.3935/rsp.v15i3.787
14. Alderotti, G., Guetto, R., Barbieri, P., Scherer, S., Vignoli, D. (2025). Unstable employment careers and (quasi-)completed fertility: evidence from the labour market deregulation in Italy, *European Sociological Review*, 41(2), str. 299–315, doi: https://doi.org/10.1093/esr/jcae027
15. Alderotti, G., Vignoli, D., Baccini, M., Matysiak, A. (2021). Employment Instability and Fertility in Europe: A Meta-Analysis. *Demography*, 58(3), str. 871–900, doi: 10.1215/00703370-9164737. PMID: 33899914.
16. Alfonso-Sánchez, M., Peña, J. (2005). Effects of consanguinity on pre-reproductive mortality: does demographic transition matter? *American Journal of Human Biology*, 17(6), str. 773–786, doi: https://doi.org/10.1002/ajhb.20444
17. Amuedo-Dorantes, C., & Kimmel, J. (2005). The Motherhood Wage Gap for Women in the United States: The Importance of College and Fertility Delay. *Review of Economics of the Household*, 3(1), str. 17–48, doi: 10.1007/s11150-004-0978-9
18. Andersen, S. N., Drange, N., Lappegård, T. (2018). Can a Cash Transfer to Families Change Fertility Behaviour? *Demographic Research*, 38, str. 897–928, doi: 10.4054/DemRes.2018.38.33
19. Anderson B. A. (1986). *Regional and cultural factors in the decline of marital fertility in Europe*, u knjizi: Watkins, C.: *The Decline of Fertility in Europe*. Princeton: Princeton University Press, str. 293–313.
20. Andersson, G. (2000). The Impact of Labour-Force Participation on Childbearing Behaviour: Pro-Cyclical Fertility in Sweden during the 1980s and the 1990s. *European Journal of Population,* 16, str. 293–333, doi: https://doi.org/10.1023/A:1006454909642
21. Andersson, G., Rønsen, M., Knudsen, L., Lappegård, T., Neyer, G., Skrede, K., Teschner, K., Vikat, A. (2009) Cohort fertility patterns in the Nordic countries. *Demographic Research*, 20(14), str. 313–352, doi: 10.4054/DemRes.2009.20.14
22. Anukriti, S., Dinarte-Diaz, L. Montoya-Aguirre, M., Sakhonchik, A. (2023). *Childcare regulation and women's participation in the labor force*. World Bank. Dostupno na: https://blogs.worldbank.org/en/impactevaluations/childcare-regulation-and-womens-participation-labor-force

23. Apps, P., Rees, R. (2001). *Fertility, Female Labor Supply and Public Policy.* IZA Discussion Paper No. 409. Bonn: Institute for the Study of Labor (IZA)
24. Atoh, M., Kandiah, V., Ivanov, S. (2004). The second demographic transition in Asia? Comparative analysis of the low fertility situation in East and South-East Asian countries. *The Japanese Journal of Population*, 2(1), str. 42–75. Dostupno na: https://www.ipss.go.jp/webj-ad/webjournal.files/population/2004_3/atohdoc2004mar.pdf
25. Auer, W., Danzer, N. (2015). *Fixed-Term Employment and Fertility: Evidence from German Micro Data. CESifo Economic Studies,* 62(4), *str.* 595–623*,* doi: 10.1093/cesifo/ifv014
26. Awad A., Yussof I. (2017). Factors affecting fertility – New evidence from Malaysia. Bulletin of Geography. *Socio-Economic Series,* 36(36), str. 7–20, doi: 10.1515/bog-2017-0011
27. Axinn, W. G., & Barber, J. S. (2001). Mass education and fertility transition. *American Sociological Review*, 66(4), str. 481–505, doi: 10.2307/3088919
28. Azmoude E, Behnam H, Barati-Far S, Kabirian M. (2017). The Relationship of SocioDemographic Factors, Fertility Behavior and Child's Perceived Value with Fertility Intention of Women in a Region in the East of Iran. *Int J Community Based Nurs Midwifery*, 5(2), str. 123–133. Dostupno na: https://www.researchgate.net/publication/338819411_The_relationship_of_socio-demographic_factors_with_fertility_intention_The_Relationship_of_Socio-Demographic_Factors_Fertility_Behavior_and_Child%27s_Perceived_Value_with_Fertility_Intention_of_Women_in#fullTextFileContent
29. Bachrach, C.A., Morgan, S.P. (2013). A Cognitive-Social Model of Fertility Intentions. *Population and Development Review,* 39(3), str. 459–485, doi: 10.1111/j.1728-4457.2013.00612.x.
30. Bagozzi, R. P., & Yi, Y. (1988). On the evaluation of structural equation models. Journal of the Academy of Marketing Science, 16(1), str. 74–94, doi: http://dx.doi.org/10.1007/BF02723327
31. Baizan, P. (2007). *The Impact of Labour Market Status on Second and Higher-order Births.* Chapter 2 of Family Formation and Family Dilemmas in Contemporary Europe, edited by Gosta Esping-Andersen, str. 93–127. Fundacion BBVA
32. Baizán, P. (2009). Regional child care availability and fertility decisions in Spain. *Demographic Research*, 21(27), str. 803–842, doi: 10.4054/DemRes.2009.21.27

33. Bano, R. P., Samosir, O. B., Djutaharta, T. (2021). The Association Between Conditional Cash Transfer and Fertility Intention in Indonesia. *Jurnal Ilmu Sosial dan Ilmu Politik*, 25(2), str. 144–161, doi: https://doi.org/10.22146/jsp.68201
34. Barbieri, P., Bozzon, R., Scherer, S., Grotti, R., Lugo, M. (2015). The Rise of a Latin Model? Family and fertility consequences of employment instability in Italy and Spain. *European Societies*, 17(4), str. 423–446, doi: https://doi.org/10.1080/14616696.2015.1064147
35. Barbos, A., Milovanska-Farrington, S. (2019). The Effect of Maternity Leave Expansions on Fertility Intentions: Evidence from Switzerland. *Journal of Family and Economic*, 40, str. 323–337, doi: https://doi.org/10.1007/s10834-019-09609-3
36. Barro, R.J. (1991). Economic growth in a cross section of countries. *The Quarterly Journal of Economics,* 106(2), str. 407–443, doi: https://doi.org/10.2307/2937943
37. Basten, S., Frejka, T. (2015). Fertility and Family Policies in Central and Eastern Europe. *Barnett Working Paper,* 15-01, str. 5–74.
38. Basten, S., Huinink, J., Klüsener, S. (2012). Spatial Variation of Sub-national Fertility Trends in Austria, Germany and Switzerland. *Comparative Population Studies*, 36(2-3), str: 573–614, doi: https://doi.org/10.12765/CPoS-2011-08
39. Basu, A. M. (2002). Why does education lead to lower fertility? A critical review of some of the possibilities. *World Development*, 30(10), str. 1779–1790, doi: 10.1016/S0305-750X(02)00072-4
40. Beaujouan, E., Berghammer, C. (2019). The Gap Between Lifetime Fertility Intentions and Completed Fertility in Europe and the United States: A Cohort Approach. *Population Research and Policy Review*, 38(4), str. 507–535, doi: 10.1007/s11113-019-09516-3
41. Becker, G. S. (1993). *A Treatise on the Family*. Harvard University Press Cambridge. Massachusetts London, England: Harvard University Press:
42. Becker, G. S., Barro, R. J. (1988). A reformulation of the economic theory of fertility. *Quarterly Journal of Economics*, 103(1), str. 1–25
43. Becker, G. S., Lewis, H. G. (1973). On the Interaction between the Quantity and Quality of Children. *Journal of Political Economy*, 81(2, Part 2), str. 279–288, doi: 10.1086/260166
44. Becker, G.S. (1960). An Economic Analysis of Fertility. *Columbia University and National Bureau of Economic Research*, str. 209–240. Dostupno na: https://www.nber.org/system/files/chapters/c2387/c2387.pdf

45. Becker, G.S.(1965). A theory of the allocation of time. *The Economic Journal*, 75(299), str. 493–517.
46. Becker, S.O., Bentolila, S., Fernandes, A., Ichino, A. (2010). Youth Emancipation and Perceived Job Insecurity of Parents and Children, *Journal of Population Economics,* 23(3), str. 1175–1799, doi: 10.1007/s00148-008-0224-5
47. Becker, T. E. (2005). Potential Problems in the Statistical Control of Variables in Organizational Research: A Qualitative Analysis With Recommendations. *Organizational Research Methods*, 8(3), str. 274–289, doi: https://doi.org/10.1177/1094428105278021
48. Begall, K. (2011). The relation of fertility with economic uncertainty, human capital characteristics, and social support in Post-Communist Estonia. In Blossfeld, H.P., Hofäcker, D. and Bertolini, S. (eds.). Youth on Globalised Labour Markets: Rising Uncertainty and its Effects on Early Employment and Family Lives in Europe. Opladen: Barbara Budrich. Dostupno na: https://bit.ly/3DJRWQS
49. Bélanger, A., Edmonston, B. (2018). Implications of world peak population for Canada. *Canadian Studies in Population*, 45(1-2), str. 1–10, doi: https://doi.org/10.25336/csp29372
50. Bergsvik, J., Fauske, A., Hart, R. K. (2021). Can policies stall the fertility fall? a systematic review of the (quasi-) experimental literature. *Population and Development Review*, 47(4), str. 913–964, doi: https://doi.org/10.1111/padr.12431
51. Bernardi, F. (2005). Public policies and low fertility: rationales for public intervention and a diagnosis for the Spanish case. *Journal of European Social Policy*, 15(2), str. 123–138. doi: 10.1177/0958928705049160
52. Bernardi, F., Nazio, T. (2005). *Globalization and transition to adulthood in Italy*. In H. P. Blossfeld, M. Mills, E. Klijizing, & K. Kurz (Eds.), *Globalization, uncertainty and youth in society*, str. 347–372. London: Routledge
53. Bernardi, L., Klärner, A., von der Lippe, H. (2008). Job Insecurity and the Timing of Parenthood: A Comparison between Eastern and Western Germany. *European Journal of Population / Revue Européenne de Démographie,* 24(3), str. 287–313, doi: 10.1007/s10680-007-9127-5
54. Berrington, A., & Pattaro, S. (2014). Educational differences in fertility desires, intentions and behaviour: A life course perspective. *Advances in Life Course Research*, str. 1–18, doi: http://dx.doi.org/10.1016/j.alcr.2013.12.003

55. Bhaumik, S.K., Nugent, J.B. (2002). Does Economic Uncertainty Have an Impact on Decisions to Bear Children? Evidence from Eastern Germany. *SSRN Electronic Journal*, doi: 10.2139/ssrn.323592
56. Bianchi, S.M. (2014). A demographic perspective on family change. *J Fam Theory Rev*, 6(1), str. 35–44, doi: 10.1111/jftr.12029
57. Billari, F.C., Kohler, H.P. (2002). *"The Impact of Union Formation Dynamics on First Births in West Germany and Italy: Are There Signs of Convergence?"* in E. Klijzing and M. Corijn (eds), *Dynamics of Fertility and Partnership in Europe: Insights and Lessons from Comparative Research*, New York, Geneva: UN, str. 43–58.
58. Billari, F.C., Philipov, D., Testa, M.R. (2009). Attitudes, norms and perceived Behavioural control: explaining fertility intentions in Bulgaria. *European Journal of Population/Revue européenne de Démographie*, 25(4), str. 439–465.
59. Billingsley, S., Ferrarini, T. (2014). Family policy and fertility intentions in 21 European countries. *Journal of Marriage and Family*, 76(2), str. 428–445. Dostupno na: https://www.jstor.org/stable/24582784
60. Biološka struktura stanovništva. (n.d.). Dostupno na: https://arhiva-2021.loomen.carnet.hr/pluginfile.php/3289218/mod_resource/content/1/Biolo%C5%A1ki_struktura_stanovni%C5%A1tva.pdf
61. Birdsall N., Jamison, D.T. (1983). Income and other factors influencing fertility in China. *Population and Development Review,* 9(4), str. 651–675, doi: https://doi.org/10.2307/1973544
62. Björklund, A. (2006). Does family policy affect fertility? *Journal of Population Economics*, 19(1), str. 3–24, doi: 10.1007/s00148-005-0024-0
63. Blacker, C.P. (1949). Stages in population growth. *Eugenics Review*, 39(3), str. 88–101.
64. Blanchet, D., Ekert-Jaffe´, O. (1994). The demographic impact of fertility benefits: Evidence from a micro-model and from macro-data. *In J. Ermisch & N. Ogawa (Eds.), The family, the market and the state in ageing societies*, str. 79–104. Oxford, England: Clarendon Press.
65. Bloom, D., Canning, D., Fink, G. (2014). Disease and development revisited. *Journal of Political Economy*, 122(6), str. 1355–1366, doi: https://doi.org/10.1086/677189
66. Bloom, D., Freeman, R. (1988). Economic development and the timing and components of population growth. *Journal of Policy Modeling*, 10(1), str. 57–81, doi: https://doi.org/10.1016/0161-8938(88)90035-x

67. Bloom, D.E., Canning, D., Sevilla, J. (2001). Economic growth and the demographic transition. Working papaer 8685. *National bureau of economic research*. Dostupno na: https://www.nber.org/system/files/working_papers/w8685/w8685.pdf
68. Blossfeld, H.-P., & Huinink, J. (1991). Human Capital Investments or Norms of Role Transition? How Women's Schooling and Career Affect the Process of Family Formation. *The American Journal of Sociology*, 97(1), str. 143–168, doi: http://dx.doi.org/10.1086/229743
69. Blossfeld, H.P., Klijzing, E., Mills, M., Kurz., K. (2005). *Globalization, Uncertainty and Youth in Society.* London/New York: Routledge
70. Bongaarts, J. (2001). Fertility and reproductive preferences in post-transitional societies. *Population and Development Review*, 27, str. 260–281. Dostupno na: https://u.demog.berkeley.edu/~jrw/Biblio/Eprints/Tempo/bongaarts.2001.pdf
71. Bongaarts, J., Watkins, S.C. (1996). Social interactions and contemporary fertility transitions. *Population and Development Review*, 22(4), str. 639–82, doi: https://doi.org/10.2307/2137804
72. Borg, M.O. (1989). The income-fertility relationship: effect of the net price of a child. *Demography,* 26(2), str. 301–310, doi: https://doi.org/10.2307/2061527
73. Boyle, P. J.,Graham, E., Feng, Z. (2007). Contextualising demography: the significance of local clusters of fertility in Scotland. MPIDR Working Papers *WP-2007-036. Max Planck Institute for Demographic Research.* Germany: Rostock. Dostupno na: https://www.demogr.mpg.de/papers/working/wp-2007-036.pdf
74. Brewster, K.L., Rindfuss, R.R. (2000). Fertility and Women's Employment in Industrialized Nations. *Annual Review of Sociology*, 26, str. 271–296.
75. Bujang, M. A., Sa'at, N., Tg Abu Bakar Sidik, T. M. I., & Lim, C. J. (2018). Sample size guidelines for logistic regression from observational studies with large population: Emphasis on the accuracy between statistics and parameters based on real life clinical data. *Malaysian Journal of Medical Sciences*, 25(4), str. 122–130, doi: https://doi.org/10.21315/mjms2018.25.4.12
76. Bumpass, L., Westoff, C.S. (1969). The prediction of completed fertility. *Demography*, 6(4), str. 445–454, doi: 10.2307/2060089
77. Buttner, T., Lutz, W. (1990). Estimating fertility responses to policy measures on the German Democratic Republic. *Population and Development Review*, 16(3), str. 539–555.

78. Buyang, M.A., Sa'at, N., Sidik, T.M.I.T.A.B., Joo, L.C. (2018). Sample Size Guidelines for Logistic Regression from Observational Studies with Large Population: Emphasis on the Accuracy Between Statistics and Parameters Based on Real Life Clinical Data. *Malays J Med Sci*, 25(4), str. 122–130, doi: https://doi.org/10.21315/mjms2018.25.4.12
79. Camussi, E., Meneghetti, D., Rella, R., Sbarra, M.L., Calegari, E., Sassi, C., Annovazzi, C. (2023). Life design facing the fertility gap: promoting gender equity to give women and men the freedom of a mindful life planning. *Frontiers in Psychology*, 14:1176663, doi: 10.3389/fpsyg.2023.1176663
80. Carmichael, G. A., Whittaker, A. (2007). Choice and circumstance: Qualitative insights into contemporary childlessness in Australia. *European Journal of Population / Revue Européenne de Démographie,* 23(2), str. 111–143*,* doi: 10.1007/s10680-006-9112-4
81. Casterline, J.B. (2003). Demographic transition. In Encyclopedia of Population, 1, ed. P Demeny, G McNicoll, str. 210–216. New York: Thomson & Gale
82. Castiglioni, M., Dalla Zuanna, G. (1994). Innovation and tradition: Reproductive and marital behaviour in Italy in the 1970s and 1980s. *European Journal of Population*, 10(2), str. 107–141.
83. Castles, F. G. (2003). The World Turned Upside Down: Below Replacement Fertility, Changing Preferences and Family-Friendly Public Policy in 21 OECD Countries. *Journal of European Social Policy*, 13(3), str. 209–227, doi: https://doi.org/10.1177/09589287030133001
84. Černič Istenič, M., Kveder, A. (2008). Urban-Rural Life Setting as the Explanatory Factor of Differences in Fertility Behaviour in Slovenia. I*nformatica*, 32, str. 11–122.
85. Chen, M., Lo, C.K.M., Chen, Q., Chan, K. L., Ip, P. (2024). Fertility Intention in Hong Kong: Declining Trend and Associated Factors. *Applied Research in Quality of Life*, 19, str. 1309–1335, doi: https://doi.org/10.1007/s11482-024-10292-2
86. Chesnais, J-C. (1999). Determinants of Below-Replacement Fertility. *Population Bulletin of the United Nations*, 40/41, str. 126–136. Dostupno na: https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/files/documents/2020/Jan/un_2000_population_bulletin_40-41.pdf
87. Christensen, M.A. (2019). Feminization of Poverty: Causes and Implications. In: Leal Filho, W., Azul, A., Brandli, L., Özuyar, P., Wall, T. (eds) Gender Equality. *Encyclopedia of the UN Sustainable Development Goals.* Springer, Cham. doi: https://doi.org/10.1007/978-3-319-70060-1_6-1

88. Christl, M., Köppl-Turyna, M., Lorenz, H., & Kucsera, D. (2020). Redistribution within the tax-benefit system in Austria. *Economic Analysis and Policy*, 68(1), str. 250–264, doi: 10.1016/j.eap.2020.09.011
89. Chung, H. (2017). National-Level Family Policies and Workers Access to Schedule Control in a European Comparative Perspective: Crowding Out or In, and for Whom? *Journal of Comparative Policy Analysis: Research and Practice*, 21(1), str. 25–46, doi: https://doi.org/10.1080/13876988.2017.1353745
90. Cigno, A. (1986). Fertility and the Tax-Benefit System: A Reconsideration of the Theory of Family Taxation. *The Economic Journal*, 96(384), str. 1035–1051, doi: https://doi.org/10.2307/2233172
91. Cigno, A. (1991). *Economics of the Family*. Oxford: Clarendon Press.
92. Čipin, I., Međimurec, P. (2017). Fertilitet i obiteljska politika u Hrvatskoj. *Političke analize,* 8(31), str. 3–9. Dostupno na: https://hrcak.srce.hr/192425
93. Čipin, I., Međimurec, P. (2024). *Demografski pojmovnik.* Zagreb: Središnji državni ured za demografiju i mlade. Dostupno na: https://bit.ly/4irjHwj
94. Čipin, I., Međimurec, P., Vlah Jerić, S. (2016). Fertility and the changing female educational attainment in Croatia. *Stanovništvo,* 54(2), str. 1–26
95. Ciritel, A. A., De Rose, A., Arezzo, M.F. (2019). Childbearing intentions in a low fertility context: the case of Romania. *Genus*, 75(4), str. 1–25, doi. https://doi.org/10.1186/s41118-018-0046-6
96. Clark, W. A. V., & Mulder, C. H. (2000). Leaving home and entering the housing market. Environment and Planning A: Economy and Space, 32, 1657–1671, doi: 10.1068/a3315
97. Clark, W. A. V., Withers, S. D. (2007). Family migration and mobility sequences in the United States: Spatial mobility in the context of the life course. *Demographic Research*, 17, str. 591-622, doi: 10.4054/DemRes.2007.17.20
98. Cleland, J., Wilson, C. (1987). Demand theories of the fertility transition: an iconoclastic view. Population Studies, 41(1), str. 5–30. Dostupno na: https://www.jstor.org/stable/2174324
99. Coale, A. J. (1973). The Demographic Transition, International Population Conference, IUSSP, Vol. 1, Liége.
100. Coale, A. J., Cotts Watkins, S. (1986). *Fertility Decline in Europe*. Princeton: Princeton University Press

101. Cohen, A., Dehejia, R., Romanov, D. (2013). Financial Incentives and Fertility. *Review of Economics and Statistics,* 95(1), str. 1–20, doi: 10.1162/rest_a_00342

102. Cohen, J.W. (1988). *Statistical power analysis for the behavioral sciences (second edition)*. Hillsdale, New Jersey: Lawrence Erlbaum Associates

103. Cowan, S. K., Wyndham Douds, K. (2022). Examining the Effects of a Universal Cash Transfer on Fertility. *Social Forces*, 101(2), str. 1003–1030, doi: https://doi.org/10.1093/sf/soac013

104. D'Addio, A.C., D'Ercole, M.M. (2005). Policies, Institutions and Fertility Rates: A Panel Data Analysis for OECD Countries. *OECD Economic Studies*, 9(2), str. 7–45, doi: 10.1787/eco_studies-v2005-art9-en

105. De Beer, J., Deerenberg, I. (2007). An explanatory model for projecting regional fertility differences in the Netherlands. *Population Research and Policy Review*, 26(5), str. 511–528, doi: 10.1007/s11113-007-9040-y

106. De Paola, M., Nistico, R., Scoppa, V. (2020). Fertility Decisions and Employment Protection: The Unintended Consequences of the Italian Jobs Act. IZA Discussion Paper Series No. 12991. Germany: IZA Institute of Labor Economics

107. De Sandre, P. (2000). Patterns of fertility in Italy and factors of its decline. *Genus,* 56(1/2), str. 19–54. Dostupno na: http://www.jstor.org/stable/29788628

108. De Wachter, D., & Neels, K. (2011). Educational differentials in fertility intentions and outcomes: Family formation in Flanders in the early 1990s. *Vienna Yearbook of Population Research*, 91(1), str. 227–258, doi: 10.2307/41342812

109. Del Boca, D., Locatelli, M. (2006). The Determinants of Motherhood and Work Status: A Survey. *IZA Discussion Paper,* 2414, str. 1–30, doi: 10.2139/ssrn.947056

110. Del Boca, D., Pasqua, S., Pronzato, C. (2007). The Impact of Institutions on Motherhood and Work. *CHILD Working Paper*, 6, str. 1–18. Dostupno na: https://www.econstor.eu/bitstream/10419/92207/1/2006-55.pdf

111. Del Boca, D., Pasqua, S., Pronzato, C. (2008). Motherhood and market work decisions in institutional context: a European perspective. *Oxford Economic Papers*, 61(Supplement 1), str. 147–171, doi: 10.1093/oep/gpn046

112. Del Boca, D., Sauer, R.M (2009). Life Cycle Employment and Fertility Across Institutional Environments. *European Economic Review*, 53(3), str. 274–292, doi: https://doi.org/10.1016/j.euroecorev.2008.06.001

113. Deurloo, M. C., Clark, W. A. V., Dieleman, F. M. (1994). The move to housing owner ship in tempo raland regional contexts. *Environment and Planning A.*, 26(11), str. 1659–1670, doi: 10.1068/a261659

114. Dobrotić, I. (2015). Politike usklađivanja obiteljskih obaveza i plaćenog rada i položaj roditelja na tržištu rada. *Revija za socijalnu politiku*, 22(3), str. 353–374, doi: https://doi.org/10.3935/rsp.v22i3.1258

115. Doepke, M. (2015). Gary Becker on the Quantity and Quality of Children. *Discussion Paper Series*, 81(1), str. 1–10.

116. Doepke, M., Hannusch, A., Kindermann, F., Tertilt, M. (2022). *The Economics of Fertility: A New Era.* Dostupno na: https://faculty.wcas.northwestern.edu/mdo738/research/DHKT_1122.pdf

117. Dommermuth, L., Klobas, J., Lappegård, T. (2011). Now or later? The Theory of Planned Behavior and timing of fertility intentions. *Advances in Life Course Research*, 16(1), str. 42–53, doi: 10.1016/j.alcr.2011.01.002

118. Družić Ljubotina, O., Sabolić, T., Kletečki Radović, M. (2017). Život obitelji s djecom u uvjetima siromaštva iz perspektive roditelja. *Ljetopis socijalnog rada,* 24(2), str. 243–276, doi: https://doi.org/10.3935/ljsr.v24i2.185

119. Državni zavod za statistiku (2001, 2011, 2021). *Popis stanovništva*. Dostupno na: https://podaci.dzs.hr/hr/podaci/stanovnistvo/popis-stanovnistva/

120. Državni zavod za statistiku Republike Hrvatske. (2014). *Statistička izvješća: Razvedeni brakovi u 2013.* Zagreb: Državni zavod za statistiku Republike Hrvatske. Dostupno na: https://web.dzs.hr/Hrv_Eng/publication/2014/SI-1519.pdf

121. Državni zavod za statistiku Republike Hrvatske. (2021a). *Procjena stanovništva prema pojedinačnim godinama, starosti i spolu, po županijama*, *31. 12.* Dostupno na: https://web.dzs.hr/PxWeb/pxweb/hr/Stanovni%C5%A1tvo/Stanovni%C5%A1tvo__Procjene%20stanovni%C5%A1tva/SP24_2.px/?rxid=f01f676e-91b8-4ca9-a9f0-3535841b9ea1

122. Državni zavod za statistiku Republike Hrvatske. (2021b). *Živorođeni prema starosti majke i redu rođenja djeteta*. Dostupno na: https://dzs.gov.hr/print.aspx?id=1554&url=print

123. Državni zavod za statistiku Republike Hrvatske. (n.d.). *Popisi stanovništva.* Dostupno na: https://podaci.dzs.hr/hr/podaci/stanovnistvo/popis-stanovnistva/

124. Državni zavod za statistiku. (2022). *Prirodno kretanje stanovništva Republike Hrvatske u 2021*. Dostupno na: https://podaci.dzs.hr/media/4rpaozj3/stan-2022-1-1-prirodno-kretanje-stanovnistva-republike-hrvatske-u-2021.pdf

125. Duclos, E., Lefebvre, P., Merrigan, P. (2001). A natural experiment on the economics of storks: Evidence on the impact of differential family policy on fertility rates in Canada. *Center for Research on Economic Fluctuations and Employment,* Working paper no. 136. Universite du Quebec a Montreal

126. Ekert, O. (1986). Effets et limites des aides financie`res aux familles: Une expe´rience et un mode`le. *Population*, 2, str. 327–348.

127. Ellsberg, D. (1961). Risk, Ambiguity, and the Savage Axioms. *The Quarterly Journal of Economics,* 75(4), str. 643–669, doi: 10.2307/1884324

128. Engelhardt, H., Prskawetz, A. (2004). On the Changing Correlation Between Fertility and Female Employment Over Space and Time. *European Journal of Population,* 20(1), str. 35–62. Dostupno na: https://www.jstor.org/stable/20164253

129. Ermisch, J. F. (1989). Purchased Child Care, Optimal Family Size and Mother's Employment: Theory and Econometric Analysis. *Journal of Population Economics*, 2(2), str. 79-102, doi: 10.1007/BF00522403

130. ESHRE Capri Workshop Group (2001). Social determinants of human reproduction. *Human Reproduction* 16(7), str. 1518–1526, doi: https://doi.org/10.1093/humrep/16.7.1518

131. Esteve, A., Garcıa-Roman, J., Lesthaeghe, R. (2012). The family context of cohabitation and single motherhood in Latin America. *Popululation and Development Review*, 38(4), str. 707–727. Dostupno na: https://www.jstor.org/stable/41811935

132. Europska komisija. (2013). Prema socijalnom ulaganju za rast i koheziju – uključujući i provedbu Europskog socijalnog fonda za razdoblje 2014. – 2020. *Revija za socijalnu politiku, 20*(2), str. 167–190. doi: https://doi.org/10.3935/rsp.v20i2.1152

133. Europska komisija. (2019). *Key Data on Early Childhood Education and Care in Europe – 2019 Edition.* Dostupno na: https://eurydice.eacea.ec.europa.eu/publications/key-data-early-childhood-education-and-care-europe-2019-edition

134. Europska komisija. (2020). Feasibility study for a child guarantee. Dostupno na: https://op.europa.eu/en/publication-detail/-/publication/c312c468-c7e0-11ea-adf7-01aa75ed71a1/language-en

135. Europska komisija. (2021). *Zelena knjiga o starenju: Poticanje međugeneracijske solidarnosti i odgovornosti.* Bruxelles

136. Europska komisija. (2023). *Access to early childhood education and care in Europe 2022/2023.* Luxembourg: European Union. Dostupno na: https://eurydice.indire.it/wp-content/uploads/2023/11/Structural-Indicators-2023-ECEC-Access-factsheet-11_2023.pdf

137. Europska komisija. (2023). *Demographic change in Europe: a toolbox for action*. Dostupno na: https://commission.europa.eu/system/files/2023-10/factsheet_toolbox_11_10_23_0.pdf

138. Europska unija. (2019). *EUR-Lex.* Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=uriserv%3AOJ.C_.2019.189.01.0004.01.HRV&toc=OJ%3AC%3A2019%3A189%3AFULL#ntc6-C_2019189HR.01000401-E0006

139. Europski parlament i Vijeće Europske unije. (2019). *Direktive: Direktiva (EU) 2019/1158 Europskog parlamenta i vijeća od 20. lipnja 2019. o ravnoteži između poslovnog i privatnog života roditelja i pružatelja skrbi i o stavljanju izvan snage Direktive Vijeća 2010/18/EU.* Službeni list Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32019L1158&from=GA

140. Eurostat (2024b). *Fertility indicators. Total fertility rate*. Online tablični kod: DEMO_FIND. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/DEMO_FIND__custom_7057377/default/table?lang=en

141. Eurostat (2024c). *Fertility indicators. Mean age of women at birth of first child.* Online tablično kod: demo_find. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/DEMO_FIND/bookmark/table?lang=en&bookmarkId=26565240-1494-4163-bf9c-4bb7215590ff

142. Eurostat. (2022). *Population structure indicators at national level: Old - age dependency ratio.* Online tablični kod: DEMO_PJANIND. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/demo_pjanind/default/table?lang=en

143. Eurostat. (2023a). *Fertility indicators: Mean age of women at birth of first child.* Online tablični kod: DEMO_FIND. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/demo_find/default/table?lang=en

144. Eurostat. (2023b). *Fertility indicators: Total fertility rate.* Online tablični kod: DEMO_FIND. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/demo_find/default/table?lang=en

145. Eurostat. (2023h). *Persons paying for formal education by household type, income group, degree of urbanisation and level of difficulty to pay*. Online tablični kod: ilc_ats07. Dostupno na : https://ec.europa.eu/eurostat/databrowser/view/ilc_ats07__custom_13382032/default/table?lang=en

146. Eurostat. (2023n). *Employment and activity by sex and age - annual data*. Online tablični kod: lfsi_emp_a__custom_9029816. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSI_EMP_A/default/table?lang=en

147. Eurostat. (2024). *Expenditure on family/children function by type of benefit and means-testing*. Online tablični kod: spr_exp_ffa**.** Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/spr_exp_ffa/default/table?lang=en

148. Eurostat. (2024). *Gross domestic product (GDP) and main components (output, expenditure and income*). Online tablični kod: nama_10_gdp. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/nama_10_gdp/default/table?lang=en

149. Eurostat. (2024). *Social protection statistics - family and children benefits.* Online tablični kod: spr_exp_func. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Social_protection_statistics_-_family_and_children_benefits

150. Eurostat. (2024). *Social protection statistics - family and children benefits.* Online tablični kod: SPR_EXP_SUM. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Social_protection_statistics_-_family_and_children_benefits

151. Eurostat. (2024a). *Employment and activity by sex and age - annual data*. Online tablični kod: LFSI_EMP_A__custom_7057194. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSI_EMP_A__custom_7057194/default/table?lang=en

152. Eurostat. (2024b). *Public expenditure on education by education level and programme orientation - as % of GDP.* Online tablični kod: educ_uoe_fine06. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/educ_uoe_fine06__custom_13554717/default/table?lang=en

153. Eurostat. (2024c). *Fertility indicators. Mean age at birth of first child*. Online tablični kod: DEMO_FIND. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/DEMO_FIND__custom_7057803/default/table?lang=en

154. Eurostat. (2025c). *Total fertility rate*. Online tablični kod: tps00199. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/tps00199/default/table

155. Eurydice (2023). *Access to early childhood and care in Europe 2022/2023*. Dostupno na: https://eurydice.eacea.ec.europa.eu/sites/default/files/2023-11/ECEC_Access_factsheet_0.pdf

156. Evandrou, M., Falkingham, J., Hills, J., Grand, J.L. (1993). Welfare Benefits in Kind and Income Distribution. *Fiscal Studies,* 14(1), str. 57–76, doi: https://doi.org/10.1111/j.1475-5890.1993.tb00343.x

157. Fagnani, J. (1991). Fertility in France: the influence of urbanization. *Kieler Geographische Schriften*, 78, str. 165–173.

158. Fahlén, S., Oláh, L. (2015). The impact of economic uncertainty on childbearing intentions in Europe. *Families and Societis Working Paper Series*, 36, str. 1–44. Dostupno na: http://bit.ly/3RaGLnl

159. Fanti, L., Gori, L. (2010). Public education, fertility incentives, neoclassical economic growth and welfare. *Bulletin of Economic Research,* 62(1), str. 59–77, doi: 10.1111/j.1467-8586.2009.00326.x

160. Fawcett, T. (2006). An introduction to ROC analysis. Pattern Recognition Letters, 27(8), str. 861–874., doi: 10.1016/j.patrec.2005.10.010

161. Feijten, P., Mulder, C. H. (2002). The timing of household events and housing events in the Netherlands: A longitudinal perspective. *Housing Studies*, 17(5), str. 773–792, doi: 10.1080/0267303022000009808

162. Ferrero Martínez, D., Iza, A. (2004). Skill premium effects on fertility and female labor force supply. *Journal of Population Economics,* 17(1), str. 1–16. Dostupno na: https://www.jstor.org/stable/20007892

163. Fiori, F., Graham, E., Feng, Z. (2014). Geographical variations in fertility and transition to second and third birth in Britain. *Advances in Life Course Research*, 21, str. 149–167, doi: 10.1016/j.alcr.2013.11.004

164. Fiori, F., Rinesi, F., Pinnelli, A., Prati, S. (2013). Economic Insecurity and the Fertility Intentions of Italian Women with One Child. *Population Research and Policy Review,* 32(3), str. 373–413, doi: 10.1007/s11113-013-9266-9

165. Fishbein, M. (1972). Toward an Understanding of Family Planning Behaviors. *Journal of Applied Social Psychology,* 2(3), str. 214–227, doi: https://doi.org/10.1111/j.1559-1816.1972.tb01273.x

166. Förster, M.F., Verbist, G. (2012). Money or kindergarten? Distributive effects of cash versus in-kind family transfers for young children. *OECD Social, Employment and Migration Working Papers*, No. 135, doi: 10.1787/5k92vxbgpmnt-en

167. Fox, J., Klüsener, S., Myrskylä, M. (2018). Is a Positive Relationship Between Fertility and Economic Development Emerging at the Sub-National Regional Level? Theoretical Considerations and Evidence from Europe. *European Journal of Population,* 35, doi: 10.1007/s10680-018-9485-1

168. Friedman, D., Hechter, M., Kanazawa, S. (1994). A Theory of the Value of Children. *Demography*, 31(3), str. 375–401, doi: 10.2307/2061749

169. Gatta, A., Mattioli, L., Mencarini, L., Vignoli, D. (2021). Employment uncertainty and fertility intentions: Stability or resilience?. *Population Studies: A Journal of Demography*, 76(3), str. 387–406, doi: https://doi.org/10.1080/00324728.2021.1939406

170. Gauthier, A. H., Liefbroer, A., Ajzen, I., Aassve, A., Beets, G., Billari, F., Bühler, C., Bujard, M., Cabaço, S., Corijn, M., Désesquelles, A., Dommermuth, L., Dykstra, P., Emery, T., Fadel, L., Fokkema, T., Hansen, T., Hlebec, V., Hoem, J., Klobas, J., Kogovšek, T., Koops, J. C., Kveder, A., Lappegård, T., Lü ck, D., Lugtig, P., MacDonald, A., Macura, M., Makay, Z., Mills, M. C., Murinkó, L., Mynarska, M., Neyer, G., Pailhé, A., Petrič, G., Pinnelli, A., Ratikainen, J., Rayboud, A., Rijken, A., Slagsvold, B., Solaz, A., Spéder, Z., Thévenon, O., Vikat, A. (2022). *Generations and Gender Survey Baseline Questionnaire 3.1.1.* Netherlands Interdisciplinary Demographic Institute. Dostupno na: https://www.ggp-i.org/data/methodology/

171. Gauthier, A.H. (2000). Public policies affecting fertility and families in Europe: A survey of the 15 member states. Paper prepared for the European Observatory on Family Matters; Annual Seminar 2000: 'Low Fertility, Families and Public Policies'; Sevilla (Spain), 15–16 September 2000. str. 1–43.

172. Gauthier, A.H. (2007). The impact of family policies on fertility in industrialized countries: a review of the literature. *Population Research and Policy Review*, 26(3), str. 323–346, doi: 10.1007/s11113-007-9033-x

173. Gauthier, A.H., de Jong, P.W. (2021). Costly children: the motivations for parental investment in children in a low fertility context. *Genus*, 77(6), str. 1–19, doi: 10.1186/s41118-020-00111-5

174. Gelo, J., Akrap, A., & Čipin, I. (2005). *Temeljne značajke demografskog razvoja Hrvatske* (bilanca 20. stoljeća). Zagreb: Ministarstvo obitelji, branitelja i međugeneracijske solidarnosti Republike Hrvatske.

175. Ghannam, A.R.E. (2005). An examination of factors affecting fertility rate differentials as compared among women in less and more developed countries. *Journal of Human Ecology,* 18(3), str. 181–192, doi: 10.1080/09709274.2005.11905828

176. Givord, P., Marbot, C. (2015). Does the cost of child care affect female labor market participation? An evaluation of a French reform of childcare subsidies. *Labour Economics*, 36, str. 99–111, doi: 10.1016/j.labeco.2015.07.003

177. Glusker, A. I., Dobie, S. A., Madigan, D., Rosenblatt, R. A., & Larson, E. H. (2000). Differences in fertility patterns between urban and rural women in Washington State 1983-1984 to 1993-1994. *Women & Health*, 31(1), str. 55–70, doi: 10.1300/J013v31n01_04

178. Goertzen, M.J. (2017). *Applying quantitative methods to e-book collections*. American Library Association (ALA) TechSource

179. Goldstein, J., Lutz, W., Testa, M. R. (2003). The emergence of Sub-Replacement Family Size Ideals in Europe. *Population Research and Policy Review,* 22(5/6), str. 479–496, doi: 10.1023/b:popu.0000020962.80895

180. Golub, R., Ivkov-Dzigurski, A., Simeunović, V. (2023). Determinants of Fertility Intentions of the Women in Bosnia and Herzegovina—An Example from the Semberija Region. *Behavioral Sciences*, 13(5), 417, doi: https://doi.org/10.3390/bs13050417

181. González, L. (2013). The Effect of a Universal Child Benefit on Conceptions, Abortions, and Early Maternal Labor Supply. *American Economic Journal: Economic Policy,* 5(3), str. 160–188, doi: 10.1257/pol.5.3.160

182. Gornick, Janet C., and Marcia K. Meyers. (2004). *Welfare Regimes in Relation to Paid Work and Care*. Chapter 3 in Janet Zollinger Giele and Elke Holst (eds.) *Changing Life Patterns in Western Industrial Societies.* Netherlands: Elsevier Science Press, str. 45–67.

183. Grey, E., Reimondos, A., Lazzari, E., Breunig, R., Stienhauser, R., Zhang, J., Biddle, N., Gray, M. (2022). *Impacts of Policies on Fertility Rates.* Australia:

Australian National University. Dostupno na: https://population.gov.au/sites/population.gov.au/files/2022-03/ANU_Impacts-of-Policies-on-Fertility-Rates-Overview.pdf

184. Gustafsson, S. (2001). Optimal age at motherhood: Theoretical and empirical considerations on postponement of maternity in Europe. *Journal of Population Economics*, 14(2), str. 225–247.

185. Gustafsson, S. (2005). Having Kids Later. Economic Analyses for Industrialized Countries. *Review of Economics of the Household*, 3(1), str. 5–16.

186. Gustafsson, S.S. and Wetzels, C.M.M.P. (2000). *Optimal Age at Giving Birth: Germany, Great Britain, the Netherlands and Sweden,* u knjizi: Gustafsson, S.S. and Meulders, D.E.: *Gender and the Labour Market. Econometric Evidence on Obstacles in Achieving Gender Equality*. London: MacMillan. str. 188–209.

187. Gutiérrez-Domènech, M. (2006). The impact of the labour market on the timing of marriage and births in Spain. *Journal of Population Economics,* 21(1), str. 83–110*,* doi: 10.1007/s00148-005-0041-z

188. Hagewen, K.J., Morgan, S.P. (2005). Intended and ideal family size in the United States, 1970-2002. *Population and Development Review*, 31(3), str. 507–527, doi: 10.1111/j.1728-4457.2005.00081.x

189. Hahn, E. D., & Soyer, R. (2005). Probit and logit models: Differences in the multivariate realm. *The Journal of the Royal Statistical Society,* Series B, 67, str. 1–14. Dostupno na: https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=c45e142a45851c8b4da074ac38fd56bb5ff78749

190. Hair, J. F., Black, W. C., Babin, B. J. (2010). *Multivariate data analysis: a global perspective*. London: Pearson Education.

191. Hair, J. F., Ringle, C. M., & Sarstedt, M. (2013). Partial Least Squares Structural Equation Modeling: Rigorous Applications, Better Results and Higher Acceptance. *Long Range Planning*, 46(1-2), str. 1–12. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2233795

192. Hakim, A., Mahmood, N. (1994). Factors affecting fertility in Pakistan [with comments]. *The Pakistan Development Review,* 33(4), str. 685–709. Dostupno na: https://www.jstor.org/stable/41259788

193. Halim, D., Perova, E., Reynolds, S. (2023). Childcare and Mothers' Labor Market Outcomes in Lower- and Middle-Income Countries. *The World Bank Research Observer*, 38(1), str. 73–114, doi: https://doi.org/10.1093/wbro/lkac003

194. Hank, K. (2001). Regional fertility differences in Western Germany: an overview of the literature and recent descriptive findings. *International Journal of Population Geography*, 7(4), str. 243–257, doi: https://doi.org/10.1002/ijpg.228

195. Hansen, C., Lønstrup, L. (2015). The rise in life expectancy and economic growth in the 20th century. *The Economic Journal*, 125(584), 838–852, doi: https://doi.org/10.1111/ecoj.12261

196. Hart, R.K., Galloway, T.A. (2023). Universal Transfers, Tax Breaks and Fertility: Evidence from a Regional Reform in Norway. *Popululation Research and Policy Review,* 42(49), str. 1–32, doi: https://doi.org/10.1007/s11113-023-09793-z

197. Heckman, J. J., Willis, R. J. (1976). Estimation of a stochastic model of reproduction: an econometric approach. NBER Chapters, in: *Household Production and Consumption*. *National Bureau of Economic Research*, str. 99–146. Dostupno na: https://www.nber.org/system/files/chapters/c3961/c3961.pdf

198. Hegewisch, A., Gornick, J. C. (2011). The impact of work-family policies on women's employment: a review of research from OECD countries. Community. *Work & Family,* 14(2), str. 119–138. doi: 10.1080/13668803.2011.571395

199. Hoem, B. (2000). Entry into motherhood in Sweden: the influence of economic factors on the rise and fall in fertility, 1986-1997. *Demographic Research,* 2, article 4, doi: 10.4054/DemRes.2000.2.4

200. Hoem, J. M. (2005). Why does Sweden have such high fertility? *Demographic Research*, 13(22), str. 559–572, doi: 10.4054/DemRes.2005.13.22

201. Hoem, J.M., Prskawetz, A., Neyer, G. (2001). Autonomy or conservative adjustment? The effect of public policies and educational attainment on third births in Austria, 1975-96. *Population Studies: A Journal of Demography,* 55(3), str. 249–261, doi: 10.1080/00324720127700

202. Hofferth, S. L., Curtin, S.C. (2003). The Impact of Parental Leave Statutes on Maternal Return to Work aftermChildbirth in the United States. OECD Social, Employment and Migration Working Papers, No. 7. Paris: OECD Publishing. Dostupno na: http://dx.doi.org/10.1787/826588878522

203. Hondroyiannis, G. (2010). Fertility Determinants and Economic Uncertainty: An Assessment Using European Panel Data. *Journal of Family and Economic Issues*, 31(1), str. 33–50. doi: 10.1007/s10834-009-9178-3

204. Horvat, J., Mijoč, J. (2019). *Istraživački SPaSS.* Zagreb: Naklada Ljevak d. o. o.

205. Hosmer, D.W.Jr., Lemeshow, S., Strudivant, R.X. (2013). *Applied Logistic Regression.* New Jersey: John Wiley & Sons, Inc.

206. Hosseini, M., Saikia, U., Dasvarma, G. (2021). The gap between desired and expected fertility among women in Iran: A case study of Tehran city. *PLOS One,* 16(9): e0257128, doi: https://doi.org/10.1371/journal.pone.0257128

207. Hotz, V., Klerman, J. A., & Willis, R. (1997). The economics of fertility in developed countries, u knjizi: Rosenzweig, M. & Stark, O.: *Handbook of Population and Family Economics*. Amsterdam

208. Hrvatski zavod za mirovinsko osiguranje. (2025). *Određivanje svote doplatka za djecu.* Dostupno na: https://www.mirovinsko.hr/hr/odredjivanje-svote-doplatka-za-djecu/270

209. Hrvatski zavod za mirovinsko osiguranje. (2025a). *Korisnici doplatka za djecu i djeca za koju pripada doplatak.* Dostupno na: https://www.mirovinsko.hr/hr/korisnici-doplatka-za-djecu-i-djeca-za-koju-pripada-doplatak/254

210. Hrvatski zavod za mirovinsko osiguranje. (2025b). *Dohodovni cenzus i svote doplatka za djecu za 2025.* Dostupno na: https://www.mirovinsko.hr/hr/dohodovni-cenzus-i-svote-doplatka-za-djecu-za-2025/272

211. Hu, M., Su, Y., Yu, X. (2022). Homeownership and fertility intentions among migrant population in urban China. *Housing Studies*, 39(5), str. 1176–1198, doi: https://doi.org/10.1080/02673037.2022.2108382

212. Jaccard, J., Davidson, A. R. (1975). A comparison of two models of social behavior: Results of a survey sample. S*ociometry*, 48, str. 497–517

213. Jackson, N. (2017). Introduction and overview. *Policy Quarterly*, 13, str. 3–9, doi: https://doi.org/10.26686/pq.v13i0.4554

214. Jemna, D.-V. (2015). Causality Relationship between Economic Development and Fertility in Romania on Regional Level. *Procedia Economics and Finance*, 20, str. 334–341, doi: 10.1016/s2212-5671(15)00081-7

215. Johnson-Hanks, J. A., Bachrach, C. A., Morgan, S. P., Kohler, H. P. (Eds.). (2011). *Understanding family change and variation: Toward a theory of conjunctural action*. New York: Springer, doi: 10.1007/978-94-007-1945-3

216. Jones, L. E., Schoonbroodt, A., Tertilt, M. (2010). Fertility Theories: Can They Explain the Negative Fertility-Income Relationship? *National Bureau of Economic Research.* Dostupno na: https://www.nber.org/system/files/chapters/c8406/revisions/c8406.rev0.pdf

217. Jones, L. E., Tertilt, M. (2006). An economic history of fertility in the U.S.: 1826 – 1960. Working Paper 12796. *National Bureau of Economic Research: Cambridge*

218. Jorgensen, S. R., Adams, R. P. (1988). Predicting Mexican-American family planning intentions: An application and test of a social psychological model. *Journal of Marriage and the Family*, 50, str. 107–119.

219. Kertzer, D.I. (2013). Understanding Family Change and Variation: Toward a Theory of Conjunctural Action. Population Studies: A Journal of Demography, 67(1), str. 129-131, doi: https://doi.org/10.1080/00324728.2013.765164

220. Kertzer, D.I., White, M.J., Bernardi, L., Gabrielli, G. (2009). Italy's Path to Very Low Fertility: The Adequacy of Economic and Second Demographic Transition Theories. *European Journal of Population*, 25(1), str. 89–115, doi: 10.1007/s10680-008-9159-5

221. Klesment, M., Puur, A. (2010). Effects of education on second births before and after societal transition: Evidence from the Estonian GGS. *Demographic Research*, 22(28), str. 891–932, doi: 10.4054/DemRes.2010.22.28

222. Kletečki Radović, M., Vejmelka, L. i Družić Ljubotina, O. (2017). Učinak siromaštva na dobrobit i kvalitetu života obitelji iz perspektive djece. *Ljetopis socijalnog rada,* 24(2), str. 199–242, doi: https://doi.org/10.3935/ljsr.v24i2.181.

223. Kline, R. (2011). Principles and Practice of Structural Equation Modeling, 3rd Edition. Guilford Press. New York.

224. Kline, R. B. (2011). *Principles and practice of structural equation modeling*. New York, London: The Guilford Press

225. Kneale, D., & Joshi, H. (2008). Postponement and childlessness: Evidence from two British cohorts. *Demographic Research*, 19(58), str. 1935–1968, doi: 10.4054/DemRes.2008.19.58

226. Kohler, H-P., Billari, F.C., Ortega, J.A. (2002). The Emergence of Lowest-Low Fertility in Europe During the 1990s. *Population and Development Review*, 28(4), str. 641–680. Dostupno na: https://www.jstor.org/stable/3092783

227. Kravdal, O. (1992). The emergence of a positive relation between education and third birth-rates in Norway with supportive evidence from the United States. *Population Studies*, 46(3), str. 459–475.

228. Kreyenfeld, M. (2002). Time squeeze, partner effect or self selection? An investigation in to the positive effect of women's education on second birth risks in West Germany. *Demographic Research*, 7(2), str. 15–48, doi: 10.4054/DemRes.2002.7.2

229. Kreyenfeld, M. (2010). Uncertainties in female employment careers and the postponement of parenthood in Germany, *European Sociological Review*, 26(3), str. 351–366, doi: 10.1093/esr/jcp026

230. Kreyenfeld, M., Andersson, G., Pailhé, A. (2012). Economic Uncertainty and Family Dynamics in Europe. *Demographic Research.* 27(4), str. 835–852, doi: 10.4054/DemRes.2012.27.28

231. Krishnan, V., Krotki, K. J. (1993). Life cycle effects on homeownership in Canada. *Housing Studies*, 8(2), str. 120–127.

232. Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association, 47(260),* str. 583–621, doi: https://doi.org/10.2307/2280779

233. Kulu, H. (2006). Fertility of internal migrants: comparison between Austria and Poland. *Population, Space and Place*, 12(3), str. 147–170, doi: 10.1002/psp.406

234. Kulu, H. (2013). Why Do Fertility Levels Vary between Urban and Rural Areas? *Regional Studies,* 47(6), str. 895–912, doi: 10.1080/00343404.2011.581276

235. Kulu, H., Vikat, A. (2007). Fertility differences by housing type: The effect of housing conditions or of selective moves? *Demographic Research*, 17, str. 775–802, doi: 10.4054/DemRes.2007.17.26

236. Kulu, H., Vikat, A., Andersson, G. (2007). Settlement size and fertility in the Nordic countries. *Population Studies,* 61(3), str. 265–285, doi: 10.1080/00324720701571749

237. Kulu, H., Washbrook, E. (2014). Residential context, migration and fertility in a modern urban society. *Advances in Life Course Research,* 21, str. 168–182, doi: 10.1016/j.alcr.2014.01.001

238. Kurkin, R., Sprocha, B., Sidlo, L., Kocourkova, J. (2018). Fertility factors in Czechia according to the results of the 2011 census. *AUC GEOGRAPHICA,* 53(2), str. 137–148, doi: https://doi.org/10.14712/23361980.2018.14

239. Lappegård, T. (2020). Future fertility trends are shaped at the intersection of gender and social stratification. *Vienna Yearbook of Population Research*, 18, str. 43–48. Dostupno na: https://www.jstor.org/stable/27041928

240. Laroque, G. (2004). Fertility and Financial Incentives in France. *CESifo Economic Studies,* 50(3), str. 423–450, doi: 10.1093/cesifo/50.3.423

241. Laroque, G., Salanié, B. (2008). Does Fertility Respond to Financial Incentives?. Discussion Paper Series, IZA Discussion Paper No. 3575. *IZA Institute of Labor Economics.* Dostupno na: https://docs.iza.org/dp3575.pdf

242. Laroque, G., Salanié, B. (2014). Identifying the Response of Fertility to Financial Incentives. *Journal of Applied Econometrics,* 29(2), str. 314–332, doi: 10.1002/jae.2332

243. Lefebvre, P., Merrigan, P., Verstraete, M. (2009). Dynamic labour supply effects of childcare subsidies: Evidence from a Canadian natural experiment on low-fee universal child care. *Labour Economics*, 16(5), str. 490–502, doi: 10.1016/j.labeco.2009.03.003

244. Lerch, M. (2019). Fertility Decline in Urban and Rural Areas of Developing Countries. *Population and Development Review*, *45*(2), str. 301–320.

245. Lesthaeghe R. (2010). The unfolding story of the Second Demographic Transition. *Popululation and development review*, 36(2), str. 211–251, doi: 10.2307/25699059

246. Lesthaeghe R. (2014). The second demographic transition: a concise overview of its development. *Proc. Natl. Acad. Sci. U.S.A.,* 111 (51), str. 18112–18115, doi: https://doi.org/10.1073/pnas.1420441111

247. Lesthaeghe, R. (1977). *The Decline of Belgian Fertility, 1800–1970.* Princeton: University Press

248. Lesthaeghe, R. (1991). The second demographic transition in Western countries– an interpretation. Interuniversity Programme in Demography, Vrije Universiteit Brussels. Dostupno na: https://brispo.research.vub.be/sites/default/files/2024-02/WP-IPD-1991-2.pdf

249. Lesthaeghe, R. (1995). *The second demographic transition in Western countries: an interpretation*, u knjizi: Mason, K.O., Jensen, A.M.: *Gender and Family Change in Industrialized Countries*. Oxford, UK: Clarendon Press, str. 17–62

250. Lesthaeghe, R. (1998). On theory development: Applications to the study of family formation. *Population and Development Review*, 24(1), str. 1–14. Dostupno na: https://www.researchgate.net/publication/257999661_On_Theory_Development_Applications_to_the_Study_of_Family_Formation_Authors_Ron_Lesthaeghe_Reviewed_works_Source_Population#fullTextFileContent

251. Lesthaeghe, R. (2020). The second demographic transition, 1986–2020: sub-replacement fertility and rising cohabitation—a global update. *Genus,* 76(10), doi: https://doi.org/10.1186/s41118-020-00077-4

252. Letablier, M.-T., Luci, A., Math, A., Thévenon, O. (2009). *The costs of raising children and the effectiveness of policies to support parenthood in European countries: a Literature Review. A report to the European Commission*

253. Lewis, J., Giullari, S. (2005). The adult worker model family, gender equality and care: the search for new policy principles and the possibilities and problems of a capabilities approach. *Economy and Society,* 34(1), str. 76–104, doi: 10.1080/0308514042000329342

254. Li, M., Xu, X. (2022). Fertility Intentions for a Second Child and Their Influencing Factors in Contemporary China. *Front. Psychol.* 13:883317, str. 1–12, doi: 10.3389/fpsyg.2022.883317

255. Lim, S. (2021). Socioeconomic differentials in fertility in South Korea. *Demographic Research,* 44, str. 941–978, doi: 10.4054/DemRes.2021.44.39

256. Loomen. (2021). Dobno - spolna piramida. Dostupno na: https://arhiva-2021.loomen.carnet.hr/mod/page/view.php?id=744185

257. Luci-Greulich, A., Thévenon, O. (2013). The Impact of Family Policies on Fertility Trends in Developed Countries. *European Journal of Population* 29, 387–416, doi: https://doi.org/10.1007/s10680-013-9295-4

258. Lutfiah, U., Besral, B., Herdayati, M. (2017). Individual and regional factors that affect fertility rates in five provinces of Indonesia. *Makara Journal of Health Research,* 21(1), str. 6–12, doi: 10.7454/msk.v21i1.6067

259. Madsen, K. (2004). The Danish model of 'flexicurity': experiences and lessons. *Transfer: European Review of Labour and Research*, 10(2), str. 187–207, doi: https://doi.org/10.1177/102425890401000205

260. Mann, H. B., & Whitney, D. R. (1947). On a Test of Whether One of Two Random Variables Is Stochastically Larger Than the Other. *The Annals of Mathematical Statistics*, 18(1), str. 50–60, doi: https://doi.org/10.1214/aoms/1177730491

261. Manski, C. F. (1990). The Use of Intentions Data to Predict Behavior: A Best-Case Analysis. *Journal of the American Statistical Association,* 85(412), str. 934–940. doi: 10.2307/2289590

262. Mansour, F. (2018). Economic Insecurity and Fertility: Does Income Volatility Impact the Decision to Remain a One-Child Family? *Journal of Family and Economic Issues,* 39(2), str. 243–257, doi: 10.1007/s10834-017-9559-y

263. Marini, M.M., Hodsdon, P.J. (1981). Effects of the Timing of Marriage and First Birth on the Spacing of Subsequent Births. *Demography*, 18(4), str. 529–548, doi: https://doi.org/10.2307/2060946

264. Martine, G. (1996). Brazil's fertility decline. 1965-95: a fresh look at key factors. *Population and Development Review,* 22(1), str. 47–75, doi: https://doi.org/10.2307/2137686

265. McDonald P. (2009). *Explanations of low fertility in East Asia: A comparative perspective.* Ultra-Low Fertility in Pacific Asia: Trends, Causes, and Policy Issues, ed. G Jones, PT Straughan, A Chan, str. 23–39. Oxford, UK: Routledge, doi: https://doi.org/10.4324/9780203890066

266. McDonald, P. (1996). Demographic life transitions: an alternative theoretical paradigm. *Health Transition Review*, *6*, str. 385–392. Dostupno na: https://openresearch-repository.anu.edu.au/bitstream/1885/41518/2/Mcdonal1.pdf

267. McDonald, P. (2000). Gender Equity in Theories of Fertility Transition. *Population and Development Review*, 26(3), str. 427–439. Dostupno na: https://www.jstor.org/stable/172314

268. McDonald, P. (2000). The "toolbox" of public policies to impact on fertility – a global view. Paper presented at the seminar "Low fertility, families and public policies", organised by the European Observatory on Family Matters in Sevilla, September 15-16, 2000. str. 1–26. Dostupno na: https://bit.ly/41yEJm1

269. McDonald, P. (2002). Sustaining Fertility through Public Policy: The Range of Options. *Population*, 57(3), str. 417–446, doi: 10.2307/3246634

270. McDonald, P. (2006). An Assessment of Policies that Support Having Children from the Perspectives of Equity, Efficiency and Efficacy. *Vienna Yearbook of Population Research*, 4, str. 213–234. Doi: 10.1553/populationyearbook2006s213

271. McLanahan S. (2004). Diverging destinies: how children are faring under the second demographic transition. *Demography*, 41(4), str. 607–627. Dostupno na: https://www.jstor.org/stable/1515222

272. Mejovšek, M. (2003). *Uvod u metode znanstvenog istraživanja u društvenim i humanističkim znanostima*. Zagreb: Naklada Slap

273. Mencarini, L., Vignoli, D., & Gottard, A. (2015). Fertility intentions and outcomes: Implementing the Theory of Planned Behaviour with graphical models. *Advances in Life Course Research*, 23, str. 14–28, doi: https://doi.org/10.1016/j.alcr.2014.12.004

274. Michielin, F. (2004). Lowest low fertility in an urban context: the role of migration in Turin, Italy. *Population, Space and Place*, 10(4), str. 331–347, doi: 10.1002/psp.337

275. Micklin, M. (1969). Urban life and differential fertility: specification of an aspect of the theory of the demographic transition. *Sociological Quarterly*, 10(4), str. 480–500, doi: https://doi.org/10.1111/j.1533-8525.1969.tb01309.x

276. Milinković, D. (1996). Populacijska politika. *Ljetopis socijalnog rada*, 3(1), str. 99–109. Dostupno na: https://hrcak.srce.hr/198153

277. Milligan, K. (2002). *Subsidizing the Stork: New Evidence on Tax Incentives and Fertility.* NBER Working Paper 8845. Dostupno na: https://www.nber.org/system/files/working_papers/w8845/w8845.pdf

278. Milligan, K. (2005). Subsidizing the Stork: New Evidence on Tax Incentives and Fertility. *Review of Economics and Statistics*, 87(3), str. 539–555, doi: 10.1162/0034653054638382

279. Mills, M., & Blossfeld, H.-P. (2005). *Globalization, uncertainty and the early life course*, u knjizi: Blossfeld, H.-P., Klijzing, E., Mills, M. & Kurz, K.: *Globalization, uncertainty, and youth in society*. London & New York: Routledge.

280. Mills, M., Blossfeld, H.-P. (2003). Globalization, uncertainty and the early life course. *Zeitschrift Für Erziehungswissenschaft,* 6(2), str. 188–218, doi:10.1007/s11618-003-0023-4

281. Ministarstvo demografije i useljeništva. (2025). *Demografske mjere na lokalnoj i županijskoj razini.* Dostupno na: https://mdu.gov.hr/demografija/demografske-mjere-na-lokalnoj-i-zupanijskoj-razini-5671/5671

282. Ministarstvo financija, Porezna uprava. (2023). *Tablica koeficijenata i iznosa osnovnog osobnog odbitka i uvećanja osnovnog osobnog odbitka za 2024. i 2025.g*. Dostupno na: https://www.porezna-uprava.hr/pozivni_centar/Stranice/tablica-osobnog-odbitka.aspx

283. Ministarstvo financija, Porezna uprava. (2025). *Osobni odbitak.* Dostupno na: https://www.porezna-uprava.hr/baza_znanja/Stranice/OsobniOdbitak.aspx

284. Ministarstvo prostornog uređenja, graditeljstva i državne imovine. (2024). *Gradnja POS-ovih zgrada u Sisku bliži se kraju.* Dostupno na: https://mpgi.gov.hr/vijesti-8/gradnja-pos-ovih-zgrada-u-sisku-blizi-se-kraju/17732

285. Ministry of Family, Labour and Social Policy Republic of Poland. (2021). *Family Care Capital. Parents will have a choice*. Dostupno na: https://www.gov.pl/web/family/family-care-capital-parents-will-have-a-choice

286. Mira, P., Ahn, N. (2002). A note on the changing relationship between fertility and female employment rates in developed countries. *Journal of Population Economics, Springer; European Society for Population Economics*, vol. 15(4), str. 667–682, doi: https://doi.org/10.1007/s001480100078

287. MISSOC. (2024). *Comparative tables*. Dostupno na: https://www.missoc.org/missoc-database/comparative-tables/

288. Modena, F., & Sabatini, F. (2012). I Would if I Could: Precarious employment and childbearing intentions in Italy. *Review of Economics of the Household, Springer*, 10(1), str. 77-97, doi: 10.1007/s11150-010-9117-y

289. Modena, F., Rondinelli, C., Sabatini, F. (2014). Economic Insecurity and Fertility Intentions: The Case of Italy. *Review of Income and Wealth,* 60(1), str. 233–255, doi: 10.1111/roiw.12044

290. Monnier, A. (1990). The Effects of Family Policies in the German Democratic Republic: A Re-Evaluation. *Population: An English Selection*, 2, str. 127–140. Dostupno na: http://www.jstor.org/stable/2949093

291. Morgan, S.P. (2001). *Should fertility intentions inform fertility forecasts? Proceedings of US Census Bureau Conference: The direction of fertility in the United States.* Washington: DC7 US Census Bureau

292. Morgan, S.P. (2003). Is Low Fertility a Twenty-First-Century Demographic Crisis? *Demography*, 40(4), str. 589–604, doi: 10.2307/1515198

293. Morrissey, T.W. (2017). Childcare and parent labor force participation: A review of the research literature. *Review of Economics of the Household*, 15(1), str. 1–24, doi: 10.1007/s11150-016-9331-3

294. Mulder, C. H., & Smits, J. (1999). First time homeownership of couples: The effect of inter gen er a tional transmission. *European Sociological Review*, 15(3), str. 323–337.

295. Mulder, C. H., Wagner, M. (1993). Migration and marriage in the life course: A method for studying synchronized events. *European Journal of Population/Revue Européenne de Démographie*, 9, str. 55–76, doi: 10.1007/BF01267901

296. Mulder, C. H., Wagner, M. (2001). The connections between family formation and first time homeownership in the context of West Germany and the Netherlands. *European Journal of Population*, 17(2), str. 137–164, doi: 10.1023/A:1010706308868

297. Muranganwa, R. (2016). *Design and implementation of a multi-agent opportunistic grid computing platform.* Doctoral dissertation. University of Fort Hare. Dostupno na: https://core.ac.uk/download/pdf/327278279.pdf

298. Myck, M., Kurowska, A., Kundera, M. (2013). Financial support for families with children and its trade-offs: balancing redistribution and parental work incentives. *Baltic Journal of Economics,* 13(2), str. 61–85, doi: 10.1080/1406099x.2013.10840533

299. Myrskylä, M., Kohler, H.-P., Billari, F. C. (2009). Advances in development reverse fertility declines. *Nature,* 460(7256), str. 741–743*,* doi: 10.1038/nature08230

300. Nargund, G. (2009). Declining birth rate in Developed Countries: A radical policy re-think is required. *Facts Views and Vision in ObGyn*, 1(3), str. 191-193. PMID: 25489464; PMCID: PMC4255510

301. Narode novine (NN 156/23). (2023). *Zakon o inkluzivnom dodatku*. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2023_12_156_2383.html

302. Narodne novine (NN 114/23 (2023). *Zakon o Porezu na dohodak.* Dostupno na: https://www.zakon.hr/z/85/Zakon-o-porezu-na-dohodak

303. Narodne novine (NN 13/2021). (2021). *Nacionalna razvojna strategija Republike Hrvatske do 2030. godine*. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2021_02_13_230.html

304. Narodne novine (NN 152/22). (2022). *Zakon o rodiljnim i roditeljskim potporama.* Dostupno na: https://www.zakon.hr/z/214/zakon-o-rodiljnim-i-roditeljskim-potporama

305. Narodne novine (NN 152/24). (2024). *Zakon o porezu na dohodak.* Dostupno na: https://www.zakon.hr/z/85/zakon-o-porezu-na-dohodak

306. Narodne novine (NN 3/2024). (2024). *Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti*. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2024_01_3_60.html

307. Narodne novine (NN 34/2025*)*. (2025). *Zakon o rodiljnim i roditeljskim potporama.* Dostupno na: https://www.zakon.hr/z/214/zakon-o-rodiljnim-i-roditeljskim-potporama

308. Narodne Novine (NN 36/2024). (2024). *Strategija demografske revitalizacije Republike Hrvatske do 2033. godine*. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2024_03_36_580.html

309. Narodne novine (NN 58/18). (2018). *Zakon o doplatku za djecu*. Dostupno na: https://www.zakon.hr/z/475/Zakon-o-doplatku-za-djecu

310. Narodne novine (NN 85/2010). (2010). *Ustav Republike Hrvatske*. Pročišćeni tekst. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2010_07_85_2422.html

311. Narodne novine (NN 94/01, 138/06, 107/07, 37/08, 61/11, 112/12, 82/15, 58/18, 156/23. (2023). *Zakon o doplatku za djecu*. Dostupno na: https://www.zakon.hr/z/475/zakon-o-doplatku-za-djecu

312. Narodne novine. (NN 18/22, 46/22, 119/22, 71/23, 156/23). (2023). *Zakon o socijalnoj skrbi*. Dostupno na: https://www.zakon.hr/z/222/zakon-o-socijalnoj-skrbi

313. Nasrpour Parvin, R. (2016). Investigating the effects of economic factors affecting the fertility rate in iran during the years 1365–1390 with the panel data approach. *Journal of Fundamental and Applied Sciences*, 8(3), str. 825-832, doi: 10.4314/jfas.v8i3s.264

314. NCSS (n.d.). Chapter 321 Logistic Regression. Dostupno na: https://www.ncss.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Logistic_Regression.pdf

315. Nickayin, S.S., Nosova, B., Turco, R., Giacalone, M., Salvati, L. (2022). Demographic Change and the Urban–Rural Divide: Understanding the Role of Density and Agglomeration in Fertility Transitions. *Land*, 11(11), str. 1–16, doi: https://doi.org/10.3390/land11111988

316. Nojković, A. (2019). *Ekonometrijski modeli uporednih podataka i panela. Modeli binarnog izbora.* Dostupno na: http://ekonometrija.ekof.bg.ac.rs/master/2018/EMUPP%20Modeli_binarnog_izbora_2018.pdf

317. Norling, J. (2021). Using intentions to predict fertility. *Journal of Demographic Economics*, 88(3), str. 1–26, doi: 10.1017/dem.2020.32

318. Notestein, F.W. (1945). *Population – The long view*. In W Schultz (ed.), *Food for the World*, str. 36–57. Chicago: University of Chicago Press

319. Notestein, F.W. (1953). Economic problems of population change. In *Proceedings of the Eighth International Conference of Agricultural Economists*, str. 13–31. London: Oxford University Press

320. Notestein, F. W. (1952). *Economic Problems of Population Change*. Ujedinjeno Kraljevstvo: Oxford University Press

321. Novelli, M., Cazzola, A., Pasquini, L. (2021). Fertility Intentions in Times of Rising Economic Uncertainty: Evidence from Italy from a Gender Perspective. *Social Indicators Research*, 154, str. 257–284, doi: https://doi.org/10.1007/s11205-020-02554-x

322. Nunnally, J. C. (1978). *Psychometric theory* (Rev. ed.). New York: McGraw-Hill.

323. Nygård, M., Lindberg, M., Nyqvist, F., Härtull, C. (2019). The Role of Cash Benefit and In-Kind Benefit Spending for Child Poverty in Times of Austerity: An Analysis of 22 European Countries 2006 – 2015. *Social Indicators Research,* 146(3), str. 533–552, doi: 10.1007/s11205-019-02126-8

324. Obadić, A., Tica, J., (2016). *Gospodarstvo Hrvatske*. Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu

325. Olivetti, C., Petrongolo, B. (2017). The Economic Consequences of Family Policies: Lessons from a Century of Legislation in High-Income Countries. *Journal of Economic Perspectives,* 31(1), str. 205–230, doi: 10.1257/jep.31.1.205

326. Origo, F., Pagani, L. (2009). Flexicurity and Job Satisfaction in Europe: The Importance of Perceived and Actual Job Stability for Well-Being at Work. *Labour Economics*, 16(5), str. 547–55, doi: https://doi.org/10.1016/j.labeco.2009.02.003

327. Oshio, T. (2019). Is a positive association between female employment and fertility still spurious in developed countries? *Demographic research*, *Max Planck*

Institute for Demographic Research, Rostock, Germany, 41(45), str. 1277–1288, doi: 10.4054/DemRes.2019.41.45

328. Ostertagova, E., Ostertag, O., & Kováč, J. (2014). Methodology and application of the Kruskal-Wallis test. *Applied Mechanics and Materials*, 611(2014), str. 115–120, doi: 10.4028/www.scientific.net/AMM.611.115

329. Pallant, J. (2020). *SPSS Survival Manual, 7th Edition*. London: Routledge, doi: https://doi.org/10.4324/9781003117452

330. Panopoulou, G., Tsakloglou, P. (1999). Fertility and economic development: theoretical considerations and cross-country evidence. *Applied Economics*, 31(11), str. 1337–1351, doi: 10.1080/000368499323229

331. Peduzzi P., Concato, J., Kemper, E., Holford, T.R., Feinstein, A.R. (1996). A simulation study of the number of events per variable in logistic regression analysis. *Journal of Clinical Epidemiology,* 49(2), str. 1373–1379, doi: 10.1016/S0895-4356(96)00236-3

332. Peng, R., Mou, W., Xu, P. (2023). Factors Associated with Fertility Intention among Chinese Married Youth during the COVID-19 Pandemic. *Behavioral Sciences*, 13(2),184, str. 1–15, doi: https://doi.org/10.3390/bs13020184

333. Pezer, M. (2020). *Utjecaj obiteljskih politika u Republici Hrvatskoj i odabranim europskim zemljama na blagostanje obitelji s djecom.* Doktorska disertacija. Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet u Zagrebu

334. Pezer, M., Mustać, N., Leventi, C. (2023). The distributional impact of social spending on in-kind and cash child transfers in Croatia. *South East European Journal of Economics and Business*, 18(1), str. 161–175, doi: 10.2478/jeb-2023-0011

335. Philipov, D. (2009). Fertility Intentions and Outcomes: The Role of Policies to Close the Gap. *European Journal of Population / Revue Européenne de Démographie,* 25(4), str. 355–361, doi: 10.1007/s10680-009-9202-1

336. Philipov, D., Liefbroer, A. C., & Klobas, J. E. (2015). *Reproductive decision-making in a macro-micro perspective*. Dordrecht: Springer.

337. Pieroni, L., d'Agostino, G., Lanari, D., Scarlato, M. (2023). Temporary employment and fertility in Italy: The effect of two labor market reforms in the early 2000s. *Economic Modelling*, 124, doi: https://doi.org/10.1016/j.econmod.2023.106298

338. Pinnelli, A., Di Cesare, M. (2005). Human fertility: sociodemographic aspects. *Contraception*, 72(4), str. 303–307, doi: 10.1016/j.contraception.2005.01.008

339. Prioux, F. (2004). Recent Demographic Developments in France. *Population*, 59(5), str. 595–633

340. Prioux, F., Mandelbaum, J. (2007). Recent Demographic Developments in France: Fertility at a More Than 30-Year High. *Population*, 62(3), str. 417–456. Dostupno na: https://www.jstor.org/stable/27645316

341. Pritchett, L.H. (1994). Desired Fertility and the Impact of Population Policies. *Population and Development Review,* 20(1), str. 1, doi: 10.2307/2137629

342. Proleksis enciklopedija (2012). *Starosna piramida*. Dostupno na: https://proleksis.lzmk.hr/46748/

343. Pučka pravobraniteljica. (2024). *Izvješće pučke pravobraniteljice: Analiza stanja ljudskih prava i jednakosti u Hrvatskoj za 2023. godinu. Zagreb*. Dostupno na: https://www.ombudsman.hr/hr/download/izvjesce_pucke_pravobraniteljice_za_2023_godinu/?wpdmdl=18399&refresh=660f9329d147a1712296745

344. Puljiz, V. (1999). Profili obiteljske politike. *Revija za socijalnu politiku*, 6(1), str. 21–33, doi: https://doi.org/10.3935/rsp.v6i1.313

345. Raithatha, Y. (2017). *Understanding the economic impact terrorism has on the destination decision making: Northern Irish tourists.* Doctoral dissertation. Dublin Business School. Dostupno na: https://esource.dbs.ie/bitstream/handle/10788/3340/mba_raithatha_y_2017.pdf?sequence=1&isAllowed=y

346. Ramdhani, A., Mnyamana, X., Karodia, A. M. (2017). Investigating the Impact of Service Delivery on Consumer Satisfaction: A Case Study of Ford-Gauteng Province (Republic of South Africa). *Singaporean Journal of Business, Economics and Management Studies*, *5*(8), str. 1–30, doi: 10.12816/0037546

347. Raute, A. (2019). Can financial incentives reduce the baby gap? Evidence from a reform in maternity leave benefits. *Journal of Public Economics,* 169, str. 203–222, doi: 10.1016/j.jpubeco.2018.07.010

348. Reher, D.S. (2011). Economic and Social Implications of the Demographic Transition. *Population and Development Review,* 37, str. 11–33. Dostupno na: https://www.jstor.org/stable/41762397

349. Rica, S.D.L., Iza, A. (2005). Career Planning in Spain: Do Fixed-term Contracts Delay Marriage and Parenthood? *Review of Economics of the Household,* 3(1), str. 49–73, doi: 10.1007/s11150-004-0979-8

350. Ricci, R. (1997). Povertà abitativa in Italia, 1989-1993 [Housing poverty in Italy, 1989–1993] (Report). Rome, Italy: Presidency of the Council of Ministers, Department of Information and Publishing. Dostupno na: https://www.lavoro.gov.it/sites/default/files/archivio-doc-pregressi/Documents/Resources/Lavoro/CIES/Poverta_abitativa_1997.pdf

351. Riederer, B., Buber-Ennser, I. (2019). Regional context and realization of fertility intentions: the role of the urban context. *Regional Studies*, 53(12), str. 1669–1679, doi: 10.1080/00343404.2019.1599843

352. Riemer, R., Whelpton, P.K. (1955). Social and psychological factors affecting fertility. XXVII. Attitudes toward restriction of personal freedom in relation to fertility planning and fertility. *The Milbank Memorial Fund Quarterly*, 33(1), str. 63–111, doi: https://doi.org/10.2307/3348522

353. Rindfuss, R. R., Bumpass, L., & John, C. S. (1980). Education and fertility: Implications for the roles women occupy. *American Sociological Review*, 45(3), str. 431–447.

354. Rindfuss, R.R., Guzzo, K.B., Morgan, S.P. (2003). The Changing Institutional Context of Low Fertility. *Population Research and Policy Review*, 22(5/6), str. 411–438. Dostupno na: https://www.jstor.org/stable/40230835

355. Riphahn, R.T., Wiynck, F. (2017). Fertility effects of child benefits. *Journal of Population Economics,* 30(4), str. 1135–1184*,* doi: 10.1007/s00148-017-0647-y

356. Rondinelli, C., Aassve, A., Billari, F. C. (2010). Women's wages and childbearing decisions: Evidence from Italy. *Demographic Research*, 22(19), str. 549–578, doi: 10.4054/DemRes.2010.22.19

357. Rondinelli, C., Zizza, R. (2010). (Non)Persistent Effects of Fertility on Female Labour Supply," Banca D'Italia, Temi di discussione (Economics Working Paper), No. 783. Dostupno na: https://www.bancaditalia.it/pubblicazioni/temi-discussione/2010/2010-0783/en_tema_783.pdf?language_id=1

358. Rosen, H.S., Gayer, T. (2009). *Public Finance*. 9th Edition. McGraw-Hill Companies, Inc

359. Ruhm, C.J. (1998). The Economic Consequences of Parental Leave Mandates: Lessons from Europe. *The Quarterly Journal of Economics*, 113(1), str. 285–317, doi: 10.1162/003355398555586

360. Santarelli, E. (2011). Economic resources and the first child in Italy: A focus on income and job stability. *Demographic Research, Max Planck Institute for*

Demographic Research, Rostock, Germany, 25(9), str. 311–336, doi: 10.4054/DemRes.2011.25.9

361. Saunders, M.N.K., Lewis, P., Thornhill, A. (2019). *Research Methods for Business Student, 8th edition*. London, United Kingdom: Pearson

362. Savezni zavod za statistiku. (1994). *Popis stanovništva, domaćinstava i stanova u 1971. godini: Nacionalni sastav stanovništva SFR Jugoslavije.* Dostupno na: https://publikacije.stat.gov.rs/G1971/Pdf/G19714001.pdf

363. Scherer, S. (2009). The Social Consequences of Insecure Jobs. *Social Indicator Research,* 93(3), str. 527–547, doi: 10.1007/s11205-008-9431-4

364. Schneider, D. (2015). The Great Recession, Fertility, and Uncertainty: Evidence From the United States. *Journal of Marriage and Family,* 77(5), str. 1144–1156, doi: 10.1111/jomf.12212

365. Schoen, R., Astone, N. M., Kim, Y. J., Nathanson, C. A., i Fields, J. M. (1999). Do Fertility Intentions Affect Fertility Behavior? *Journal of Marriage and the Family,* 61(3), str. 790–799*,* doi: 10.2307/353578

366. Schreiber-Gregory, D., Bader, K. (2018). Logistic and Linear Regression Assumptions: Violation Recognition and Control. *SESUG.* Dostupno na: https://bit.ly/3FuHwVI

367. Schultz, P. (1973). Economic factors economic factors affecting population growth: a preliminary survey of economic analyses of fertility. *The American Economic Review,* 63(2), str. 71–78. Dostupno na: https://www.jstor.org/stable/1817054

368. Scotland, J. (2012). Exploring the Philosophical Underpinnings of Research: Relating Ontology and Epistemology to the Methodology and Methods of the Scientific, Interpretive, and Critical Research Paradigms. *English Language Teaching*, 5(9), str. 9–16, doi: 10.5539/elt.v5n9p9

369. Sekaran, U., Bougie, R. (2016). *Research Methods for Business: A Skill-Building Approach, 7th edition.* John Wiley & Sons Ltd.

370. Sewell, W. H. (1992). A Theory of Structure: Duality, Agency, and Transformation. American Journal of Sociology, 98(1), str. 1–29.

371. Simon, C.J., Tamura, R. (2009). Do higher rents discourage fertility? Evidence from U.S. Cities, 1940-2000. *Regional Science and Urban Economics*, Elsevier, 39(1), str. 33-42, doi: https://doi.org/10.1016/j.regsciurbeco.2008.08.002

372. Sleebos, J. (2003). Low fertility rates in OECD countries: facts and policy responses. OECD social, employment and migration working papers no. 15. Dostupno

na: https://www.oecd.org/content/dam/oecd/en/publications/reports/2003/10/low-fertility-rates-in-oecd-countries_g17a1501/568477207883.pdf

373. Sleebos, J. (2003). Low fertility rates in OECD countries: facts and policy responses. OECD Labour Market and Social Policy Occasional Papers, No. 15. Paris: OECD Publishing, str. 1-62, doi: https://doi.org/10.1787/568477207883

374. Slesnick, D. T. (1996). Consumption and poverty: How effective are in-kind transfers? *Economic Journal*, 106(439), str. 1527–1545, doi: https://doi.org/10.2307/2235199

375. Sobotka, T. (2008). Overview chapter 6: the diverse faces of the second demographic transition in Europe. *Demographic Res*earch, 19(8), str. 171–224, doi: 10.4054/DemRes.2008.19.8

376. Sobotka, T. (2011). Reproductive decision-making in a macro-micro perspective (REPRO). Synthesis and policy implications. *European Demographic Research Papers 1*. Vienna: Vienna Institute of Demography of the Austrian Academy of Sciences. Dostupno na: https://www.oeaw.ac.at/fileadmin/subsites/Institute/VID/PDF/Publications/EDRP/edrp_2011_01.pdf

377. Sobotka, T., Skirbekk, V., Philipov, D. (2011). Economic recession and fertility in the developed world. *Population and Development Review*, 37(2), str. 267–306, doi: 10.1111/j.1728-4457.2011.00411.x

378. Spector, P. E., & Brannick, M. T. (2011). Methodological Urban Legends: The Misuse of Statistical Control Variables. *Organizational Research Methods*, 14(2), str. 287–305, doi: 10.1177/1094428110369842

379. Spéder, Z., Kapitány, B. (2009). How are time-dependent childbearing intentions realized? Realization, postponement, abandonment, bringing forward. *European Journal of Population / Revue européenne de Démographie*, 25(4), str. 503–523, doi: https://doi.org/10.1007/s10680-009-9189-7

380. Spéder, Z., Murinkó, L., Oláh, L. S. (2019). Cash support vs. tax incentives: The differential impact of policy interventions on third births in contemporary Hungary. *Population Studies: A Journal of Demography*, 74(1), str. 39–54, doi: 10.1080/00324728.2019.1694165

381. Središnji državni ured za demografiju i mlade Republike Hrvatske. (2024). *Strategija demografske revitalizacije Republike Hrvatske do 2033. godine.* Dostupno na:

https://mdu.gov.hr/UserDocsImages/Direktorij%202/Slike%20od%2013.2024/Dokumenti/Strategija%20demografske%20revitalizacije%20Republike%20Hrvatske%20do%202033.%20godine.pdf

382. Središnji državni ured za demografiju i mlade. (2023). *Nacionalni program za mlade za razdoblje 2023. do 2025.* Zagreb: Središnji državni ured za demografiju i mlade. Dostupno na: https://mdu.gov.hr/UserDocsImages/Direktorij%202/Slike%20od%20111.23/Dokumenti%20od%20111.23/Nacionalni%20program%20za%20mlade%202023-2025%20A4%20HR%20web..pdf

383. Središnji državni ured za demografiju i mlade. (2023a). *Demografske mjere jedinica lokalne i područne (regionalne) samouprave u 2023. godini: Analiza stanja*. Zagreb: Središnji državni ured za demografiju i mlade.

384. Stiglitz, J.E., Sen, A., Fitoussi, J.P. (2009). *Report by the Commission on the Measurement of Economic Performance and Social Progress.* Dostupno na: https://ec.europa.eu/eurostat/documents/8131721/8131772/Stiglitz-Sen-Fitoussi-Commission-report.pdf

385. Stock, J. H, Watson, M. W. (2006). *Introduction to Econometrics, 2nd Edition*. Boston: Pearson

386. Stokes, C. (1995). Explaining the demographic transition: institutional factors in fertility decline1. *Rural Sociology*, 60(1), str. 1–22, doi: https://doi.org/10.1111/j.1549-0831.1995.tb00560.x

387. Ström, S. (2010) Housing and first births in Sweden, 1972–2005. *Housing Studies*, 25(4), str. 509-526, doi: 10.1080/02673031003711519

388. Stropnik, N. (1995). Ciljevi, mjere i posljedice populacijske i obiteljske politike. *Revija za socijalnu politiku*, 2(3), str. 215–222, doi: https://doi.org/10.3935/rsp.v2i3.516

389. Šućur, Z., Kletečki Radović, M., Ljubotina, O.D., Babić, (2015). *Siromaštvo*. Zagreb: Ured UNICEF-a za Hrvatsku. Dostupno na: https://www.unicef.hr/wp-content/uploads/2015/09/Publikacija_Siromastvo_Unicef_2015_online.pdf

390. Svjetska banka. (2019). *Obiteljske politike: Analitička podloga za Nacionalnu razvojnu strategiju Republike Hrvatske do 2030*. Dostupno na: https://thedocs.worldbank.org/en/doc/266921604613782895-0080022020/original/5Obiteljskepolitike.pdf

391. Symeonidou, H. (2000). Expected and Actual Family Size in Greece: 1983–1997. *European Journal of Population*, 16, str. 335–352, doi: https://doi.org/10.1023/A:1006441411252

392. Testa, M. R. (2006). Eurobarometer - *Childbearing Preferences and Family Issues in Europe*. Special Eurobarometer 253 / Wave 65.1 – TNS Opinion & Socia

393. Thévenon, O. (2009). *Assessing the Costs of Children: A Challenge for Policy*. U Letablier, M.-T., Luci, A., Math, A., Thévenon, O.: *The Costs of Raising Children and the Effectiveness of Policies to Support Parenthood in European Countries: A Literature Review*. European Commission, str. 17–37.

394. Thévenon, O., & Solaz, A. (2013). Labour market effects of parental leave policies in OECD countries. *OECD Social, Employment and Migration Working Papers*, (141), str. 1–67, doi: https://doi.org/10.1787/5k8xb6hw1wjf-en

395. Thévenon, O., Gauthier, A. H. (2011). Family policies in developed countries: a 'fertility-booster' with side-effects. *Community, Work & Family*, 14(2), str. 197–216, doi: 10.1080/13668803.2011.571400

396. Thygesen, L. C., Knudsen, L. B., Keiding, N. (2005). Modelling regional variation of first-time births in Denmark 1980-1994 by an age-period-cohort model. *Demographic Research*, 13(23), str. 573–596, doi: 10.4054/DemRes.2005.13.23

397. Tocchioni, V., Berrington, A., Vignoli, D., Vitali, A. (2021). The Changing Association Between Homeownership and the Transition to Parenthood. *Demography*, 58(5), str. 1843–1865, doi: https://doi.org/10.1215/00703370-9420322

398. Tromans, N., Natamba, E., Jefferies, J. (2009). Have women born outside the UK driven the rise in UK births since 2001?. Population Trends, 136, str. 28–42, doi: 10.1057/pt.2009.17

399. Tropf, F.C., Mandemakers, J.J. (2017). Is the association between education and fertility postponement causal? The role of family background factors. *Demography,* 54(1), str. 71–91, doi: 10.1007/s13524-016-0531-5

400. Ujedinjeni narodi. (2008). Department of Economic and Social Affairs. *World Economic and Social Survey 2008: Overcoming Economic Insecurity*. Dostupno na: https://www.un.org/en/development/desa/publications/world-economic-and-social-survey-2008-overcoming-economic-insecurity.htm

401. Ujedinjeni narodi. (2024). *World Population Prospects 2024, Online Edition.* Dostupno na:

https://population.un.org/wpp/downloads?folder=Standard%20Projections&group=Fertility

402. UNFPA - United Nations Population Fund (2025). *The Real Fertility Crisis: The pursuit of reproductive agency in a changing world*. New York: UNFPA. Dostupno na: https://www.unfpa.org/sites/default/files/pub-pdf/swp25-layout-en-v250609-web.pdf

403. UNICEF - United Nations Children's Fund (n.d.). *Redesigning the Workplace to be Family-Friendly: What governments and businesses can do*. Dostupno na: https://www.unicef.org/early-childhood-development/family-friendly-policies

404. UNICEF. (2021). *Provedba dubinske analize politika, programa, usluga, izvora financiranja te mehanizama usmjerenih suzbijanju siromaštva i socijalne isključenosti djece u Hrvatskoj*. Zagreb. Dostupno na: https://www.unicef.org/croatia/media/9946/file

405. United Nations Economic Commission for Europe. (1992). *Fertility and Family surveys.* Dostupno na: https://unece.org/DAM/pau/_docs/ffs/FFS_2000_Prog_QuestModel.pdf

406. van de Kaa D.J. (2002). The idea of a second demographic transition in industrialized countries. Paper presented at the Sixth Welfare Policy Seminar of the National Institute of Population and Social Security, Tokyo, Japan, 29 January 2002. Dostupno na: https://wp.aleteia.org/wp-content/uploads/sites/2/2013/08/kaa.pdf

407. van de Kaa, D. J. (1987). Europe's second demographic transition. *Population Bulletin*, 42(1), str. 1–59.

408. van de Kaa, D.J. (2001). Postmodern fertility preferences: from changing value orientation to new behavior. *Popululation and development review*, 27, str. 290–331.

409. van Wijk, D.C., de Valk, H.A.G., Liefbroer, A.C. (2021). Temporary employment and family formation: An income or insecurity effect? *European Sociological Review, 37*(4), str. 641–658, doi: https://doi.org/10.1093/esr/jcab007

410. Vignoli, D., Drefahl, S., De Santis, G. (2012). Whose job instability affects the likelihood of becoming a parent in Italy? A tale of two partners. *Demographic Research*, 26(2), str. 41–62, doi: 10.4054/DemRes.2012.26.2

411. Vignoli, D., Rinesi, F., Mussino, E. (2012). A Home to Plan the First Child? Fertility Intentions and Housing Conditions in Italy. *Population, Space and Place,* 19(1), str. 60–71, doi: https://doi.org/10.1002/psp.1716

412. Vignoli, D., Tanturri, M. L., Acciai, F. (2016). Home bitter home? Gender, living arrangements, and the exclusion from homeownership among older Europeans. *Genus*, 72(9), str. 1–18, doi: https://doi.org/10.1186/s41118-016-0014-y

413. Vijeće Europske unije. (2021). *Preporuke: Preporuka vijeća (EU) 2021/1004 od 14. lipnja 2021. o uspostavi europskog jamstva za djecu*. Službeni list Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32021H1004

414. Vikat, A. (2004). Women's Labor Force Attachment and Childbearing in Finland. *Demographic Research Special Collection* 3(8), str. 177–212, doi: 10.4054/DemRes.2004.S3.8

415. Vlada Republike Hrvatske. (2018). *Prijedlog zakona o izmjenama i dopunama zakona o doplatku za djecu.* Dostupno na: https://vlada.gov.hr/UserDocsImages//2016/Sjednice/2018/05%20svibnja/96%20sjednica%20VRH//96%20-%201.pdf

416. Vlada Republike Hrvatske. (2023). *APN obradio sve ovogodišnje zahtjeve za stambene subvencije.* Dostupno na: https://vlada.gov.hr/vijesti/apn-obradio-sve-ovogodisnje-zahtjeve-za-stambene-subvencije/38539

417. Wang, Q., Sun, X. (2016). The role of socio-political and economic factors in fertility decline: a cross-country analysis. *World Development,* 87, str. 360–370, doi: https://doi.org/10.1016/j.worlddev.2016.07.004

418. Werding, M. (2014). Children are costly, but raising them may pay: The economic approach to fertility. *Demographic Research*, 30(1), str. 253–276, doi: 10.4054/DemRes.2014.30.8

419. Wertheimer-Baletić, A. (1985). Karakteristike i problem reprodukcije stanovništva u SR Hrvatskoj, u knjizi: Wertheimer-Baletić, A.: *Demografska teorija, razvoj stanovništva Hrvatske i populacijska politika*. Samobor: Meridijani.

420. Wertheimer-Baletić, A. (1992). Demografske promjene i globalni demografski procesi u Hrvatskoj u poslijeratnom razdoblju. *Encyclopaedia moderna*, 2(38), str. 238–351.

421. Wertheimer-Baletić, A. (1999). *Stanovništvo i razvoj.* (Population and development). Zagreb: MATE d.o.o.

422. Wertheimer-Baletić, A. (2003). Determinante reprodukcije stanovništva Hrvatske u drugoj polovici 20. Stoljeća, u knjizi: Wertheimer-Baletić, A.: *Demografska teorija, razvoj stanovništva Hrvatske i populacijska politika*. Samobor: Meridijani.

423. Wertheimer-Baletić, A. (2003). Razvoj stanovništva Hrvatske – reprodukcijske odrednice. *Zbornik radova Ekonomskog fakulteta u Rijeci,* 21(2), str. 29–47. Dostupno na: https://hrcak.srce.hr/103494

424. Wertheimer-Baletić, A. (2005). Populacijska politika u razvijenim europskim zemljama. *Rad Hrvatske akademije znanosti i umjetnosti. Razred za društvene znanosti*, 492, str. 297–330. Dostupno na: http://www.hazu.hr/~azrnic/eRad492/Rad492WertheimerB.pdf

425. Wertheimer-Baletić, A. (2009). *Starenje stanovništva kao svjetski proces*. Zagreb: HAZU.

426. Wertheimer-Baletić, A. (2006). Eksplicitna i implicitna populacijska politika u europskim zemljama. *Zbornik Ekonomskog fakulteta u Zagrebu,* 4 (1), str. 1–22.

427. Wertheimer-Baletić, A. (2016). Demografski tranzicijski procesi – kontinuitet ili diskontinuitet. *Rad Hrvatske akademije znanosti i umjetnosti. Razred za društvene znanosti,* (525=51), str. 7–63. Dostupno na: https://hrcak.srce.hr/154740

428. Western, B., Bloome, D., Sosnaud, B., Tach, L. (2012). Economic Insecurity and Social Stratification. *Annual Review of Sociology*, 38, str. 341–359, doi: https://doi.org/10.1146/annurev-soc-071811-145434

429. Westoff, C. F., Ryder, N. B. (1977). The Predictive Validity of Reproductive Intentions. *Demography*, 14(4), str. 431–453, doi: 10.2307/2060589

430. Westoff, C.F., Mishler, E.G., Kelly, E.L. (1957). Preferences in size of family and eventual fertility twenty years after. *American Journal of Sociology*, 62(5), str. 491–497, doi: 10.1086/222079

431. Willis, R. J. (1973). A New Approach to the Economic Theory of Fertility Behavior. *Journal of Political Economy*, 81(2), str. S14-S64, doi: https://doi.org/10.1086/260152

432. Wilthagen, T., Tros, F. (2004). The concept of 'flexicurity': a new approach to regulating employment and labour markets. *Transfer: European Review of Labour and Research*, 10(2), str. 166–86, doi: https://doi.org/10.1177/102425890401000204

433. Wooldridge, J. M. (2012). *Introductory econometrics: A modern approach* (5th ed.). Mason: South-Western Cengage Learning

434. Yun, S. (2015). A Comparative Study on the Relationship between Differential Fertility and Care Arrangement of the Welfare States. J. Korean Soc. Child Welf., 48, str. 1–32.

435. Zaidi, B., Morgan, S.P. (2017). The Second Demographic Transition Theory: A Review and Appraisal. *Annual Review of Sociology*, 43, str. 473–492, doi: https://doi.org/10.1146/annurev-soc-060116-053442

436. Zhang T-T, Cai X-Y, Shi X-H, Zhu W, Shan S-N. (2023). The Effect of Family Fertility Support Policies on Fertility, Their Contribution, and Policy Pathways to Fertility Improvement in OECD Countries. *International Journal of Environmental Research and Public Health*, 20(6):4790, str. 1–25, doi: https://doi.org/10.3390/ijerph20064790

437. Zhou, M., Guo, W. (2020). Fertility intentions of having a second child among the floating population in China: Effects of socioeconomic factors and home ownership. *Population Space and Place*, 26(2), e2289, doi: https://doi.org/10.1002/psp.2289

438. Žukauskas, P., Vveinhardt, J., Andriukaitienė, R. (2018). Philosophy and Paradigm of Scientific Research. Management Culture and Corporate Social Responsibility, doi:10.5772/intechopen.70628

Popis tablica

Tablica 1. Ključne značajke i etape druge demografske tranzicije 28
Tablica 2. Demografski trendovi u Republici Hrvatskoj 30
Tablica 3. Broj žena u fertilnoj dobi u popisima od 1971. do 2021 34
Tablica 4. Žene u fertilnoj dobi prema godinama starosti (popisi stanovništva od 1971. do 2021.) 35
Tablica 5. Dobna struktura žena u fertilnoj dobi (popisi stanovništva od 1971. do 2021.) 35
Tablica 6. Specifične stope fertiliteta prema starosti majke (na 1000) 36
Tablica 7. Komponente obiteljske politike 48
Tablica 8. Pregled literature – kronološki pregled objavljenih radova utjecajnih čimbenika fertiliteta 68
Tablica 9. Zaposlenost žena, stopa fertiliteta i starost majke pri prvom porodu 98
Tablica 10. Mjere socijalne politike usmjerene obiteljima s djecom u Republici Hrvatskoj 106
Tablica 11: Koeficijenti i iznosi osobnog odbitka za uzdržavanu djecu poreznog obveznika u Republici Hrvatskoj (2025. godina) 110
Tablica 12. Iznosi doplatka za djecu i dohodovni pragovi cenzusa za kućanstvo u Republici Hrvatskoj (2025. godina) 111
Tablica 13. Trend rashoda za obiteljske/dječje naknade u stalnim cijenama prema vrsti isplate, EU, 2000. – 2020. (indeks 2000 = 100) 117
Tablica 14. Izdatci za obiteljske/dječje naknade prema vrsti, Europska Unija, 2000. – 2020. godina 118
Tablica 15. Izdaci za obiteljske/dječje naknade prema vrsti, Republika Hrvatska, 2008. – 2020. godina 119
Tablica 16. Potpore i naknade namijenjene obiteljima s djecom u odabranim zemljama članicama Europske unije 122
Tablica 17. Živorođeni prema starosti majke 138
Tablica 18. Prednosti i nedostatci različitih vrsta upitnika 143
Tablica 19. Dinamika pozivanja ispitanika i broj poziva 144
Tablica 20. Ponderiranje podataka korištenjem RIM procedure 146
Tablica 21. Mjerenje ekonomske sigurnosti 148
Tablica 22. Mjerenje fiskalnih instrumenata javnih politika 149
Tablica 23. Mjerenje elemenata Teorije planiranog ponašanja 153
Tablica 24. Opis uzorka 171
Tablica 25. Financijsko stanje kućanstva 176
Tablica 26. Razlika u broju živorođene djece s obzirom na starosnu dob 178
Tablica 27. Razlika u broju živorođene djece s obzirom na najviši završeni stupanj obrazovanja 179
Tablica 28. Razlika u broju živorođene djece s obzirom na tip naselja 181
Tablica 29. Razlika u broju živorođene djece s obzirom na regiju prema indeksu razvijenosti 182
Tablica 30. Razlika u broju živorođene djece s obzirom na stambene uvjete 183
Tablica 31. Razlika u broju živorođene djece s obzirom na vrstu ugovora o radu 185
Tablica 32. Deskriptivna analiza kriterijskih i prediktorskih varijabli 188
Tablica 33. Povezanost sigurnosti posla i namjere rađanja u sljedeće dvije godine 192
Tablica 34. Povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine 197
Tablica 35. Povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine 202
Tablica 36. Testiranje povezanosti ekonomske sigurnosti i fertilnog jaza 206
Tablica 37. Povezanost izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine 209
Tablica 38. Povezanost neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine 214
Tablica 39. Povezanost transfera u naravi i namjere rađanja u sljedeće dvije godine 219
Tablica 40. Testiranje razlike u namjeri rađanja (M1) ovisno o indeksu razvijenosti 224
Tablica 41. Sažetak statusa hipoteza 225

Tablica 42. Logistička regresija namjere rađanja u sljedeće dvije godine.....235

Popis slika

Slika 1. Pretpostavljeni model namjere rađanja u sljedeće dvije godine s postavljenim hipotezama... 14
Slika 2. Etape demografske tranzicije ... 21
Slika 3. Oblici dobno – spolne strukture ... 23
Slika 4. Konceptualni okvir odrednica fertiliteta ... 53
Slika 5. Vremenski jaz između roditeljskog dopusta i zajamčenog mjesta u RPOO, 2022/2023 ... 60
Slika 6. Shematski prikaz nove ekonomske teorije ... 79
Slika 7. Koraci istraživačkog procesa ... 134
Slika 8. Dizajn istraživanja doktorskog rada ... 138
Slika 9. Funkcije raspodjele probit i logit modela ... 161
Slika 10. Smjernice za tumačenje koeficijenta korelacije ... 170
Slika 11. Konačni model namjere rađanja u sljedeće dvije godine ... 227

Popis grafikona

Grafikon 1. Distribucija rađanja prema dobi majke, Republika Hrvatska 38
Grafikon 2. Potpore za rođenje djeteta tijekom 2023. i 2024. godine u najvećim gradovima Republike Hrvatske 113
Grafikon 3. Rashodi za obiteljske/dječje naknade (% BDP-a) u 2000. i 2020. godini 117
Grafikon 4. Prosječan broj živorođenih prema starosti majke 140
Grafikon 5. Sigmoidalna funkcija $PY = 1X = 11 + e - (\beta 0 + \beta 1X1 + \cdots + \beta nXn)$ 164
Grafikon 6. Broj djece po dobnim skupinama žena 175
Grafikon 7. Veličina fertilnog jaza 190
Grafikon 8. ROC krivulja M1, M2, M3 (Blok 3) 195
Grafikon 9. ROC krivulja M1, M2 i M3 (Blok 3) 200
Grafikon 10. ROC krivulja M1, M2 i M3 (Blok 3) 205
Grafikon 11. ROC krivulja M1, M2 i M3 (Blok 3) 212
Grafikon 12. ROC krivulja M1, M2 i M3 217
Grafikon 13. ROC krivulja M1, M2 i M3 222

Prilozi

Prilog 1: Upitnik

. gender0

2. birth_year0

.....

3. birth_month0

4. HR_nuts3

21. Zagreb
1. Zagrebačka
2. Krapinsko-zagorska
3. Sisačko-moslavačka
4. Karlovačka
5. Varaždinska
6. Koprivničko-križevačka
7. Bjelovarsko-bilogorska
8. Primorsko-goranska
9. Ličko-senjska
10. Virovitičko-podravska
11. Požeško-slavonska
12. Brodsko-posavska
13. Zadarska
14. Osječko-baranjska
15. Šibensko-kninska
16. Vukovarsko-srijemska
17. Splitsko-dalmatinska
18. Istarska
19. Dubrovačko-neretvanska
20. Međimurska

1. SCR1

(gender0=2)

Imate li Vi osobno djecu/dijete? Pod time mislimo na djecu/dijete koje ste Vi osobno rodili.

1. Da
2. Ne

2. UVOD
(SCR1=2)
Poštovana,
pred Vama se nalazi upitnik za istraživanje namjere rađanja te Vas pozivamo da sudjelujete u istraživanju koje se provodi u svrhu izrade
doktorskog rada na poslijediplomskom doktorskom studiju Management na Ekonomskom fakultetu u Osijeku. Istraživanje je u potpunosti
anonimno, a podatci zaštićeni. Rezultati istraživanja će biti prikazani u obliku prosjeka svih ispitanika.

Unaprijed zahvaljujemo na sudjelovanju i savjesnom pristupu kojim doprinosite rješavanju aktualnih demografskih i ekonomskih problema
u Republici Hrvatskoj.

1.

3. Q4a
(SCR1=2)
Molimo Vas da odgovorite na sljedeća pitanja koja se odnose na Vas. Neka pitanja djeluju osjetljivijima, no napominjemo, Vaše mišljenje
nam je izuzetno važno, a rezultati će biti prikazani u obliku prosjeka svih ispitanika.

Koliki je idealan broj djece, prema Vašem mišljenju, u Republici Hrvatskoj (po paru)?

Upišite:

.....

4. Q4b
(SCR1=2)
Koliko puta ste ukupno rodili, odnosno koliki je Vaš ukupan broj poroda?

0. 0
1. 1
2. 2
3. 3
4. 4
5. 5
6. više od 5

5. Q4c
(SCR1=2)
Koliko djece je živorođeno?

0. 0
1. 1
2. 2
3. 3
4. 4
5. 5
6. više od 5

6. Q4e
(SCR1=2) AND (Q4C=0)
Koliki je Vaš željeni broj djece? Koliko djece biste željeli imati?

0. 0
1. 1
2. 2
3. 3
4. 4
5. 5
6. više od 5

7. Q1_ATT
(SCR1=2) AND (Q4C=0)
Iako možda ne namjeravate imati dijete, svejedno želimo čuti Vaše mišljenje o ovoj mogućnosti.

Pretpostavimo da ćete tijekom sljedeće dvije godine imati dijete. Molimo da označite kakav bi to utjecaj imalo na različite aspekte Vašeg
života, tako da za svaku izjavu izrazite mišljenje koristeći sljedeću ljestvicu: 1 – jako loš, 2 – loš, 3 – niti loš niti dobar, 4 – dobar, 5 – jako dobar.

Answers
1. jako loš
2 loš
3. niti loš niti dobar
4. dobar
5. jako dobar
6. nije primjenjivo/ne mogu procijeniti

Options
1. Mogućnost da radite što želite.
2. Vašu financijsku situaciju.
3. Mogućnost da ostvarite neke druge životne ciljeve.
4. Radost i zadovoljstvo koje dobivate od života.
5. Vaše daljnje mogućnosti zapošljavanja.

6. Vaš trenutni posao.
7. Mogućnosti zapošljavanja Vašeg partnera.
8. Skrb i sigurnost koju možete dobiti u starosti.
9. Bliskost između vas i Vašeg partnera.

8. Q2_PBC

(SCR1=2) AND (Q4C=0)

Sljedeće izjave odnose se na uvjete koje je potrebno ispuniti prije nego što pojedinci/parovi dobiju dijete/još jedno dijete.

Bez obzira planirate li imati dijete ili ne, molimo Vas da označite u kojoj mjeri smatrate da ćete imati ispunjene navedene uvjete u sljedeće dvije godine, tako da za svaki uvjet izrazite stupanj sigurnosti koristeći sljedeću ljestvicu: 1 – definitivno ne, 2 – vjerojatno ne, 3 – nisam sigurna, 4 – vjerojatno da, 5 – definitivno da.

Answers

1. definitivno ne
2. vjerojatno ne
3. nisam sigurna
4. vjerojatno da
5. definitivno da

Options

1. Moći ću si s financijskog aspekta priuštiti imati dijete.
2. Imat ću odgovarajući smještaj koji će mi omogućiti da imam dijete.
3. Bit ću dovoljno zdrava da mogu imati dijete.
4. Osjećat ću se spremnom da imam dijete.
5. Imat ću partnera s kojim ću imati dijete.
6. Moći ću uskladiti svoj poslovni i obiteljski život ako budem imala dijete.
7. Imat ću pristup zadovoljavajućoj zdravstvenoj skrbi za djecu ako budem imala dijete.
8. Imat ću pristup vrtićima/jaslicama.
9. Imat ću mogućnost otići na roditeljski dopust.
10. Imat ću potporu obitelji/bliskih ljudi u slučaju potrebe za čuvanjem djeteta/djece.

9. Q3_SN

(SCR1=2) AND (Q4C=0)

Sljedeće izjave govore o tome što bi drugi ljudi mogli misliti o tome da imate dijete u sljedeće dvije godine.

Molimo izrazite stupanj slaganja odnosno neslaganja s navedenim izjavama koristeći sljedeću ljestvicu: 1 -uopće se ne slažem, 2 – ne slažem se, 3 – niti se slažem, niti se ne slažem, 4 – slažem se, 5 - u potpunosti se slažem.

Answers
1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem
6. nije primjenjivo/ne mogu procijeniti

Options
1. Većina mojih prijatelja smatra da trebam imati dijete.
2. Moji roditelji smatraju da trebam imati dijete.
3. Moj partner smatra da trebamo imati dijete.
4. Članovi moje obitelji smatraju da trebam imati dijete.
5. Važno mi je mišljenje mojih prijatelja pri odluci o rađanju.
6. Važno mi je mišljenje mojih roditelja pri odluci o rađanju.
7. Važno mi je mišljenje mog partnera pri odluci o rađanju.
8. Važno mi je mišljenje članova moje obitelji pri odluci o rađanju.

10. Q5_NR
(SCR1=2) AND (Q4C=0)
Molimo Vas da uz svaku izjavu izrazite stupanj slaganja odnosno neslaganja s navedenom izjavom koristeći sljedeću ljestvicu: 1 –
definitivno ne, 2 – vjerojatno ne, 3 – nisam sigurna, 4 – vjerojatno da, 5 – definitivno da.

Answers
1. definitivno ne
2. vjerojatno ne
3. nisam sigurna
4. vjerojatno da
5. definitivno da

Options
1. Namjeravam imati dijete u sljedeće 2 godine (biološko dijete/djecu).
2. Pretpostavimo da tijekom sljedeće 2 godine nećete imati dijete, namjeravate li uopće imati dijete u budućnosti?

11. Q5b
(SCR1=2) AND (Q4C=0)
Molimo Vas da u postotku izrazite koliko ste sigurni da ćete roditi dijete.

.....%

12. Q6_NN
(SCR1=2) AND (Q4C=0) AND (Q5_NR.1 in [1,2,3])

Ako ne želite imati dijete u sljedeće dvije godine, molimo Vas da uz svaku izjavu izrazite stupanj slaganja odnosno neslaganja s
navedenom razlozima za takvu odluku koristeći sljedeću ljestvicu: 1 - uopće se ne slažem, …, 5 - u potpunosti se slažem.

Answers
1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem

Options
1. Prestara sam/moj partner je prestar.
2. Nemam potporu partnera/supružnika.
3. Nemam dovoljno financijskih resursa.
4. Zabrinuta sam oko buduće ekonomske situacije.
5. Zdravstveni problemi.
6. Zabrinuta sam da će dijete imati zdravstvenih problema.
7. Odgoj djece je težak.
8. Neadekvatni stambeni uvjeti.
9. Supružnik je nezaposlen.
10. Previše kućanskih obveza.
11. Nedostatak vrtića/jaslica.
12. Moj posao i profesionalne aktivnosti to ne bi dopuštale.
13. Imat ću dijete/djecu u budućnosti, ali ne u sljedeće dvije godine.

13. Q7_SP
(SCR1=2) AND (Q4C=0)
Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate dijete koristeći sljedeću ljestvicu: 1 -uopće ne bi
utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. djelomično ne bi utjecalo
3. niti bi utjecalo niti ne bi utjecalo
4. djelomično bi utjecalo
5. u potpunosti bi utjecalo

Options
1. Status zaposlenja (zaposlena/nezaposlena).
2. Sigurnost/stabilnost posla.

3. Vrsta ugovora o radu (neodređeno/određeno).
4. Vrsta radnog odnosa – samozaposlena.
5. Vrsta radnog odnosa – zaposlena kod drugog poslodavca (privatni sektor).
6. Vrsta radnog odnosa – zaposlena kod drugog poslodavca (javni sektor).

14. Q7_FS

(SCR1=2) AND (Q4C=0)

Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate dijete koristeći sljedeću ljestvicu: 1 - uopće ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. djelomično ne bi utjecalo
3. niti bi utjecalo niti ne bi utjecalo
4. djelomično bi utjecalo
5. u potpunosti bi utjecalo

Options

1. Visina prihoda kućanstva.
2. Ušteđevina.
3. Financijska pomoć od strane obitelji/prijatelja/bliskih ljudi.
4. Financijska mogućnost da se nosite s neočekivanim troškovima.

15. Q7_SU

(SCR1=2) AND (Q4C=0)

Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate dijete koristeći sljedeću ljestvicu: 1 - uopće ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. djelomično ne bi utjecalo
3. niti bi utjecalo niti ne bi utjecalo
4. djelomično bi utjecalo
5. u potpunosti bi utjecalo

Options

1. Posjedovanje nekretnine.
2. Stambeni uvjeti adekvatni za proširenje obitelji.

16. Q8

(SCR1=2) AND (Q4C=0)
Kućanstvo može imati više izvora prihoda i više od jednog člana kućanstva može pridonositi kućnom budžetu.

Razmišljajući o ukupnom mjesečnom prihodu Vašeg kućanstva, može li Vaše kućanstvo podmiriti sve svoje obveze?

1. S velikim poteškoćama
2. Uz određene poteškoće
3. Prilično lako
4. Lako
5. Vrlo lako

17. UVOD3
(SCR1=2) AND (Q4C=0)
U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

NOVČANI TRANSFERI (izravni i neizravni)

1.

18. Q9a_T
(SCR1=2) AND (Q4C=0)
Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate dijete koristeći sljedeću ljestvicu: 1 –uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options
1. Smanjeni porezi na dohodak za ljude s uzdržavanom djecom.
2. Dječji doplatak za obitelji s djecom neovisan o veličini obiteljskih primanja.
3. Dječji doplatak za majku ili oca koji ne rade jer žele skrbiti o svojoj djeci.
4. Značajno povećanje izdvajanja za dječje doplatke iz proračuna.

5. Snižene stope PDV-a za dječje potrepštine
6. Povećanje naknade tijekom poštede od rada.
7. Novčana pomoć za opremu novorođenog djeteta.
8. Plaćeni očinski dopust.
9. Rodiljne i roditeljske potpore.
10. Povećanje naknade kod korištenja prava na rad s polovicom radnog vremena radi pojačane njege djeteta.
11. Povećanje jednokratne novčane potpore za novorođeno dijete.
12. Povećanje pronatalitetnog dodatka uz doplatak.
13. Povećanje zajamčene minimalne naknade za kućanstva koja imaju djecu.

19. UVOD4

(SCR1=2) AND (Q4C=0)

U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

TRANSFERI U NARAVI I SUBVENCIJE

1.

20. Q9b_T

(SCR1=2) AND (Q4C=0)

Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options

14. Sufinanciranje cijene dječjih vrtića.
15. Značajno smanjenje troškova obrazovanja za djecu.
16. Sufinanciranje troškova produženog boravka.
17. Sufinanciranje kupnje školskih potrepština.
18. Sufinanciranje troškova prehrane.
19. Sufinanciranje smještaja u učeničkim/studentskim domovima.
20. Sufinanciranje najamnine za stanovanje.

21. Koncesija ili darovanje zemljišta za izgradnju prve nekretnine za roditelje.
22. Subvencioniranje kamata na stambene kredite.
23. Sufinanciranje prijevoza učenika/studenata.
24. Dodjeljivanje učeničkih/studentskih stipendija.
25. Sufinanciranje savjetovališta za obitelj, brak, roditeljstvo.
26. Sufinanciranje kupnje prve nekretnine za sve građane.

21. UVOD6
(SCR1=2) AND (Q4C=0)
U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

OSTALE MJERE iz sustava socijalne skrbi

1.

22. Q9c_T
(SCR1=2) AND (Q4C=0)
Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options
27. Mogućnost korištenja dužeg očinskog dopusta.
28. Mogućnost korištenja dužeg roditeljskog dopusta.
29. Rad s polovicom punog radnog vremena.
30. Rad s polovicom punog radnog vremena zbog pojačane njege djeteta.
31. Slobodan radni dan za prenatalni pregled.
32. Fleksibilno radno vrijeme za roditelje s malom djecom.
33. Stanka za dojenje djeteta.
34. Mirovanje radnog odnosa do treće godine djetetova života.
35. Dostupniji vrtići za djecu do 3. godine.
36. Dostupniji vrtići za djecu od 3. do 5. godine.

37. Rad vrtića u dvije smjene.
38. Osiguran dnevni boravak u školama.

23. Q10

(SCR1=2) AND (Q4C=0)

Smatrate li da bi neka mjera koja nije prethodno navedena značajno pomogla u odgoju djece i/ili smanjenju troškova odgoja djece? Ako da, molimo da navedete, koja/koje bi to bila/bile:

.....

24. Q11_UM

(SCR1=2) AND (Q4C=0)

Bi li mjere koje smatrate poželjnima imale utjecaj na Vaš osobni život?
Molimo Vas da uz svaku tvrdnju izrazite stupanj slaganja koristeći sljedeću ljestvicu: 1 – uopće se ne slažem, … 5 – u potpunosti se slažem.

Answers

1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem

Options

1. Omogućilo bi mi postizanje željenog broja djece.
2. Omogućilo bi mi da ranije imam dijete.
3. Razmotrila bih ponovno mogućnost da imam dijete.

25. Q12_BFEP

(SCR1=2) AND (Q4C=0)

Molimo da označite u kojoj mjeri bi navedeni čimbenici utjecali na Vašu odluku da imate dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, …, 5 – u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo

Options

1. Visoka stopa inflacije.

2. Visoke stope nezaposlenosti.
3. Pad bruto domaćeg proizvoda.
4. Troškovi stanovanja.
5. Rat u bližem okruženju .
6. Općenita ekonomska situacija.
7. Politička podrška za djecu i njihove roditelje u Republici Hrvatskoj.
8. Općenita politička situacija u zemlji.
9. Demografska politika i aktivnosti središnje države.
10. Demografska politika i aktivnosti lokalnih i regionalnih vlasti.
11. Ravnomjernija raspodjela financijskih sredstava namijenjenih djeci i roditeljima na lokalnoj i regionalnoj razini.

26. Q13_SF

(SCR1=2) AND (Q4C=0)

Danas žene imaju manje djece nego u prethodnim generacijama.

Molimo da označite u kojoj mjeri smatrate da su navedeni čimbenici utjecali na trend smanjenja broja djece koristeći sljedeću ljestvicu: 1 – uopće nije utjecalo, …, 5 – u potpunosti je utjecalo.

Answers

1. uopće nije utjecalo
2. nije utjecalo
3. niti je utjecalo, niti nije utjecalo
4. utjecalo je
5. u potpunosti je utjecalo

Options

1. Ekonomska kriza i nezaposlenost.
2. Veći broj zaposlenih žena.
3. Veći broj razvoda.
4. Osjećaj prenapučenosti.
5. Idealiziranje manjih obitelji.
6. Financijski teret odgoja djece.
7. Povećana želja za neovisnošću i osobnim napretkom muškaraca i žena.
8. Strah od problema koji dolaze tijekom odgoja djece.
9. Neadekvatni stambeni uvjeti.
10. Strah od budućnosti.

ŽENE S DJECOM

27. UVOD2

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Poštovana,

pred Vama se nalazi upitnik za istraživanje namjere rađanja te Vas pozivamo da sudjelujete u istraživanju koje se provodi u svrhu izrade doktorskog rada na poslijediplomskom doktorskom studiju Management na Ekonomskom fakultetu u Osijeku. Istraživanje je u potpunosti anonimno, a podatci zaštićeni. Rezultati istraživanja će biti prikazani u obliku prosjeka svih ispitanika.

Unaprijed zahvaljujemo na sudjelovanju i savjesnom pristupu kojim doprinosite rješavanju aktualnih demografskih i ekonomskih problema u Republici Hrvatskoj.

1.

28. DQ1_ATT

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Iako možda ne namjeravate imati još jedno dijete, svejedno želimo čuti Vaše mišljenje o ovoj mogućnosti.

Pretpostavimo da ćete tijekom sljedeće dvije godine imati još jedno dijete. Molimo da označite kakav bi to utjecaj imalo na različite aspekte Vašeg života, tako da za svaku izjavu izrazite mišljenje koristeći sljedeću ljestvicu: 1 – jako loš, 2 – loš, 3 – niti loš niti dobar, 4 – dobar, 5 – jako dobar.

Answers

1. jako loš
2. loš
3. niti loš niti dobar
4. dobar
5. jako dobar
6. nije primjenjivo/ne mogu procijeniti

Options

1. Mogućnost da radite što želite.
2. Vašu financijsku situaciju.
3. Mogućnost da ostvarite neke druge životne ciljeve.
4. Radost i zadovoljstvo koje dobivate od života.
5. Vaše daljnje mogućnosti zapošljavanja.
6. Vaš trenutni posao.

7. Mogućnosti zapošljavanja Vašeg partnera.
8. Skrb i sigurnost koju možete dobiti u starosti.
9. Bliskost između vas i Vašeg partnera.

29. DQ2_PBC

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Sljedeće izjave odnose se na uvjete koje je potrebno ispuniti prije nego što pojedinci/parovi dobiju dijete/još jedno dijete.

Bez obzira planirate li imati još jedno dijete ili ne, molimo Vas da označite u kojoj mjeri smatrate da ćete imati ispunjene navedene uvjete
u sljedeće dvije godine, tako da za svaki uvjet izrazite stupanj sigurnosti koristeći sljedeću ljestvicu: 1 – definitivno ne, 2 – vjerojatno ne, 3 –
nisam sigurna, 4 – vjerojatno da, 5 – definitivno da.

Answers

1. definitivno ne
2. vjerojatno ne
3. nisam sigurna
4. vjerojatno da
5. definitivno da

Options

1. Moći ću si s financijskog aspekta priuštiti imati još jedno dijete.
2. Imat ću odgovarajući smještaj koji će mi omogućiti da imam još jedno dijete.
3. Bit ću dovoljno zdrava da mogu imati još jedno dijete.
4. Osjećat ću se spremnom da imam još jedno dijete.
5. Imat ću partnera s kojim ću imati još jedno dijete.
6. Moći ću uskladiti svoj poslovni i obiteljski život ako budem imala još jedno dijete.
7. Imat ću pristup zadovoljavajućoj zdravstvenoj skrbi za djecu ako budem imala još jedno dijete.
8. Imat ću pristup vrtićima/jaslicama.
9. Imat ću mogućnost otići na roditeljski dopust.
10. Imat ću potporu obitelji/bliskih ljudi u slučaju potrebe za čuvanjem djeteta/djece.

30. DQ3_SN

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Sljedeće izjave govore o tome što bi drugi ljudi mogli misliti o tome da imate još jedno dijete u sljedeće dvije godine.

Molimo izrazite stupanj slaganja odnosno neslaganja s navedenim izjavama koristeći sljedeću ljestvicu: 1 -uopće se ne slažem, 2 – ne
slažem se, 3 – niti se slažem, niti se ne slažem, 4 – slažem se, 5 - u potpunosti se slažem.

Answers
1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem
6. nije primjenjivo/ne mogu procijeniti

Options
1. Većina mojih prijatelja smatra da trebam imati još jedno dijete.
2. Moji roditelji smatraju da trebam imati još jedno dijete.
3. Moj partner smatra da trebamo imati još jedno dijete.
4. Članovi moje obitelji smatraju da trebam imati još jedno dijete.
5. Važno mi je mišljenje mojih prijatelja pri odluci o rađanju.
6. Važno mi je mišljenje mojih roditelja pri odluci o rađanju.
7. Važno mi je mišljenje mog partnera pri odluci o rađanju.
8. Važno mi je mišljenje članova moje obitelji pri odluci o rađanju.

31. DQ4a
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo Vas da odgovorite na sljedeća pitanja koja se odnose na Vas. Neka pitanja djeluju osjetljivijima, no napominjemo, Vaše mišljenje
nam je izuzetno važno, a rezultati će biti prikazani u obliku prosjeka svih ispitanika.

Koliki je idealan broj djece, prema Vašem mišljenju, u Republici Hrvatskoj (po paru)?

Upišite:
.....

32. DQ4b
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Koliko puta ste ukupno rodili, odnosno koliki je Vaš ukupan broj poroda?

1. 1
2. 2
3. 3
4. 4
5. 5
6. 6
7. 7
8. 8
9. 9
10. 10
11. 11

12. 12

33. DQ4c
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Koliko djece je živorođeno?

1. 1
2. 2
3. 3
4. 4
5. 5
6. 6
7. 7
8. 8
9. 9
10. 10
11. 11
12. 12

34. DQ4d_1
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Koje godine je rođeno 1. dijete?

1.

35. DQ4d_2
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>1)
Koje godine je rođeno 2. dijete?

1.

36. DQ4d_3
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>2)
Koje godine je rođeno 3. dijete?

1.

37. DQ4d_4
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>3)
Koje godine je rođeno 4. dijete?

1.

38. DQ4d_5

((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>4)
Koje godine je rođeno 5. dijete?

1.

39. DQ4d_6
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>5)
Koje godine je rođeno 6. dijete?

1.

40. DQ4d_7
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>6)
Koje godine je rođeno 7. dijete?

1.

41. DQ4d_8
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>7)
Koje godine je rođeno 8. dijete?

1.

42. DQ4d_9
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>8)
Koje godine je rođeno 9. dijete?

1.

43. DQ4d_10
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>9)
Koje godine je rođeno 10. dijete?

1.

44. DQ4d_11
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>10)
Koje godine je rođeno 11. dijete?

1.

45. DQ4d_12
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4C>11)
Koje godine je rođeno 12. dijete?

1.

46. DQ4e
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Ako imate dijete/djecu, koliki je bio Vaš željeni broj djece kada ste bili u 20im godinama starosti?

1. 0
2. 1
3. 2
4. 3
5. 4
6. 5
7. više od 5

47. DQ4g
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Jeste li ostvarili broj djece koji ste željeli u 20im godinama starosti?

1. Da
2. Ne

48. DQ4f
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4g=2)
Je li stvarni broj djece koju imate:

1. manji od željenog
2. veći od željenog
3. jednak željenom
4. manji od željenog ali i dalje namjeravam imati još djece

49. DQ5_G
((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ4g=2) AND (DQ4f in [1,2,4])
Molimo označite u kojoj mjeri su sljedeći razlozi utjecali na razliku između željenog i ostvarenog broja djece koristeći sljedeću ljestvicu: 1
-uopće nije utjecalo, 2 – djelomično nije utjecalo, 3 – niti je utjecalo niti nije utjecalo, 4 – djelomično je utjecalo, 5 - u potpunosti je
utjecalo.

Answers
1. uopće nije utjecalo
2. djelomično nije utjecalo
3. niti je utjecalo, niti nije utjecalo

4. djelomično je utjecalo
5. u potpunosti je utjecalo

Options
2. Problemi s partnerom/nisam pronašla odgovarajućeg partnera.
3. Problem usklađivanja posla i obitelji.
4. Zdravstveni problemi.
5. Visoki troškovi uzdržavanja i odgoja djece.
6. Promjene u prioritetima.
7. Nije bilo pravo vrijeme.
8. Neadekvatni stambeni uvjeti za proširenje obitelji.
9. Neposjedovanje vlastite nekretnine.
10. Nesiguran posao.
11. Status zaposlenja – nezaposlena.
12. Izostanak financijske pomoći od članova obitelji/prijatelja/bliskih ljudi.
13. Financijski problemi – nemogućnost podmirivanja neočekivanih troškova.
14. Mali prihodi kućanstva.
15. Ostalo.

50. DQ6_NR
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo Vas da uz svaku izjavu izrazite stupanj slaganja odnosno neslaganja s navedenom izjavom koristeći sljedeću ljestvicu: 1 –
definitivno ne, 2 – vjerojatno ne, 3 – nisam sigurna, 4 – vjerojatno da, 5 – definitivno da.

Answers
1. definitivno ne
2. vjerojatno ne
3. nisam sigurna
4. vjerojatno da
5. definitivno da

Options
1. Namjeravam imati još jedno dijete u sljedeće 2 godine (biološko dijete/djeca).
2. Pretpostavimo da tijekom sljedeće 2 godine nećete imati još jedno dijete, namjeravate li uopće imati još jedno dijete u budućnosti?

51. DQ6b
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo Vas da u postotku izrazite koliko ste sigurni da ćete roditi još jedno dijete.

.....%

52. DQ7_NN

((SCR1=1) or ((SCR1=2) and (Q4c>0))) AND (DQ6_NR.1 in [1,2,3])
Ako ne želite imati dijete u sljedeće dvije godine, molimo Vas da uz svaku izjavu izrazite stupanj slaganja odnosno neslaganja s
navedenom razlozima za takvu odluku koristeći sljedeću ljestvicu: 1 - uopće se ne slažem, …, 5 - u potpunosti se slažem.

Answers
1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem

Options
1. Imam željeni broj djece.
2. Prestara sam/moj partner je prestar.
3. Nemam potporu partnera/supružnika.
4. Nemam dovoljno financijskih resursa.
5. Zabrinuta sam oko buduće ekonomske situacije.
6. Zdravstveni problemi.
7. Zabrinuta sam da će dijete imati zdravstvenih problema.
8. Odgoj djece je težak.
9. Neadekvatni stambeni uvjeti.
10. Supružnik je nezaposlen.
11. Previše kućanskih obveza.
12. Nedostatak vrtića/jaslica.
13. Moj posao i profesionalne aktivnosti to ne bi dopuštale.
14. Imat ću dijete/djecu u budućnosti, ali ne u sljedeće dvije godine.
15. Nemam potporu supružnika/partnera.

53. DQ8_SP
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate još jedno dijete koristeći sljedeću ljestvicu: 1 -
uopće ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi
utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo

Options
1. Status zaposlenja (zaposlena/nezaposlena).
2. Sigurnost/stabilnost posla.
3. Vrsta ugovora o radu (neodređeno/određeno).
4. Vrsta radnog odnosa – samozaposlena.
5. Vrsta radnog odnosa – zaposlena kod drugog poslodavca (privatni sektor).
6. Vrsta radnog odnosa – zaposlena kod drugog poslodavca (javni sektor).

54. DQ8_FS

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate još jedno dijete koristeći sljedeću ljestvicu: 1 - uopće ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo

Options
1. Visina prihoda kućanstva.
2. Ušteđevina.
3. Financijska pomoć od strane obitelji/prijatelja/bliskih ljudi.
4. Financijska mogućnost da se nosite s neočekivanim troškovima.

55. DQ8_SU

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Molimo Vas da uz svaki čimbenik izrazite stupanj utjecaja na Vašu odluku o tome da imate još jedno dijete koristeći sljedeću ljestvicu: 1 - uopće ne bi utjecalo, 2 – djelomično ne bi utjecalo, 3 – niti bi utjecalo niti ne bi utjecalo, 4 – djelomično bi utjecalo, 5 - u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo

Options
1. Posjedovanje nekretnine.
2. Stambeni uvjeti adekvatni za proširenje obitelji.

56. DQ9
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Kućanstvo može imati više izvora prihoda i više od jednog člana kućanstva može pridonositi kućnom budžetu.

Razmišljajući o ukupnom mjesečnom prihodu Vašeg kućanstva, može li Vaše kućanstvo podmiriti sve svoje obveze?

1. S velikim poteškoćama
2. Uz određene poteškoće
3. Prilično lako
4. Lako
5. Vrlo lako

57. UVOD7
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

NOVČANI TRANSFERI (izravni i neizravni)

1.

58. Q10a_T
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate još jedno dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers
1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options
1. Smanjeni porezi na dohodak za ljude s uzdržavanom djecom.
2. Dječji doplatak za obitelji s djecom neovisan o veličini obiteljskih primanja.
3. Dječji doplatak za majku ili oca koji ne rade jer žele skrbiti o svojoj djeci.
4. Značajno povećanje izdvajanja za dječje doplatke iz proračuna.
5. Snižene stope PDV-a za dječje potrepštine
6. Povećanje naknade tijekom poštede od rada.
7. Novčana pomoć za opremu novorođenog djeteta.
8. Plaćeni očinski dopust.
9. Rodiljne i roditeljske potpore.
10. Povećanje naknade kod korištenja prava na rad s polovicom radnog vremena radi pojačane njege djeteta.
11. Povećanje jednokratne novčane potpore za novorođeno dijete.
12. Povećanje pronatalitetnog dodatka uz doplatak.
13. Povećanje zajamčene minimalne naknade za kućanstva koja imaju djecu.

59. UVOD8
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

TRANSFERI U NARAVI I SUBVENCIJE

1.

60. Q10b_T
((SCR1=1) or ((SCR1=2) and (Q4c>0)))
Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate još jedno dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers
1. u potpunosti ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options

14. Sufinanciranje cijene dječjih vrtića.
15. Značajno smanjenje troškova obrazovanja za djecu.
16. Sufinanciranje troškova produženog boravka.
17. Sufinanciranje kupnje školskih potrepština.
18. Sufinanciranje troškova prehrane.
19. Sufinanciranje smještaja u učeničkim/studentskim domovima.
20. Sufinanciranje najamnine za stanovanje.
21. Koncesija ili darovanje zemljišta za izgradnju prve nekretnine za roditelje.
22. Subvencioniranje kamata na stambene kredite.
23. Sufinanciranje prijevoza učenika/studenata.
24. Dodjeljivanje učeničkih/studentskih stipendija.
25. Sufinanciranje savjetovališta za obitelj, brak, roditeljstvo.
26. Sufinanciranje kupnje prve nekretnine za sve građane.

61. UVOD9

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

U nastavku ćemo navesti neke mjere koje su neke europske države već primjenjivale kako bi svojim građanima olakšale podizanje, odgoj i obrazovanje djece.

OSTALE MJERE iz sustava socijalne skrbi

1.

62. Q10c_T

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Molimo da označite u kojoj mjeri bi navedene mjere utjecale na Vašu odluku da imate još jedno dijete koristeći sljedeću ljestvicu: 1 – uopće ne bi utjecalo, 2 – ne bi utjecalo, 3 – niti bi utjecalo, niti ne bi utjecalo, 4 – utjecalo bi, 5 – u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo
6. nisam upoznata s navedenom demografskom mjerom

Options

27. Mogućnost korištenja dužeg očinskog dopusta.
28. Mogućnost korištenja dužeg roditeljskog dopusta.
29. Rad s polovicom punog radnog vremena.

30. Rad s polovicom punog radnog vremena zbog pojačane njege djeteta.
31. Slobodan radni dan za prenatalni pregled.
32. Fleksibilno radno vrijeme za roditelje s malom djecom.
33. Stanka za dojenje djeteta.
34. Mirovanje radnog odnosa do treće godine djetetova života.
35. Dostupniji vrtići za djecu do 3. godine.
36. Dostupniji vrtići za djecu od 3. do 5. godine.
37. Rad vrtića u dvije smjene.

38. Osiguran dnevni boravak u školama.

63. DQ11

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Smatrate li da bi neka mjera koja nije prethodno navedena značajno pomogla u odgoju djece i/ili smanjenju troškova odgoja djece? Ako da, molimo da navedete, koja/koje bi to bila/bile:

.....

64. DQ12_UM

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Bi li mjere koje smatrate poželjnima imale utjecaj na Vaš osobni život?
Molimo Vas da uz svaku tvrdnju izrazite stupanj slaganja koristeći sljedeću ljestvicu: 1 – uopće se ne slažem, … 5 – u potpunosti se slažem.

Answers

1. uopće se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem

Options

1. Omogućilo bi mi postizanje željenog broja djece.
2. Omogućilo bi mi da ranije imam dijete.
3. Razmotrila bih ponovno mogućnost da imam još jedno dijete.

65. DQ13_BFEP

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Molimo da označite u kojoj mjeri bi navedeni čimbenici utjecali na Vašu odluku da imate još jedno dijete koristeći sljedeću ljestvicu: 1 –
uopće ne bi utjecalo, …, 5 – u potpunosti bi utjecalo.

Answers

1. uopće ne bi utjecalo
2. ne bi utjecalo
3. niti bi utjecalo, niti ne bi utjecalo
4. utjecalo bi
5. u potpunosti bi utjecalo

Options

1. Visoka stopa inflacije.
2. Visoke stope nezaposlenosti.
3. Pad bruto domaćeg proizvoda.

4. Troškovi stanovanja.
5. Rat u bližem okruženju .
6. Općenita ekonomska situacija.
7. Politička podrška za djecu i njihove roditelje u Republici Hrvatskoj.
8. Općenita politička situacija u zemlji.
9. Demografska politika i aktivnosti središnje države.
10. Demografska politika i aktivnosti lokalnih i regionalnih vlasti.
11. Ravnomjernija raspodjela financijskih sredstava namijenjenih djeci i roditeljima na lokalnoj i regionalnoj razini.

66. DQ14

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Ako imate dijete/djecu, jeste li imali mogućnost nastaviti s radom kod istog poslodavca nakon isteka rodiljnog/roditeljskog dopusta?

1. Da
2. Ne
3. Nije primjenjivo/nisam (bila) zaposlena

67. DQ15

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Ako imate dijete/djecu, je li Vam poslodavac omogućio fleksibilno radno vrijeme nakon povratka s rodiljnog/roditeljskog dopusta?

1. Da
2. Ne
3. Nije primjenjivo/nisam (bila) zaposlena

68. DQ16_SF

((SCR1=1) or ((SCR1=2) and (Q4c>0)))

Danas žene imaju manje djece nego u prethodnim generacijama.
Molimo da označite u kojoj mjeri smatrate da su navedeni čimbenici utjecali na trend smanjenja broja djece koristeći sljedeću ljestvicu: 1 –
uopće nije utjecalo, …, 5 – u potpunosti je utjecalo.

Answers

1. uopće nije utjecalo
2. nije utjecalo
3. niti je utjecalo, niti nije utjecalo
4. utjecalo je
5. u potpunosti je utjecalo

Options

1. Ekonomska kriza i nezaposlenost.

2. Veći broj zaposlenih žena.
3. Veći broj razvoda.
4. Osjećaj prenapučenosti.
5. Idealiziranje manjih obitelji.
6. Financijski teret odgoja djece.
7. Povećana želja za neovisnošću i osobnim napretkom muškaraca i žena.
8. Strah od problema koji dolaze tijekom odgoja djece.
9. Neadekvatni stambeni uvjeti.
10. Strah od budućnosti.

69. DM13

Molimo da odaberete stambene uvjete koji se odnose na Vas.

1. potpuno vlasništvo nad stanom
2. potpuno vlasništvo nad kućom
3. djelomično vlasništvo nad stanom
4. djelomično vlasništvo nad kućom
5. najam
6. ostalo

70. Wactivity0

Koja od sljedećih kategorija najbolje opisuje Vaš trenutni radni status?

1. Stalno zaposlen (kod poslodavca)
2. Vlasnik poduzeća - poslodavac
3. Obrtnik
4. Samostalni poduzetnik
5. Samozaposleni stručnjak (odvjetnik, liječnik, arhitekt)
6. Slobodna profesija (umjetnik, samostalni novinar, samostalni glumac)
7. Honorarni rad, autorski ugovor
8. Nezaposlen
9. Umirovljenik
10. Osnovnoškolac
11. Srednjoškolac
12. Student
14. Poljoprivrednik, radi - pomaže u poljoprivredi
15. Kućanica
16. Ispomoć u kućanstvu (radionica, kafić)
17. Radno nesposoban - invalid,...
97. Drugo
98. Ne želim odgovoriti

71. DM7

(Wactivity0 in [1,2,3,4,5,6,7,16])

Vrsta zaposlenja:

1. privatni sektor
2. javni sektor
3. samozaposlena

72. DM8
(Wactivity0 in [1,2,3,4,5,6,7,16]) AND (Wactivity0=1)
Vrsta ugovora o radu:

1. neodređeno
2. određeno

73. DM9
(Wactivity0 in [1,2,3,4,5,6,7,16]) AND (Wactivity0=1)
Radno vrijeme:

1. puno radno vrijeme
2. pola radnog vremena

74. WP_position
(Wactivity0 in [1])
Vaš položaj na radnom mjestu:

1. Vodeći položaj na razini tvrtke, organizacije, ustanove
2. Vodeći položaj na razini radne jedinice, službe, sektora, odjela
3. Zaposleni, koji neposredno vodi ili nadzire rad drugih zaposlenih (majstor, nadzornik)
4. Zaposleni, koji nema neposredno podređenih (izvršitelj posla)

98. Ne želim odgovoriti

75. WP_activity
(Wactivity0 in [1])
Glavna djelatnost organizacije, u kojoj ste zaposleni:

1. Proizvodnja ili poljoprivreda
2. Usluge
3. Zaposlen-a u javnoj upravi, zavodu, nevladinoj organizaciji

98. Ne želim odgovoriti

76. hhsize1
Koliko Vaše kućanstvo ima članova, uključujući i Vas?

1. 1 član
2. 2
3. 3

4. 4
5. 5
6. 6
7. 7
8. 8 ili više članova
98. Ne želim odgovoriti

80. incomeH

((not (hhsize1=1)))

Molimo Vas da razmišljate o posljednja tri mjeseca. Koliki je bio ukupni prosječni mjesečni prihod svih članova zajedničkog kućanstva uključujući sve izvore prihoda? Plaće svih članova sa svim dodacima, honorari, mirovine, dječji doplatci, stipendije, naknade za nezaposlene ili sl., itd.

0. Bez prihoda kućanstva
200. Do 200 EUR
300. Više od 200 EUR do 400 EUR
500. Više od 400 EUR do 600 EUR
700. Više od 600 EUR do 800 EUR
900. Više od 800 EUR do 1.000 EUR
1100. Više od 1.000 EUR do 1.200 EUR
1300. Više od 1.200 EUR do 1.400 EUR
1500. Više od 1.400 EUR do 1.600 EUR
1700. Više od 1.600 EUR do 1.800 EUR
1900. Više od 1.800 EUR do 2.000 EUR
2100. Više od 2.000 EUR do 2.200 EUR
2300. Više od 2.200 EUR do 2.400 EUR
2500. Više od 2.400 EUR do 2.600 EUR
2700. Više od 2.600 EUR do 2.800 EUR
2900. Više od 2.800 EUR do 3.000 EUR
3100. Više od 3.000 EUR do 3.200 EUR
3300. Više od 3.200 EUR do 3.400 EUR
3500. Više od 3.400 EUR do 3.600 EUR
3700. Više od 3.600 EUR do 3.800 EUR
3900. Više od 3.800 EUR do 4.000 EUR
4000. Više od 4.000 EUR
9998. Ne znam / ne želim odgovoriti

.....

84. incomedesc0

Koji opis financijskog stanja najbolje opisuje Vas ili Vaše kućanstvo?

1. Prihodi našeg kućanstva su jedva dovoljni za hranu

2. Prihodi našeg kućanstva su dovoljni za hranu, ali teško si možemo priuštiti novu odjeću
3. Prihodi su dovoljni za kupovinu hrane i odjeće, ali trenutno bismo si teško mogli priuštiti novi televizor, frižider ili perilicu rublja
4. Prihodi su dovoljni za kupovinu kućnih aparata, ali bismo si teško mogli priuštiti novi automobil
5. Prihodi su dovoljni za sve, osim za kupovinu novog stana ili vikendice
6. Ako bi bilo potrebno, mogli bismo si priuštiti kupovinu stana ili vikendice

85. marital0

Koja od sljedećih kategorija najbolje opisuje Vaš trenutni bračni status?

1. Samac (neudana/ neoženjen)
2. Udana/oženjen
3. Živim u zajednici
4. Rastavljen/rastavljena
5. Udana/oženjen, ali živimo odvojeno
6. Udovica/udovac

98. Ne želim odgovoriti

Prilog 2: Povezanost sigurnosti posla i namjere rađanja u sljedeće dvije godine

Hipoteza H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja, mjerenje namjere rađanja M1

Opcija 1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,533	,114	,000	1,704
	Stavovi_Q1DQ1.att	,124	,260	,633	1,132
	Subjektivne_norme_Q3SNDQ3SN_stand	,654	,175	,000	1,923
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,864	,309	,000	6,449
	Broj_djece_Q4CDQ4C	-2,229	,397	,000	,108
	Djeca_SCR1(da)	7,361	1,289	,000	1573,708
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,159	,032	,000	,853
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna (poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	1,908	,895	,033	6,741
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-,757	,566	,181	,469
	Godine_starosti_RESP_AGE0 by Tip_naselja_new (urbano) by bracni_status(udana)	,015	,009	,092	1,015
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(živi u zajednici)	-,002	,010	,860	,998
	Radno_vrijeme_DM9(pola radnog vremena)	-1,232	,818	,132	,292
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(II.)	-1,195	,557	,032	,303
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(III.)	-1,380	,706	,051	,252
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(IV.)	,207	,456	,650	1,230
	Constant	-9,634	1,279	,000	,000

Opcija 2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,490	,123	,000	1,633
	Stavovi_Q1DQ1.att	-,242	,285	,396	,785
	Subjektivne_norme_Q3SNDQ3SN_stand	,768	,192	,000	2,155
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,779	,334	,000	5,926
	Broj_djece_Q4CDQ4C	-1,993	,360	,000	,136
	Djeca_SCR1(DA)	,407	1,163	,726	1,503
	Djeca_SCR1(DA) by Godine_starosti_RESP_AGE0	-,042	,030	,162	,958
	Djeca_SCR1(DA) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	-,951	1,269	,454	,386

	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-,443	,770	,565	,642
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(udana)	,003	,008	,659	1,003
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II.)	-1,971	,751	,009	,139
	Constant	-6,580	1,371	,000	,001

Hipoteza H1a: *Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja*, mjerenje namjere rađanja M2

Opcija 1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,520	,138	,000	1,682
	Stavovi_Q1DQ1.att	,475	,303	,118	1,607
	Subjektivne_norme_Q3SNDQ3SN_stand	,873	,227	,000	2,394
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,817	,351	,000	6,156
	Broj_djece_Q4CDQ4C	-2,387	,434	,000	,092
	Djeca_SCR1(da)	7,766	1,434	,000	2359,374
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,175	,035	,000	,839
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna (poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	1,995	,956	,037	7,353
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-,530	,730	,468	,589
	Godine_starosti_RESP_AGE0 by Tip_naselja_new (urbano) by bracni_status(udana)	,019	,011	,077	1,019
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(živi u zajednici)	-,003	,013	,793	,997
	Radno_vrijeme_DM9(pola radnog vremena)	-,650	1,002	,517	,522
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(II.)	-1,634	,848	,054	,195
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(III.)	-1,093	,630	,083	,335
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by INDEKS_REGIJE(IV.)	-1,829	,809	,024	,161
	Constant	-9,151	1,780	,000	,000

Opcija 2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,504	,141	,000	1,656
	Stavovi_Q1DQ1.att	-,026	,308	,933	,974
	Subjektivne_norme_Q3SNDQ3SN_stand	1,029	,247	,000	2,797
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,676	,360	,000	5,344
	Broj_djece_Q4CDQ4C	-2,076	,384	,000	,125

	Djeca_SCR1(ne)	1,246	1,412	,378	3,477
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,062	,036	,089	,940
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	18,725	34336,258	1,000	135533734,605
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-,113	,955	,906	,893
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(udana)	,002	,009	,793	1,002
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by Indeks_regije	-,268	,290	,355	,765
	Constant	-6,426	1,558	,000	,002

Hipoteza H1a: Postoji statistički značajna pozitivna povezanost sigurnosti posla i namjere rađanja, mjerenje namjere rađanja M3

Opcija 1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,428	,096	,000	1,534
	Stavovi_Q1DQ1.att	,346	,205	,092	1,413
	Subjektivne_norme_Q3SNDQ3SN_stand	,983	,163	,000	2,673
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,159	,214	,000	3,187
	Broj_djece_Q4CDQ4C	-1,064	,199	,000	,345
	Djeca_SCR1(ne)	1,628	,982	,097	5,095
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,047	,026	,075	,954
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno1)	-,416	1,100	,705	,660
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(1određeno)	,688	,466	,140	1,989
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(udana)	,000	,006	,979	1,000
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(živi u zajednici)	-,006	,009	,489	,994
	Radno_vrijeme_DM9(pola radnog vremena)	-,304	,603	,614	,738
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by INDEKS_REGIJE(II.)	,020	,663	,976	1,021
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by INDEKS_REGIJE(III.)	-,788	,572	,168	,455
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by INDEKS_REGIJE(IV.)	,414	,487	,396	1,513
	Constant	-5,943	,944	,000	,003

Opcija 2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	sigurnost_posla_Q7DQ8	,340	,105	,001	1,405
	Stavovi_Q1DQ1.att	,209	,230	,364	1,232
	Subjektivne_norme_Q3SNDQ3SN_stand	1,142	,182	,000	3,134
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,089	,238	,000	2,972

	Broj_djece_Q4CDQ4C	-1,000	,212	,000	,368
	Djeca_SCR1(ne)	1,950	1,181	,099	7,031
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,050	,032	,116	,951
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by Indeks_regije_new(III. i IV. skupina)	-,483	,650	,458	,617
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	19,767	17265,136	,999	384354750,071
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,566	,502	,260	1,761
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status_3_kategorije(udana)	,003	,006	,686	1,003
	Constant	-5,168	1,030	,000	,006

Prilog 3: Povezanost financijske sigurnosti i namjere rađanja u sljedeće dvije godine

		B	S.E.	Sig.	Exp(B)
Step 1[a]	financ_sigurnost_Q7DQ8	,324	,145	,025	1,382
	Stavovi_Q1DQ1.att	-,191	,304	,531	,826
	Subjektivne_norme_Q3SNDQ3SN_stand	,785	,200	,000	2,192
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,719	,350	,000	5,581
	Broj_djece_Q4CDQ4C	-1,861	,415	,000	,156
	Djeca_SCR1(da)	7,652	1,381	,000	2104,363
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,195	,036	,000	,823
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II.)	,420	,447	,347	1,523
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,350	,942	,013	10,480
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,598	,731	,029	,202
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(udana)	,017	,009	,052	1,018
	Broj_djece_Q4CDQ4C by INCOMEH by Indeks_regije_new(1)	,000	,000	,766	1,000
	INCOMEH by Indeks_regije_new(I. i II. skupina)	,000	,000	,896	1,000
	Constant	-7,449	1,439	,000	,001

Prilog 4: Povezanost potpunog vlasništva nad nekretninom i namjere rađanja u sljedeće dvije godine

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	DM13_potpuno_vlasnistvo	-,129	,243	,597	,879
	Stavovi_Q1DQ1.att	-,036	,232	,876	,964
	Subjektivne_norme_Q3SNDQ3SN_stand	,664	,159	,000	1,943
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,561	,269	,000	4,762
	Broj_djece_Q4CDQ4C	-2,217	,339	,000	,109
	Djeca_SCR1(ne)	,041	,912	,964	1,041
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,039	,024	,101	,962
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,680	,500	,174	,507
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(1)	-1,882	1,040	,070	,152
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-,432	,532	,416	,649
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status_2(sama/neudana/živi u zajednici)	-,017	,008	,028	,983
	Constant	-4,441	,994	,000	,012

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	DM13_potpuno_vlasnistvo	-,379	,285	,183	,685
	Stavovi_Q1DQ1.att	,124	,259	,631	1,133
	Subjektivne_norme_Q3SNDQ3SN_stand	,949	,204	,000	2,584
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,618	,301	,000	5,044
	Broj_djece_Q4CDQ4C	-2,410	,367	,000	,090
	Djeca_SCR1(ne)	,347	1,137	,760	1,415
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,043	,030	,156	,958
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,519	,699	,458	,595
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	-2,282	1,435	,112	,102
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,234	,685	,732	1,264
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(sama/neudana/živi u zajednici)	-,022	,010	,022	,978
	Constant	-4,486	1,122	,000	,011

Hipoteza H1c: Postoji statistički značajna pozitivna povezanost potpunog vlasništva nad nekretninom i namjere rađanja, mjerenje namjere rađanja M2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	DM13_potpuno_vlasnistvo	-,325	,212	,125	,722
	Stavovi_Q1DQ1.att	,273	,198	,167	1,314
	Subjektivne_norme_Q3SNDQ3SN_stand	1,025	,157	,000	2,786
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	,983	,200	,000	2,671
	Broj_djece_Q4CDQ4C	-1,106	,196	,000	,331
	Djeca_SCR1(ne)	1,583	,947	,095	4,870
	Djeca_SCR1(ne) by Godine_starosti_RESP_AGE0	-,040	,026	,124	,961
	Djeca_SCR1(ne) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,303	,543	,577	,739
	Djeca_SCR1(ne) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	-,197	1,058	,852	,821
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,540	,449	,229	1,716
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(urbano) by bracni_status(sama/neudana/živi u zajednici)	-,012	,008	,114	,988
	Constant	-3,549	,752	,000	,029

Prilog 5: Povezanost izravnih novčanih transfera i namjere rađanja u sljedeće dvije godine

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	izravni_novcani_transferi_Q9aQ10a	,616	,163	,000	1,851
	Stavovi_Q1DQ1.att	-,307	,359	,393	,736
	Subjektivne_norme_Q3SNDQ3SN_stand	1,025	,235	,000	2,788
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,955	,434	,000	7,065
	Broj_djece_Q4CDQ4C	-1,366	,451	,002	,255
	Djeca_SCR1(da)	8,748	1,855	,000	6299,192
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,202	,044	,000	,817
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-1,923	,661	,004	,146
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,664	1,072	,013	14,357
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,549	,813	,057	,212
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,022	,014	,108	,978
	bracni_status_3_kategorije(udana)	,776	,541	,151	2,173
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,188	,086	,029	,829
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,220	,563	,696	1,246
	Constant	-9,028	1,709	,000	,000

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	izravni_novcani_transferi_Q9aQ10a	,632	,201	,002	1,881
	Stavovi_Q1DQ1.att	-,014	,409	,973	,986
	Subjektivne_norme_Q3SNDQ3SN_stand	1,409	,325	,000	4,092
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,864	,477	,000	6,452
	Broj_djece_Q4CDQ4C	-1,545	,494	,002	,213
	Djeca_SCR1(da)	9,324	2,176	,000	11204,098
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,220	,050	,000	,802
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-1,940	,791	,014	,144
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,498	1,186	,035	12,158
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,371	1,080	,204	,254

	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,030	,016	,055	,970
	bracni_status_3_kategorije(udana)	,385	,684	,573	1,470
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,182	,094	,052	,834
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,406	,722	,574	1,501
	Constant	-8,642	1,845	,000	,000

Hipoteza H3a: Postoji statistički značajna pozitivna povezanost izravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M3

		B	S.E.	Sig.	Exp(B)
Step 1[a]	izravni_novcani_transferi_Q9aQ10a	,417	,125	,001	1,518
	Stavovi_Q1DQ1.att	,246	,269	,361	1,279
	Subjektivne_norme_Q3SNDQ3SN_stand	1,249	,210	,000	3,488
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,164	,281	,000	3,204
	Broj_djece_Q4CDQ4C	-,734	,260	,005	,480
	Djeca_SCR1(da)	3,206	1,162	,006	24,683
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,099	,027	,000	,906
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,401	,414	,333	,670
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	1,510	,846	,074	4,526
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,285	,613	,642	1,330
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,024	,010	,019	,977
	bracni_status_3_kategorije(udana)	-,292	,524	,578	,747
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,009	,053	,873	,992
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,829	,465	,074	2,292
	Constant	-5,409	1,142	,000	,004

Prilog 6: Povezanost neizravnih novčanih transfera i namjere rađanja u sljedeće dvije godine

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Neizravni_novcani_transferi_Q9aQ10a	,696	,157	,000	2,007
	Stavovi_Q1DQ1.att	-,239	,363	,511	,788
	Subjektivne_norme_Q3SNDQ3SN_stand	1,056	,241	,000	2,876
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	2,022	,445	,000	7,554
	Broj_djece_Q4CDQ4C	-1,370	,462	,003	,254
	Djeca_SCR1(da)	8,580	1,883	,000	5324,573
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,201	,044	,000	,818
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-2,056	,677	,002	,128
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,914	1,061	,006	18,429
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,655	,821	,044	,191
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,024	,014	,081	,976
	bracni_status(udana)	,941	,557	,091	2,562
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,184	,086	,033	,832
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,130	,578	,822	1,139
	Constant	-9,893	1,790	,000	,000

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Neizravni_novcani_transferi_Q9aQ10a	,777	,198	,000	2,176
	Stavovi_Q1DQ1.att	,022	,417	,958	1,022
	Subjektivne_norme_Q3SNDQ3SN_stand	1,481	,333	,000	4,396
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,984	,501	,000	7,270
	Broj_djece_Q4CDQ4C	-1,531	,509	,003	,216
	Djeca_SCR1(da)	9,194	2,207	,000	9836,593
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,224	,050	,000	,800

	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-2,092	,825	,011	,123
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,849	1,197	,017	17,273
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,544	1,120	,168	,214
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,034	,016	,038	,967
	bracni_status(udana)	,638	,718	,374	1,892
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,184	,094	,049	,832
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,347	,772	,653	1,415
	Constant	-9,808	2,007	,000	,000

Hipoteza H3b: Postoji statistički značajna pozitivna povezanost neizravnih novčanih transfera i namjere rađanja, mjerenje namjere rađanja M3

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Neizravni_novcani_transferi_Q9aQ10a	,359	,111	,001	1,433
	Stavovi_Q1DQ1.att	,301	,267	,259	1,351
	Subjektivne_norme_Q3SNDQ3SN_stand	1,252	,210	,000	3,498
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,128	,277	,000	3,089
	Broj_djece_Q4CDQ4C	-,696	,261	,008	,499
	Djeca_SCR1(da)	3,118	1,167	,008	22,604
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,098	,027	,000	,907
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,341	,416	,412	,711
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	1,523	,834	,068	4,588
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,244	,620	,694	1,277
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,023	,010	,022	,977
	bracni_status(udana)	-,265	,523	,612	,767
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,011	,053	,831	,989
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,765	,465	,100	2,149
	Constant	-5,276	1,119	,000	,005

Prilog 7: Povezanost transfera u naravi i namjere rađanja u sljedeće dvije godine

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M1

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Transferi_narav_Q9bQ10b	,530	,165	,001	1,699
	Stavovi_Q1DQ1.att	-,234	,354	,508	,791
	Subjektivne_norme_Q3SNDQ3SN_stand	1,029	,235	,000	2,797
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,869	,418	,000	6,482
	Broj_djece_Q4CDQ4C	-1,442	,449	,001	,237
	Djeca_SCR1(da)	9,109	1,854	,000	9040,108
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,211	,043	,000	,810
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-1,979	,661	,003	,138
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,767	1,050	,008	15,904
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,843	,822	,025	,158
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,021	,013	,117	,979
	bracni_status_3_kategorije(udana)	,870	,546	,111	2,388
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,182	,086	,034	,834
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,187	,556	,737	1,205
	Constant	-8,698	1,661	,000	,000

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M2

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Transferi_narav_Q9bQ10b	,545	,213	,011	1,724
	Stavovi_Q1DQ1.att	,077	,404	,850	1,080
	Subjektivne_norme_Q3SNDQ3SN_stand	1,440	,326	,000	4,219
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,844	,471	,000	6,321
	Broj_djece_Q4CDQ4C	-1,601	,493	,001	,202

	Djeca_SCR1(da)	9,935	2,183	,000	20632,031
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,235	,050	,000	,790
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-2,081	,785	,008	,125
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	2,598	1,171	,027	13,438
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	-1,508	1,137	,185	,221
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,029	,015	,060	,971
	bracni_status_3_kategorije(udana)	,386	,682	,571	1,471
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,178	,093	,056	,837
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,397	,713	,578	1,487
	Constant	-8,638	1,871	,000	,000

Hipoteza H3c: Postoji statistički značajna pozitivna povezanost transfera u naravi i namjere rađanja, mjerenje namjere rađanja M3

		B	S.E.	Sig.	Exp(B)
Step 1[a]	Transferi_narav_Q9bQ10b	,204	,127	,109	1,226
	Stavovi_Q1DQ1.att	,325	,266	,223	1,384
	Subjektivne_norme_Q3SNDQ3SN_stand	1,271	,209	,000	3,565
	Percipirana_kontrola_ponasanja_PBC_Q2DQ2	1,065	,273	,000	2,901
	Broj_djece_Q4CDQ4C	-,714	,256	,005	,490
	Djeca_SCR1(da)	3,491	1,160	,003	32,835
	Djeca_SCR1(da) by Godine_starosti_RESP_AGE0	-,106	,027	,000	,899
	Djeca_SCR1(da) by EDU_new(srednje ili niže) by Indeks_regije_new(I. i II. skupina)	-,357	,411	,385	,700
	Djeca_SCR1(da) by Podmirivanje_financ_obveza_Q8DQ9_binarna(poteškoće) by Vrsta_ugovora_o_radu_DM8(određeno)	1,510	,830	,069	4,527
	Sektor_zaposlenja_DM7(privatni) by Vrsta_ugovora_o_radu_DM8(određeno)	,255	,625	,683	1,291
	Godine_starosti_RESP_AGE0 by Tip_naselja_new(ruralno) by bracni_status(udana)	-,021	,010	,031	,979
	bracni_status_3_kategorije(udana)	-,249	,514	,628	,779
	Broj_clanova_kucanstva_HHSIZE1 by Djeca_SCR1(da) by ukupni_prihod_kucanstva	-,009	,052	,859	,991
	Indeks_regije_new(I. i II. skupina) by Tip_naselja_new(ruralno)	,773	,461	,093	2,167
	Constant	-4,652	1,139	,000	,010

Popis objavljenih radova

Ileš, M., Karačić, D. (2024). Reproductive changes in the population of the Republic of Croatia. *Athens journal of social sciences*, 11 (1), str. 37-52, doi: 10.30958/ajss.11-1-3

Novaković, D., **Ileš, M.**, Karačić, D. (2022). Challenges in proxy lifecycle portfolio modeling of mandatory pension funds in the Republic of Croatia. U: Barković Bojanić, I., Erceg, A. (ur.). Economics and Aging - emerging issues. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, str. 83-97

Stanić, R., **Ileš, M.**, Perić, J. (2022). Jačanje poduzetničkih kompetencija kroz primjere dobre prakse. Obrazovanje za poduzetništvo - E4E, 12(1), str. 167-183, doi: 10.38190/ope.12.1.10

Karačić, D., Bedeković, M., **Ileš, M.** (2022). Regional inequalities and non-tax revenues in the Republic of Croatia. U Leko-Šimić, M. (ur.). 11th International scientific symposium Region, Entrepreneurship, Development. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, str. 345-358.

Ileš, M. (2021). Prognoziranje pojava s trendom modelima eksponencijalnog izglađivanja. Evropska revija, 7 (13), str. 51-63.

Ileš, M. (2021). Financijska pismenost i financijsko blagostanje zaposlenika u javnom sektoru. U Sudarić, Ž., Petrašević, T. (ur.). Zbornik radova 11. međunarodna konferencije Razvoj javne uprave. Vukovar: Veleučilište „Lavoslav Ružička“ u Vukovaru, str. 154-164.

Ileš, M. (2021). Population policy and demographic revitalization in the Republic of Croatia – the financial aspect. *International journal of management and applied science*, 7(8), str. 65-71.

Krmpotić, D., **Ileš, M.**, Bičvić, D. (2020). The impact of fiscal autonomy on regional development in the Republic of Croatia. U Vinogradova, M., Pochinok, N., Bakhtina, O. et al. (ur.). 60th International Scientific Conference on Economic and Social Development – XX International Social Congress. Book of Proceedings. Varazdin Development and Entrepreneurship Agency, Varazdin, Croatia; University North, Koprivnica, Croatia; Russian State Social University, Moscow, Russian Federation; Faculty of Management University of Warsaw, Warsaw, Poland; Faculty of Law, Economics, Moskva, str. 39-48.

Karačić, D., Krmpotić, D., **Ileš, M.** (2020). Tax and own revenues of large cities in the Republic of Croatia. U Cermakova, K., Mozayeni, S., Hromada, E. (ur.). Proceedings of the 14th Economics & Finance Conference. International Institute of Social and Economic Sciences; International Society for Academic Studies, z. s., Prag, str. 89-98, doi: 10.20472/EFC.2020.014.009

Ileš, M., Hojsak, F. (2020). The impact of fiscal decentralization on the quality of life in the Republic of Croatia. *International journal of management and applied science*, str. 1-8.

Karačić, D., **Ileš, M.**, Klanac, N. (2019). Environmental incomes in the function of preserving and protecting the environment. U Barković, D., Crnković, B., Zekić Sušac, M. et al. (ur.). Interdisciplinary Management Research XV (IMR 2019): Book of Proceedings / Interdisziplinäre Managementforschung XV (IMR 2019) / Osijek: Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek Croatia; Postgraduate doctoral Study Program in Management Hochschule Pforzheim University,

Germany; Croatian Academy of Sciences and Arts, str. 1821-1838.

Karačić, D., **Ileš, M.**, Klanac, N. (2018). Tax incentives in function of developing research and development. Proceedings of the 6th International Conference "Vallis Aurea" focus on: Research & Innovation. Požega: DAAAM International Vienna, str. 169-177.

Mijoč, I., **Ileš, M.**, Brocić, B. (2018). The role of internal audit in increasing quality of business operations of insurance companies. U interdisciplinary management research. Ekonomski fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hochschule Pforzheim University of Applied Sciences, Hrvatska akademija znanosti i umjetnosti (HAZU), Opatija, str. 1356-1381.