Razvoj modela za planiranje specijalističkoga usavršavanja doktora medicine u Republici Hrvatskoj

Relić, Danko

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, School of Medicine / Sveučilište u Zagrebu, Medicinski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:105:535797

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Dr Med - University of Zagreb School of Medicine Digital Repository





SVEUČILIŠTE U ZAGREBU

MEDICINSKI FAKULTET

Danko Relić

Razvoj modela za planiranje specijalističkoga usavršavanja doktora medicine u Republici Hrvatskoj

DISERTACIJA

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU

MEDICINSKI FAKULTET

Danko Relić

Razvoj modela za planiranje specijalističkoga usavršavanja doktora medicine u Republici Hrvatskoj

DISERTACIJA

Zagreb, 2021.

Disertacija je izrađena u Katedri za medicinsku statistiku, epidemiologiju i medicinsku informatiku Škole narodnog zdravlja „Andrija Štampar“ Medicinskog fakulteta Sveučilišta u Zagrebu.

Senat Sveučilišta u Zagrebu na sjednici održanoj 15. studenoga 2016. godine prihvatio je temu disertacije s naslovom: „Razvoj modela za planiranje specijalističkoga usavršavanja doktora medicine u Republici Hrvatskoj“.

Voditeljica rada: prof. dr. sc. Jadranka Božikov

ZAHVALA

Zahvalnost na ukazanoj podršci, trudu i nesebičnoj pomoći iskazujem mentorici prof. dr. sc. Jadranki Božikov bez koje disertacije ne bi bilo.

Zahvaljujem stručnom povjerenstvu prof. dr. sc. Mirjani Kujundžić Tiljak, prof. dr. sc. Aleksandru Džakuli i prof. dr. sc. Nadi Čikeš na konstruktivnim savjetima.

Hvala svim djelatnicima Škole narodnog zdravlja "Andrija Štampar", a osobito Katedre za medicinsku statistiku, epidemiologiju i medicinsku informatiku Medicinskog fakulteta Sveučilišta u Zagrebu na podršci, pomoći i razumijevanju koje su mi pružali tijekom izrade disertacije.

Hvala prijateljima i kolegama na bezuvjetnoj moralnoj podršci i vjeri u moj uspjeh.

Disertaciju posvećujem obitelji, uz posebnu zahvalu mojoj supruzi Matei za ljubav, razumijevanje, strpljenje i podršku, kćerima Oliviji i Lauri koje su mi svakodnevni izvor motivacije i snage te mojim roditeljima Miri i Ivici na ljubavi, vjeri, trudu, odricanju, odgoju i usađenim vrlinama.

Ne vjerujte onima koji vam obećavaju lagana rješenja.
Bez žrtve se ne može sagraditi ništa veliko.

Sveti papa Ivan Pavao II.

SADRŽAJ

1. Uvod i svrha istraživanja ... 1
1.1. Modeli planiranja ljudskih resursa u sustavu zdravstva ... 4
1.1.1. Planiranje temeljem ponude (eng. *Supply forecasting*) ... 4
1.1.2. Planiranje temeljem potražnje (eng. *Demand forecasting*) ... 5
1.1.3. Planiranje temeljem praćenja potreba (eng. *Needs-based forecasting*) ... 5
1.2. Izazovi planiranja ljudskih resursa ... 6
1.3. Planiranje potreba za doktorima medicine u zdravstvenom sustavu Republike Hrvatske ... 7
1.4. Model i modeliranje ... 16
1.4.1. Vrste modela ... 16
1.4.2. Primjene sistemske dinamike u medicini i zdravstvu ... 17
1.4.3. Programski alati za modeliranje ... 17
1.5. Svrha istraživanja ... 18
2. Hipoteza ... 19
3. Ciljevi istraživanja ... 20
4. Podaci i metode rada ... 21
4.1. Podaci ... 21
4.1.1. Radni ciklus doktora medicine u Hrvatskoj ... 23
4.1.2. Raspodjela liječnika specijalista po specijalizacijama i godinama starosti ... 26
4.1.3. Liječnici koji su započeli specijalizaciju u desetogodišnjem razdoblju (2007. do 2016.) ... 27
4.1.4. Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) ... 27
4.1.5. Procjene kretanja broja stanovnika u Hrvatskoj ... 28
4.1.6. Scenariji ... 28
4.2. Metode ... 31
4.2.1. Računalne metode ... 31
4.2.2. Simboli sistemske dinamike ... 31
4.2.3. Rezervoar (Stock) vs. Pokretna traka (Conveyor) ... 32
4.3. Validacija simulacijskog modela ... 32
4.4. Etička dopusnica ... 32
5. Rezultati ... 33
5.1. Opterećenje specijalista - Ocjena sadašnjeg stanja ... 33
5.1.2. Primarna zdravstvena zaštita ... 33
5.1.3. Specijalističko-konzilijarna zdravstvena zaštita ... 42
5.2. Konceptualni model ... 54
5.2.1. Osnovna struktura modela ... 54
5.3. Simulacijski model ... 56
5.3.1. Model po fazama radnog ciklusa liječnika ... 58

5.4. Rezultati simulacijskih eksperimenata 60
5.4.1 Scenarij 1 60
5.4.2. Scenarij 2 63
5.4.3. Scenarij 3 66
5.4.4. Scenarij 4 69
5.4.5. Scenarij 5 72
5.5. Validacija modela 76
6. Rasprava 77
7. Zaključci 90
8. Sažetak 94
9. Summary 95
10. Literatura 96
11. Životopis 104
Prilog 105
Grafički prikaz broja liječnika specijalista na 100.000 stanovnika (Izvor: Eurostat) 105

POPIS KRATICA I AKRONIMA

AZVO	Agencija za visoko obrazovanje
CEZIH	Centralni zdravstveni informacijski sustav Republike Hrvatske
DZS	Državni zavod za statistiku
EU	Europska unija
FINA	Financijska agencija
HLK	Hrvatska liječnička komora
HZJZ	Hrvatski zavod za javno zdravstvo
HZMO	Hrvatski zavod za mirovinsko osiguranje
HZZ	Hrvatski zavod za zapošljavanje
HZZO	Hrvatski zavod za zdravstveno osiguranje
HZZZSR	Hrvatski zavod za zaštitu zdravlja i sigurnost na radu
MIZ	Ministarstvo zdravstva
OECD	*Organisation for Economic Co-operation and Development*
OM	Obiteljska medicina
PC	*Personal computer* (Osobno računalo)
PZZ	Primarna zdravstvena zaštita
RH	Republika Hrvatska
SAD	Sjedinjene Američke Države
SKZZ	Specijalističko-konzilijarna zdravstvena zaštita
STELLA	*Systems Thinking, Experimental Learning Laboratory with Animation*
UK	Ujedinjeno Kraljevstvo
WHO	*World Health Organization* (Svjetska zdravstvena organizacija)

1. Uvod i svrha istraživanja

Osiguranje adekvatnog i održivog broja radnika u zdravstvu, sa odgovarajućim znanjima i vještinama, ključno je pitanje zdravstvene politike širom svijeta, a kako bi se osigurali zahtjevi za zdravstvenom zaštitom u skladu s demografskim, geografskim, tehnološkim, kulturnim, političkim, socioekonomskim i epidemiološkim čimbenicima (1–3).

Nedostatak odgovarajuće politike planiranja i upravljanja ljudskim resursima u mnogim zemljama ima za posljedicu kroničnu neravnotežu s višestrukim učinkom na zaposlenike u zdravstvu: kvantitativna neravnoteža, kvalitativne razlike, neravnomjerna raspodjela i nedostatak koordinacije između pojedinih aktivnosti u upravljanju ljudskim resursima (1, 4).

Iako je određivanje optimalnog omjera između broja zdravstvenih djelatnika i stanovnika sastavni dio nacionalnih politika upravljanja ljudskim resursima u zdravstvu, u većini slučajeva ostao je raskorak između planova i njihova ostvarenja (5).

Stvaranje i "oblikovanje" populacije zdravstvenih djelatnika pod istodobnim je utjecajem dvaju glavnih determinirajućih procesa: s jedne strane odvija se proces izobrazbe, a s druge proces prestanka profesionalne aktivnosti odnosno zaposlenja. Broj i struktura zdravstvenih djelatnika često su značajno modificirani migracijama među državama, ali i unutarnjim migracijama (preseljenje u drugo mjesto stanovanja i/ili rada). Kod planiranja obrazovanja zdravstvenih djelatnika, pa tako i doktora medicine specijalista različitih specijalnosti koji su predmet ovog istraživanja, i dalje je temeljno pitanje koliko je liječnika potrebno obrazovati za zadovoljenje zdravstvenih potreba stanovništva i izbjeći stvaranje manjka ili viška (6–9).

Problemi vezani uz planiranje, obrazovanje i korištenje znanja i sposobnosti zdravstvenih djelatnika odavno su prepoznati u najrazvijenijim zemljama svijeta. Morris je 1957. godine upozorio na mogući problem “viška“ liječnika u Ujedinjenom Kraljevstvu (10), a 1970. godine su u Sjedinjenim Američkim Državama za razdoblje do 1990. godine predvidjeli katastrofalan “višak“ od 70.000 liječnika (11). Rasprave oko teorije i prakse viška odnosno manjka zdravstvenih djelatnika dosežu vrhunac krajem osamdesetih i početkom devedesetih godina. Tada je naglašeno da bi učinkovita politika rješavanja problema zapošljavanja liječnika prije provedbe trebala imati odgovore na pitanja kvalitetne i kontinuirane izobrazbe liječnika, njihove iskorištenosti i učinkovitosti rada, funkcije u odnosu na druge zdravstvene djelatnike, odabira specijalizacije i geografske raspodjele (11, 12).

Važnost adekvatnog praćenja broja liječnika vidi se po tome što je kao razlog krive procjene broja liječnika u Ujedinjenom Kraljevstvu (10), SAD-u (11) i Kanadi navedena činjenica da se nije raspolagalo osnovnim znanjem koje bi pomoglo u analizi njihove distribucije, kao i to da statističko praćenje podataka o liječnicima ne zadovoljava (13).

Dugoročno planiranje kadrovskih potreba trebalo bi biti utemeljeno na brojnim podacima i pretpostavkama: osim početnog broja, dobne i spolne strukture, kako aktivnih doktora tako i studenata medicine, potrebno je uključiti i podatke (pretpostavke ili predviđanja) o kretanju stanovništva (korisnika zdravstvene zaštite), promjene u radnom i zdravstvenom zakonodavstvu, ali i gospodarske mogućnosti države i pojedinaca. Posljednjih godina posebna pozornost pridaje se planiranju ljudskih resursa u razvijenim zemljama, te su mnoge zemlje definirale potrebe za radnicima kako je prikazano u tablici 1.

Tablica 1. Planiranje potreba za zdravstvenim radnicima u pojedinim zemljama (14)

DRŽAVA	INSTITUCIJA	GODINA DONOŠENJA PLANA	STRUKE OBUHVAĆENE PLANIRANJEM	RAZDOBLJE PLANIRANJA
Australija	Radnici u zdravstvu Australije	2012.	Liječnici, medicinske sestre/tehničari, primalje	2010. do 2025.
Belgija	Federalna javna služba	2009.	Liječnici	2004. do 2035.
Kanada	Institut zdravlja Kanade	2007.	Liječnici	2000. do 2025,
Kanada	Kanadski zbor medicinskih sestara	2009.	Medicinske sestre/tehničari	2007. do 2022.
Kanada	Ministarstvo zdravstva	2009.	Liječnici	2008. do 2030.
Čile	Ministarstvo zdravstva	2009.	Liječnici specijalisti u javnim bolnicama	2009. do 2012.
Danska	Nacionalni odbor za zdravstvo	2010.	Liječnici	2010. do 2030.
Finska	Ministarstvo rada i gospodarstva, Ministarstvo obrazovanja	2011.	Cijelo tržište rada	2008. do 2025.
Francuska	Ministarstvo zdravstva	2009./2011.	Liječnici/Medicinske sestre	2006. do 2030.
Njemačka	Federalno povj.	2010.	Medicinske sestre	2005. do 2025.

Njemačka	Federalno povjerenstvo	2012.	Liječnici u ambulantama	Godišnje odobravanje / otvaranje ambulanti
Irska	Centar za obuku i zapošljavanje	2009.	Svi zdravstveni radnici	2008. do 2020.
Izrael	Ministarstvo zdravstva	2010.	Liječnici i medicinske sestre	2009. do 2025.
Italija	Ministarstvo zdravstva		Liječnici (22 specijalnosti)	Godišnje odobravanje specijalizacija
Japan	Nacionalno povjerenstvo za socijalnu sigurnost	2008.	Svi zdravstveni radnici	2007. do 2025.
Japan	Ministarstvo zdravstva, rada I socijalne skrbi	2006.	Liječnici	2005. do 2040.
Japan	Ministarstvo zdravstva, rada i socijalne skrbi	2010.	Medicinske sestre	2011. do 2015.
Južna Koreja	Korejski institut za zdravstvo i socijalnu skrb	2012.	15 zdravstvenih struka (uključujući liječnike i medicinske sestre)	2010. do 2025.
Nizozemska	Savjetodavni odbor za planiranje radne snage u zdravstvu	2010.	Liječnici i stomatolozi	2010. do 2028.
Norveška	Norveški zavod za statistiku	2012.	Zdravstveni radnici	2010. do 2035.
Švicarska	Švicarski zdravstveni observatorij	2008.	Liječnici u ambulantama	2005. do 2030.
Švicarska	Švicarski zdravstveni observatorij	2009.	Zdravstveni radnici	2006. do 2020.
Velika Britanija	Centar za ljudske resurse	2012.	Liječnici u NHS	2011. do 2040.
Sjedinjene Američke Države	Nacionalni centar za analizu radne snage u zdravstvu		Liječnici i medicinske sestre	2010. do 2030.

Planiranje uravnoteženog broja potrebnih doktora medicine specijalista komplicira se i problemom odabira željene specijalizacije od strane potencijalnih kandidata. Neke specijalizacije su mnogo atraktivnije i za njih ima puno više kandidata te za takve postoji mogućnost izbora najkvalitetnijih kandidata, dok istovremeno postoji opasnost od negativne selekcije za manje atraktivne specijalizacije. Preferiranje nekih specijalizacija postoji već i za vrijeme studija, kada se počinju formirati stavovi i sklonosti, a koje mogu kasnije kod izbora specijalizacije rezultirati frustracijama (6).

1.1. Modeli planiranja ljudskih resursa u sustavu zdravstva

Mnoge zemlje suočene su s nedostatnim ljudskim resursima za pružanje osnovne zdravstvene skrbi, a za to postoje brojni razlozi: nedostatan broj radnika, emigracija, neodgovarajuća znanja i vještine te nepovoljna demografska slika korisnika zdravstvene zaštite (15, 16). Postoje različiti modeli planiranja ljudskih resursa u zdravstvu.

1.1.1. Planiranje temeljem ponude (eng. *Supply forecasting*)

Planiranje potrebnog broja i strukture zdravstvenih radnika može se provoditi temeljem zatečenog stanja uz pretpostavku da je zatečeni broj zdravstvenih radnika kako pojedine zdravstvene ustanove, tako i sustava u cjelini odgovarajući te se planira samo njihova reprodukcija tj. nadomještanje resursa. Planiranje temeljem ponude temelji se na procjeni potrebnog broja liječnika koji će zadovoljiti potrebe stanovništva na postojećoj razini zdravstvene zaštite. Prednost ovog modela je što s velikom preciznošću može procijeniti potrebe u narednih 10 do 15 godina. Nedostatak je što se temelji na pretpostavci da je trenutni odnos broja liječnika i populacije dobar te ne razmatra opciju da će se potrebe za zdravstvenom zaštitom u nadolazećem razdoblju povećavati (3, 17–23).

U planiranju ljudskih resursa temeljem ponude potrebno je voditi računa o svim oblicima ulaska i izlaska zdravstvenih radnika iz sustava. Izlazak iz sustava uključuje umirovljenje, bolest ili smrt, promjene u karijeri, smanjenje broja radnih sati i emigraciju. Ulazak u sustav uključuje diplomante na studijima medicine, imigrante, promjene u karijeri s ulaskom u sustav zdravstva, povećanje broja radnih sati, te kasniji odlazak u mirovinu (15, 24). U nastojanju da se razvije kvalitetna i kompetentna radna snaga, mnoge zdravstvene ustanove usredotočene su na zapošljavanje i edukaciju zdravstvenih radnika bez sustavnog planiranja, odnosno više su fokusirane na ulazak u sustav nego na izlazak iz sustava (25).

1.1.2. Planiranje temeljem potražnje (eng. *Demand forecasting*)

Osim zatečenog stanja, pri planiranju ljudskih resursa u sustavu zdravstva koriste se i drugi parametri kao što su broj pruženih usluga ili primjena novih tehnologija i metoda rada. Takav model temelji se na potražnji odnosno zahtjevima stanovništva u kojem se broj liječnika procjenjuje temeljem broja pruženih zdravstvenih usluga na određenu populaciju u prethodnom razdoblju (17, 26–28).

Prednost planiranja temeljem potražnje je u uvažavanju promjene na razini zdravstvenih usluga i zdravstvenog sustava (uvođenje novih tehnologija i/ili novih lijekova). Uvođenje novih tehnologija svakako mora utjecati na planiranje broja zdravstvenih radnika, bilo da se radi o automatizaciji poslovnih procesa koji mogu zahtijevati manji broj radnika ili uvođenje novih tehnologija koje zahtijevaju promjenu obrazovne strukture ili broja radnika sa specifičnim znanjima. Nedostatak ovog modela je što se temelji na postojećoj razini korištenja usluga, ne uvažava moguću ulogu preventivnih procedura što može u budućem razdoblju smanjiti potrebe za uslugama te zahtijeva veliku količinu podataka (17, 26–28).

1.1.3. Planiranje temeljem praćenja potreba (eng. *Needs-based forecasting*)

Planiranje broja liječnika može se provoditi temeljem praćenja zdravstvenih potreba stanovništva pri čemu se koriste različiti epidemiološki podaci. U ovom modelu kao osnova za planiranje koriste se stvarne potrebe stanovništva. Potrebe se odnose na broj zdravstvenih radnika ili broj zdravstvenih usluga potrebnih za postizanje optimalnog broja usluga kojima se osigurava zdravlje stanovništva. Ovaj model kombinira podatke o zdravstvenom stanju stanovništva i učestalost pojedinih bolesti, demografske podatke i podatke o standardu zdravstvenih usluga. Nedostatak ovog modela je što zahtjeva detaljna znanja o efikasnosti pojedinih procedura u liječenju zdravstvenih stanja, a uz to ne uvažava napredak tehnologije i promjene u organizaciji zdravstvene zaštite (3, 17, 28–30).

Zdravstvena administracija, Ministarstvo zdravstva (MIZ) i Hrvatski zavod za zdravstveno osiguranje (HZZO) putem različitih propisa i provedbenih akata imaju utjecaj na planiranje ljudskih resursa u zdravstvenim ustanovama u sustavu javnog zdravstva i to na način da definiraju standarde potrebnog broja liječnika (31). Do standarda broja liječnika može se doći empirijski ili usporednom analizom (eng. *benchmarking*) koja se temelji na identifikaciji regije ili zemlje koje su slične u svojim demografskim i zdravstvenim karakteristikama, ali se znatno razlikuju u troškovima zdravstvene zaštite i iskorištenosti zdravstvenih kapaciteta.

Nedostatak ovog modela je što je primjenjiv jedino ukoliko se pronađu usporedive regije (3, 17, 28, 32).

Svi prikazani modeli mogu se koristiti pojedinačno ili u različitim kombinacijama, što je puno češći slučaj (24).

Planiranje ljudskih resursa u zdravstvu nije egzaktna znanost, a modeli na kojima se temelji uključuju niz pretpostavki o tome kako očekujemo da će se pojedini čimbenici na strani ponude i potražnje kretati u budućnosti. Svi modeli zahtijevaju redovito ažuriranje podataka uzimajući u obzir promjene gospodarskog okruženja i okruženja pružanja zdravstvenih usluga kao i praćenje utjecaja različitih politika planiranja ljudskih resursa i scenarija (15).

1.2. Izazovi planiranja ljudskih resursa

Sve zemlje koje provode planiranje ljudskih resursa u zdravstvenom sustavu suočavaju se sa sličnim izazovima (24).

Izazov dostupnosti podataka jedan je od prvih izazova u planiranju ljudskih resursa, a radi se o utvrđivanju trenutne situacije kao polazne pozicije za planiranje i dostupnost podataka, posebno ukoliko ne postoje jedinstveni registri u kojima se mogu pronaći strukturirani podaci o zdravstvenim radnicima. Nadalje, kod planiranja ljudskih resursa potreban je cijeli niz demografskih podataka, podataka o korištenju zdravstvene zaštite (broj i vrsta usluga), vrsti i iskorištenosti zdravstvenih resursa (15).

Demografski izazovi prisutni su posebno u razvijenim zemljama koje su suočene sa starenjem populacije pri čemu se relativno smanjuje broj mlađeg stanovništva, a povećava se udio stanovnika treće životne dobi koji će trebati sve više zdravstvenih usluga u budućnosti. Sve relevantne projekcije pokazuju smanjenje broja stanovnika Hrvatske u sljedećim desetljećima. U Hrvatskoj će 2051. godine biti 3.456.866 stanovnika dok će se broj osoba dobi preko 65 godina povećati za više od 20% (s 888.304 u 2021. g. na 1.068.133 u 2051. g.) (33).

Financijski izazovi posebno su važni u vrijeme recesije. Trošak za radnike u zdravstvu predstavlja oko 70% troška zdravstvene zaštite u cjelini. Ukoliko se potreba za zdravstvenim uslugama poveća u budućnosti kao rezultat starenja populacije, potrošnja za zdravstvo će se također povećati (34).

Izazov koordinacije predstavlja važan izazov s obzirom da planiranje ljudskih resursa zahtijeva koordiniranu akciju svih dionika u zdravstvenom sustavu (15). Zdravstveni sustav u RH je djelomično decentraliziran, te uz zdravstvene ustanove u vlasništvu države postoje i zdravstvene ustanove u vlasništvu područne samouprave koja upravlja, a dijelom sudjeluje i u financiranju zdravstvene zaštite. S druge strane dodiplomska edukacija zdravstvenih radnika u potpunosti je u ingerenciji ministarstva nadležnog za obrazovanje i znanost. Slijedom prethodno napisanog, uz resorno ministarstvo u planiranje ljudskih resursa trebale bi se uključiti i druge nadležne institucije (31).

Izazov implementacije strategije ili prihvaćenog modela planiranja ljudskih resursa prisutan je prije svega zbog propisa (zakoni, pravilnici, kolektivni ugovori), organizacije zdravstvenog sustava koji je djelomično decentraliziran, vlasništva nad ustanovama, sustava upravljanja i slično.

Izazov distribucije prisutan je zbog urbano-ruralne razlike i zadovoljavanja potreba za zdravstvenim radnicima u ruralnim područjima što predstavlja izazov planiranja ljudskih resursa u mnogim zemljama (35, 36). U Hrvatskoj je utvrđena statistički značajna razlika u broju liječnika na 100.000 stanovnika između pretežno urbanih i pretežno ruralnih županija (37). Glavni razlog neujednačene raspodjele liječnika je koncentracija kliničkih bolničkih ustanova prvenstveno u gradu Zagrebu, ali i u drugim regionalnim središtima Rijeci, Splitu i Osijeku, te nedovoljna zainteresiranost liječnika za rad u manjim gradovima, a osobito nedovoljni interes za rad u primarnoj zdravstvenoj zaštiti, poglavito u ruralnim područjima. Već za vrijeme pripravničkog staža liječnici preferiraju rad u Zagrebu i nerado odlaze u druge krajeve Hrvatske. Glavni razlozi odlaska liječnika iz ruralnih područja su profesionalna opterećenost, razlozi vezani uz stil života, obiteljske obveze i nedostatak stručne potpore u ruralnim područjima (16).

Neravnomjerna raspodjela liječnika između urbanih i ruralnih županija utječe na opterećenost rada liječnika PZZ s naglaskom na opću/obiteljsku medicinu, pri čemu liječnici u ruralnim sredinama u prosjeku imaju više osiguranika u skrbi od liječnika u urbanim sredinama što direktno utječe na razinu dostupnosti PZZ (36).

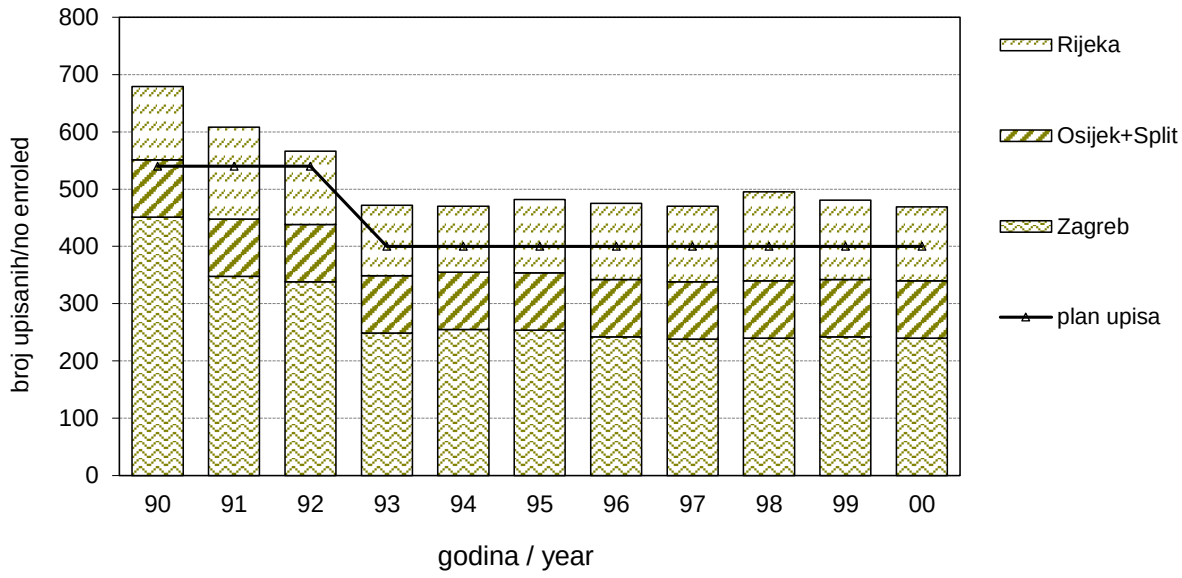
1.3. Planiranje potreba za doktorima medicine u zdravstvenom sustavu Republike Hrvatske

Planiranje zapošljavanja doktora medicine u sklopu specijalističkog usavršavanja provodi se na način da zdravstvena ustanova utvrđuje plan specijalističkog usavršavanja za svaku

kalendarsku godinu, te Ministarstvo zdravstva izdaje suglasnost na plan specijalističkog usavršavanja. Tek nakon dobivanja suglasnosti MIZ-a na plan specijalističkog usavršavanja, provodi se natječaj za specijalističko usavršavanje te se zapošljavaju specijalizanti različitih profila (38–43) .

Uz ovaj opis administrativnog postupka planiranja potreba za specijalizantima, sustavu trenutačno nedostaje dugoročni plan potreba za specijalizantima. Svake godine je potrebno evaluirati proteklo razdoblje, aktualno stanje i po potrebi raditi korekcije. Važno je naglasiti da je dosadašnja praksa rezultirala neravnomjernom geografskom raspodjelom liječnika u Hrvatskoj te starijom dobi specijalista - prosječna dob specijalista je 51 godina (44).

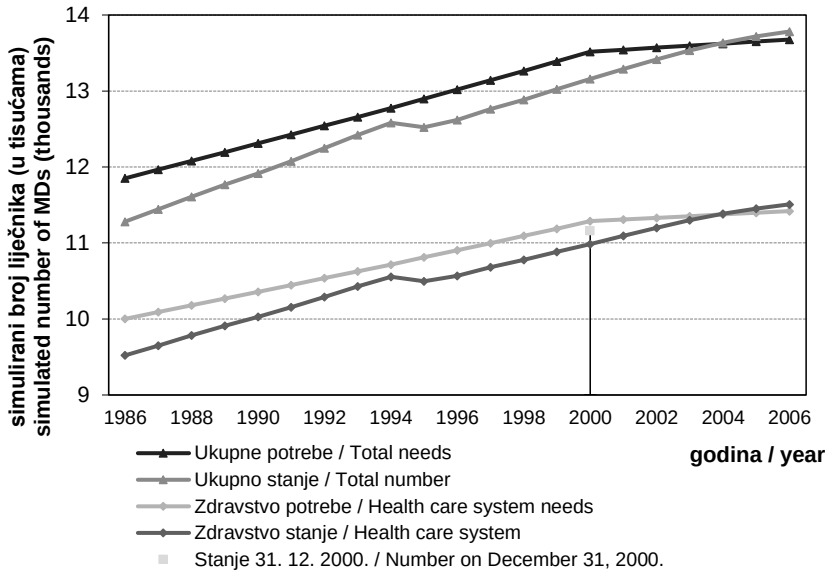
U literaturi možemo pronaći svega nekoliko radova na temu regionalne raspodjele te planiranja potreba za liječnicima u Hrvatskoj (6, 35, 37, 45–51). Zajednica zdravstvenih fakulteta SR Hrvatske imenovala je u veljači 1989. radnu skupinu čiji je zadatak bio izraditi procjenu potreba za zdravstvenim kadrovima različitih profila do 2000. godine. Radna skupina čije je osnivanje bilo potaknuto raspravama o upisnim kvotama na zdravstvene fakultete i prijedlozima za njihovo smanjivanje prihvatila je prijedlog da se kao metoda upotrijebi simulacija stanja i potreba za različitim profilima zdravstvenih stručnjaka te je izrađen model kojim je izveden niz simulacijskih eksperimenata s različitim pretpostavkama o broju upisanih studenata i drugim relevantnim aspektima, a rezultati su poslužili kao osnovica za donošenje upisne politike (52). Jedan od zaključaka Radne skupine bio je da treba smanjiti upisne kvote te su kvote smanjene s 540 na 450 tek ak. godine 1993./94. i takve su zadržane do početka 2000-ih kada su upisne kvote opet povećane. Tih godina je bilo skoro tisuću nezaposlenih liječnika evidentiranih od strane Hrvatskog zavoda za zapošljavanje (53). Povećanje upisnih kvota za domaće studente na medicinske fakultete u Hrvatskoj dogodilo se posljednji put 2009.g. Medicinski fakultet Sveučilišta u Zagrebu je upisne kvote povećao s 240 na 300.



Slika 1. Studenti upisani na četiri medicinska fakulteta u Hrvatskoj u razdoblju 1990.-2000. po godinama.

(Podaci za Zagreb i Rijeku dobiveni od studentskih referada, a za Split i Osijek zajedno procjena na 100 godišnje. Linijom je prikazan godišnji plan broja upisanih prema usvojenoj varijanti od 540 upisanih iz 1989. revidiranoj na 400 upisanih od 1993. na dalje prema prijedlogu iz 1993.)

Osim upisnih kvota i druge promjene su imale veliki značaj za broj liječnika kao npr. prelazak s petogodišnjeg na šestogodišnji studij medicine (upisani u prvu godinu studija ak. god. 1990./1991.) čime je "izgubljena" cijela jedna generacija liječnika.



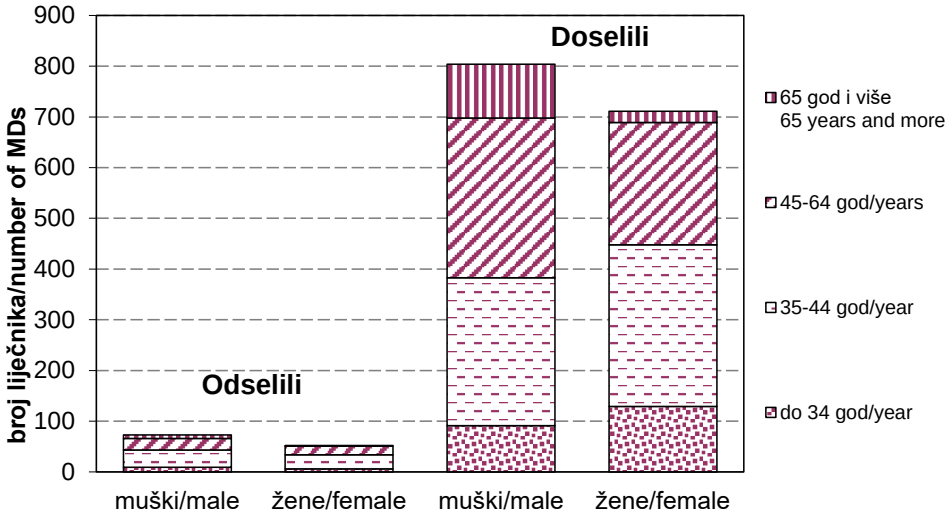
Slika 2. Rezultati simulacije stanja i potreba za liječnicima u Hrvatskoj do 2006 uz 540 upisanih studenata godišnje. (46)

(Kvadratićem je označen broj liječnika zaposlenih u zdravstvenim ustanovama i privatnoj praksi 31. prosinca 2000.)

Prije Domovinskog rata Hrvatska je bila umjereno razvijena europska zemlja s dostatnim brojem liječnika (210 na 100.000 stanovnika) i tradicionalno kvalitetnom preventivnom medicinom. Rat i agresija na Hrvatsku 1991./92. g. rezultirali su desecima tisuća ubijenih i ranjenih osoba (više od 7.000 osoba s amputacijama). Ukupno je bilo preko 60.000 žrtava rata kojima je bila potrebna rehabilitacija. Tijekom i nakon rata, zdravstveni sustav suočio se ne samo s ratnim posljedicama, već i s nedostatkom resursa (49).

Ratna zbivanja na području Republike Hrvatske od 1990. do 1998. godine utjecala su na demografsku strukturu stanovništva, društveno-ekonomske uvjete i zdravlje populacije. Posljedice tog štetnog utjecaja su dugoročne i jasno vidljive u zdravstvu i stanju zdravlja stanovništva pa danas bilježimo povećanu smrtnost kod određenih, stresom induciranih bolesti, neuropsihijatrijska stanja izazvana PTSP-om, povećanu stopu samoubojstava te kao izravnu posljedicu rata financijsko opterećenje po cijeli zdravstveni sustav (54).

S početkom Domovinskog rata u RH uselilo se čak 1.515 doktora uglavnom iz drugih republika bivše Jugoslavije, dok je tek 124 onih koji su iselili (55).



Slika 3. Broj liječnika koji su odselili odnosno doselili u Republiku Hrvatsku u razdoblju 1. 1. 1990. – 31. 7. 2000. po spolu i dobi koju bi imali 2000. godine.

Izvor podataka statistika stanovnika Ministarstva unutarnjih poslova RH

Prema podacima studentske referade Medicinskog fakulteta Sveučilišta u Zagrebu na medicinske fakultete prešlo je više od 300 studenata samo u nekoliko godina počevši od ak. godine 1990./91. i to u dva vala (prvi val iz Kosova nakon zatvaranja škola i fakulteta, te drugi val iz Bosne i Hercegovine po početku rata 1993.g.). Ukupno je na taj način samo na Medicinski fakultet Sveučilišta u Zagrebu primljeno 320 studenata na 2. do 5. godinu studija u desetogodišnjem razdoblju od ak. god. 1990./91.

Mnoge zemlje svijeta nastoje javne zdravstvene usluge učiniti dostupnima što većem dijelu stanovnika, a po mogućnosti i ukupnom stanovništvu. To iziskuje velik i rasprostranjen sustav zdravstva koji troši mnogo javnog novca, a zbog problema u upravljanju takvim sustavom javljaju se neučinkovitosti. Stoga se često provode reforme kako bi zdravstveni sustav postao učinkovitiji, a korištenje resursa racionalnije (56).

Od neovisnosti 1991.g., hrvatski zdravstveni sustav svjedoči, kao i mnogi drugi diljem Europe, stalno prisutnoj neusklađenosti između javno dostupnih sredstava i sve većih izdataka. Proveden je niz reformi kojima su se pokušali riješiti problemi koji su uzrokovali eskalaciju krize; najznačajnije za financiranje zdravstvene zaštite provedene su 1990., 1993. i 2002.g. Reforma 1990.g. centralizirala je prethodno decentralizirani sustav prikupljanja sredstava i razdvojene regionalne sustave upravljanja pružateljima zdravstvenih usluga. Reforme iz 1993. i 2002. usredotočene su na ograničavanje potrošnje. 1993.g. smanjen je

opseg besplatnih zdravstvenih usluga koje su do tada građani mogli koristiti (57). 2002.g. dodatno je smanjen opseg usluga pokrivenih u potpunosti obveznim zdravstvenim osiguranjem tj. povećana je participacija za niz zdravstvenih usluga, uvedeno je dopunsko osiguranje čija je svrha bila pokrivanje razlike između pune cijene zdravstvene usluge i cijene koja se podmiruje putem HZZO-a i smanjena je najniža visina naknade za bolovanje s 80% na 70% osnovice za naknadu (58). Reforme su se uglavnom koncentrirale na prihodovanje dodatnih financijskih sredstava u sustav financiranja i preusmjeravanje zdravstvenih troškova s javnih na privatne izvore. Pritom je ugroženo načelo dostupnosti zdravstvenih usluga, dok problemi relativno visoke zdravstvene potrošnje i neučinkovitosti nisu odgovarajuće riješeni (57).

Primarna zdravstvena zaštita (PZZ) je uz nedostatak resursa nakon 90-ih pretrpjela značajne promjene. Prva promjena, uvedena 1993.g., odnosila se na slobodan odabir liječnika PZZ. Odgovornost s liječnika PZZ koji su pokrivali određeni teritorij prelazi na pacijente koji ih odabiru. Svojevrsna "privatizacija" PZZ dogodila se 1996.g. stupanjem na snagu Pravilnika o uvjetima za davanje u zakup zdravstvenih ustanova PZZ i lječilišta kojom je dobar dio liječnika postao privatnim poduzetnicima. Odluka o obustavi investicijskih ulaganja u zdravstvenim ustanovama uključenim u mrežu zdravstvene djelatnosti Republike Hrvatske iz 1997.g. kojom sredstva za investicijska ulaganja prethodno planirana centralno na nacionalnoj razini postaju odgovornost jedinica područne (regionalne) samouprave (51).

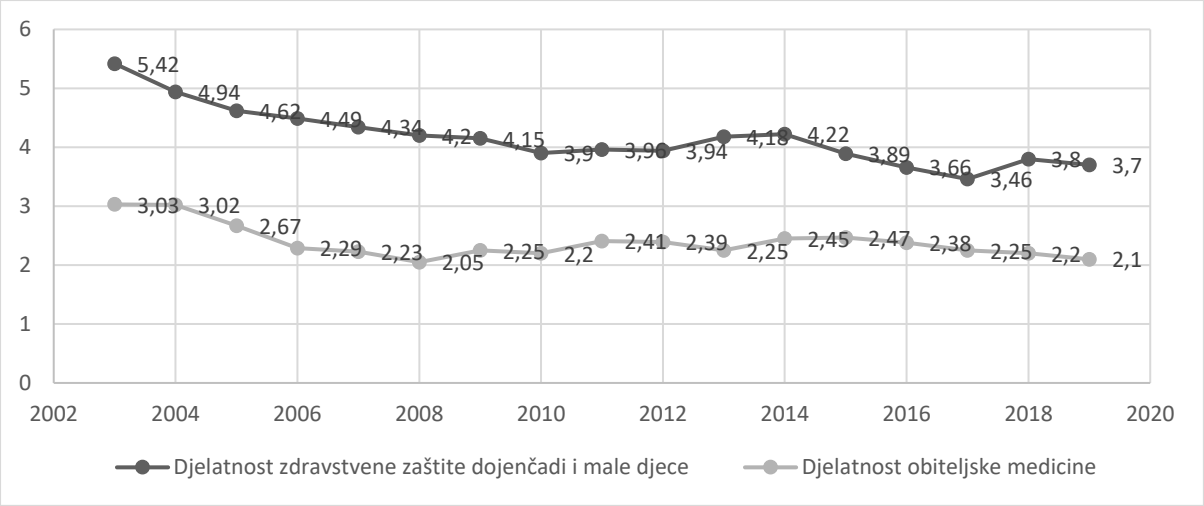
Ministarstvo zdravstva je 1996.g. po prvi puta ustrojilo Mrežu javne zdravstvene službe (u daljem tekstu: Mreža) prema kojoj je određen potreban broj timova u PZZ i ona se nije značajnije mijenjala do današnjih dana. Prema tom dokumentu mjerila za određivanje Mreže uključuju: ukupan broj stanovnika Republike Hrvatske, ukupan broj osiguranih osoba Hrvatskog zavoda za zdravstveno osiguranje, demografske karakteristike stanovnika, zdravstveno stanje stanovništva, socijalnu strukturu stanovnika, gravitirajući broj stanovnika, karakteristike pojedinih područja, raspoloživost zdravstvenim resursima, utjecaj okoliša na zdravlje stanovništva i gospodarske mogućnosti. Prema definiranoj Odluci o osnovama za sklapanje ugovora o provođenju zdravstvene zaštite iz obveznog zdravstvenog osiguranja za PZZ u djelatnosti obiteljske medicine je 1.700 po timu/liječniku, u djelatnosti zdravstvene zaštite predškolske djece 950 dok je u djelatnosti zdravstvene zaštite žena to 6.000 pacijentica po timu (59). Iz podataka prikazanih u tablici 2 evidentan je nedostatak liječnika u PZZ uzmemo li kao referentnu vrijednost Mrežom definirani standardni broj pacijenata po timu.

Tablica 2. Prikaz broja timova i osiguranika po timu u PZZ
(Izvor: Hrvatski zdravstveno-statistički ljetopisi, HZJZ)

Godina	2010	2011	2012	2013	2014	2015	2016	2017	2018
OPĆA/OBITELJSKA MEDICINA									
Broj timova	2.285	2.286	2.311	2.310	2.275	2.305	2.300	2.318	2.286
Prosječan broj osiguranika po timu	1.802	1.840	1.847	1.806	1.837	1.788	1.803	1.772	1.794
ZDRAVSTVENA ZAŠTITA PREDŠKOLSKE DJECE									
Broj timova	253	258	271	273	273	276	277	280	280
Prosječan broj osiguranika po timu	1.556	1.445	1.517	1.481	1.498	1.430	1.424	1.440	1.518
ZDRAVSTVENA ZAŠTITA ŽENA (ugovor s HZZO)									
Broj timova	229	227	231	250	259	261	263	265	265
Prosječan broj osiguranika po timu	6.706	6.486	6.737	6.505	6.459	6.581	6.380	6.537	6.509
ZDRAVSTVENA ZAŠTITA ŽENA (bez ugovora s HZZO)									
Broj timova	65	70	60	49	53	43	46	42	46
Prosječan broj korisnika po timu	1.558	1.640	1.889	1.345	1.516	1.267	1.302	1.329	1.212

Na strukturu specijalnosti u PZZ do 2005. godine utjecala je stagnacija i pad broja specijalista opće medicine i pedijatrije, te ulaz u sustav određenog broja specijalista školske medicine nakon razdvajanja preventive i kurative u djelatnosti školske medicine 1998. godine. Nakon ovog negativnog trenda, 2006. godine povećan je ukupni broj specijalista obiteljske medicine. Rezultat je to projekta Ministarstva zdravstva i Škole narodnog zdravlja „Andrija Štampar" Medicinskog fakulteta Sveučilišta u Zagrebu koji je počeo 2002. godine, a po kojem će u sljedećih 15 do 20 godina većinu liječnika obiteljske medicine činiti specijalisti. Od 1995. godine iz djelatnosti PZZ izvješćuje se o ukupnom broju osiguranika u skrbi te posebno o broju onih osiguranika koji su u tekućoj godini koristili zdravstvenu zaštitu (broj korisnika). U skrbi timova primarne zdravstvene zaštite u 2019. godini zabilježeno je 4.357.406 osiguranika od kojih je bilo 3.310.976 korisnika (76,0% od ukupnog broja osiguranika). U odnosu na 2018. godinu, iskazani broj osiguranika i korisnika smanjen je, vjerojatno zbog manjeg broja pristiglih izvješća. U djelatnosti opće/obiteljske medicine, u 2019. godini, zdravstvenu zaštitu koristilo je 75,6% osiguranika, a u djelatnosti za zdravstvenu zaštitu dojenčadi i male djece 80,6%, što je neznatno manje nego prethodne godine. U 2019. godini zabilježeni broj posjeta u liječničkim ordinacijama bio je 39.645.165 ili za 2,1% manje nego u odnosu na 2018. godinu. Broj posjeta bez pregleda u ordinaciji zabilježen tijekom 2019. godine iznosi 26.752.292. Od 1995. godine prati se i broj upućivanja na specijalističke preglede: 2019. godine zabilježeno je 5.924.905 upućivanja od strane timova primarne

zdravstvene zaštite, što je za 1,2% manje nego u 2018. godini. U djelatnosti opće/obiteljske medicine u 2019. godini jedno upućivanje specijalisti dolazi na 2,1 pregleda, a u djelatnosti za zdravstvenu zaštitu dojenčadi i male djece na 3,7 pregleda – slika 4 (60).



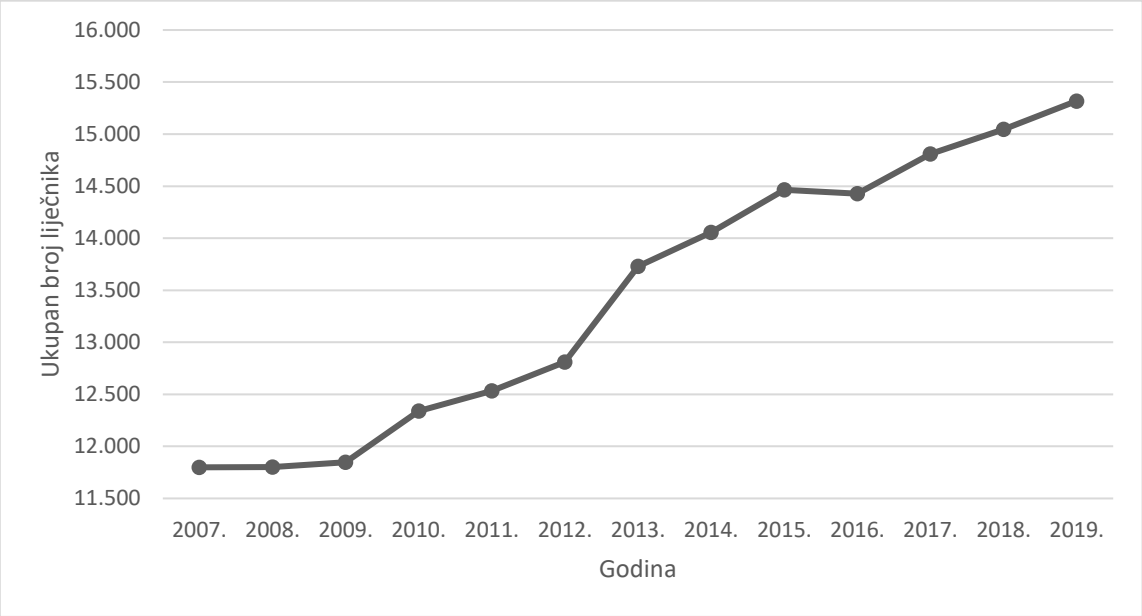
Slika 4. Broj pregleda na jedno upućivanje na specijalističko-konzilijarni pregled u djelatnosti obiteljske medicine i djelatnosti zdravstvene zaštite dojenčadi i male djece u Hrvatskoj u razdoblju od 2003. do 2019.g.

Prema Nacionalnoj strategiji razvitka zdravstva 2006. – 2011. broj liječnika na 1.000 stanovnika prati europski smjer razvoja, koji je u porastu, pa tako Republika Hrvatska i tu bilježi zdrav i konstantan uzlazni trend tijekom posljednjih 20 godina. No, budući da 2004. u Republici Hrvatskoj djeluju 2,3 liječnika na 1.000 stanovnika, dok je EU prosjek 3,3 liječnika na 1.000 stanovnika, trend bi trebao rasti strmije kako bi Republika Hrvatska dostigla EU prosjek (54).

Studija o regionalnoj raspodjeli liječnika u Hrvatskoj provedena 2006.g. pokazala je da postoje značajne razlike u broju liječnika na 100.000 stanovnika između županija. Na primjer, broj liječnika opće/obiteljske medicine kretao se od 47,1 u Požeško-slavonskoj županiji do 61,8 u Primorsko-goranskoj županiji (državni prosjek bio je 54,2) (61). Također, postojale su značajne razlike u broju specijalista na 100.000 stanovnika između županija (35).

Nacionalna strategija razvoja zdravstva 2012. – 2020. ističe kao jedan od temeljnih problema planiranja razvoja ljudskih resursa u zdravstvu nepostojanje jasnog sustava praćenja zdravstvenih djelatnika. Postojeći registri koje održavaju HZJZ i strukovne komore sadržavaju podatke koji se osvježavaju prilikom obnove licence ili prilikom novog zaposlenja. Postoji potreba za razvojem cjelovitog sustava za praćenje ljudskih resursa u

zdravstvu u Hrvatskoj koji bi omogućio bolje projekcije i procjene potrebnog broja zdravstvenih djelatnika. Određeni broj liječnika i drugih zdravstvenih djelatnika nakon stjecanja diplome odabire karijere izvan sustava kliničke medicine, posebice u znanosti, istraživanju ili farmaceutskoj industriji i drugim granama gospodarstva što dodatno ukazuje na potrebu za izradom sustava za praćenje ljudskih resursa jer se odljev zdravstvenih djelatnika u ova zanimanja također treba uračunati u planiranje budućih potreba sustava. Vanjska migracija zdravstvenih djelatnika bila je usmjerena ka Sloveniji, Njemačkoj, Austriji, Velikoj Britaniji, Italiji i ostalim zapadnim europskim zemljama i SAD-u. Prisutne su i unutarnje migracije koje se odnose na zapošljavanje izvan zdravstvenog sustava i prelazak u druge profesije, kao i migracije iz ruralnih područja prema većim urbanim centrima. Zaključeno je kako za kvalitetniju analizu spomenutih migracija nedostaju istraživanja, odnosno sustavno državno praćenje i izvještavanje. U Hrvatskoj je 2011. bilo stalno zaposleno sveukupno 12.532 liječnika. U odnosu na 1980. godinu broj liječnika na 100.000 stanovnika povećao se sa 167 na 281 što je tada još uvijek bilo manje od prosjeka za EU (320/100.000) (62). U 2019.g. prosječan broj liječnika na 100.000 stanovnika u Hrvatskoj je porastao na 330, ali još uvijek blago zaostaje za brojem liječnika u EU koji je u stalnom porastu te je 2019.g. iznosio 360 na 100.000 stanovnika (63).



Slika 5. Prikaz ukupnog broja liječnika u Hrvatskoj po godinama

S pristupanjem Europskoj uniji 2013. godine dolazi do odljeva doktora medicine u druge zemlje članice. Dobna struktura zaposlenih doktora medicine je nepovoljna, osobito nedostaje specijalista nekih specijalnosti (pedijatara, ginekologa, obiteljskih liječnika i dr.) stoga je potrebno planirati kako zadovoljiti potrebe za ovim kadrovima.

1.4. Model i modeliranje

Model je pojednostavljeni prikaz realnog sustava napravljen s ciljem da posluži boljem razumijevanju i/ili daljnjem proučavanju tog sustava i eksperimentiranju s njim. Realni sustav je više ili manje izdvojeni dio stvarnoga svijeta koji čini funkcionalnu cjelinu. Realnim sustavom smatramo i nešto što u stvarnosti ne postoji, nego je zamišljeno (planirano) za napraviti u budućnosti (64).

Modeliranje je stvaranje (oblikovanje) modela. Model omogućava istraživačima mijenjanje parametara na prilično jednostavan način te sukladno tome je moguće uvidjeti način i procijeniti kako promjene utječu na konačne rezultate. Cilj modela, ponajprije konceptualnih, je sinteza poznatih podataka u jednu cjelinu iz koje je moguće, ako postoje numerički podaci, stvoriti matematičke ili simulacijske modele. Niti jedan model ne može zamijeniti realne sustave, ali može dati glavne smjernice njihovog funkcioniranja (64).

1.4.1. Vrste modela

Modeli se mogu podijeliti na: statističke, matematičke i simulacijske. Zadatak statističkih modela je povezivanje opaženih varijabli bez ulaženja u kauzalnost, a matematičkih i simulacijskih oponašanje rada sustava (pretendiraju biti strukturno valjani) (65).

Razvijene su dvije glavne metode simulacijskog modeliranja: simulacija diskretnih događaja i kontinuirana simulacija čija je posebna podvrsta sistemska dinamika. Svrha je simulacije diskretnih događaja detaljan prikaz ponašanja realnog sustava uz uporabu stohastičkih varijabli. U modelima sistemske dinamike agregiraju se entiteti i događaji u odjeljke i tokove kako bi se simuliralo ponašanje sustava sa povratnom vezom (engl. *feedback loop*) za koje se pretpostavlja da su deterministički po svojoj naravi iako uključuju varijable probabilističkih karaktera. Na taj se način najčešće modeliraju i simuliraju ekonomski, društveni i biološki fenomeni (64).

U slučaju da struktura i rad sustava nisu u potpunosti poznati, modeli se grade na pretpostavkama, a služe ponajprije za provjeru hipoteza o sustavu koji prikazuju. Ukoliko je slaganje rezultata modela i stvarnog sustava zadovoljavajuće, model se može primijeniti za eksperimentiranje tj. može se koristiti za predviđanje ponašanja stvarnog sustava u uvjetima koji su financijski, praktično ili etički neprikladni za eksperimentalnu provjeru (npr. simulacija nuklearnih reakcija ili djelovanje lijekova na ljude) (65).

1.4.2. Primjene sistemske dinamike u medicini i zdravstvu

Iako su metode i tehnike sistemske dinamike razvijene radi boljeg razumijevanja i rješavanja drukčijih problema one su izuzetno primjenjive i u području biomedicine gdje je realni sustav koji se promatra čovjek (zdrav ili bolestan) ili populacija. Ovakvi modeli barataju s količinom lijeka, enzima ili nutrijenata koji se akumuliraju u nekom tkivu ili pak (statistički) kumuliraju ljude koji se nalaze u određenom stanju s obzirom na promatranu bolest (64).

U literaturi se može naći veliki broj radova u kojima su takvi modeli korišteni za prikaz širenja bolesti u populaciji (epidemiološki modeli kretanja zaraznih, ali i masovnih nezaraznih bolesti u populaciju) ili primjerice simulaciju umnažanja organizama. Mnogi od njih nastali su upravo radi istraživanja tih procesa tj. napravljeni su kako bi omogućili bolje upoznavanje modeliranih sustava i verifikaciju hipoteza o sustavima. Neki od njih poslije su pretvoreni u programe za učenje, dok su pak drugi već primarno razvijeni upravo da bi se upotrebljavali u edukaciji. U primjenama sistemske dinamike na probleme u području epidemiologije i javnog zdravstva obično se promatra čitava populacija (64).

1.4.3. Programski alati za modeliranje

Suvremeni programski alati automatski proizvode programski kod na temelju dijagrama toka i upisanih vrijednosti pojedinih parametra što je veliko olakšanje za korisnika koji sada više ne mora pisati naredbe programa.

Jezik *DYNAMO (DYNAmic MOdels)* razvili su P. Fox i A. L. Pugh III g. 1959. za velika računala. Doživio je više inačica, a početkom devedesetih godina pojavio se *Professional DYNAMO Plus*, verzija za osobna računala (11,12). Programski paket pod nazivom *Ithink* ili *Stella* najprije je napravljen za *Macintosh*, a danas postoji za *Macintosh* (*Ithink*) i *Windows* (*Stella*), grafički je orijentiran i uključuje niz alata koji olakšavaju razvoj modela. Grafičko

korisničko sučelje omogućuje krajnje jednostavnu implementaciju dijagrama toka modela iz kojeg će program automatski napraviti programski kôd. Isto vrijedi i za još neke programske proizvode kao primjerice *Vensim* i *Powersim* (64).

1.5.3.1. STELLA (Systems Thinking Experimental Learning Laboratory with Animation)

Programski jezik za modeliranje sistemskom dinamikom kreirao je Barry Richmond 1985.g. Modelira se pomoću grafičkih prikaza sustava pomoću četiri temeljna građevna elementa. *STELLA* se koristi u akademskim krugovima kao nastavni alat, ali i u brojnim različitim istraživačkim i poslovnim aplikacijama. Programski jezik je dobio puno pozitivnih kritika zbog jednostavnosti korištenja i prihvatljive cijene (66).

1.5. Svrha istraživanja

Temeljem pregledane literature o temi planiranja specijalističkog usavršavanja doktora medicine može se zaključiti da ovo važno pitanje nije sustavno obrađeno i istraženo u hrvatskom zdravstvenom sustavu.

Svrha ove disertacije je izraditi model, u obliku računalnog programa, za simulaciju potrebnog broja specijalista različitih specijalnosti u Republici Hrvatskoj temeljen na predvidivim promjenama broja i dobne strukture stanovništva. Razvijenim modelom biti će moguće simulirati dinamiku upućivanja na specijalističko usavršavanje u uvjetima različitih scenarija migracija liječnika specijalista s ciljem procjene optimalne strategije kojom se osigurava stabilna opskrba specijalistima različitih specijalnosti i korigira procjep između ponude i potražnje.

Dobiveni rezultati će omogućiti izradu preporuka za donošenje racionalnog plana upućivanja na specijalističko usavršavanje. Posredno će se razvijeni model moći prilagoditi i primijeniti za procjenu potreba i simulaciju kadrovske obnove drugih profila zdravstvenih djelatnika kao i za druge države.

2. Hipoteza

Procijep između priljeva i potreba za doktorima medicine različitih specijalnosti do 2035. g. moguće je korigirati primjenom simulacijskog modela koji uz dosad poznate parametre eksploatira dodatno i one koji se iz pokušaja kreiranja modela pokažu potencijalno značajnim novim parametrima.

3. Ciljevi istraživanja

Opći cilj istraživanja je razviti model za simulaciju dinamike upućivanja doktora medicine na specijalističko usavršavanje u Republici Hrvatskoj.

Specifični ciljevi istraživanja su:

1. Procijeniti potreban broj specijalista različitih specijalnosti u Republici Hrvatskoj do 2035.g.

2. Realizirati model u obliku računalnog programa temeljem procijenjenih najpotentnijih prediktora.

3. Sustavnim simulacijskim eksperimentima razvijenim modelom procijeniti mogućnosti korigiranja procijepa između priljeva i potreba za doktorima medicine u različitim scenarijima.

4. Podaci i metode rada

4.1. Podaci

U istraživanju su korišteni podaci iz *Demografskog atlas hrvatskog liječništva* koji kumuliraju podatke prikupljene iz podatkovnih baza i dokumentacije (67):

- Hrvatske liječničke komore (HLK),
- Hrvatskog zavoda za javno zdravstvo (HZJZ),
- Hrvatskog zavoda za zdravstveno osiguranje (HZZO),
- Financijske agencije (FINA),
- Državnog zavoda za statistiku (DZS),
- Hrvatskog zavoda za mirovinsko osiguranje (HZMO),
- Hrvatskog zavoda za zapošljavanje (HZZ),
- Hrvatskog zavoda za zaštitu zdravlja i sigurnost na radu (HZZZSR),
- Agencije za znanost i visoko obrazovanje (AZVO),
- Medicinskih fakulteta Sveučilišta u Zagrebu i Rijeci.

Liječnici (doktori medicine, dr. med.) su prema *Nacionalnoj klasifikaciji zanimanja* iz 2010. usklađenoj sa *Međunarodnom standardnom klasifikacijom zanimanja* (ISCO88) definirani kao oni koji primjenjuju preventivne i kurativne mjere, poboljšavaju i razvijaju koncepte, teorije i operativne metode te provode istraživanja u području medicine i zdravstvene skrbi. Prema usuglašenim definicijama koje koriste Eurostat, WHO i OECD, liječnike možemo brojiti prema različitim konceptima: praktičari, profesionalno aktivni ili licencirani (67).

Profesionalno aktivni liječnici su liječnici koji obavljaju liječničku praksu ili bilo koji drugi liječnici kojima je liječničko obrazovanje preduvjet za obavljanje posla (npr. za testiranja lijekova ili medicinska istraživanja). **Licencirani liječnici** su svi liječnici koji obavljaju liječničku praksu, profesionalno aktivni liječnici, kao i svi drugi registrirani liječnici koji imaju važeću licencu neovisno o tomu gdje su zaposleni (67).

U skladu s međunarodnim preporukama i praksom većine razvijenih zemalja, u ovo istraživanje uključeni su svi liječnici koji obavljaju liječničku praksu te izravno provode zdravstvenu zaštitu odnosno pružaju usluge pacijentima. Njihovi zadaci su: medicinski pregledi i dijagnosticiranje, propisivanje lijekova te konzervativno i/ili kirurško liječenje

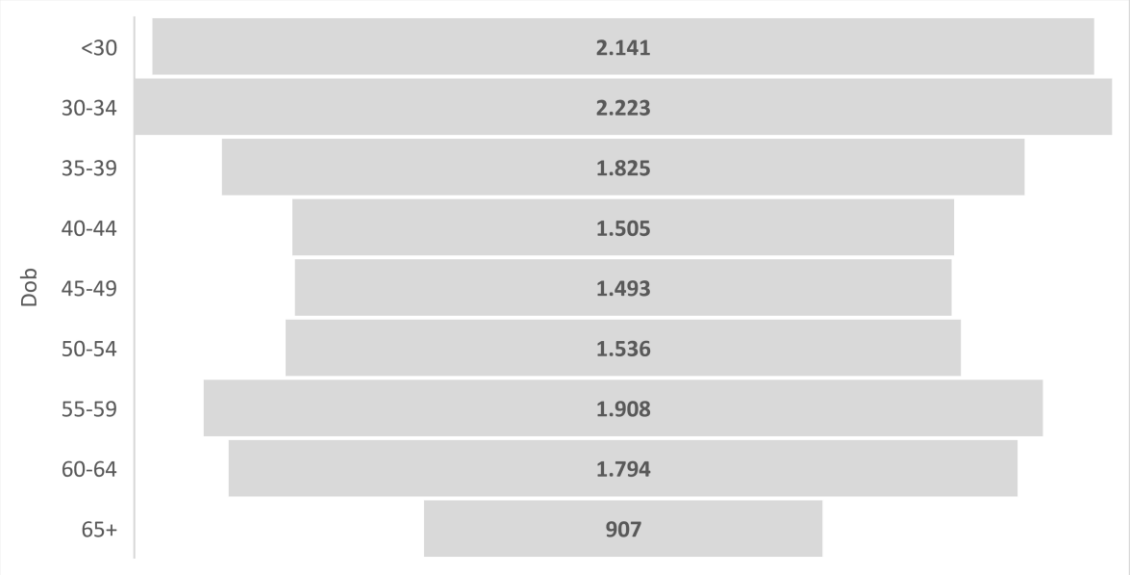
određenih bolesti, poremećaja ili ozljeda, savjetovanje i primjena preventivnih mjera i liječenja. Ova definicija u kategoriju liječnika ubraja:

- Osobe koje su završile studij medicine na sveučilišnoj razini i koje imaju licencu za obavljanje liječničke djelatnosti;
- Pripravnike i specijalizante s odgovarajućom diplomom koji pružaju zdravstvene usluge pod nadzorom drugih liječnika tijekom svojega poslijediplomskog stažiranja ili specijalizacije u zdravstvenoj ustanovi;
- Liječnike koji rade u zdravstvenim ustanovama/ordinacijama i samozaposlene liječnike koji pružaju usluge neovisno o mjestu pružanja usluga (javni ili privatni zdravstveni sektor);
- Strane liječnike kojima je nadležna institucija izdala odobrenje za samostalan rad u Hrvatskoj (67).

Istovremeno, definicijom su isključeni:

- Doktori dentalne medicine/stomatolozi/oralni kirurzi;
- Liječnici koji rade u upravi, istraživanju i na drugim poslovima koji isključuju izravni kontakt s pacijentima;
- Umirovljeni liječnici;
- Liječnici koji rade u inozemstvu (67).

Broj liječnika kontinuirano se mijenja jer novi liječnici gotovo svakodnevno ulaze u sustav, a mnogi na različite načine iz njega izlaze. U ovoj disertaciji polazi se od stanja na dan 15.10.2020. g. U Hrvatskoj je tada bilo 15.332 liječnika, od čega 63% liječnica (9.659). Ta brojka, demografskom terminologijom, pokazuje aktivne zalihe liječnika, neposrednih pružatelja zdravstvene zaštite u Hrvatskoj, bez obzira na vrstu radnog odnosa. Od tog, ukupnog broja, najviše je bilo liječnika specijalista (9.984), zatim liječnika specijalizanata (2.923), potom liječnika bez specijalizacije (2.425).



Slika 6. Raspodjela ukupnog broja liječnika u Hrvatskoj po dobnim kategorijama prema podacima Atlasa HLK (pristupljeno 15.10.2020.g.)

4.1.1. Radni ciklus doktora medicine u Hrvatskoj

Proces izobrazbe i stručnog usavršavanja liječnika je dugotrajan. Taj proces, od upisa studija medicine, preko pripravničkog staža/rada liječnika pod nadzorom do specijalizacije (potencijalno i subspecijalizacije), u najkraćem slučaju traje 15 godina, a često je to i dulje.

Pripravnički staž je rad kojim se zdravstveni radnik osposobljava za samostalan rad. Pripravnički staž obavlja se prema propisanom programu. Programom se utvrđuje raspored i trajanje rada u pojedinim stručnim jedinicama. Programom se utvrđuju stručni poslovi kojima se pripravnici osposobljavaju za samostalan rad. Trajanje pripravničkog staža je 5 mjeseci (iznimno 2 godine za doktore medicine koji su završili petogodišnji studij medicine) (67). Godine 2019. ukinut je obvezan pripravnički staž za doktore medicine (za liječnike koji su studij medicine upisali nakon 1. srpnja 2013. g.). Nakon završenog studija doktori medicine imaju dvije mogućnosti – ići na specijalističko usavršavanje ili raditi pod nadzorom mentora u općoj ili hitnoj medicini.

Rad liječnika pod nadzorom definiran je Pravilnikom o načinu provođenja rada pod nadzorom doktora medicine bez specijalizacije (NN 63/2019) na način da doktor medicine može raditi pod nadzorom u djelatnosti obiteljske (opće) medicine, u djelatnosti hitne medicine koju obavlja zavod za hitnu medicinu jedinice područne (regionalne) samouprave odnosno Grada Zagreba te u djelatnosti hitne medicine koju obavlja bolnička zdravstvena ustanova. Rad pod nadzorom nije obvezan (68).

Specijalističko usavršavanje (specijalizacija) je oblik organiziranog stjecanja kompetencija prema propisanom programu koji se može obavljati samo u ovlaštenim zdravstvenim ustanovama, trgovačkim društvima koja obavljaju zdravstvenu djelatnost, odnosno kod ovlaštenih doktora medicine koji obavljaju privatnu praksu, a koji ispunjavaju uvjete propisane Pravilnikom o specijalističkom usavršavanju doktora medicine. Trajanje specijalizacije je 4 do 6 godina ovisno o specijalizaciji (definirano Pravilnikom o specijalističkom usavršavanju doktora medicine i Pravilnikom o specijalističkom usavršavanja doktora medicine iz obiteljske medicine). Specijalizacija je u prošlosti bila opcija jer su mnogi liječnici neposredni pružatelji zdravstvene zaštite u djelatnosti opće medicine mogli raditi bez specijalizacije, no to će u budućnosti biti iznimka (67).

Pravilnik o specijalističkom usavršavanju doktora medicine (NN 100/11, 33/11, 54/12, 49/13, 139/14, 116/15, 62/16, 69/16 - Ispravak i 6/17) u Hrvatskoj propisuje sljedeće specijalizacije i njihovo trajanje (tablica 3).

Tablica 3. Popis specijalizacija i trajanje prema Pravilniku o specijalističkom usavršavanja doktora medicine

Specijalizacija	Trajanje u mjesecima
Abdominalna kirurgija	60
Alergologija i klinička imunologija	60
Anesteziologija, reanimatologija i intenzivna medicina	60
Dermatologija i venerologija	48
Dječja i adolescentna psihijatrija	60
Dječja kirurgija	60
Endokrinologija i dijabetologija	60
Epidemiologija	48
Fizikalna medicina i rehabilitacija	52
Gastroenterologija	60
Ginekologija i opstetricija	60
Hematologija	60
Hitna medicina	60
Infektologija	60
Internistička onkologija	60
Javnozdravstvena medicina	48
Kardiologija	60
Kardiotorakalna kirurgija	60

Klinička farmakologija s toksikologijom	48
Klinička mikrobiologija	60
Klinička radiologija	60
Laboratorijska imunologija	60
Maksilofacijalna kirurgija	60
Medicina rada i športa	48
Nefrologija	60
Neurokirurgija	72
Neurologija	60
Nuklearna medicina	48
Oftalmologija i optometrija	48
Onkologija i radioterapija	60
Opća interna medicina	60
Opća kirurgija	60
Ortopedija i traumatologija	60
Otorinolaringologija	60
Patologija i citologija	60
Pedijatrija	60
Plastična, rekonstrukcijska i estetska kirurgija	60
Psihijatrija	60
Pulmologija	60
Reumatologija	60
Sudska medicina	60
Školska i adolescentna medicina	48
Transfuzijska medicina	60
Urologija	60
Vaskularna kirurgija	60
Pedijatrijska infektologija	60

Specijalizacija obiteljske medicine regulirana je Pravilnikom o specijalističkom usavršavanju doktora medicine iz obiteljske medicine (NN 129/11, 129/12, 120/13, 31/17) i traje 48 mjeseci.

4.1.2. Raspodjela liječnika specijalista po specijalizacijama i godinama starosti

Za razvoj i testiranje ovog modela uzeto je u obzir sljedećih sedam programa specijalističkog usavršavanja: obiteljska medicina, psihijatrija, pedijatrija, ginekologija i opstetricija, neurokirurgija, anesteziologija, reanimatologija i intenzivna medicina te neurologija (u daljem tekstu: 7 specijalizacija). Sve ostale specijalizacije svrstane su u kategoriju „ostale specijalizacije“. Distribucija postojećih liječnika specijalista po navedenim specijalističkim kategorijama dobivena je na način da je iz online *Atlasa liječništva HLK* na dan 15.10.2020. g. preuzet broj i dobna raspodjela liječnika specijalista po petogodišnjima dobnim skupinama (tablica 4).

Tablica 4. Raspodjela liječnika specijalista po dobnima kategorijama

Dob (god)	Obiteljska medicina	Psihijatrija	Pedijatrija	Ginekologija i opstetricija	Neurokirurgija	Anesteziologija, reanimatologija i intenzivna medicina	Neurologija	Ostale specijalizacije
60 – 65	310	79	171	142	10	85	49	702
55 – 59	337	107	107	133	12	91	54	764
50 – 54	170	94	89	139	9	90	54	926
45 – 49	104	92	113	107	6	109	60	880
40 – 44	76	66	109	107	13	114	48	935
35 – 39	73	65	91	79	19	107	55	865
30 – 35	33	23	20	22	3	53	12	801
Ukupno	1.103	526	700	729	72	649	332	5.873

4.1.3. Liječnici koji su započeli specijalizaciju u desetogodišnjem razdoblju (2007. do 2016.)

U razdoblju od 2007. do 2016. godine započeto je ukupno 4.295 specijalizacija. Detaljnija raspodjela prikazana je u tablici 5 (67).

Tablica 5. Započete specijalizacije u razdoblju 2007. do 2016.g.

	2007.	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**	**Ukupno**
Obiteljska m.	34	34	30	56	25	35	34	26	41	2	**317**
Psihijatrija	37	22	25	22	28	26	17	25	26	13	**241**
Pedijatrija	54	32	32	29	16	30	19	28	49	25	**314**
Ginekologija	43	22	20	20	16	20	20	24	51	4	**240**
Neurokirurgija	3	1	7	8	3	4	3	2	7	3	**41**
Anesteziologija	44	28	26	17	26	40	35	91	49	31	**387**
Neurologija	25	15	17	16	15	13	19	18	21	8	**167**
Ostale spec.	343	203	224	216	243	252	214	297	394	202	**2.588**
Ukupno	**583**	**357**	**381**	**384**	**372**	**420**	**361**	**511**	**638**	**288**	**4.295**

4.1.4. Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.)

Dana 14. rujna 2020.g. stupio je na snagu Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (u daljnjem tekstu: Nacionalni plan) (69). Nacionalnim planom MIZ utvrđuje za područje Republike Hrvatske potreban broj specijalizacija doktora medicine te predstavlja temelj za donošenje godišnjeg plana potrebnih specijalizacija zdravstvenih radnika. Potreban broj specijalizacija doktora medicine prikazan je u tablici 6.

Tablica 6. Broj specijalizacija doktora medicine za razdoblje 2020. – 2024.g. prema Nacionalnom planu

Specijalizacija	**Potreban broj u RH (2020. – 2024.)**
Obiteljska medicina	504
Psihijatrija	164
Pedijatrija	244
Ginekologija i opstetricija	185
Neurokirurgija	28
Anesteziologija, reanim.	188
Neurologija	103
Ostale specijalizacije	2.409
Ukupno	3.825

4.1.5. Procjene kretanja broja stanovnika u Hrvatskoj

Predviđanja kretanja broja stanovnika dobivena su iz studija i projekcija vodećih hrvatskih demografskih stručnjaka te su prikazana u tablici 7 (33). Pokazalo se da su ove projekcije puno preciznije od projekcija Državnog zavoda za statistiku. Projekcije stanovništva polaze od određenih hipoteza. Uz ostale hipoteze koje su korištene pri izradi projekcija ključna je ona koja pretpostavlja nastavljanje recentnih demografskih trendova, što znači bez društvene intervencije u područje fertiliteta i politike ekonomskog razvoja s naglašenim prostornim aspektom. Projekcije polaze od dobno-spolnog sastava utvrđenog popisom iz 2011.g. prema kojemu sve županije imaju izrazito regresivan tip dobne strukture (33).

Tablica 7. Projekcija broja stanovnika u Hrvatskoj do 2051. godine

Broj stanovnika 2011. i projicirani do 2051. godine				
2011.	2021.	2031.	2041.	2051.
4.284.889	4.151.550	3.964.385	3.723.497	3.456.866

4.1.6. Scenariji

Rezultati simulacija ovise o ulaznim parametrima koji su podložni brojnim, često vrlo promjenjivim i nestabilnim promjenama, stoga je simulacijske eksperimente potrebno provoditi po prethodno definiranim scenarijima. Sustavnim simulacijskim eksperimentima razvijenim modelom procjenjuje se mogućnost korigiranja broja specijalista u različitim scenarijima.

Navedenih 7 specijalizacija odabrano je iz nekoliko razloga. Prvi je taj što predstavljaju primarnu, ali i sekundarnu/tercijarnu razinu zdravstvene zaštite. Niti jedna od navedenih specijalizacija nije doživjela značajne administrativne promjene u bližoj prošlosti kao što se dogodilo sa specijalizacijom iz npr. interne medicine ili kirurgije. Izmjenama Pravilnika o specijalističkom usavršavanju doktora medicine 2011. g., a u kontekstu pretpristupnih pregovora u procesu pristupanja Hrvatske Europskoj uniji, brojne dotadašnje subspecijalizacije su postale zasebne specijalizacije (70).

Scenarij 1

Korišteni su povijesni podaci o broju započetih specijalizacija u razdoblju od 2007. do 2016.g. sa svrhom prikazivanja trendova u slučaju da se nastavilo sa dotadašnjom dinamikom upućivanja na specijalističko usavršavanje.

Scenarij 2

Nacionalnim planom specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) predviđeno je raspisivanje 3.825 specijalizantskih mjesta za doktore medicine što je utemeljeno na potrebama koje su iskazale jedinice regionalne samouprave (69). Postoji realna mogućnost, utemeljena na iskustvima prijašnjih godina, da određeni broj raspisanih specijalizantskih mjesta neće biti konzumiran stoga je u ovom scenariju predviđena 80%-tna iskorištenost kvota zacrtanih Nacionalnim planom specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.).

Scenarij 3

Reprodukcija prijedloga Nacionalnog plana specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) uz pretpostavku da predviđene kvote za doktore medicine budu u potpunosti konzumirane te uz povećanje godišnje upisne kvote na medicinske fakultete na nacionalnoj razini za 10% (umjesto 590, 650 godišnje) od 2022.g.

Scenarij 4

Reprodukcija prijedloga Nacionalnog plana specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) uz pretpostavku da predviđene kvote za doktore medicine budu u potpunosti konzumirane uz postupno povećanje za 5 mjesta godišnje realiziranih imigrantskih kvota (2020. g. 15 mjesta, 2022. g. 20 mjesta, 2024. g. 25 mjesta, 2026. g. 30 mjesta, 2028. g. 35 mjesta, 2030. g. 40 mjesta, 2032. g. 45 mjesta, 2034. g. 50 mjesta, 2035. g. 55 mjesta).

Scenarij 5

Reprodukcija prijedloga Nacionalnog plana specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) uz pretpostavku da predviđene kvote za doktore medicine budu u potpunosti konzumirane do 2024. g., a od 2025. g. smanjeno je konzumiranje predviđenih kvota za 20% za sve specijalizacije.

Tablica 8. Parametri i ulazni podaci za simulaciju pojedinih scenarija

	Scenarij 1	**Scenarij 2**	**Scenarij 3**	**Scenarij 4**	**Scenarij 5**
Broj upisanih studenata u prvu godinu studija medicine	590		650	590	
Ukupan broj studenata na studijima medicine (sve godine)	3.360				
Trajanje studija medicine (god)	6				
Odljev studenata (% godišnje)	10				
Broj doktora medicine koji čekaju na specijalizaciju / Rad pod nadzorom	1.291	1.303			
Iskorištena imigracijska kvota (godišnje)	5	15	15	15 (2020.) do 55 (2035.)	15
Stopa odljeva u inozemstvo doktora medicine (% godišnje)	1,5	3			
Procjena broja liječnika koji rade izvan zdravstva	1.000				
Trajanje radnog vijeka liječnika (god)	40				
Broj liječnika koji rade bez specijalizacije	1.134	1.081			
Prosječan preostali radni vijek liječnika bez specijalizacije (god)	20				
Broj rješenja o započetom specijalističkom usavršavanju godišnje					**2020./2025.**
Obiteljska medicina	42	80	101	101	101/80
Psihijatrija	30	27	33	33	33/27
Pedijatrija	38	40	49	49	49/40
Ginekologija i opstetricija	31	30	37	37	37/30
Neurokirurgija	6	6	6	6	6/6
Anesteziologija, reanimatologija i intenzivna m.	48	31	38	38	38/31
Neurologija	20	16	20	20	20/16
Ostale specijalizacije	281	307	384	384	384/307
Broj specijalizanata					
Obiteljska medicina	171	178			
Psihijatrija	124	122			
Pedijatrija	273	274			
Ginekologija i opstetricija	151	156			
Neurokirurgija	29				
Anesteziologija, reanimataologija i intenzivna m.	278				
Neurologija	113				
Ostale specijalizacije	1.854	1.860			
Odljev specijalizanata (% godišnje) -zbog emigracije, morbiditeta, mortaliteta, invaliditeta	1				
Odljev specijalista (% godišnje) - emigracija, morbiditet, mortalitet, invaliditet	1,1				

4.2. Metode

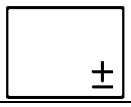
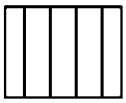
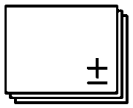
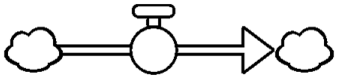
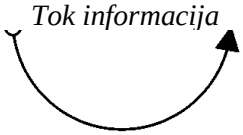
4.2.1. Računalne metode

Izrada simulacijskog modela, simulacijski eksperimenti i proračuni izvedeni su na PC kompatibilnom računalu s *Microsoft Windows 10* operacijskim sustavom. Za izradu simulacijskog modela i za izvođenje simulacijskih eksperimenata korišten je programski paket *Stella Architect v1.9.1* s grafičkim sučeljem za izradu i simulaciju modela metodom sistemske dinamike (71). Za proračune je korišten opći program za tablično računanje *Microsoft Excel* iz programskog paketa *Microsoft Office 365*.

4.2.2. Simboli sistemske dinamike

Za grafički prikaz (dijagram toka) simulacijskog modela korišteni su simboli sistemske dinamike koje koristi program *Stella Architect* prikazani u tablici 9.

Tablica 9. Standardni simboli sistemske dinamike korišteni pri simulacijskom modeliranju specijalističkog usavršavanja doktora medicine

Simbol i naziv	Opis
Rezervoar 	• Odjeljak u kojem se privremeno ili trajno akumulira materijal (tvar, ljudi, stanice, količina bilo čega ovisno o primjeni) • Omogućuje više ulaznih i izlaznih tokova.
Pokretna traka 	• Odjeljak u kojem se materijal zadržava onoliko koliko je određeno u trenutku njegova ulaska, može se zamisliti kao pokretna traka. • Omogućuje više ulaznih tokova, ali samo dva izlazna.
Niz 	• Niz odjeljaka određenog tipa (rezervoar, pokretna traka ili tok), može se definirati kao jednodimenzionalni ili višedimenzionalni.
Pomoćna varijabla 	• Simbol kojim se prikazuju pomoćne varijable koje u pravilu predstavljaju informacije o parametrima modela (konstantne ili varijabilne veličine).
Tok materijala 	• Tok materijala između odjeljaka; može biti jednosmjeran ili dvosmjeran. • Omogućuje konverziju količine materijala.
Tok informacija 	• Tok informacija među pojedinim elementima modela. • Informacije determiniraju tokove.

Model je koncipiran kao sustav s više odjeljaka. Svaki odjeljak predstavlja liječnike (ili studente medicine) u nekoj fazi radnog vijeka ili obrazovanja/usavršavanja, a praktično svi su dobno strukturirani.

4.2.3. Rezervoar (Stock) vs. Pokretna traka (Conveyor)

Pri izradi modela metodom sistemske dinamike, odjeljke možemo prikazivati pomoću *rezervoara* ili *pokretne trake*. *Rezervoar* predstavlja odjeljak u kojem je dinamika promjena karakterizirana kašnjenjem prvog reda. Time će se promjena na ulazu u odjeljak odraziti na njegov izlaz s određenim kašnjenjem. *Pokretna traka* je, s druge strane, karakterizirana kašnjenjem beskonačnog reda, tj. svaki liječnik koji uđe u odjeljak pojaviti će se na njegovu izlazu nakon onoliko vremena koliko je bilo određeno u trenutku ulaska.

4.3. Validacija simulacijskog modela

Dostupni povijesni podaci korišteni su za validaciju modela i uspoređeni su s rezultatima simulacije. Model se općenito smatra pouzdanim ako je relativna greška manja od 0,1 (72). Analiza osjetljivosti glavnih ulaznih parametara pokazala je da svaka promjena jednog ulaznog parametra donosi istu promjenu izlaznih varijabli (tj. ako se broj iskorištenih specijalizantskih mjesta poveća/smanji za 5% izlazna varijabla dugoročno će pokazati jednako povećanje/smanjenje).

4.4. Etička dopusnica

Etičko povjerenstvo Medicinskog fakulteta Sveučilišta u Zagrebu u razmatranju načela etičnosti donijelo je zaključak da je istraživanje etički prihvatljivo.

5. Rezultati

5.1. Opterećenje specijalista - Ocjena sadašnjeg stanja

5.1.2. Primarna zdravstvena zaštita

Hrvatski zavod za javno zdravstvo (HZJZ) objavio je analizu podataka iz Centralnog zdravstvenog informacijskog sustava Republike Hrvatske (CEZIH) za 2019. godinu kojom je pokazao podatke koji putem komunikacijskih poruka dolaze u Hrvatski zavod za zdravstveno osiguranje (HZZO) iz ordinacija primarne zdravstvene zaštite (PZZ), konkretno iz djelatnosti opće/obiteljske medicine, zdravstvene zaštite predškolske djece te zdravstvene zaštite žena. Metodologija prikupljanja podataka razlikuje se od dosadašnjih načina prikupljanja i obrade objavljivanih u *Hrvatskom zdravstveno-statističkom ljetopisu* te sukladno tome podaci prikupljeni iz CEZIH-a nisu u potpunosti usporedivi s onima prikazanima u ljetopisima.

Pojam *korisnik* se odnosi na svakog osiguranika koji je koristio zdravstvenu zaštitu u pojedinoj ordinaciji, bez obzira na to je li taj liječnik izabrani liječnik primarne zdravstvene zaštite za tog osiguranika ili nije. Pojam *kontakt* se odnosi na svaki kontakt sa zdravstvenom zaštitom: posjet, pregled, telefonska konzultacija i ostalo.

Tablica 10. Opterećenje liječnika u PZZ u 2019.g.

Djelatnost	Broj ugovorenih timova	Broj korisnika ukupno	Prosječan broj korisnika po timu	Broj kontakata ukupno	Prosječan broj kontakata po tima	Broj kontakata po timu po danu*
Obiteljska / Opća medicina	2.168	3.228.629	1.489	42.844.471	19.762	76,0
Zdravstvena zaštita žena	260	528.706	2.033	1.921.474	7.390	28,4
Zdravstvena zaštita predškolske djece	259	346.781	1.339	2.904.756	11.215	43,1

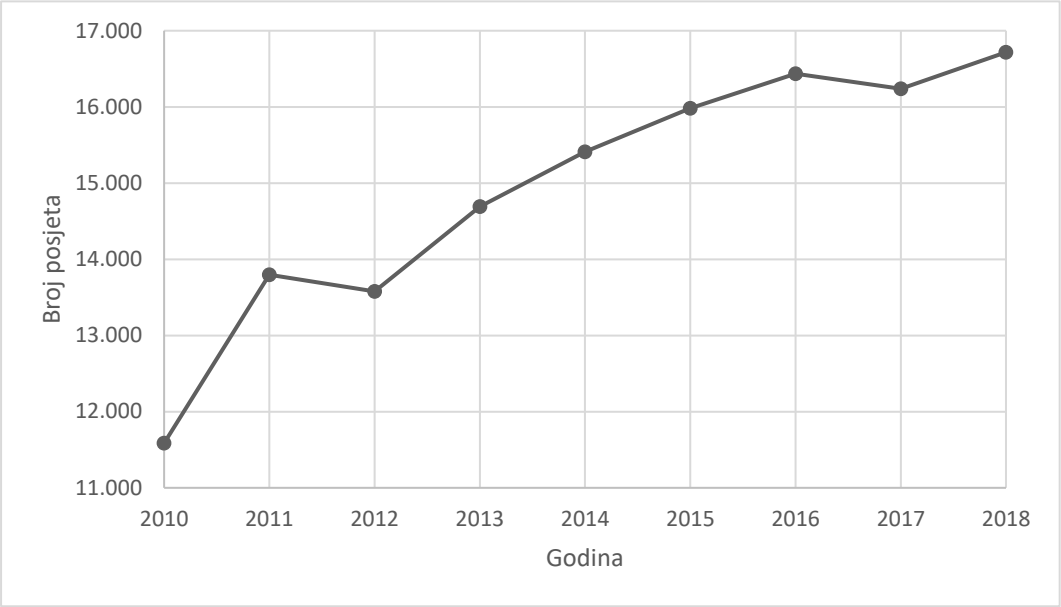
**Broj obračunskih dana u 2019.g. N=260 sukladno Zakonu o radu, članak 61.*

Za prikaz opterećenja specijalista na primarnoj razini zdravstvene zaštite u nastavku su korišteni podaci dostupni u *Hrvatskim zdravstveno-statističkim ljetopisima*.

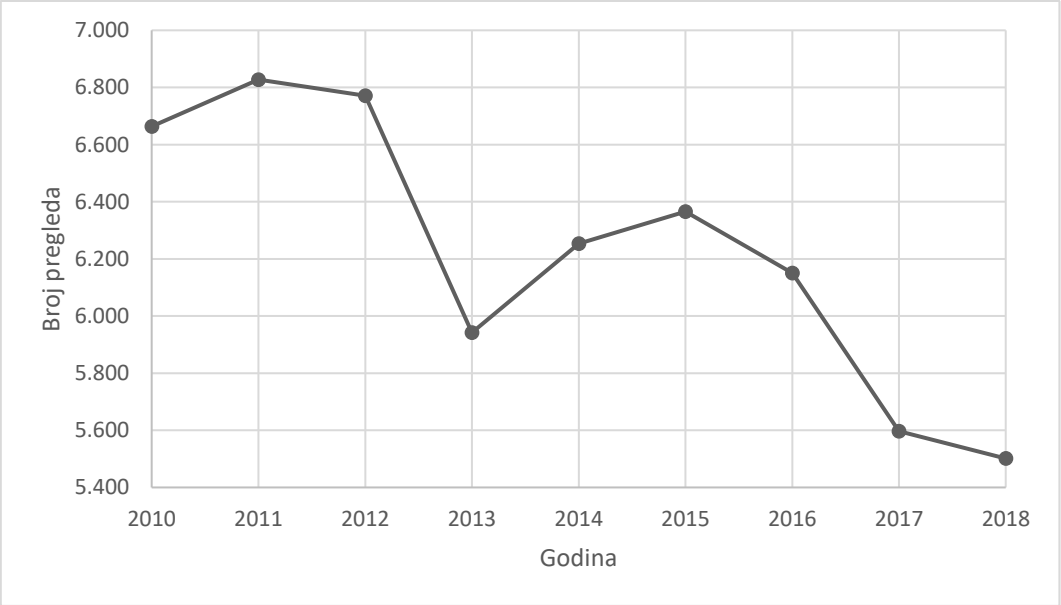
5.1.2.1. Obiteljska/opća medicina

Na slikama 7 i 8 prikazano je kretanje broja posjeta i pregled u ambulantama opće/obiteljske medicine od 2010. g. Vidljivo je kako broj posjeta po timu konstanto raste dok broj pregleda

osjetno pada. U promatranom osmogodišnjem razdoblju broj timova nije značajnije rastao (2010. g. 2.285 timova, a 2018. g. 2.286 timova). Stoga povećanje broja posjeta, a smanjenje broja pregleda treba promatrati kroz povećan broj pacijenata po timu te sve veće administrativno opterećenje liječnika opće/obiteljske medicine (tablica 11).



Slika 7. Prikaz broja posjeta po timu u obiteljskoj/općoj medicini.



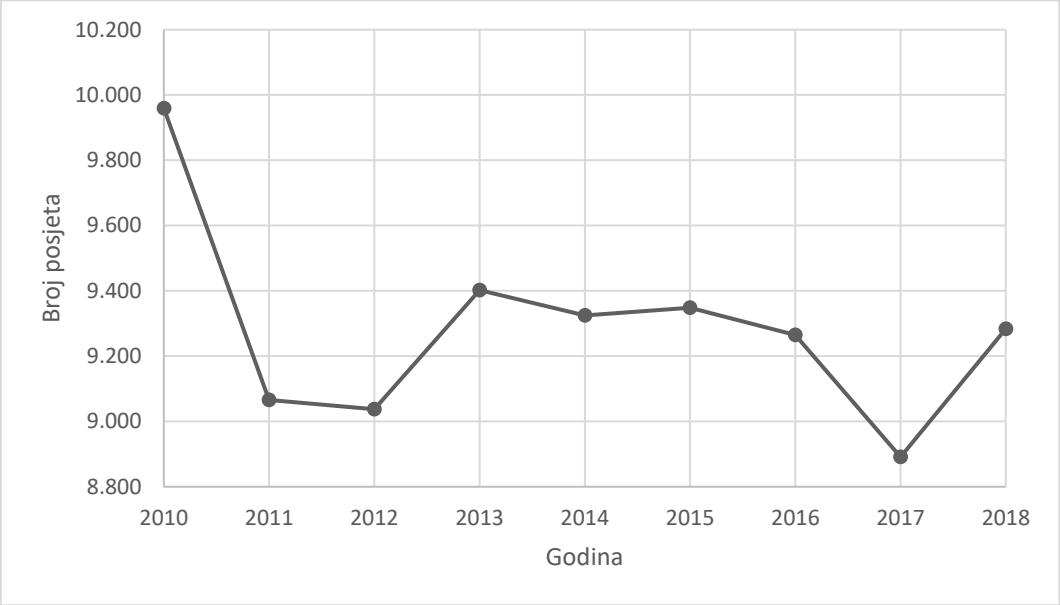
Slika 8. Prikaz broja pregleda po timu u obiteljskoj/općoj medicini

Tablica 11. Prikaz opterećenja specijalista u djelatnosti opće/obiteljske medicine

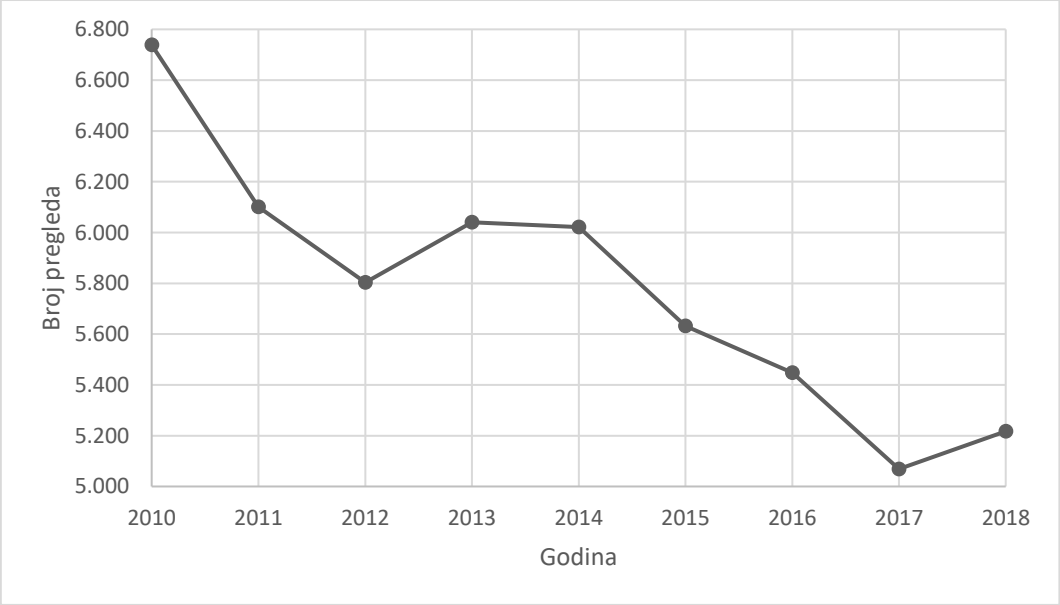
Godina		2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.
Obračunski radni dani		261	261	261	260	261	261	261	260	261
Broj timova		2.285	2.286	2.311	2.31	2.275	2.305	2.300	2.318	2.286
OSIGURANICI / KORISNICI	Broj osiguranika u skrbi	4.116.562	4.207.291	4.269.074	4.172.236	4.180.118	4.122.396	4.145.872	4.106.950	4.101.631
	Broj osiguranika po timu (prosjek)	1.802	1.84	1.847	1.806	1.837	1.788	1.803	1.772	1.794
	Broj korisnika	3.093.749	3.225.828	3.226.013	3.188.519	3.173.459	3.236.064	3.233.569	3.201.954	3.135.408
POSJETE	Ordinacija	26.111.559	31.213.732	31.047.097	33.617.950	34.715.078	36.503.556	37.483.780	37.324.960	37.883.421
	Kuća	363.695	325.172	331.843	324.211	340.673	329.802	318.585	319.276	331.665
	Ukupno	26.475.254	31.538.904	31.378.940	33.942.161	35.055.751	36.833.358	37.802.365	37.644.236	38.215.086
	Po timu	11.587	13.797	13.578	14.694	15.409	15.98	16.436	16.24	16.717
	Po timu po danu	44	53	52	57	59	61	63	62	64
PREGLEDI	Ordinacija	14.894.614	15.290.219	15.326.432	13.420.861	13.907.947	14.361.412	13.844.178	12.671.758	12.256.761
	Kuća	331.339	317.443	322.798	304.995	319.534	310.429	300.367	302.019	319.143
	Ukupno	15.225.953	15.607.662	15.649.230	13.725.856	14.227.481	14.671.841	14.144.545	12.973.777	12.575.904
	Po timu	6.663	6.827	6.772	5.942	6.254	6.365	6.15	5.597	5.501
	Po timu po danu	26	26	26	23	24	24	24	22	21

5.1.2.2. Zdravstvena zaštita predškolske djece

Na slikama 9 i 10 prikazano je kretanje broja posjeta i pregled u ambulantama zdravstvene zaštite predškolske djece od 2010.g. Vidljivo je kako su broj posjeta i broj pregleda u padu. Broj timova je u promatranom razdoblju porastao s 253 tima 2010. g. na 280 timova 2018. g. što je zasigurno doprinijelo padu posjeta i pregleda po timu. Unatoč tome ne smije se zanemariti administrativno opterećenje i preopterećenje pacijentima i u djelatnosti zdravstvene zaštite predškolske djece u primarnoj razini zdravstvene zaštite (tablica 12).



Slika 9. Prikaz broja posjeta po timu u djelatnosti zdravstvene zaštite predškolske djece



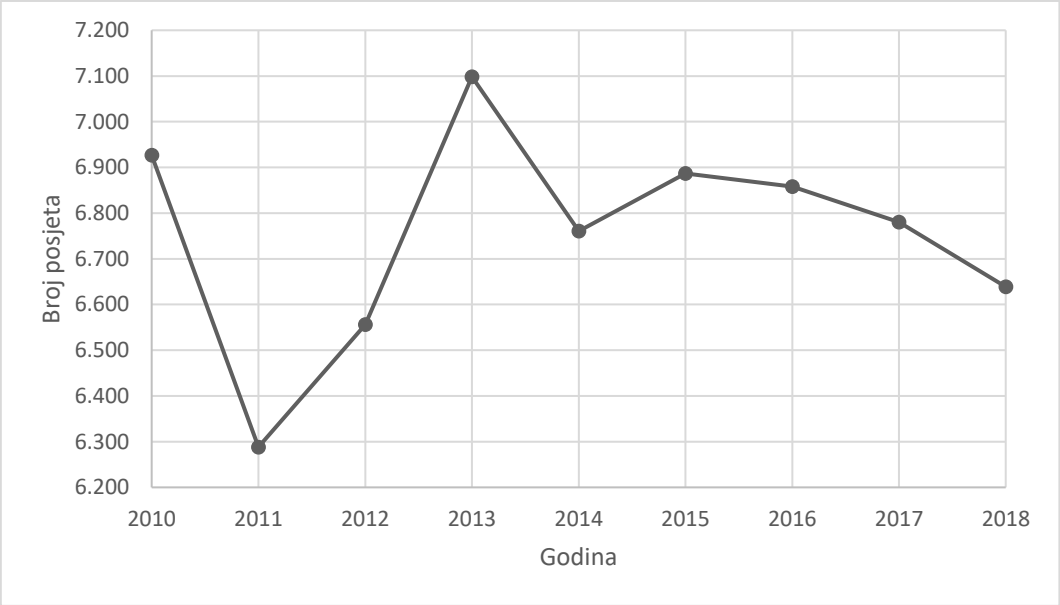
Slika 10. Prikaz broja pregleda po timu u djelatnosti zdravstvene zaštite predškolske djece

Tablica 12. Prikaz opterećenja specijalista u djelatnosti zdravstvene zaštita dojenčadi i male djece

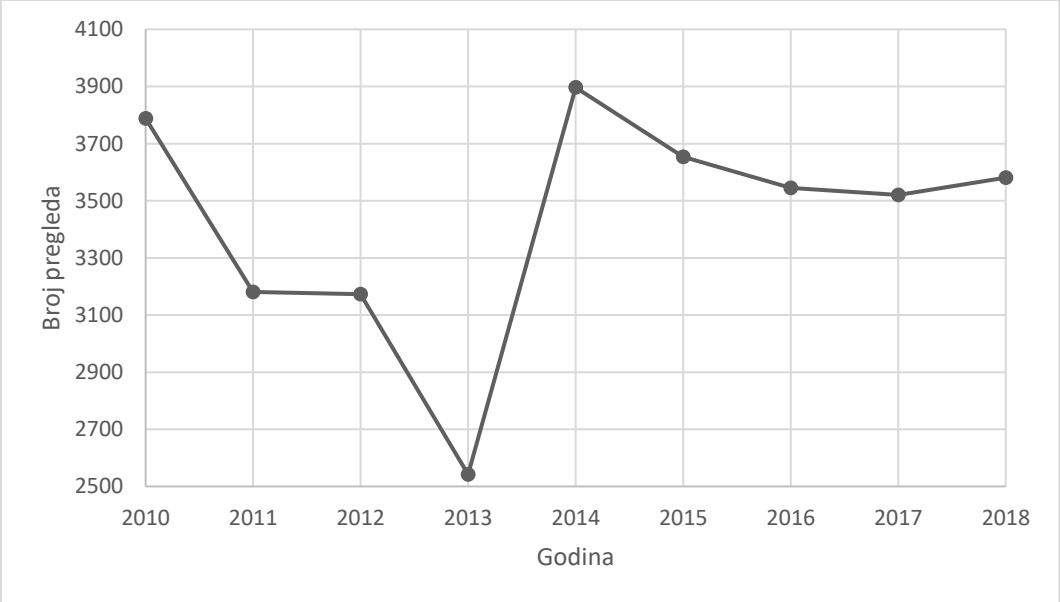
Godina		**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**	**2017.**	**2018.**
Obračunski radni dani		261	261	261	260	261	261	261	260	261
Broj timova		253	258	271	273	273	276	277	280	280
OSIGURANICI / KORISNICI	**Broj osiguranika u skrbi**	393.766	372.747	410.986	404.339	409.053	394.553	394.490	403.312	425.122
	Broj osiguranika po timu (prosjek)	1.556	1.445	1.517	1.481	1.498	1.430	1.424	1.440	1.518
	Broj korisnika	324.106	321.938	342.562	333.724	326.869	322.606	334.611	333.700	347.464
POSJETE	**Ordinacija**	2.514.491	2.338.550	2.449.113	2.566.745	2.545.616	2.580.120	2.566.414	2.489.583	2.599.350
	Kuća	5.274	584	0	0	0	0	0	0	0
	Ukupno	2.519.765	2.339.134	2.449.113	2.566.745	2.545.616	2.580.120	2.566.414	2.489.583	2.599.350
	Po timu	9.960	9.066	9.037	9.402	9.325	9.348	9.265	8.891	9.283
	Po timu po danu	38	35	35	36	36	36	35	34	36
PREGLEDI	**Ordinacija**	1.703.856	1.573.452	1.572.719	1.648.868	1.643.935	1.554.397	1.508.974	1.419.225	1.460.773
	Kuća	1.030	514	0	0	0	0	0	0	0
	Ukupno	1.704.886	1.573.996	1.572.719	1.648.868	1.643.935	1.554.397	1.508.974	1.419.225	1.460.773
	Po timu	6.739	6.101	5.803	6.040	6.022	5.632	5.448	5.069	5.217
	Po timu po danu	26	23	22	23	23	22	21	19	20

5.1.2.3. Zdravstvena zaštita žena (ugovor s HZZO)

Na slikama 11 i 12 prikazano je kretanje broja posjeta i pregled u ambulantama zdravstvene zaštite žena (ugovor s HZZO) od 2010. g. Vidljivo je kako su broj posjeta i broj pregleda na gotovo istoj razini uz manje oscilacije uzrokovane vjerojatno administrativnim razlozima. U promatranom razdoblju broj timova je porastao sa 229 koliko ih je bilo 2010. g. na 265 timova 2018. g. Prosječan broj osiguranika po timu se blago smanjio tijekom navedenog razdoblja (s 2010. g. 6.706 na 6.509) što je još uvijek iznad propisanog standarda (tablica 13).



Slika 11. Prikaz broja posjeta po timu u djelatnosti zdravstvene zaštite žena (ugovor s HZZO)



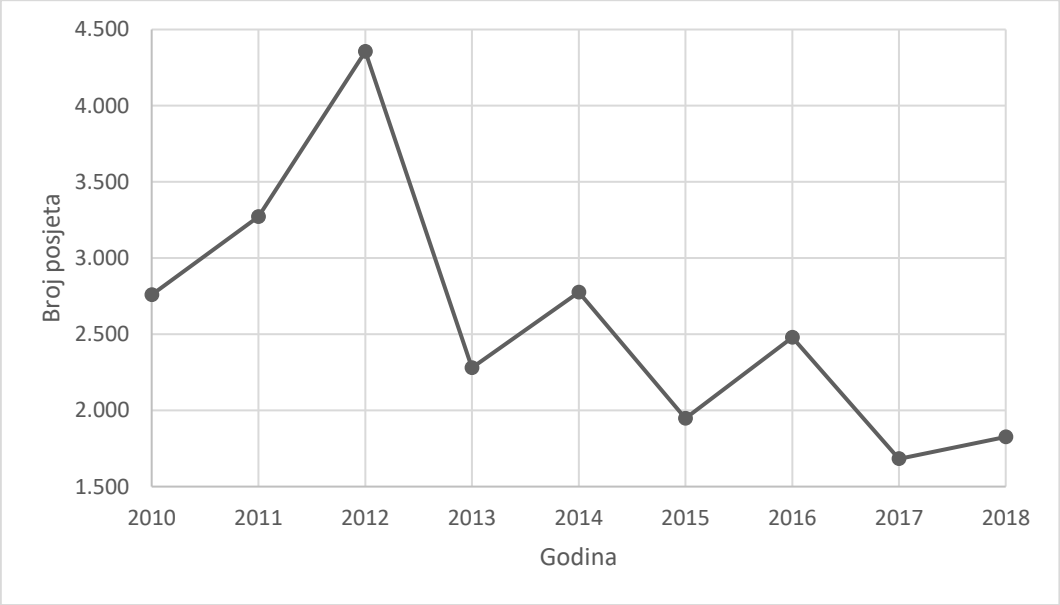
Slika 12. Prikaz broja pregleda po timu u djelatnosti zdravstvene zaštite žena (ugovor s HZZO)

Tablica 13. Prikaz opterećenja specijalista u djelatnosti zdravstvene zaštita žena (ugovor s HZZO)

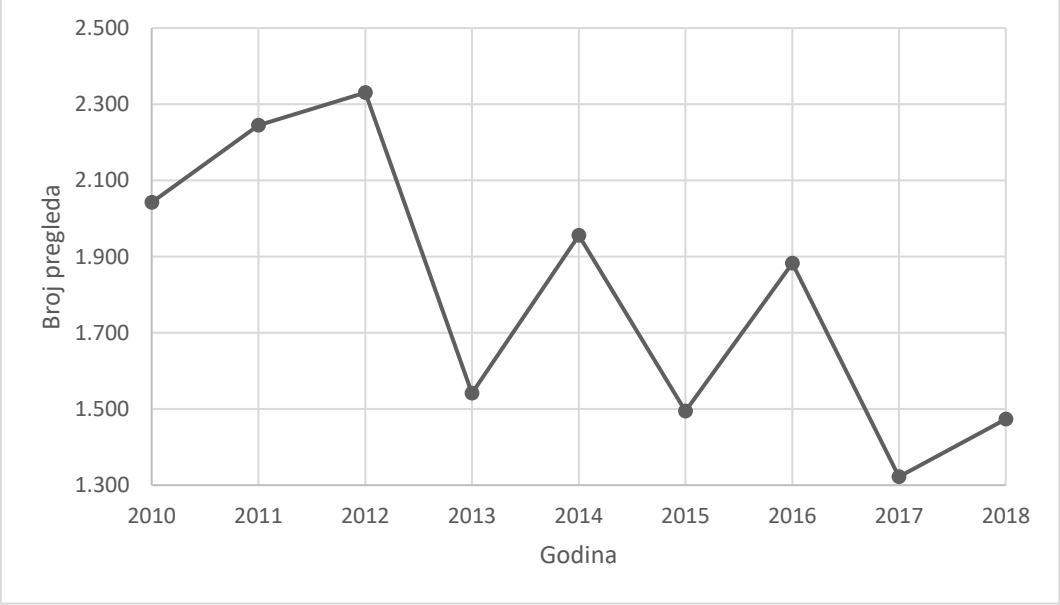
Godina		2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.
Obračunski radni dani		261	261	261	260	261	261	261	260	261
Broj timova		229	227	231	250	259	261	263	265	265
OSIGURANICI / KORISNICI	Broj osiguranika u skrbi	1.535.626	1.472.336	1.556.145	1.626.373	1.672.864	1.717.604	1.677.980	1.732.358	1.724.780
	Broj osiguranika po timu (prosjek)	6.706	6.486	6.737	6.505	6.459	6.581	6.380	6.537	6.509
	Broj korisnika	631.660	543.352	531.941	593.336	620.270	559.115	561.050	549.589	563.031
POSJETE	Ordinacija	1.586.235	1.427.442	1.514.437	1.774.593	1.750.945	1.797.365	1.803.587	1.796.845	1.759.285
	Po timu	6.927	6.288	6.556	7.098	6.760	6.886	6.858	6.781	6.639
	Po timu po danu	27	24	25	27	26	26	26	26	25
PREGLEDI	Ordinacija	867.474	721.991	732.991	635.558	1.009.122	953.612	932.226	932.771	948.912
	Po timu	3.788	3.181	3.173	2.542	3.896	3.654	3.545	3.520	3.581
	Po timu po danu	15	12	12	10	15	14	14	14	14

5.1.2.4. Zdravstvena zaštita žena (bez ugovora s HZZO)

Na slikama 13 i 14 prikazano je kretanje broja posjeta i pregled u ambulantama zdravstvene zaštite žena (bez ugovora s HZZO) od 2010. g. Vidljivo je smanjenje broja posjeta i pregleda po timu tijekom godina. Broj timova se od 2010. g. kada je ih bilo 65 smanjio na 46 u 2018. g. Smanjio se i prosječan broj korisnika po timu sa 1.558 (2010. g.) na 1.212 (2018. g.) dok je vrhunac dosegnut 2012. g kada je prosječno bilo 1.889 korisnika po timu. Jedan od razloga koji su uzrokovali ovakva kretanja može se tražiti u pokretanju Nacionalnog programa ranog otkrivanja vrata maternice 2012.g. (tablica 14).



Slika 13. Prikaz broja posjeta po timu u djelatnosti zdravstvene zaštite žena (bez ugovora s HZZO)



Slika 14. Prikaz broja pregleda po timu u djelatnosti zdravstvene zaštite žena (bez ugovora s HZZO)

Tablica 14. Prikaz opterećenja specijalista u djelatnosti zdravstvene zaštita žena (bez ugovora s HZZO)

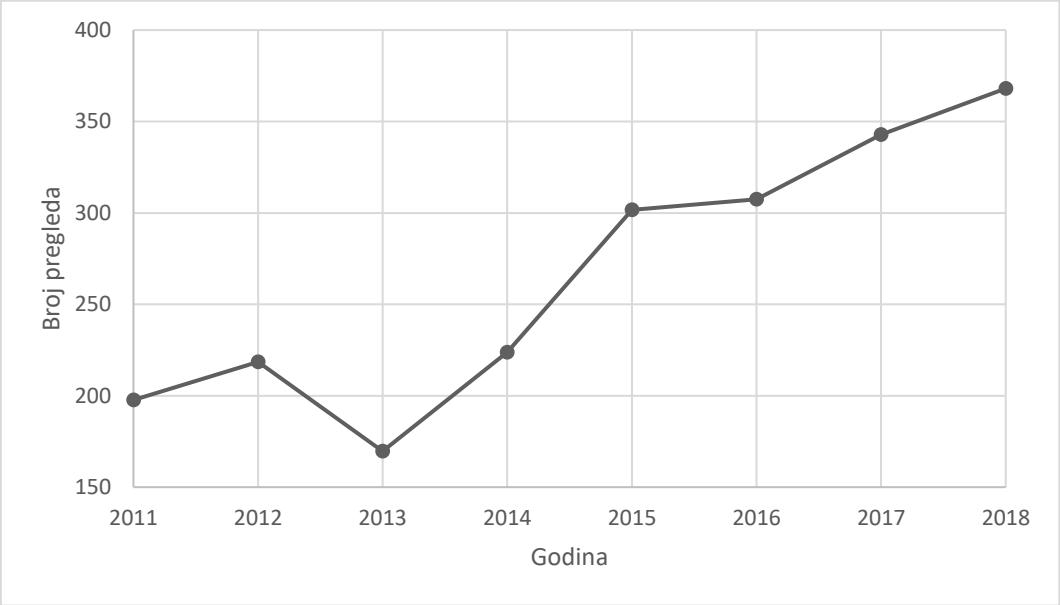
		KORISNICI		POSJETE		PREGLEDI	
Godina	**Broj timova**	**Broj korisnika**	**Po timu**	**Posjete**	**Po timu**	**Pregledi**	**Po timu**
2018.	46	55.732	1.212	83.964	1.825	67.785	1.474
2017.	42	55.818	1.329	70.645	1.682	55.530	1.322
2016.	46	59.898	1.302	114.036	2.479	86.591	1.882
2015.	43	54.481	1.267	83.741	1.947	64.267	1.495
2014.	53	80.347	1.516	147.063	2.775	103.668	1.956
2013.	49	65.902	1.345	111.697	2.280	75.516	1.541
2012.	60	113.312	1.889	261.329	4.355	139.839	2.331
2011.	70	114.796	1.640	228.937	3.271	157.105	2.244
2010.	65	101.268	1.558	179.295	2.758	132.727	2.042

5.1.3. Specijalističko-konzilijarna zdravstvena zaštita

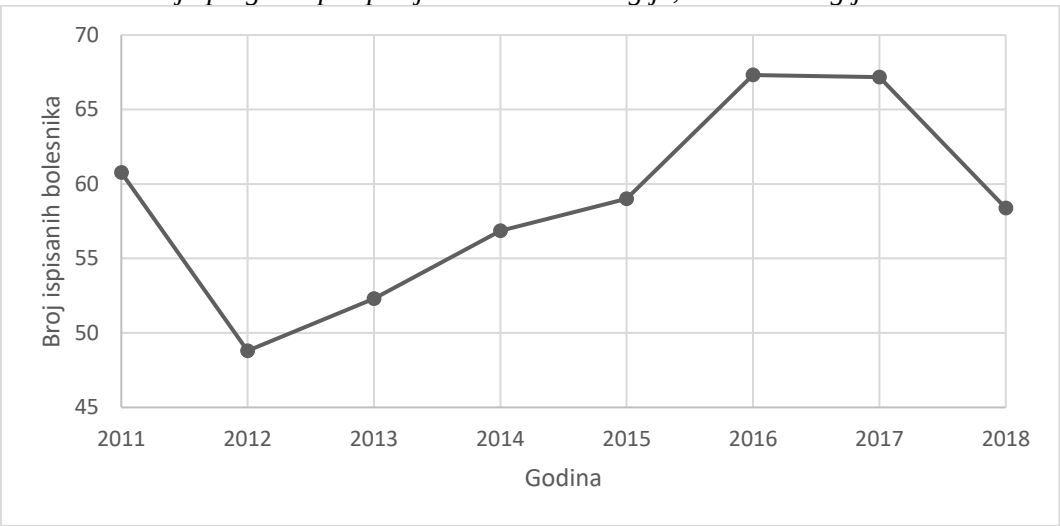
U specijalističko-konzilijarnoj zdravstvenoj zaštiti (sekundarna i tercijarna razina) za prikaz opterećenja specijalista korišteni su podaci o broju pregleda te broju ispisanih bolesnika po specijalistu dostupni u *Hrvatskim zdravstveno-statističkim ljetopisima*.

5.1.3.1. Anesteziologija, reanimatologija i intenzivna medicina

Na slikama 15 i 16 vidi se da tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu anesteziologije u SKZZ raste unatoč povećanju broja specijalista 511 koliko ih je bilo 2011.g. do 597 specijalista 2018.g. što jasno pokazuje da se opterećenje specijalista anesteziologije, reanimatologije i intenzivne medicine povećalo (tablica 15).



Slika 15. Prikaz broja pregleda po specijalistu anesteziologije, reanimatologije i intenzivne medicine



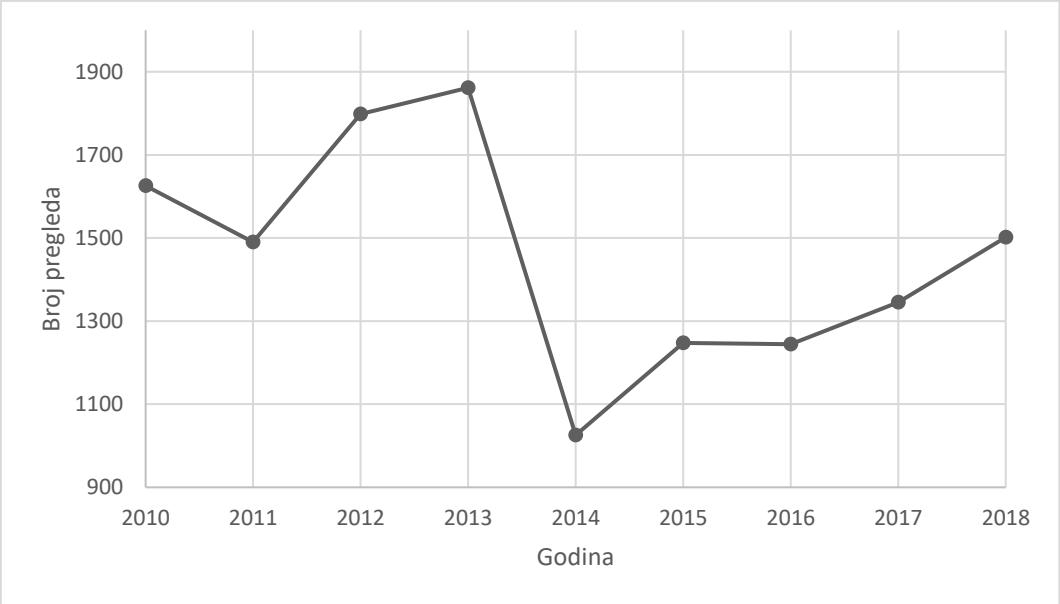
Slika 16. Prikaz broja ispisanih bolesnika po specijalistu anesteziologije, reanimatologije i intenzivne medicine

Tablica 15. Prikaz opterećenja specijalista anesteziologije. reanimatologije i intenzivne medicina u SKZZ

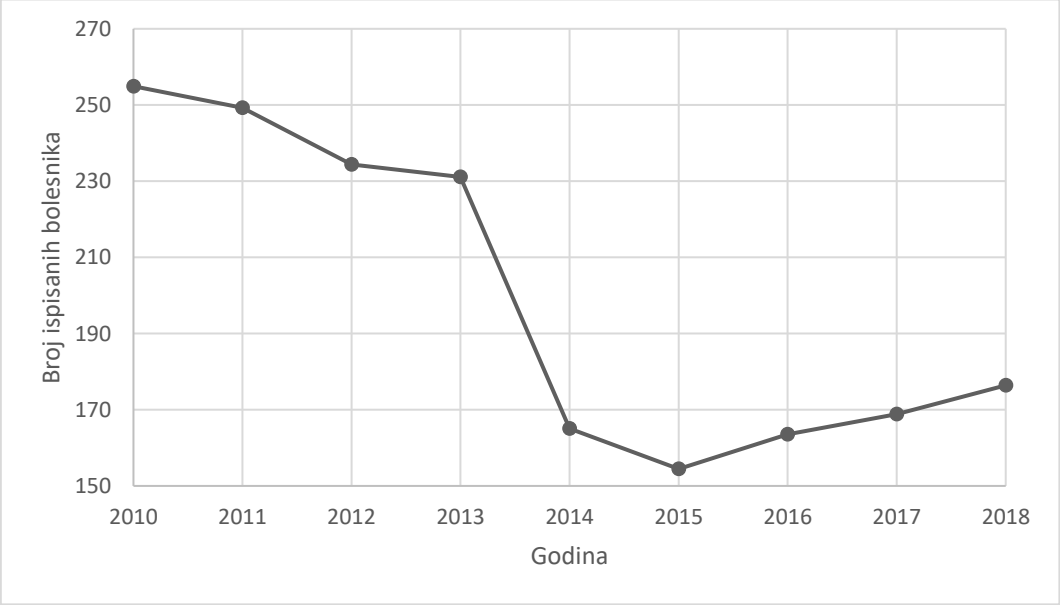
GODINA	SPECIJALISTI	PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom i bez ugovora s HZZO	Broj pregleda po specijalistu	Ispisani bolesnici	Ispisani bolesnici po specijalistu
2018.	597	3.975	219.718	368	34.857	58
2017.	578	3.710	198.141	343	38.822	67
2016.	578	5.500	177.677	307	38.907	67
2015.	609	5.410	183.723	302	35.939	59
2014.	600	13.322	134.298	224	34.115	57
2013.	585	715	99.248	170	30.602	52
2012.	575	209	125.678	219	28.061	49
2011.	511	61	100.990	198	31.049	61

5.1.3.2. Ginekologija i opstetricija

Tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu ginekologije i opstetricije u SKZZ pada (slike 17 i 18). Razloge se može tražiti u povećanju broja specijalista s 600 koliko ih je bilo 2011. g. do 688 specijalista 2018. g. što ide u prilog smanjenju opterećenja specijalista (tablica 16).



Slika 17. Prikaz broja pregleda po specijalistu ginekologije i opstetricije u SKZZ



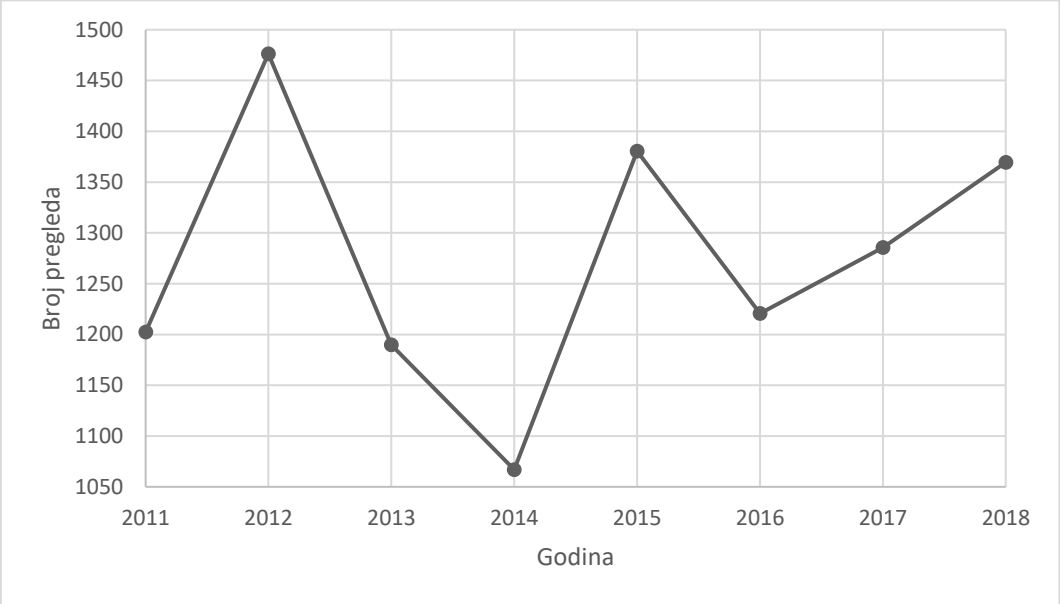
Slika 18. Prikaz broja ispisanih bolesnika po specijalistu ginekologije i opstetricije u SKZZ

Tablica 16. Prikaz opterećenja specijalista ginekologije i opstetricije u SKZZ

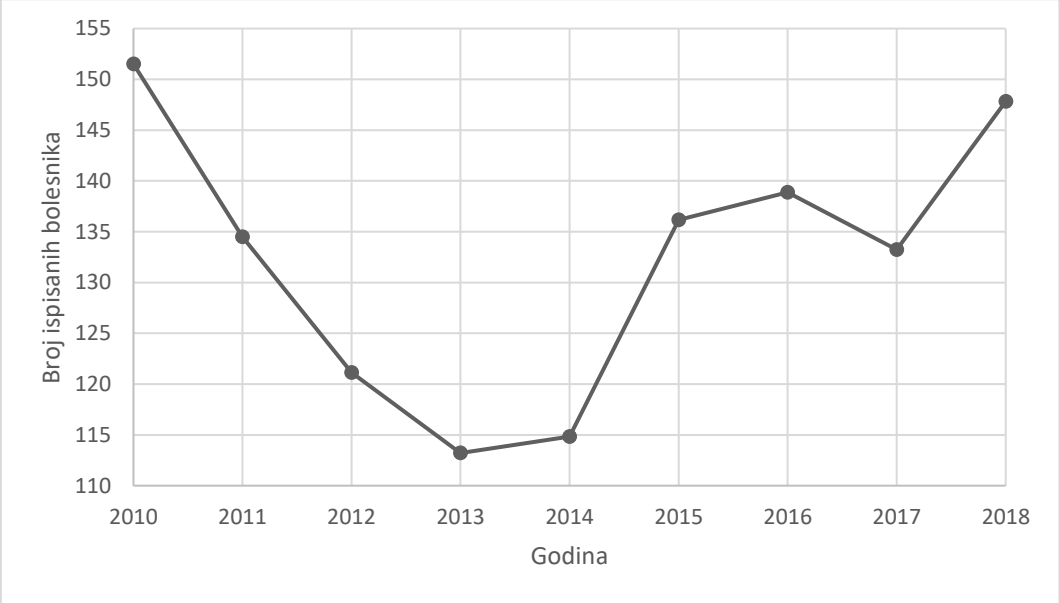
GODINA	SPECIJALISTI		PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj specijalista (bolničkih)	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom s HZZO	Broj pregleda po specijalistu	Ispisani bolesnici	Ispisani bolesnici po specijalistu
2018.	**688**	**423**	**121.340**	**513.734**	**1.501**	**121.353**	**176**
2017.	**694**	**427**	**113.854**	**460.476**	**1.345**	**117.191**	**169**
2016.	**679**	**416**	**105.192**	**412.435**	**1.244**	**111.029**	**164**
2015.	**697**	**434**	**94.146**	**447.368**	**1.248**	**107.656**	**154**
2014.	**686**	**427**	**107.668**	**330.235**	**1.026**	**113.249**	**165**
2013.	**663**	**413**	**84.822**	**332.157**	**1.862**	**109.559**	**231**
2012.	**654**	**417**	**77.140**	**331.125**	**1.799**	**108.774**	**234**
2011.	**613**	**386**	**88.873**	**198.664**	**1.490**	**104.703**	**249**
2010.	**600**	**371**	**79.099**	**220.012**	**1.626**	**105.287**	**255**

5.1.3.3. Neurologija

Tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu neurologije u SKZZ pada osjetno 2014. g. pa se opet povećava do 2018 .g (slike 19 i 20). Razlog se može tražiti u povećanju broja specijalista s 232 koliko ih je bilo 2009. g. do 335 specijalista 2018. g. što ide u prilog povećanja opsega posla u djelatnosti neurologije u SKZZ (tablica 17).



Slika 19. Prikaz broja pregleda po specijalistu neurologije



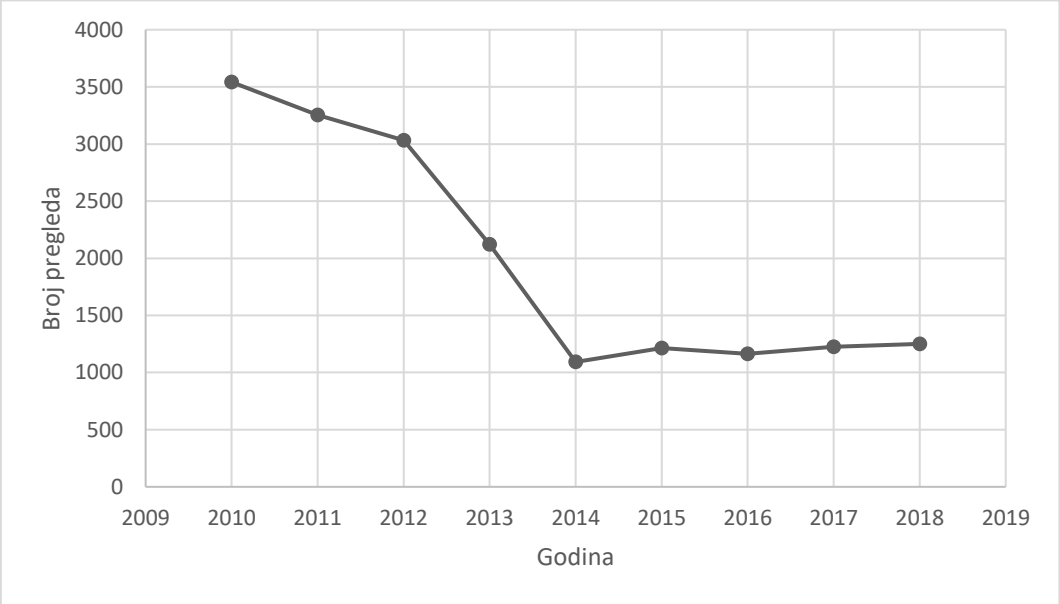
Slika 20. Prikaz broja ispisanih bolesnika po specijalistu neurologije

Tablica 17. Prikaz opterećenja specijalista neurologije u SKZZ

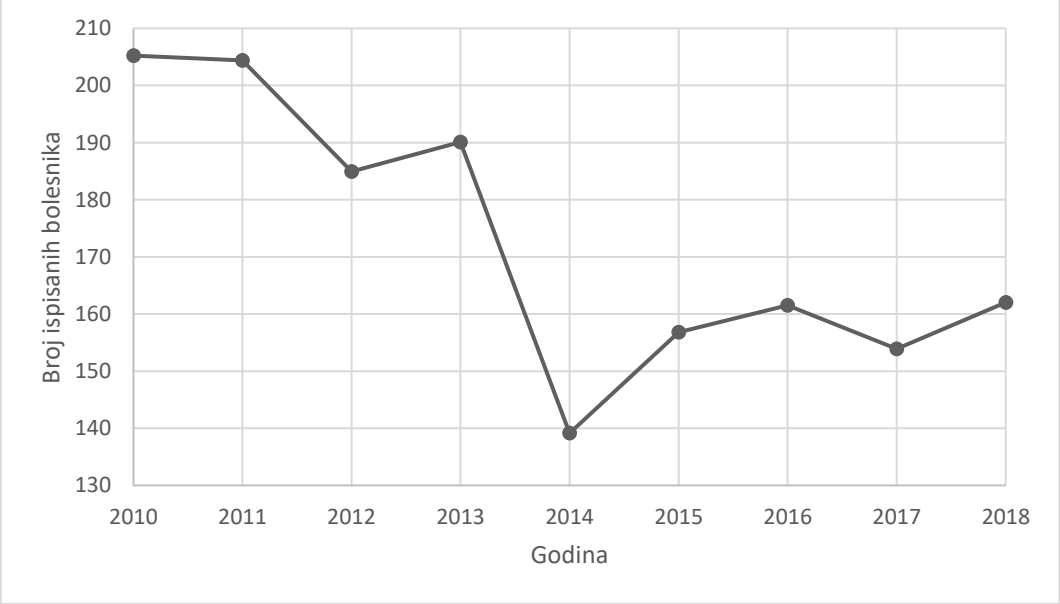
GODINA	SPECIJALISTI	PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom s HZZO	Broj pregleda po specijalistu	Ispisani boles0nici	Ispisani bolesnici po specijalistu
2018.	**335**	**19.805**	**438.897**	**1.369**	**49.525**	**148**
2017.	**338**	**28.147**	**406.330**	**1.285**	**45.033**	**133**
2016	**328**	**26.622**	**373.742**	**1.221**	**45.550**	**139**
2015.	**337**	**18.259**	**446.950**	**1.380**	**45.891**	**136**
2014.	**333**	**28.391**	**326.901**	**1.067**	**38.240**	**115**
2013.	**313**	**25.275**	**347.086**	**1.190**	**35.435**	**113**
2012.	**291**	**13.875**	**415.706**	**1.476**	**35.247**	**121**
2011.	**260**	**18.024**	**294.595**	**1.202**	**34.969**	**134**
2010.	**239**	**23.415**	**40.694**	**268**	**36.211**	**152**
2009.	**232**	**23.558**	**291.993**	**1.360**	**27.543**	**119**

5.1.3.4. Pedijatrija

Tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu pedijatrije u SKZZ pada (slike 21 i 22). Razloge se može tražiti u povećanju broja specijalista s 591 koliko ih je bilo 2010. g. do 710 specijalista 2018. g. što ide u prilog smanjenju opterećenja specijalista (tablica 18).



Slika 21. Prikaz broja pregleda po specijalistu pedijatrije u SKZZ



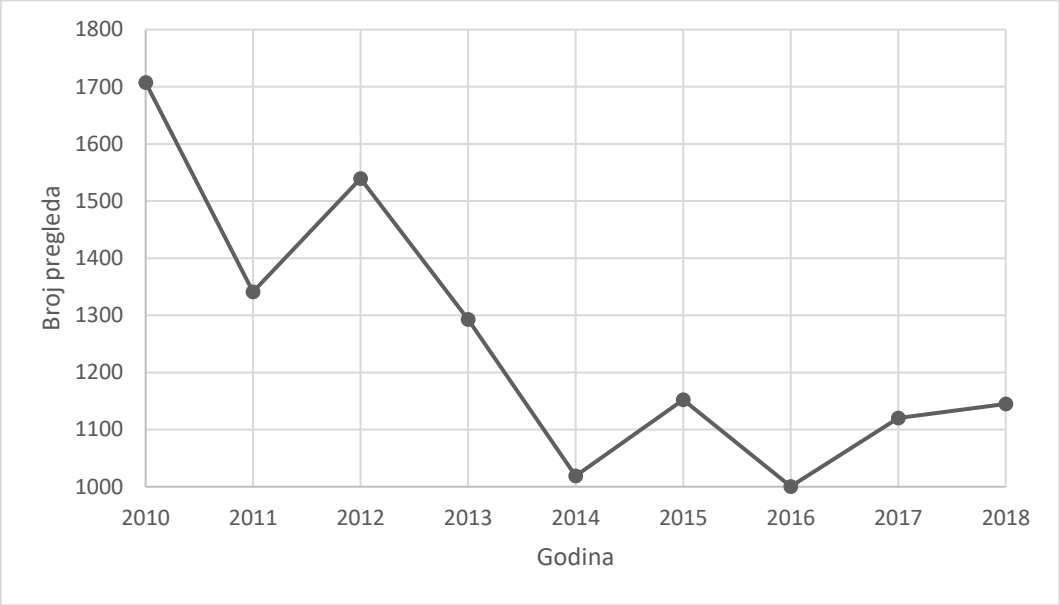
Slika 22. Prikaz broja ispisanih bolesnika po specijalistu pedijatrije u SKZZ

Tablica 18. Prikaz opterećenja specijalista pedijatrije u SKZZ

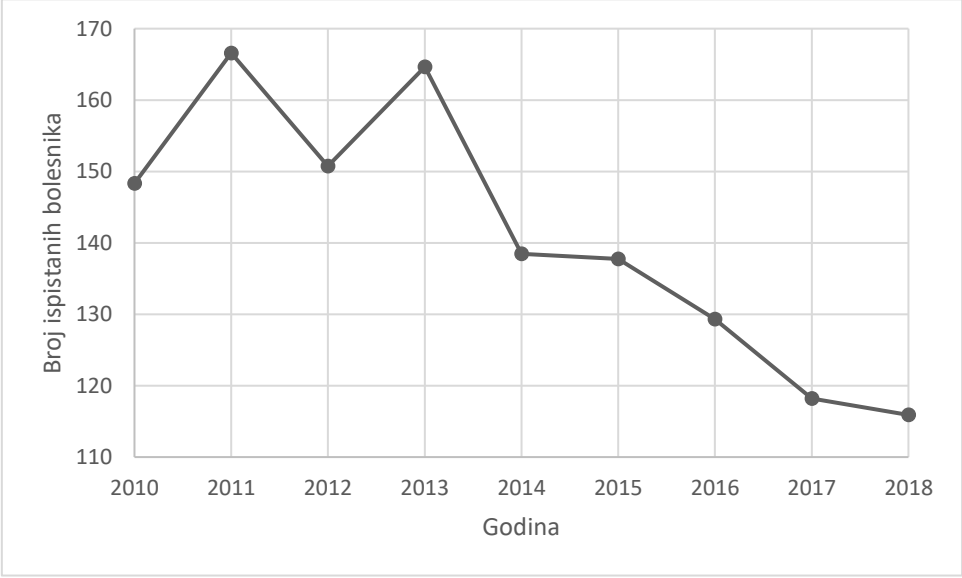
GODINA	SPECIJALISTI		PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj specijalista (bolničkih)	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom s HZZO	Broj pregleda po specijalistu	Ispisani bolesnici	Ispisani bolesnici po specijalistu
2018.	710	430	19.799	518.533	1.252	115.038	162
2017.	707	427	9.905	513.957	1.227	108.815	154
2016.	707	430	8.788	492.163	1.165	114.188	162
2015.	712	436	10.424	518.660	1.213	111.645	157
2014.	707	434	36.961	437.293	1.093	98.371	139
2013.	664	391	10.017	433.642	2.123	91.631	190
2012.	655	384	2.987	597.369	3.032	86.736	185
2011.	602	344	8.870	485.516	3.253	83.798	204
2010.	591	338	47.770	458.686	3.542	81.268	205

5.1.3.5. Psihijatrija

Tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu psihijatrije u SKZZ pada (slike 23 i 24). Razloge se može tražiti u povećanju broja specijalista s 390 koliko ih je bilo 2011. g. do 528 specijalista 2018. g. što ide u prilog smanjenju opterećenja specijalista (tablica 19).



Slika 23. Prikaz broja pregleda po specijalistu psihijatrije u RH



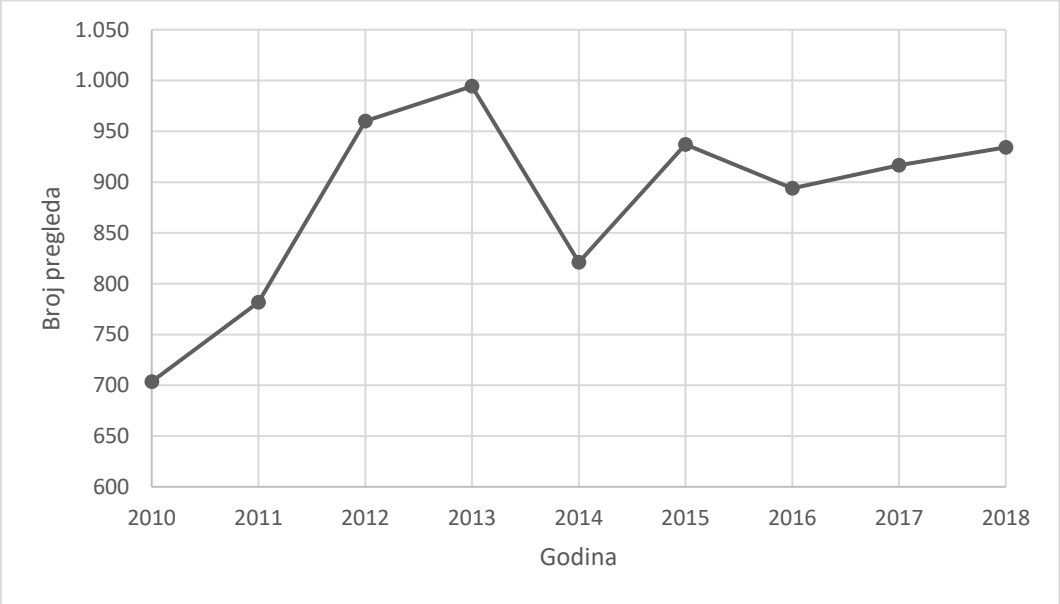
Slika 24. Prikaz broja ispisanih bolesnika po specijalistu psihijatrije u RH

Tablica 19. Prikaz opterećenja specijalista psihijatrije u SKZZ

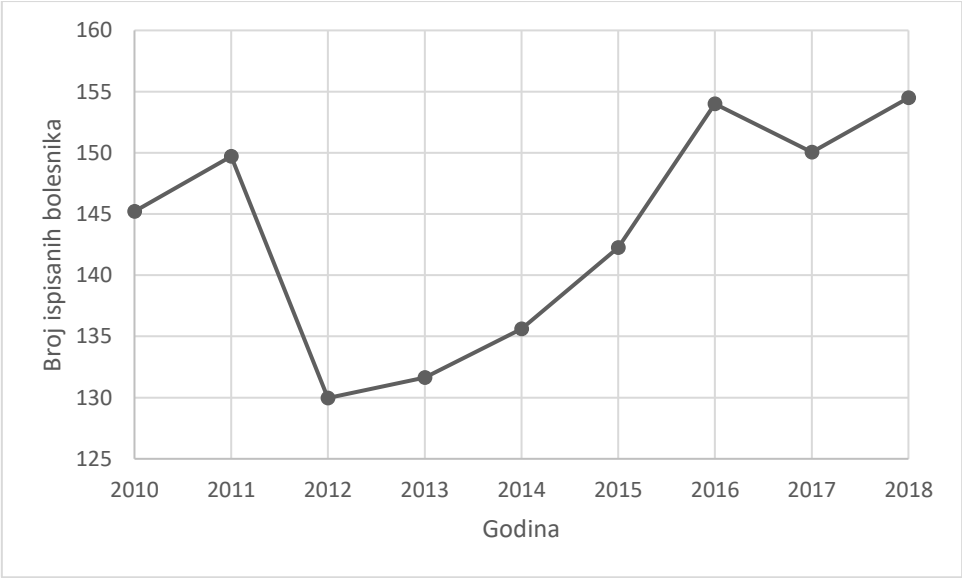
GODINA	SPECIJALISTI	PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom i bez ugovora s HZZO	Broj pregleda po specijalistu	Ispisani bolesnici	Ispisani bolesnici po specijalistu
2018.	528	29.047	575.531	1.145	61.197	116
2017.	522	25.179	559.582	1.120	61.703	118
2016.	518	29.449	488.821	1.001	66.982	129
2015.	529	36.462	573.062	1.152	72.880	138
2014.	519	54.769	474.154	1.019	71.855	138
2013.	435	37.966	524.461	1.293	71.623	165
2012.	434	26.977	641.047	1.539	65.434	151
2011.	390	22.288	500.770	1.341	64.970	167
2010.	375	28.348	610.234	1.707	55.474	148

5.1.3.6. Neurokirurgija

Na slikama 25 i 26 vidi se da tijekom promatranog razdoblja broj pregleda i ispisanih bolesnika po specijalistu neurokirurgije u SKZZ raste unatoč blagom povećanju broja specijalista s 58 koliko ih je bilo 2010. g. na 70 specijalista 2018. g. što jasno pokazuje da se opterećenje specijalista neurokirurgije povećalo (tablica 20).



Slika 25. Prikaz broja pregleda po specijalistu neurokirurgije



Slika 26. Prikaz broja ispisanih bolesnika po specijalistu neurokirurgije

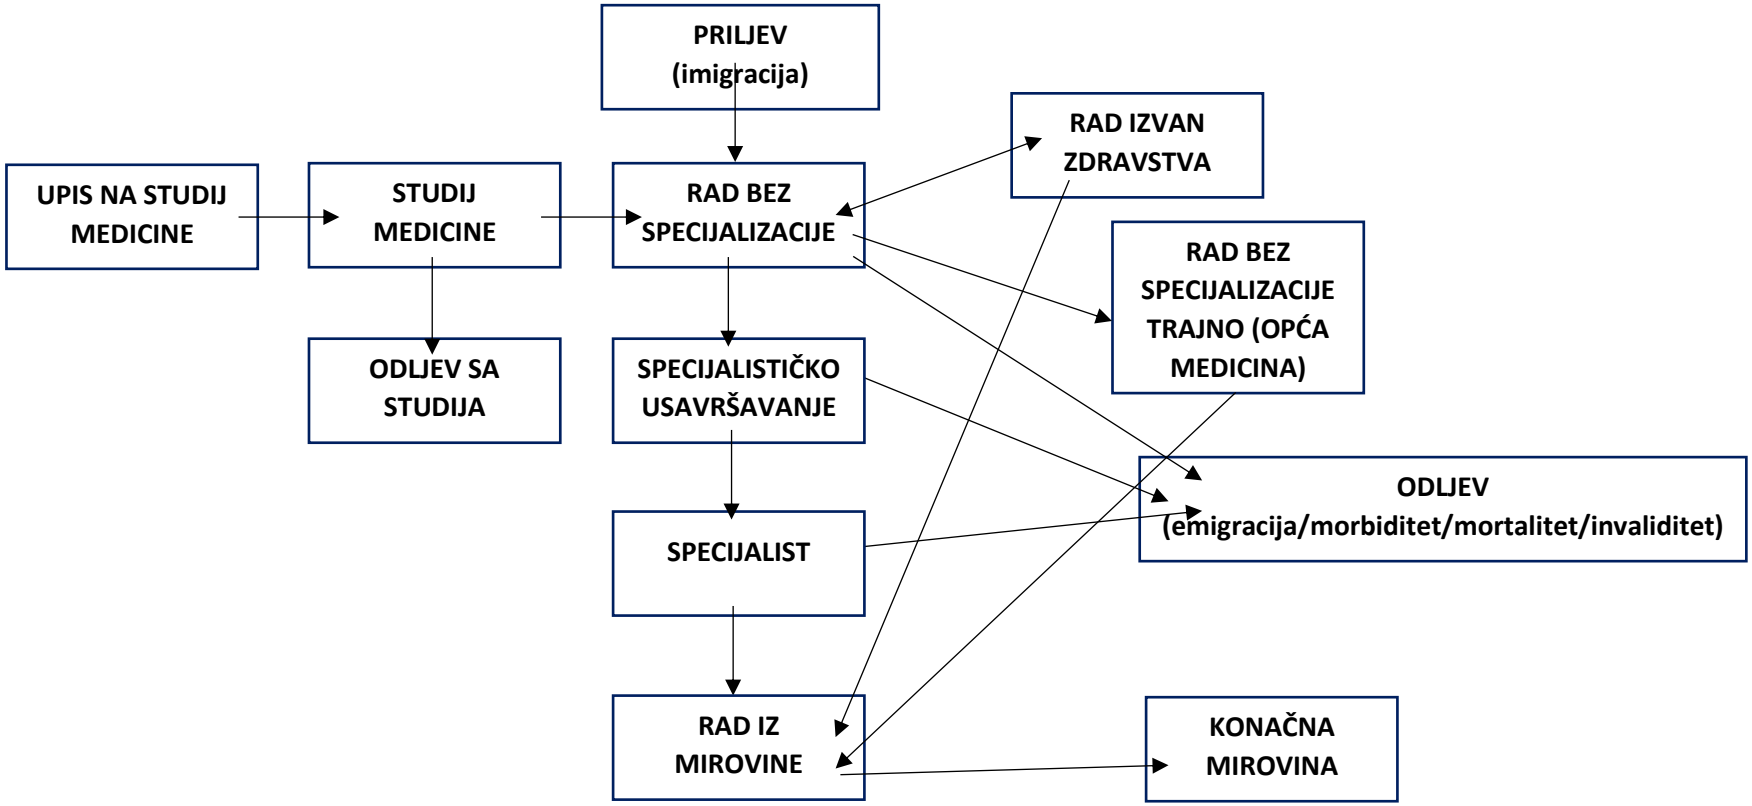
Tablica 20. Prikaz opterećenja specijalista neurokirurgije u SKZZ

GODINA	SPECIJALISTI	PREGLEDI			ISPISANI BOLESNICI	
	Doktori medicine sa zaposlenjem u zdravstvenom sustavu RH	Broj pregleda u ordinacijama bez ugovora s HZZO	Ukupan broj pregleda s ugovorom s HZZO	Broj pregleda po specijalistu	Ispisani bolesnici	Ispisani bolesnici po specijalistu
2018.	70	2.867	62.523	934	10.814	154
2017.	71	2.444	62.638	917	10.654	150
2016.	65	3.728	54.378	894	10.010	154
2015.	64	0	59.961	937	9.104	142
2014.	61	3.876	46.228	821	8.272	136
2013.	60	10.616	49.042	994	7.899	132
2012.	62	0	59.526	960	8.058	130
2011.	54	713	41.493	782	8.084	150
2010.	58	110	40.694	704	8.422	145

5.2. Konceptualni model

5.2.1. Osnovna struktura modela

Konceptualni model za planiranje specijalističkog usavršavanja doktora medicine u Republici Hrvatskoj je koncipiran kao sustav s više odjeljaka gdje su odjeljci organizirani u dvodimenzionalnu matricu. Svaki odjeljak predstavlja liječnike u određenoj fazi obrazovnog ili radnog ciklusa.



Slika 27. Dijagram toka konceptualnog modela za planiranje specijalističkog usavršavanja za doktore medicine u Republici Hrvatskoj

Osnovne pretpostavke ovog modela su:

1. Studij medicine u Republici Hrvatskoj traje 6 godina.

2. Specijalističko usavršavanje za doktore medicine u Republici Hrvatskoj je obvezno osim za privremeni rad liječnika pod nadzorom koji je definiran Pravilnikom o načinu provođenja rada pod nadzorom doktora medicine bez specijalizacije (NN 63/2019).

3. Sukladno važećim odredbama doktori medicine mogu neko vrijeme nakon polaganja stručnog ispita raditi bez specijalizacije pod nadzorom u primarnoj zdravstvenoj zaštiti (opća medicina, hitna medicina).

4. Trajanje specijalističkog usavršavanja za pojedine programe definirano je *Pravilnikom o specijalističkom usavršavanju doktora medicine* i *Pravilnikom o specijalističkom usavršavanju doktora medicine iz obiteljske medicine*.

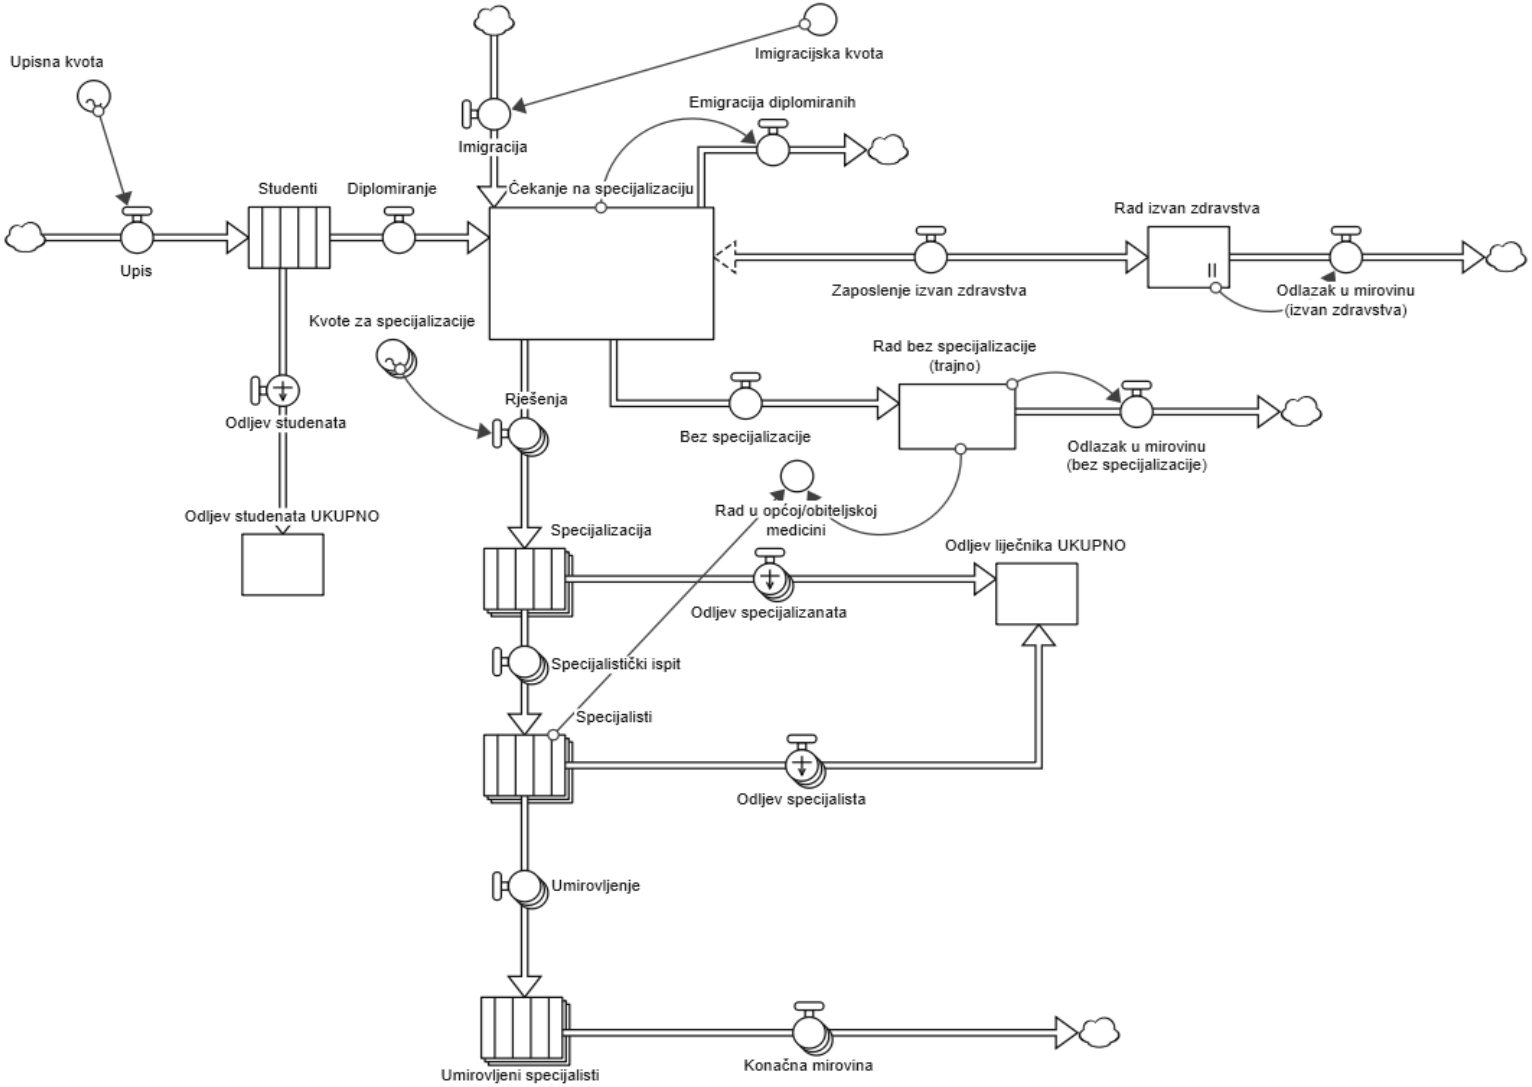
5. Imigracijske kvote određuje Vlada Republike Hrvatske na godišnjoj razini.

6. Dob za odlazak u starosnu mirovinu doktora medicine je 65 godina jednako za oba spola. Trenutačno postoji mogućnost i praksa da se radni vijek produžuje najdulje do 70. godine ili da se radi iz mirovine pola radnog vremena.

7. Određeni broj doktora medicine radni vijek će završiti bez da je završio bilo koju specijalizaciju s obzirom na to da specijalističko usavršavanje nije za sve bilo obvezno – radi se o doktorima medicine koji rade u općoj medicini i kojih je 2020. godine bilo 1.134.

5.3. Simulacijski model

Sljedeća faza u modeliranju je pretvaranje konceptualnog modela u simulacijski model (slika 28). U tu svrhu korišten je programski paket *Stella Architect v1.9.1* - korišteno je viša vrsta odjeljaka koji su sastavni dio navedenog programskog paketa.



Slika 28. Dijagram toka simulacijskog modela za planiranje specijalističkog usavršavanja za doktore medicine u Republici Hrvatskoj

5.3.1. Model po fazama radnog ciklusa liječnika

5.3.1.1. Studij medicine

Upisna kvota predstavlja ukupni godišnji broj upisnih mjesta na svim medicinskim fakultetima te je realizirana u modelu kao pomoćna varijabla koja određuje *ulazni tok materijala* „**Upis**“.

Studenti su svi studenti medicine u Hrvatskoj - određeno je da vrijeme zadržavanja bude 6 godina budući da 90% studenata studij medicine završi u tom roku dok ih 10% nikada ne završi studij (**Odljev studenata**).

Diplomiranje je prikazano kao *ulazno – izlazni tok materijala* koji pokazuje prijelaz studenata u populaciju liječnika koji čekaju na specijalizaciju.

5.3.1.2. Razdoblje nakon diplomiranja

Čekanje na specijalizaciju je u modelu prikazano kao *rezervoar* u kojem se akumuliraju liječnici koji imaju licencu za rad, ali nisu još započeli specijalističko usavršavanje. Liječnici nakon završetka studija pa do početka specijalističkog usavršavanja rade uglavnom u primarnoj zdravstvenoj zaštiti (opća i hitna medicina) – rad doktora medicine pod nadzorom.

Zaposleni izvan zdravstva su liječnici koji rade izvan sustava zdravstva – najčešće je to u farmaceutskoj industriji, istraživačkim institutima, visokom obrazovanju, ali i drugdje. *Tok* koji povezuju *rezervoar/kategoriju* “**Čekanje na specijalizaciju**” sa *rezervoarom* “**Rad izvan zdravstva**” je dvosmjeran stoga što uvijek postoji i određen broj liječnika koji se vrate u sustav zdravstva nakon određenog vremena (primjerice nakon nekoliko godina rada izvan sustava). S druge, strane jednosmjerni *tok* “**Odlazak u mirovinu (izvan zdravstva)**” definira one liječnike koji se ne vrate u sustav zdravstva nego radni vijek provedu izvan zdravstva te tako dočekaju mirovinu.

Imigracijska kvota je broj diplomiranih koji pomoću *toka* “**Imigracija**” ulaze u *rezervoar* “**Čekanje na specijalizaciju**”. *Tok* **Emigracija diplomiranih** (onih koji još nisu započeli specijalističko usavršavanje) ide iz *rezervoara* “**Čekanje na specijalizaciju**”. Imigracijsku kvotu definira Vlada Republike Hrvatske svake godine Odlukom o utvrđivanju godišnje kvote dozvola za zapošljavanje stranaca (koja se po potrebi može povećati), a **emigracija diplomiranih** je procijenjeni broj onih koji odlaze na rad izvan Hrvatske iz “**Čekanje na specijalizaciju**”.

"**Rad bez specijalizacije trajno**" predstavlja broj liječnika koji su trajno zaposleni u sustavu zdravstva bez da su završili specijalizaciju. To su liječnici koji rade u općoj i hitnoj medicini te će kroz 20-ak godina praktično svi biti umirovljeni.

5.3.1.3. Specijalističko usavršavanje

Pomoćnom varijablom "**Kvote za specijalizacije**" opisan je tok materijala "**Rješenja**" tj. broj rješenja Ministarstva zdravstva RH o odobrenju pojedine specijalizacije godišnje.

Slijedom toga, ovisno o broju izdanih rješenja puni se *pokretna traka* "**Specijalizacija**" za pojedinu specijalizaciju. Vrijeme zadržavanja u toj *pokretnoj traci* određeno je vremenskim trajanjem pojedinog programa specijalističkog usavršavanja definirano Pravilnikom o specijalističkom usavršavanju doktora medicine (41).

Odljev specijalizanata prikazan je kao *tok materijala* tj. postotak onih koji odustaju od specijalističkog usavršavanja po pojedinoj specijalizaciji.

5.3.1.4. Liječnici specijalisti

Nakon proteka vremena trajanja specijalističkog usavršavanja liječnici specijalizanti pristupaju specijalističkom ispitu koji je u modelu prikazan *tokom materijala* "**Specijalistički ispit**" koji ih vodi u sljedeći niz "**Specijalisti**". Tu su raspoređeni u 35 dobnih skupina (31. do 65. godine života) te se tamo i zadržavaju najviše 35 godina tj. do odlaska u starosnu mirovinu što je prikazano *tokom materijala* „**Umirovljenje**" koji ide u *niz* „**Umirovljeni specijalisti**".

Odljev specijalista prikazan je *tokom materijala* te se izražava postotkom od ukupnog broja specijalista pojedine specijalnosti.

„**Rad u općoj/obiteljskoj medicini**" označen je kao *pomoćna varijabla* te predstavlja zbroj specijalista obiteljske medicine te broj doktora medicine koji trajno rade bez specijalizacije.

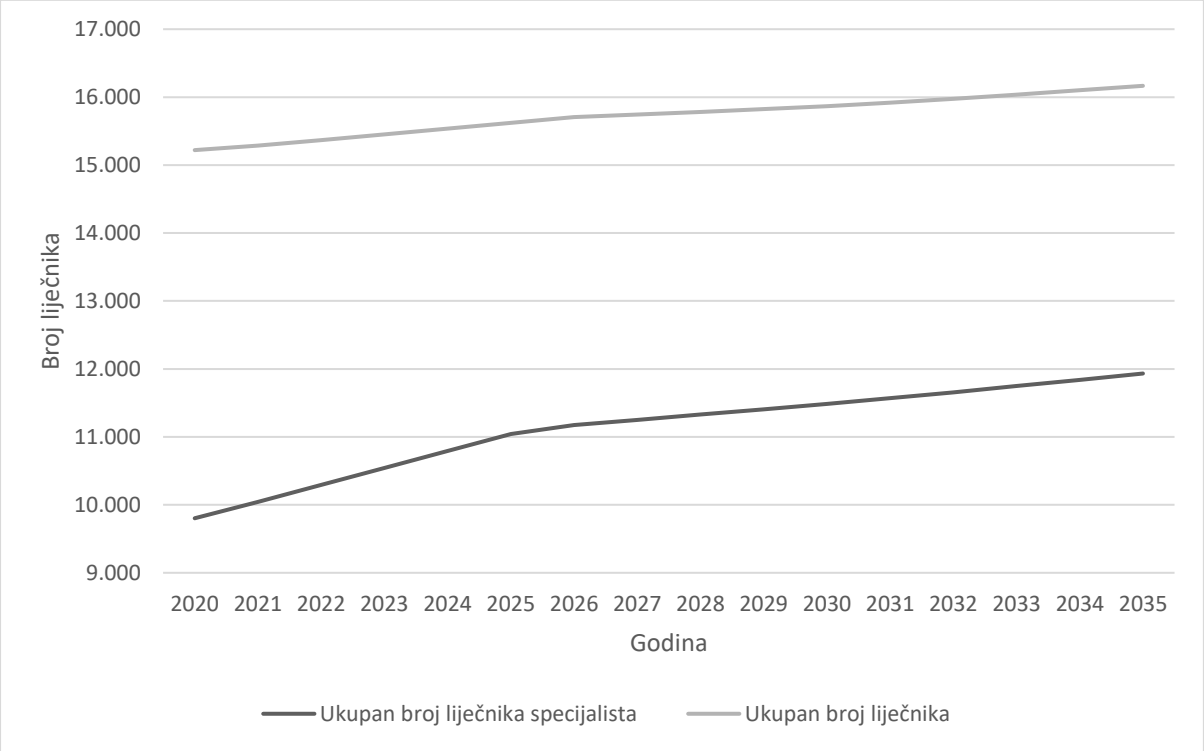
Umirovljeni specijalisti su još jedan *niz* u kojem su specijalisti u mirovini po specijalizacijama te postoji mogućnost povremenog rada u zdravstvenom sustavu. Iz njega odlaze u konačnu mirovinu.

Vremenska jedinica korištena za simulaciju je godina pa su svi parametri tako zadani.
Simulacijski eksperimenti provedeni su s integracijskim intervalom dt=1 godina.

5.4. Rezultati simulacijskih eksperimenata

Na slikama 29 do 34 prikazani su rezultati dobiveni simulacijskim modeliranjem pet ranije opisanih scenarija, a detaljni brojčani rezultati u tablicama 22, 24, 26, 28 i 30.

5.4.1 Scenarij 1



Slika 29. Rezultati dobiveni simulacijskim modeliranjem (Scenarij 1) – projekcija kretanja ukupnog broja liječnika i ukupnog broja liječnika specijalista do 2035.g.

Tablica 21. Prikaz rezultata dobivenih simulacijskim modeliranjem (Scenarij 1) – projekcija kretanja broja liječnika na 100.000 stanovnika

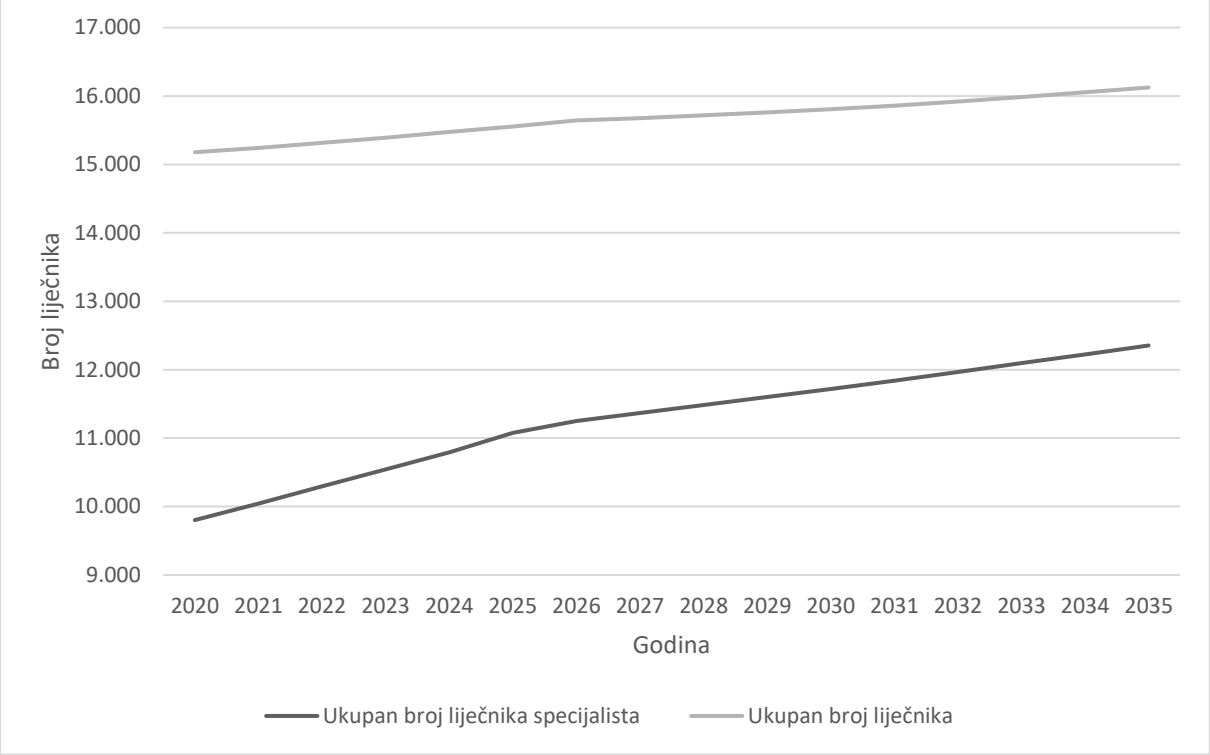
Godina	Simulirani ukupan broj liječnika	Projicirani broj stanovnika	Broj liječnika na 100.000 stanovnika
2021.	15.289	4.151.550	368,3
2031.	15.917	3.964.385	401,5
2041.	16.699	3.723.497	448,5
2051.	17.848	3.456.866	516,3

Tablica 22. Rezultati simulacija s obzirom na fazu radnog ciklusa liječnika - Scenarij 1

	SPECIJALISTI												
Godina	**Obiteljska medicina**	**Psihijatrija**	**Pedijatrija**	**Ginekologija i opstetricija**	**Neurokirurgija**	**Anesteziologija, reanimatologija i int. m.**	**Neurologija**	**Ostale specijalizacije**	**Ukupan broj liječnika specijalista**	**Specijalizanti**	**Čekanje na specijalizaciju**	**Rad bez specijalizacije (trajno)**	**Ukupan broj liječnika**
2020.	1.096	521	696	725	71	638	342	5.713	9.803	2.993	1.291	1.134	15.221
2021.	1.074	527	715	724	75	672	353	5.906	10.045	2.880	1.287	1.077	15.289
2022.	1.056	534	734	723	77	707	364	6.101	10.296	2.768	1.282	1.023	15.369
2023.	1.038	540	753	723	79	742	375	6.295	10.545	2.656	1.278	972	15.451
2024.	1.021	547	772	723	81	776	387	6.487	10.794	2.544	1.274	924	15.535
2025.	1.003	553	792	723	84	810	398	6.677	11.040	2.433	1.269	877	15.620
2026.	986	565	794	724	86	836	407	6.776	11.175	2.434	1.265	834	15.708
2027.	954	569	804	722	89	858	413	6.841	11.250	2.434	1.266	792	15.743
2028.	924	573	813	720	91	880	420	6.906	11.328	2.434	1.267	752	15.781
2029.	894	577	823	719	94	901	426	6.972	11.405	2.434	1.268	715	15.823
2030.	866	581	832	718	97	923	431	7.037	11.486	2.434	1.269	679	15.868
2031.	838	586	842	718	100	944	437	7.103	11.568	2.434	1.270	645	15.917
2032.	840	592	855	717	103	966	443	7.141	11.657	2.434	1.271	613	15.975
2033.	843	599	867	715	106	987	449	7.180	11.748	2.434	1.272	582	16.036
2034.	846	606	880	714	109	1.009	455	7.219	11.840	2.434	1.273	553	16.100
2035.	850	613	893	713	113	1.030	462	7.260	11.933	2.434	1.274	525	16.167
2036.	853	620	906	713	116	1.051	468	7.301	12.028	2.434	1.275	499	16.236
2037.	868	628	914	718	120	1.069	473	7.351	12.140	2.434	1.276	474	16.324
2038.	883	635	923	723	123	1.086	478	7.401	12.254	2.434	1.277	450	16.415
2039.	898	643	932	728	127	1.104	483	7.453	12.368	2.434	1.277	428	16.508
2040.	913	651	941	734	130	1.122	489	7.505	12.484	2.434	1.278	407	16.603
2041.	927	659	950	739	134	1.139	494	7.558	12.600	2.434	1.279	386	16.699

2042.	947	671	960	745	136	1.156	501	7.603	12.717	2.434	1.280	367	16.798
2043.	966	682	969	750	139	1.173	508	7.648	12.836	2.434	1.281	349	16.899
2044.	985	694	979	756	141	1.189	515	7.695	12.955	2.434	1.281	331	17.002
2045.	1.004	706	989	762	143	1.206	522	7.743	13.075	2.434	1.282	315	17.106
2046.	1.022	718	999	768	146	1.222	529	7.792	13.196	2.434	1.283	299	17.212
2047.	1.041	730	1.012	778	147	1.240	535	7.852	13.336	2.434	1.284	284	17.337
2048.	1.060	742	1.024	788	149	1.258	541	7.913	13.475	2.434	1.285	270	17.464
2049.	1.079	754	1.037	798	150	1.275	548	7.975	13.615	2.434	1.285	256	17.591
2050.	1.098	765	1.050	808	152	1.292	554	8.037	13.756	2.434	1.286	243	17.720
2051.	1.116	777	1.062	819	153	1.310	560	8.098	13.895	2.434	1.287	231	17.848

5.4.2. Scenarij 2



Slika 30. Rezultati dobiveni simulacijskim modeliranjem (Scenarij 2) – projekcija kretanja ukupnog broja liječnika i ukupnog broja liječnika specijalista do 2035.g.

Tablica 23. Prikaz rezultata dobivenih simulacijskim modeliranjem (Scenarij 2) – projekcija kretanja broja liječnika na 100.000 stanovnika

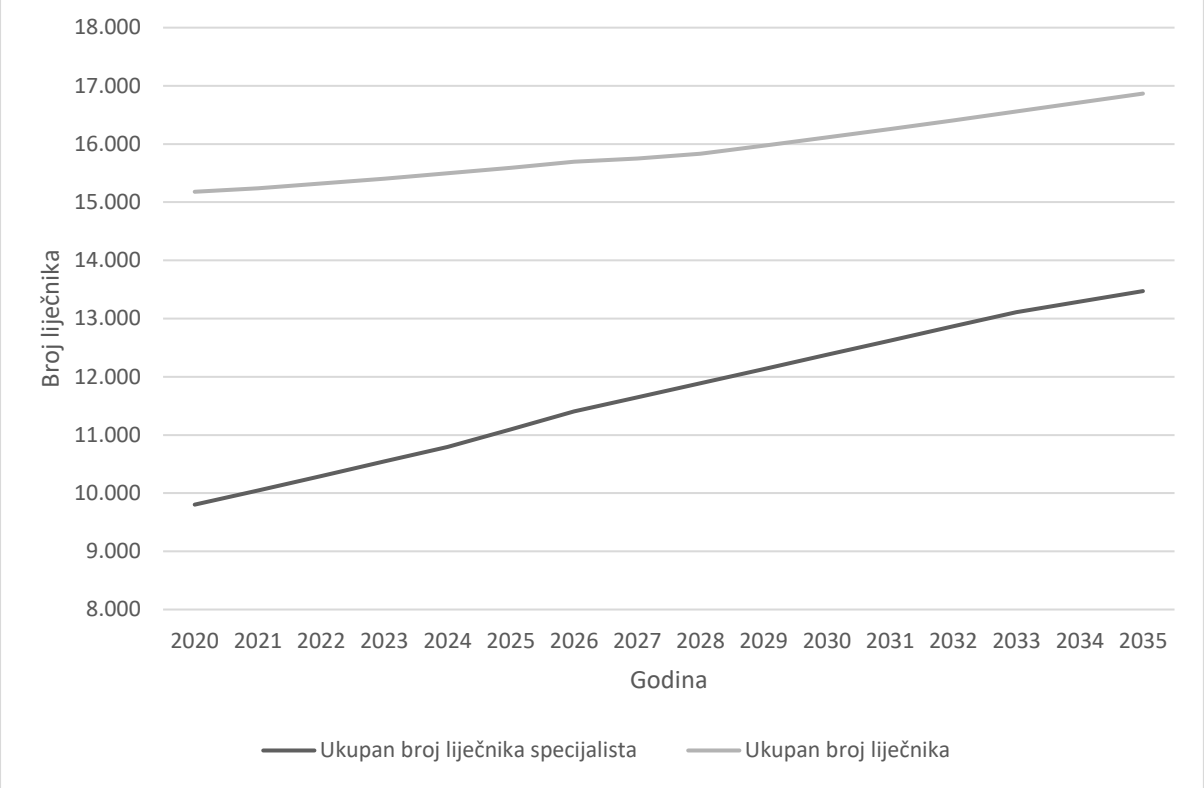
Godina	Simulirani ukupni broj liječnika	Projicirani broj stanovnika	Broj liječnika na 100.000 st.
2021.	15.241	4.151.550	367,1
2031.	15.859	3.964.385	400,0
2041.	16.697	3.723.497	448,4
2051.	17.936	3.456.866	518,9

Tablica 24. Rezultati simulacija s obzirom na fazu radnog ciklusa liječnika - Scenarij 2

	SPECIJALISTI												
Godina	**Obiteljska medicina**	**Psihijatrija**	**Pedijatrija**	**Ginekologija i opstetricija**	**Neurokirurgija**	**Anesteziologija, reanimatologija i int. m.**	**Neurologija**	**Ostale specijalizacije**	**Ukupan broj liječnika specijalista**	**Specijalizanti**	**Čekanje na specijalizaciju**	**Rad bez specijalizacije (trajno)**	**Ukupan broj liječnika**
2020.	1.096	521	696	725	71	638	342	5.713	9.803	2.993	1.303	1.081	15.180
2021.	1.074	527	715	724	75	672	353	5.906	10.045	2.921	1.248	1.027	15.241
2022.	1.056	534	734	723	77	707	364	6.101	10.296	2.850	1.194	976	15.315
2023.	1.038	540	753	723	79	742	375	6.295	10.545	2.779	1.142	927	15.393
2024.	1.021	547	772	723	81	776	387	6.487	10.794	2.707	1.092	880	15.473
2025.	1.041	553	792	723	84	810	398	6.677	11.078	2.599	1.043	836	15.557
2026.	1.061	562	796	723	86	819	403	6.802	11.252	2.601	996	795	15.643
2027.	1.066	563	808	720	89	824	406	6.892	11.368	2.601	955	755	15.678
2028.	1.072	564	819	717	91	830	408	6.983	11.485	2.601	915	717	15.718
2029.	1.079	565	830	715	94	835	410	7.073	11.601	2.601	877	681	15.760
2030.	1.086	567	842	714	97	841	412	7.163	11.720	2.601	840	647	15.808
2031.	1.093	568	853	712	100	846	414	7.254	11.841	2.601	803	615	15.859
2032.	1.131	572	868	710	103	852	416	7.316	11.968	2.601	768	584	15.921
2033.	1.168	576	883	708	106	857	419	7.378	12.096	2.601	734	555	15.985
2034.	1.206	581	897	706	109	863	421	7.442	12.224	2.601	701	527	16.053
2035.	1.243	585	912	704	113	869	424	7.505	12.354	2.601	669	501	16.125
2036.	1.280	589	926	703	116	875	426	7.570	12.485	2.601	638	476	16.199
2037.	1.328	594	937	707	120	878	428	7.643	12.633	2.601	608	452	16.294
2038.	1.375	599	947	711	123	881	429	7.716	12.782	2.601	579	429	16.391
2039.	1.422	604	958	715	127	884	431	7.790	12.931	2.601	550	408	16.490
2040.	1.469	609	969	720	130	887	433	7.864	13.081	2.601	523	388	16.592
2041.	1.516	615	979	725	134	890	435	7.939	13.232	2.601	496	368	16.697

2042.	1.566	624	991	729	136	893	438	8.005	13.383	2.601	470	350	16.803
2043.	1.616	634	1.002	734	139	895	442	8.072	13.534	2.601	445	332	16.912
2044.	1.666	643	1.014	739	141	898	446	8.140	13.686	2.601	421	316	17.023
2045.	1.715	652	1.025	744	143	901	450	8.209	13.839	2.601	397	300	17.137
2046.	1.763	662	1.037	749	146	904	454	8.278	13.992	2.601	374	285	17.252
2047.	1.811	671	1.051	758	147	909	456	8.359	14.163	2.601	352	271	17.386
2048.	1.859	681	1.065	768	149	913	459	8.440	14.334	2.601	330	257	17.522
2049.	1.907	690	1.079	777	150	918	462	8.522	14.505	2.601	310	244	17.659
2050.	1.954	700	1.093	787	152	922	465	8.603	14.676	2.601	289	232	17.798
2051.	2.000	710	1.107	796	153	927	468	8.684	14.845	2.601	270	220	17.936

5.4.3. Scenarij 3



Slika 31. Rezultati dobiveni simulacijskim modeliranjem (Scenarij 3) – projekcija kretanja ukupnog broja liječnika i ukupnog broja liječnika specijalista do 2035.g.

Tablica 25. Prikaz rezultata dobivenih simulacijskim modeliranjem (Scenarij 3) – projekcija kretanja broja liječnika na 100.000 stanovnika

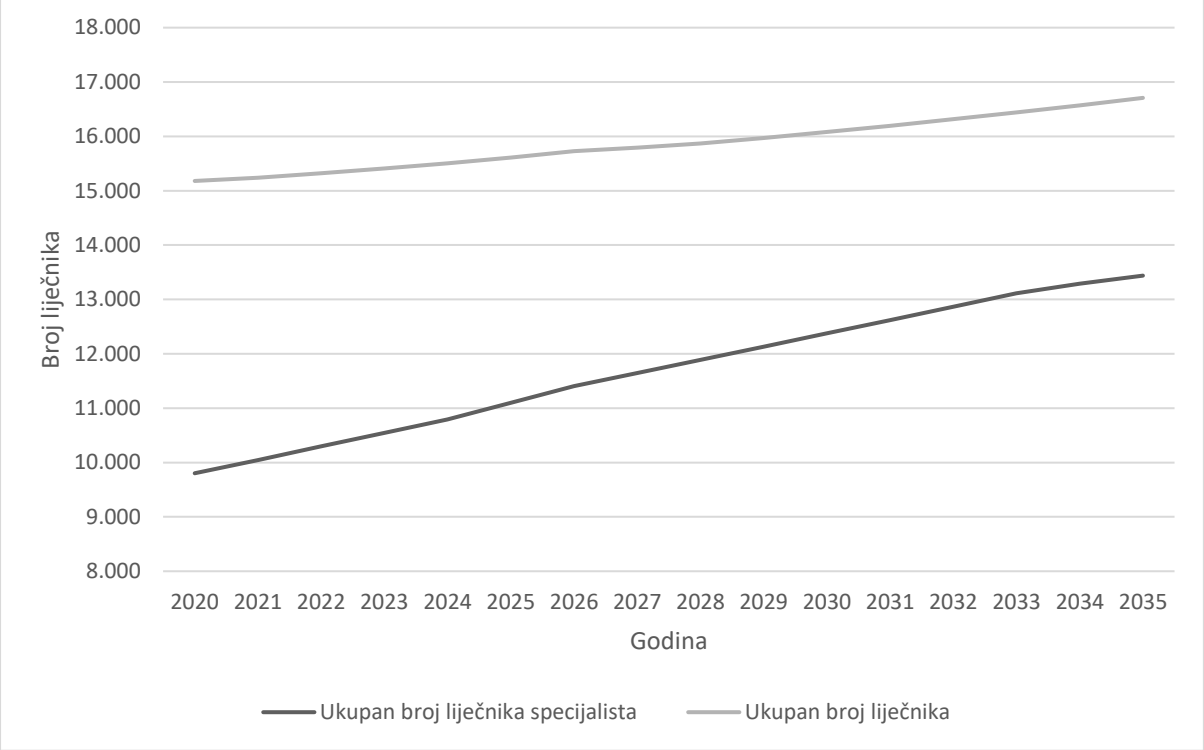
Godina	Simulirani ukupan broj liječnika	Projicirani broj stanovnika	Broj liječnika na 100.000 st.
2021.	15.241	4.151.550	367,1
2031.	16.257	3.964.385	410,1
2041.	17.303	3.723.497	480,9
2051.	19.813	3.456.866	573,1

Tablica 26. Rezultati simulacija s obzirom na fazu radnog ciklusa liječnika - Scenarij 3

	SPECIJALISTI									Specijalizanti	Čekanje na specijalizaciju	Rad bez specijalizacije (trajno)	Ukupan broj liječnika
Godina	**Obiteljska medicina**	**Psihijatrija**	**Pedijatrija**	**Ginekologija i opstetricija**	**Neurokirurgija**	**Anesteziologija, reanimatologija i int. m.**	**Neurologija**	**Ostale specijalizacije**	**Ukupan broj liječnika specijalista**				
2020.	1.096	521	696	725	71	638	342	5.713	9.803	2.993	1.303	1.081	15.180
2021.	1.074	527	715	724	75	672	353	5.906	10.045	3.052	1.117	1.027	15.241
2022.	1.056	534	734	723	77	707	364	6.101	10.296	3.112	936	976	15.319
2023.	1.038	540	753	723	79	742	375	6.295	10.545	3.171	761	927	15.404
2024.	1.021	547	772	723	81	776	387	6.487	10.794	3.230	591	880	15.495
2025.	1.061	553	792	723	84	810	398	6.677	11.099	3.231	426	836	15.593
2026.	1.102	568	805	730	86	826	407	6.878	11.403	3.232	266	795	15.696
2027.	1.128	575	825	734	89	838	413	7.044	11.646	3.232	116	755	15.750
2028.	1.154	582	845	738	91	850	420	7.209	11.890	3.227	0	717	15.834
2029.	1.180	589	866	742	94	862	426	7.373	12.132	3.159	0	681	15.972
2030.	1.207	596	886	747	97	874	431	7.537	12.376	3.091	0	647	16.114
2031.	1.234	603	905	753	100	887	437	7.700	12.619	3.023	0	615	16.257
2032.	1.291	613	928	757	103	899	443	7.833	12.868	2.955	0	584	16.407
2033.	1.348	622	951	761	106	911	449	7.961	13.110	2.893	0	555	16.559
2034.	1.404	632	974	766	109	923	455	8.027	13.291	2.893	0	527	16.712
2035.	1.460	642	997	770	113	935	462	8.094	13.472	2.893	0	501	16.867
2036.	1.516	651	1.019	775	116	947	468	8.161	13.654	2.893	0	476	17.023
2037.	1.582	662	1.038	785	120	956	473	8.237	13.852	2.893	0	452	17.198
2038.	1.647	672	1.056	796	123	965	478	8.312	14.050	2.893	0	429	17.373
2039.	1.713	682	1.075	806	127	975	483	8.389	14.248	2.893	0	408	17.550
2040.	1.777	692	1.093	817	130	984	489	8.465	14.446	2.893	0	388	17.727
2041.	1.841	703	1.111	827	134	993	494	8.542	14.644	2.893	0	368	17.906
2042.	1.909	717	1.130	838	136	1.001	501	8.611	14.842	2.893	0	350	18.086
2043.	1.976	731	1.149	848	139	1.010	508	8.680	15.040	2.893	0	332	18.266

2044.	2.042	746	1.168	859	141	1.018	515	8.750	15.238	2.893	0	316	18.447
2045.	2.107	760	1.186	869	143	1.027	522	8.820	15.436	2.893	0	300	18.629
2046.	2.172	774	1.205	880	146	1.035	529	8.892	15.633	2.893	0	285	18.812
2047.	2.237	788	1.226	895	147	1.045	535	8.974	15.848	2.893	0	271	19.012
2048.	2.301	803	1.247	910	149	1.055	541	9.057	16.062	2.893	0	257	19.213
2049.	2.364	817	1.268	924	150	1.065	548	9.140	16.276	2.893	0	244	19.413
2050.	2.427	831	1.289	939	152	1.075	554	9.223	16.489	2.893	0	232	19.614
2051.	2.488	845	1.310	954	153	1.085	560	9.305	16.699	2.893	0	220	19.813

5.4.4. Scenarij 4



Slika 32. Rezultati dobiveni simulacijskim modeliranjem (Scenarij 4) – projekcija kretanja ukupnog broja liječnika i ukupnog broja liječnika specijalista do 2035.g.

Tablica 27. Prikaz rezultata dobivenih simulacijskim modeliranjem (Scenarij 4) – projekcija kretanja broja liječnika na 100.000 stanovnika

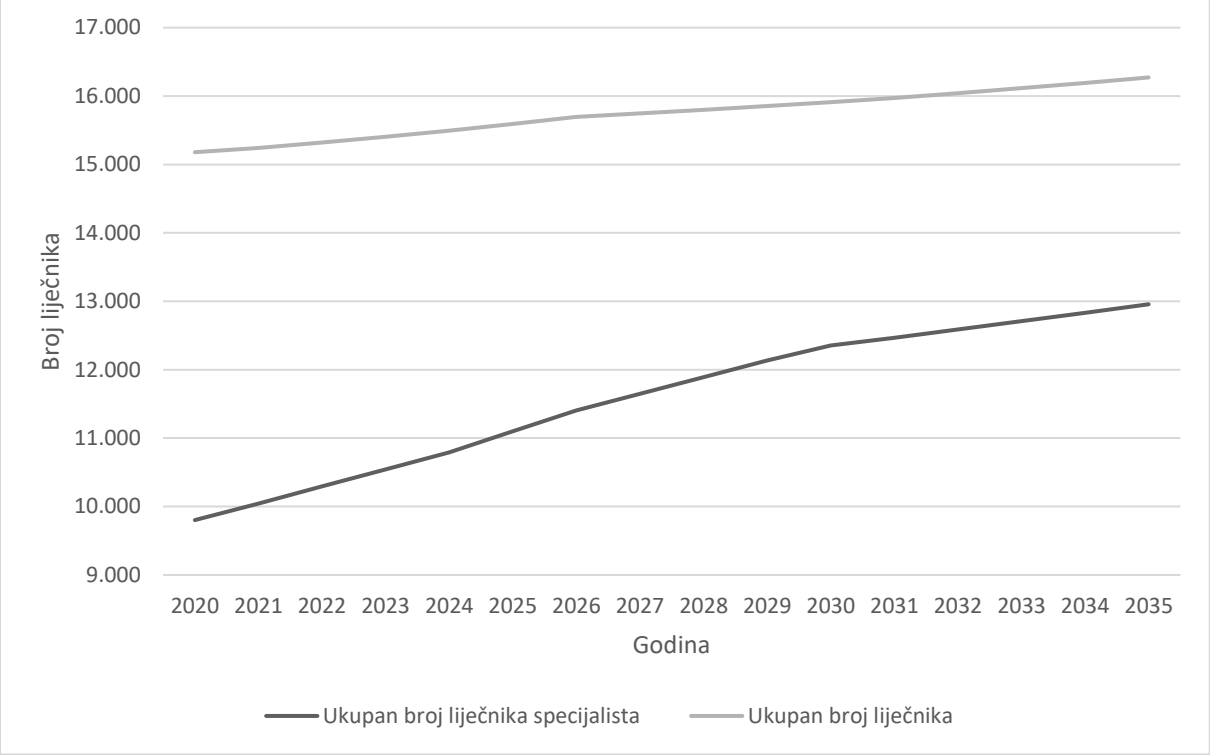
Godina	Simulirani ukupan broj liječnika	Projicirani broj stanovnika	Broj liječnika na 100.000 stanovnika
2021.	15.241	4.151.550	367,1
2031.	16.193	3.964.385	408,5
2041.	17.670	3.723.497	474,6
2051.	19.462	3.456.866	563,0

Tablica 28. Rezultati simulacija s obzirom na fazu radnog ciklusa liječnika - Scenarij 4

	SPECIJALISTI									Specijalizanti	Čekanje na specijalizaciju	Rad bez specijalizacije (trajno)	Ukupan broj liječnika
Godina	**Obiteljska medicina**	**Psihijatrija**	**Pedijatrija**	**Ginekologija i opstetricija**	**Neurokirurgija**	**Anesteziologija, reanimatologija i int. m.**	**Neurologija**	**Ostale specijalizacije**	**Ukupan broj liječnika specijalista**				
2020.	1.096	521	696	725	71	638	342	5.713	9.803	2.993	1.303	1.081	15.180
2021.	1.074	527	715	724	75	672	353	5.906	10.045	3.052	1.117	1.027	15.241
2022.	1.056	534	734	723	77	707	364	6.101	10.296	3.112	936	976	15.319
2023.	1.038	540	753	723	79	742	375	6.295	10.545	3.171	766	927	15.409
2024.	1.021	547	772	723	81	776	387	6.487	10.794	3.230	601	880	15.505
2025.	1.061	553	792	723	84	810	398	6.677	11.099	3.231	446	836	15.612
2026.	1.102	568	805	730	86	826	407	6.878	11.403	3.232	295	795	15.725
2027.	1.128	575	825	734	89	838	413	7.044	11.646	3.232	160	755	15.793
2028.	1.154	582	845	738	91	850	420	7.209	11.890	3.232	28	717	15.867
2029.	1.180	589	866	742	94	862	426	7.373	12.132	3.158	0	681	15.972
2030.	1.207	596	886	747	97	874	431	7.537	12.376	3.056	0	647	16.079
2031.	1.234	603	905	753	100	887	437	7.700	12.619	2.959	0	615	16.193
2032.	1.291	613	928	757	103	899	443	7.833	12.868	2.863	0	584	16.315
2033.	1.348	622	951	761	106	911	449	7.967	13.116	2.772	0	555	16.443
2034.	1.404	632	974	766	109	923	455	8.027	13.291	2.754	0	527	16.572
2035.	1.460	642	997	770	113	935	462	8.060	13.438	2.769	0	501	16.708
2036.	1.516	651	1.019	775	116	947	468	8.099	13.591	2.784	0	476	16.851
2037.	1.582	662	1.038	785	120	956	473	8.146	13.761	2.799	0	452	17.012
2038.	1.647	672	1.056	796	123	965	478	8.199	13.937	2.809	0	429	17.175
2039.	1.713	682	1.075	806	127	975	483	8.252	14.112	2.819	0	408	17.339
2040.	1.777	692	1.093	817	130	984	489	8.311	14.293	2.824	0	388	17.504
2041.	1.841	703	1.111	827	134	993	494	8.376	14.478	2.824	0	368	17.670
2042.	1.909	717	1.130	838	136	1.001	501	8.433	14.664	2.824	0	350	17.838
2043.	1.976	731	1.149	848	139	1.010	508	8.490	14.850	2.824	0	332	18.006

2044.	2.042	746	1.168	859	141	1.018	515	8.548	15.036	2.824	0	316	18.175
2045.	2.107	760	1.186	869	143	1.027	522	8.607	15.222	2.824	0	300	18.346
2046.	2.172	774	1.205	880	146	1.035	529	8.666	15.408	2.824	0	285	18.517
2047.	2.237	788	1.226	895	147	1.045	535	8.737	15.611	2.824	0	271	18.706
2048.	2.301	803	1.247	910	149	1.055	541	8.809	15.814	2.824	0	257	18.895
2049.	2.364	817	1.268	924	150	1.065	548	8.880	16.016	2.824	0	244	19.084
2050.	2.427	831	1.289	939	152	1.075	554	8.953	16.218	2.824	0	232	19.274
2051.	2.488	845	1.310	954	153	1.085	560	9.023	16.418	2.824	0	220	19.462

5.4.5. Scenarij 5



Slika 33. Rezultati dobiveni simulacijskim modeliranjem (Scenarij 5) – projekcija kretanja ukupnog broja liječnika i ukupnog broja liječnika specijalista do 2035.g.

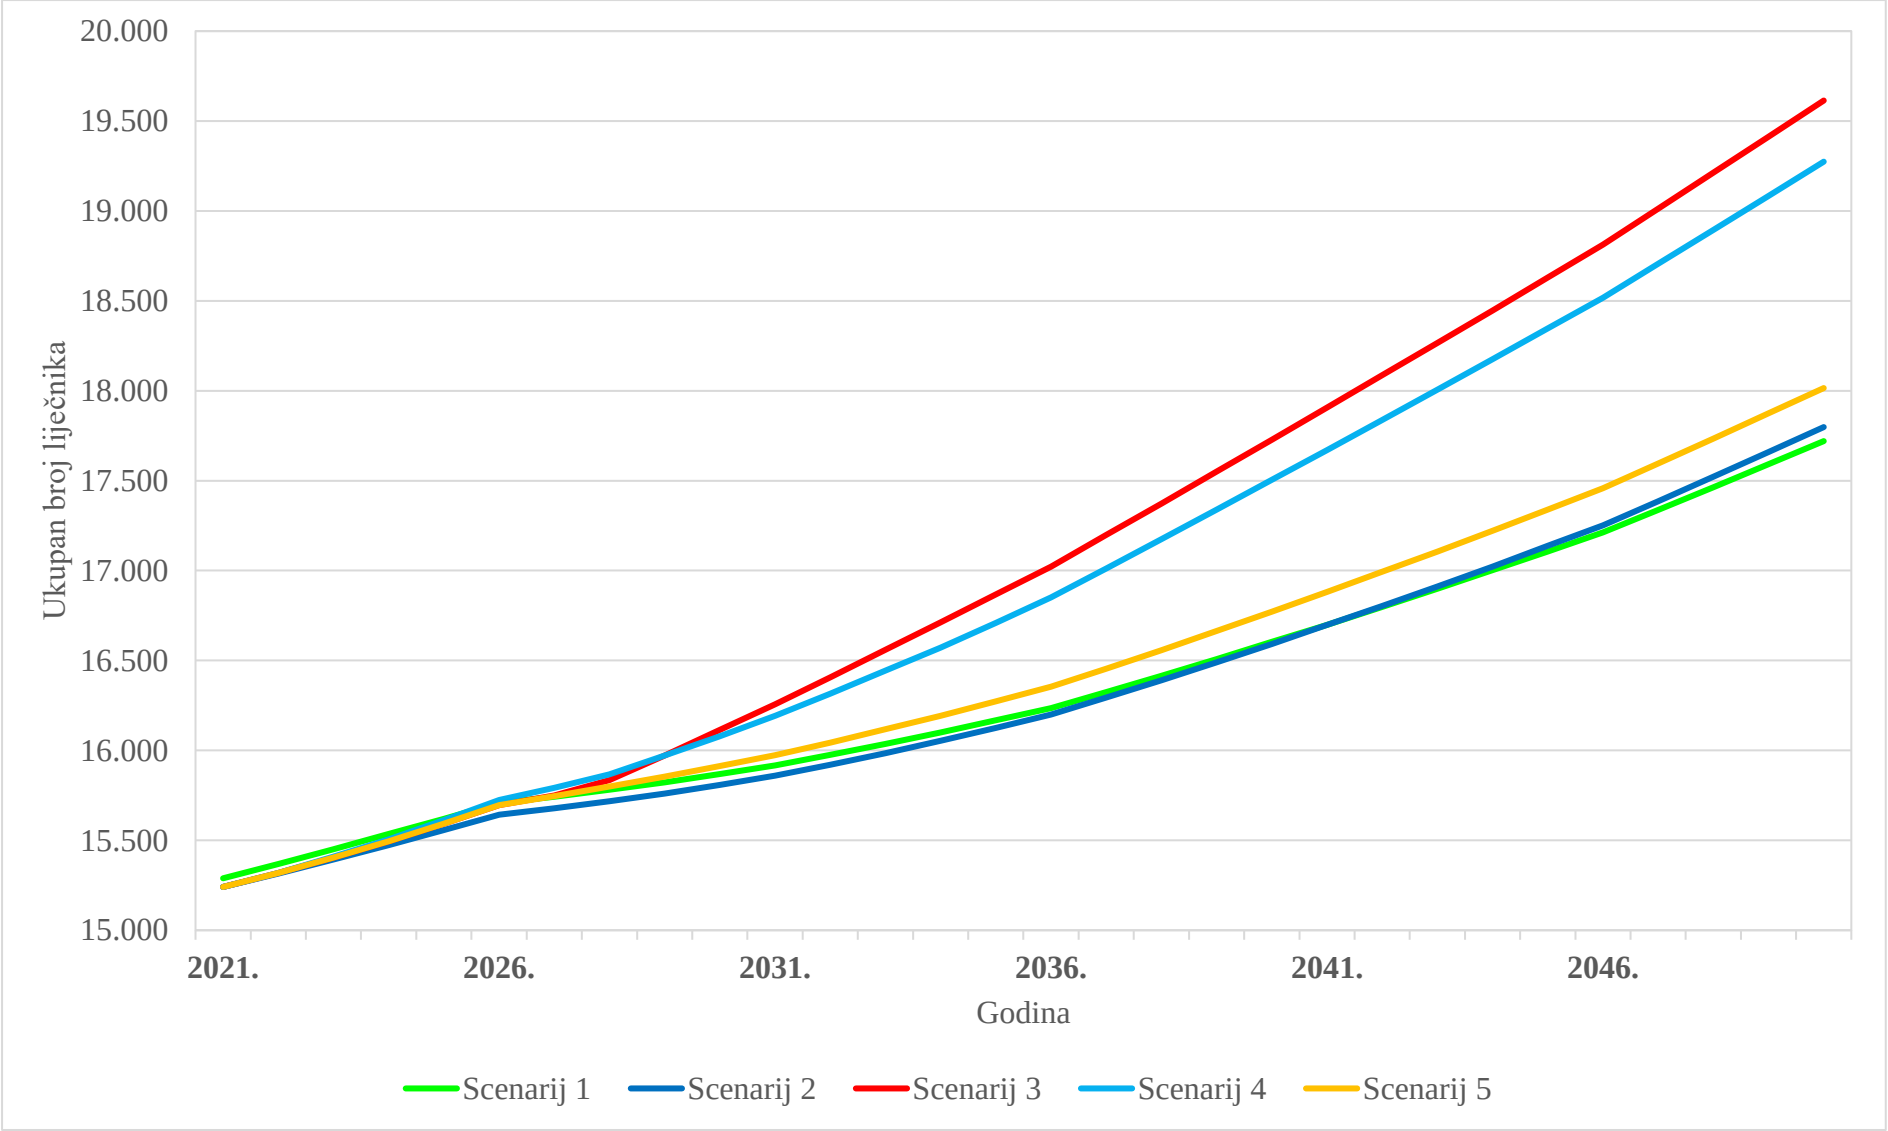
Tablica 29. Prikaz rezultata dobivenih simulacijskim modeliranjem (Scenarij 5) – projekcija kretanja broja liječnika na 100.000 stanovnika

Godina	Simulirani ukupan broj liječnika	Projicirani broj stanovnika	Broj liječnika na 100.000 stanovnika
2021.	15.241	4.151.550	367,1
2031.	15.974	3.964.385	402,9
2041.	16.881	3.723.497	453,4
2051.	18.165	3.456.866	525,5

Tablica 30. Rezultati simulacija s obzirom na fazu radnog ciklusa liječnika - Scenarij 5

	SPECIJALISTI												
Godina	**Obiteljska medicina**	**Psihijatrija**	**Pedijatrija**	**Ginekologija i opstetricija**	**Neurokirurgija**	**Anesteziologija, reanimatologija i int. m.**	**Neurologija**	**Ostale specijalizacije**	**Ukupan broj liječnika specijalista**	**Specijalizanti**	**Čekanje na specijalizaciju**	**Rad bez specijalizacije (trajno)**	**Ukupan broj liječnika**
2020.	1.096	521	696	725	71	638	342	5.713	9.803	2.993	1.303	1.081	15.180
2021.	1.074	527	715	724	75	672	353	5.906	10.045	3.052	1.117	1.027	15.241
2022.	1.056	534	734	723	77	707	364	6.101	10.296	3.112	936	976	15.319
2023.	1.038	540	753	723	79	742	375	6.295	10.545	3.171	761	927	15.404
2024.	1.021	547	772	723	81	776	387	6.487	10.794	3.230	591	880	15.495
2025.	1.061	553	792	723	84	810	398	6.677	11.099	3.231	426	836	15.593
2026.	1.102	568	805	730	86	826	407	6.878	11.403	3.101	397	795	15.696
2027.	1.128	575	825	734	89	838	413	7.044	11.646	2.970	375	755	15.746
2028.	1.154	582	845	738	91	850	420	7.209	11.890	2.840	352	717	15.799
2029.	1.180	589	866	742	94	862	426	7.373	12.132	2.710	331	681	15.854
2030.	1.186	596	886	747	97	874	431	7.537	12.355	2.601	310	647	15.913
2031.	1.193	597	897	746	100	880	433	7.624	12.469	2.601	289	615	15.974
2032.	1.230	601	911	743	103	885	435	7.682	12.589	2.601	270	584	16.044
2033.	1.266	605	925	741	106	890	438	7.740	12.711	2.601	251	555	16.117
2034.	1.302	609	939	738	109	896	440	7.800	12.833	2.601	232	527	16.193
2035.	1.338	613	953	736	113	901	442	7.860	12.956	2.601	214	501	16.272
2036.	1.374	617	967	734	116	907	445	7.921	13.081	2.601	197	476	16.354
2037.	1.421	621	977	738	120	909	446	7.990	13.223	2.601	180	452	16.455
2038.	1.468	626	987	742	123	912	447	8.059	13.365	2.601	164	429	16.558
2039.	1.514	631	998	746	127	915	449	8.129	13.508	2.601	148	408	16.664
2040.	1.560	636	1.008	750	130	917	451	8.199	13.651	2.601	132	388	16.771
2041.	1.605	641	1.018	755	134	920	452	8.270	13.795	2.601	117	368	16.881
2042.	1.655	650	1.029	759	136	923	456	8.333	13.940	2.601	103	350	16.993

2043.	1.703	659	1.040	763	139	925	459	8.396	14.085	2.601	89	332	17.106
2044.	1.752	668	1.051	768	141	927	463	8.460	14.230	2.601	75	316	17.222
2045.	1.800	677	1.062	773	143	930	467	8.525	14.377	2.601	62	300	17.339
2046.	1.847	686	1.073	777	146	933	470	8.591	14.523	2.601	49	285	17.458
2047.	1.895	695	1.087	786	147	937	473	8.668	14.688	2.601	36	271	17.595
2048.	1.941	705	1.101	796	149	941	475	8.745	14.852	2.601	24	257	17.734
2049.	1.988	714	1.114	805	150	945	478	8.823	15.017	2.601	13	244	17.874
2050.	2.034	723	1.128	814	152	949	481	8.901	15.181	2.601	1	232	18.015
2051.	2.079	732	1.142	823	153	954	484	8.977	15.344	2.601	0	220	18.165



Slika 34. Usporedni prikaz rezultata simulacija kretanja ukupnog broja liječnika do 2051.g. za svih pet scenarija

5.5. Validacija modela

Valjanost simulacijskog modela je uvijek važno provjeriti na način da se provede validacija raspoloživim povijesnim podacima. Model se smatra pouzdanim ako je relativna greška manja od 0.1 (72). Za validaciju modela korišteni su podaci iz 2008.g. (tablica 31), a rezultat simulacije je prikazan u tablici 32.

Tablica 31. Glavni parametri korišteni u validaciji simulacijskog modela

ULAZ	PROFESIONALNI STATUS	IZLAZ
UPISNA KVOTA Zagreb: 248 Rijeka: 134 Osijek: 107 Split: 76 Ukupno: **565**	**STUDIJ MEDICINE** (**3.238** studenata) Trajanje **6 godina**	**Odljev sa studija:** **10%** generacije
ZAVRŠAVA STUDIJ Ukupno: **508** **IMIGRACIJSKA KVOTA** Ukupno: **5** godišnje	**ČEKANJE NA SPECIJALIZACIJU** **(950** liječnika**)**	**Emigracija diplomiranih:** **2%** godišnje **20 liječnika** godišnje se zapošljava izvan zdravstva
	TRAJNI RAD BEZ SPECIJALIZACIJE (OPĆA MEDICINA) (**1.130** liječnik**)**	Odlazak u mirovinu tijekom sljedećih **30 godina**
	LIJEČNICI IZVAN ZDRAVSTVA (1.000 liječnika**)**	Odlazak u mirovinu tijekom sljedećih **40 godina**
BROJ RJEŠENJA O SPEC. USAVRŠAVANJU Ukupno: **357**	**BROJ SPECIJALIZANATA** Ukupno: **1.852**	Odljev specijalizanata: **1%**
	SPECIJALISTI Ukupno: **7.999**	Odljev specijalista: **10%**

Tablica 32. Usporedba povijesnih podataka i podataka dobivenih simulacijskim modeliranjem

Početna godina	2008.
Završna godina	2020.
Ukupan broj liječnika - Stvarno stanje (na dan 15.10.2020.)	15.332
Ukupan broj liječnika - Simulirano stanje za 2020.	15.881
Relativna greška	**0,036**

6. Rasprava

Cilj ovog istraživanja je kreiranje predikcijskog modela kao podrške za odlučivanje prilikom planiranja specijalističkog usavršavanja doktora medicine u Republici Hrvatskoj temeljem analize raspoloživih podataka.

Metoda sistemske dinamike pokazala se prikladnom za modeliranje dinamike kretanja broja liječnika uključujući profesionalno napredovanje i starenje te za predviđanje broja doktora medicine prema različitim scenarijima. Pomoću ovog modela testirano je više scenarija i pretpostavki o planiranju specijalističkog usavršavanja doktora medicine u Hrvatskoj. Razvijen je višedijelni model dinamike sustava kojim su obuhvaćene sve faze (ciklusi) školovanja i rada liječnika specijalista, od upisa na studij medicine preko specijalističkog usavršavanja i radnog vijeka u zdravstvenom sustavu (ili nekom drugom sustavu koji zapošljava doktore medicine) do odlaska u mirovinu. U praksi to obuhvaća 45 i više godina životnog vijeka, a model također uključuje odljev i priljev liječnika u/iz inozemstva. Razvijen je sveobuhvatni model koji je dokumentiran i dostupan za uporabu i eventualne izmjene parametara i ulaznih podataka te može poslužiti kao prototip za daljnja istraživanja. Rezultati modeliranja razvijenim modelom jasno pokazuju, u svim simuliranim scenarijima, da će se broj liječnika u Hrvatskoj povećavati do 2035. g. Različiti scenariji simuliraju moguće buduće situacije kao rezultat promjenjivih parametara modela i vrijednosti ulaznih podataka te mogu koristiti pri donošenju odluka vezanih za planiranje specijalističkog usavršavanja doktora medicine u Hrvatskoj.

Svi prikazani scenariji ukazuju na to da Hrvatska trenutno ima dovoljan broj liječnika u odnosu na populaciju. S postojećom upisnom politikom Hrvatska bi se u narednim godinama mogla suočiti čak i s viškom liječnika već viđenim u prošlosti (46, 73).

Preduvjet nastavka ovog dobrog trenda prikazanog u pet simuliranih scenarija jest da se u narednim godinama i nadalje nastave raspisivati specijalizantska mjesta sukladno usvojenom Nacionalnom planu specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.), ali i da najmanje 80% raspisanih mjesta bude i konzumirano.

Uz rastući trend broja liječnika u Hrvatskoj potrebno je uzeti u obzir tehnološki napredak i razvoj u medicini te mješavinu vještina (eng. *skill mix)* i prijenos zadataka (*eng. task shift)* tj. preusmjeravanje određenih radnih zadataka na druge zdravstvene radnike pri čemu je potrebno voditi računa o adekvatnom broju onih na koje su radni zadaci preusmjereni. U

mnogim razvijenim zemljama liječnici više nemaju "monopol" nad izvođenjem određenih zahvata, a kompetencije ostalih kvalificiranih zdravstvenih radnika se proširuju (74). Dobar primjer prijenosa zadataka (eng. *task shift*) dogodio se u Sloveniji koja je tijekom 2010. i 2011. g. provela mjere za osnaživanje primarne zdravstvene zaštite (PZZ) koje su, između ostalih, uključivale uvođenje tzv. referentnih ambulanti (slo. *referenčne ambulante*) u kojima su uz postojeće medicinske sestre/tehničare dodane i medicinske sestre/tehničari s visokim stupnjem obrazovanja i stečenih kompetencija te su dobile višu razinu odgovornosti u liječenju kroničnih bolesnika i provođenju preventivne zdravstvene zaštite. Primjer referentnih ambulanti u Sloveniji jedan je od rijetkih mogućih način pružanja integralne zdravstvene zaštite te iako nije došlo do skraćenja trajanja konzultacija u PZZ, ishodi liječenja pacijenata su poboljšani (75–77).

U Hrvatskoj se liječnici u PZZ, u kojoj obiteljska medicina (OM) ima najvažniju ulogu i čini temelj zdravstvene zaštite, uglavnom bave kurativnom, a u puno manjoj mjeri preventivnom zdravstvenom zaštitom zbog prekomjernog radnog opterećenja koje se tijekom godina povećava. Posljednjih dvadeset godina u Hrvatskoj se sve više ističe problem naglog porasta radnog opterećenja u OM što najzornije prikazuje povećanje broja posjeta. Primjerice, u djelatnosti OM u Republici Hrvatskoj je 1990. godine za 4.784.265 stanovnika zabilježeno 15.907.836 posjeta odnosno 3,3 posjete godišnje po osiguraniku, a 2017. godine za 4.124.531 stanovnika 37.324.960 posjeta odnosno 9,08 godišnje po osiguraniku (78, 79). O svemu ovome bi također trebalo voditi računa prilikom planiranja broja specijalista osobito onih u PZZ.

Broj pregleda po pacijentu godišnje može se uvelike razlikovati od države do države, a vjerojatno je da će i ukupno vrijeme koje pacijent provede sa svojim liječnikom PZZ jako varirati (80). Trajanje konzultacija u PZZ je jedan od važnih parametara koji je potrebno uzeti u obzir. Studija koju su proveli Irving i sur. ukazuje na to da u svijetu postoje jako velike razlike i u trajanju pregleda u PZZu. Od 48 sekundi u Bangladešu do 22,5 minute u Švedskoj dok u Hrvatskoj prosječno trajanje pregleda iznosi 11,5 minuta (81). Nepostojanje statistički značajnog odnosa između trajanja pregleda i stope pregleda po pacijentu na godišnjoj razini sugerira da ako se poveća trajanje, ne mora nužno uslijediti smanjenje broja pregleda. Utvrđena je povezanost između duljeg trajanja konzultacija i smanjenog prijema u bolnicu za dijabetes što podržava druge rezultate istraživanja koji ukazuju na to da snažna PZZ može smanjiti prijem u jedinice sekundarne i tercijarne razine zdravstvene zaštite (82).

Eurostat prikuplja podatke iz 36 zemalja (od kojih je 30 dostavilo podatke o broju liječnika) te je relevantan izvor za usporedbu. Usporedbom broja liječnika opće/obiteljske medicine vidljivo je da se Hrvatska nalazi na 23. mjestu u odnosu na većinu zemalja koje su dostavile podatke za 2018. g. s 60,57 liječnika na 100.000 stanovnika. Najveći broj liječnika opće/obiteljske medicine ima Portugal 244,30, a najmanje Grčka 33,9 na 100.000 stanovnika. Broj specijalista preostalih šest specijalizacija promatranih u ovoj disertaciji je puno povoljniji u usporedbi s većinom drugih promatranih zemalja. Hrvatska se nalazi u sredini ili pri samom vrhu grafika usporedbe kada se promatra broj specijalista na broj stanovnika – detaljni grafikoni dostupni su u prilogu (slike P1 do P8).

Prema dostupnim podacima broj timova u PZZ je tijekom devetogodišnjeg razdoblja porastao u djelatnosti zdravstvene zaštite predškolske djece (s 253 tima 2010. g. na 280 timova 2018. g.) te zdravstvene zaštite žena (s 229 timova 2010. g. na 265 timova 2018. g.). dok u djelatnosti obiteljske/opće medicine nije bilo značajnije promjene u broju timova (2285 timova u 2010 .g., 2286 timova u 2018. g.) (83,84).

Prosječan broj osiguranika po timu u 2018. g. od 1.794 za djelatnost opće/obiteljske medicine (standard je 1.700), 1.518 za djelatnost zdravstvene zaštite predškolske djece (standard je 950) te 6.509 za djelatnost zdravstvene zaštite žena (standard je 6.000) ukazuju na nedostatan broj liječnika u svim navedenim djelatnostima ako se kao cilj odrede standardi propisani *Odlukom o osnovama za sklapanje ugovora o provođenju zdravstvene zaštite iz obveznog zdravstvenog osiguranja* (61). Kao što Vrcić Keglević i sur. upozoravaju da je za budućnost planiranja potrebno revidirati propisane standarde pacijenata na jednog liječnika opće/obiteljske medicine u smislu smanjenja tog broja, u istom smjeru je potrebno razmišljati i kod zdravstvene zaštite predškolske djece te zdravstvene zaštite žena (51). Pri tome je potrebno imati na umu da standardi nisu prilagođavani od 1996. g., a osobito da postoji neujednačena geografska podjela te preopterećenost u pojedinim dijelovima države, poglavito u ruralnim krajevima (Slavonija, Dalmatinska zagora, otoci itd.)

Uzevši u obzir zbroj ugovorenih timova PZZ bez zaposlenog liječnika – nositelja tima u Hrvatskoj je u lipnju 2020. g. u odnosu na planiranu mrežu HZZO-a, nedostajalo 204 obiteljska liječnika, 75 pedijatara i 103 ginekologa. Analizom broja radnih sati može se zaključiti da obiteljski liječnik ima prosječno tek jedan sat za svakog pacijenta godišnje, ginekolog 15 minuta za svaku pacijenticu, a pedijatar sat i 15 minuta za svako dijete u skrbi (85).

Uz broj liječnika važno je uzeti u obzir i njihovu dobnu strukturu. Hrvatska ima 29.4% liječnika starijih od 55 godina. Radi se o prihvatljivom udjelu, osobito ako to usporedimo sa drugim zemljama: Italija (55%), Bugarska (50.8%), Estonija (45.9%), Francuska (45.1%), Njemačka (44.6%), Mađarska (43.4%), Španjolska (34.1%), Švedska (33.7%), Danska (32.5%), Austrija (29.7%) i Slovenija (29.5%) (86). Rezultati simulacija u istraživanju usmjerenom na dobnu raspodjelu ukazuju da se dobna raspodjela hrvatskih liječnika s vremenom popravlja u korist mlađih liječnika (87).

Ekvivalent punog radnog vremena liječnika (eng. *full time equivalent – FTE*) definira se kao omjer ostvarenih radnih sati u odnosu na puno radno vrijeme. Prema podacima *Demografskog atlasa hrvatskog liječništva* HLK 2016. g. liječnici na sekundarnoj razini zdravstvene zaštite radili su u prosjeku 14% više od punog radnog opterećenja, a na tercijarnoj 10% više iz čega bi se dalo zaključiti kako postoji problem manjka liječnika na sekundarnoj i tercijarnoj razini zdravstvene zaštite (67). Na primarnoj razini prosječna radna opterećenost manja je za 2% od pune, odnosno usklađena je s propisanim prosječnim tjednim brojem radnih sati (67). Uzimajući u obzir samo FTE za Hrvatsku vrlo lako bi se moglo doći do zaključka da je broj liječnika u PZZ dovoljan što je ranije u tekstu demantirano. Podatke o FTE nezahvalno je koristiti za analize i izrade modela. Veliki je manjak sustava evidencije rada činjenica da se prilikom određivanja FTE u obzir uzima samo javno zdravstvo. Rad i dijagnostičko terapijski postupci obavljeni u zdravstvenim ustanovama u privatnom vlasništvu (bez ugovora s HZZO) se ne evidentiraju i ne registriraju na jednak način kao što je to slučaj u javnom zdravstvenom sustavu što predstavlja veliko ograničenje i izazov u pokušajima kvalitetnog planiranja zdravstvenih kadrova osobito u kontekstu činjenice da dio zaposlenih u javnom zdravstvu također radi i privatno.

S obzirom na dostupnost podataka opterećenje u SKZZ promatrano je po broju ambulantnih pregleda te broju ispisanih bolesnika po specijalistu, a upravo takav način prikaza su primijenili i Senese i sur. prilikom izrade modela za procjenu potreba za specijalizantskim mjestima liječnika u talijanskoj regiji *Emilia – Romagna* (88).

Europska komisija predlaže sljedeće aktivnosti za održivost radne snage u zdravstvenim sektorima zemalja članica EU: predviđanje potreba za radnom snagom i unapređivanje metodologije planiranja razvoja radne snage, anticipiranje budućih potreba za vještinama u zdravstvenim profesijama, dijeljenje dobre prakse o učinkovitom pronalaženju i strategijama zadržavanja zdravstvenih stručnjaka (89).

Postojeća organizacija zdravstvenog sustava u Republici Hrvatskoj ne prepoznaje zdravstvene radnike kao ključni resurs. S obzirom na različite i nejasno odijeljene nadležnosti pojedinih dionika u zdravstvenom sustavu otežano je praćenje procesa kojima pojedini dionici utječu na upravljanje ljudskim resursima. Primjerice sustav izrade i provedbe nastavnih programa na sveučilištima reguliraju se kroz sveučilišna tijela i državne agencije. Razvoj kompetencija i licenciranje u nadležnosti je komora, a planiranje sustava, broja potrebnih specijalista i reguliranje rada profesija u sustavu u nadležnosti Ministarstva zdravstva. Svaki od navedenih dionika prema svojim kriterijima i procedurama sudjeluje u procesu razvoja pojedine profesije, bez značajnije mogućnosti da se u proces na vrijeme uključe drugi dionici. Ne postoji jasna odgovornost za ljudske resurse u zdravstvu Republike Hrvatske te u takvoj situaciji pojedini dionici mogu paralelno razvijati dokumente koji će nakon završetka biti operativno nepovezani (90).

Temeljem Zakona o zdravstvenoj zaštiti, uz prethodno pribavljeno mišljenje HZZO i nadležnih komora, ministar zdravstva donosi *Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika* za petogodišnje razdoblje (u daljnjem tekstu: nacionalni plan). Nacionalni plan donosi se na prijedlog predstavničkih tijela jedinica područne (regionalne) samouprave odnosno Grada Zagreba. U nacionalnom planu se navodi da se temelji na: potrebi razvoja zdravstvene djelatnosti na primarnoj, sekundarnoj i tercijarnoj razini, potrebi zdravstvenog sustava za odgovarajućim specijalnostima zdravstvenih radnika, broju, rasporedu te dobnoj strukturi zdravstvenih radnika. Nadalje, nacionalni plan bi trebao biti temelj za donošenje godišnjeg plana potrebnih specijalizacija i užih specijalizacija zdravstvenih radnika (69). Nacionalnim planom specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.) ukupno je predviđeno raspisivanje 3.825 specijalizantskih mjesta (765 godišnje) što je u vrijeme donošenja tog plana bilo apsolutno opravdano (obzirom na promjene regulative o liječničkom stažu odnosno radu doktora medicine pod nadzorom) i činjenicu da je više od 1.300 doktora medicine čekalo na specijalizaciju, te još nedovoljni broj specijalista u sustavu (djelomice i zbog pojačanog odlaska u inozemstvo nakon priključenja Europskoj uniji). Međutim, imajući u vidu da godišnje u Hrvatskoj diplomira oko 530 studenata medicine, teško je za očekivati popunjavanje predviđenih specijalizantskih mjesta, osobito u duljem vremenskom razdoblju. Iskustva od prijašnjih godina pokazuju da se za određeni broj raspisanih specijalizantskih mjesta neće javiti dovoljan broj kandidata što je u obzir uzeto u simuliranom scenariju 2 (80% konzumiranih kvota). Tek s povećanjem upisnih kvota na studij medicine može se očekivati maksimalna iskorištenost predloženih kvota za specijalističko usavršavanje doktora

medicine. Stoga je ovakav Nacionalni plan odličan i dobrodošao u ovom trenutku, ali je dugoročno taj intenzitet upućivanja na specijalističko usavršavanje neodrživ ukoliko se ne povećaju upisne kvote na studij medicine poželjno od 2022. g. (scenarij 3) ili se ne poveća broj kandidata na drugi način (potencijalno moguće imigracijom ili zadržavanjem diplomiranih studenata studija na engleskom jeziku).

Prema evidenciji Vlade RH od 31. srpnja 2020. g. iskorištenost kvota radnih dozvola za zapošljavanje stranaca u Hrvatskoj za 2020. g. je bila takva da je od 45 mjesta predviđenih za doktore medicine samo 7 iskorišteno dok su 2 kandidata u postupku rješavanja administrativnih procedura. Otkako je Hrvatska postala članicom Europske unije 2013. g. do kraja 2016. g. samo 30 liječnika školovanih u inozemstvu je zaposleno u Hrvatskoj među kojima je najveći broj došao iz Makedonije (10 od 30 ili 32,3%), Bosne i Hercegovine (6 ili 19,4%), Srbije (5 ili 16,1%), Sirije (3 ili 9,7%), te po jedan liječnik iz Slovačke, Crne Gore, Litve, Rusije, Slovenije i Kosova (67). Scenarij 4 predviđa postupno povećanje priljeva doktora medicine koji iz inozemstva dolaze raditi u Hrvatsku do 2035. g., a koje možemo očekivati s priključenjem susjednih zemalja Europskoj uniji (trenutačni kandidati za članstvo: Albanija, Crna Gora, Srbija, Sjeverna Makedonija te potencijalni kandidati: Bosna i Hercegovina te Kosovo).

Scenarij 5 predviđa smanjenje broja konzumiranih specijalizacija od 2025. g. tj. u sljedećem petogodišnjem razdoblju za koji će nacionalni plan biti donesen, a što bi se i spontano dogodilo jer nema dovoljno doktora medicine koji bi konzumirali raspisana mjesta za specijalističko usavršavanje na trenutačnoj razini.

Sistemska dinamika pokazala se snažnom metodom ne samo kada se koristi u istraživanju, već također kao sredstvo pri donošenju odluka koje pružaju potrebne informacije kreatorima politika i donosiocima odluka (91). Brojne skupine znanstvenika također su koristile sistemsku dinamiku za predviđanje potreba/potražnje i ponude za liječnicima na nacionalnim ili regionalnim razinama.

Svi simulirani scenariji ovog istraživanja rezultirali su povećanjem ukupnog broja liječnika u Hrvatskoj što je sukladno rezultatima koje su dobili japanski istraživači Takata i sur. koji su istom metodom simulirali kretanje broja liječnika u Japanu od 2008. g do 2050. g. uz pretpostavku povećanih upisnih kvota na medicinske fakultete što je analogno našem scenariju 3. U Japanu su osamdesetih godina smanjene upisne kvote na medicinske fakultete

zbog suviška liječnika na tržištu što je rezultiralo apsolutnim i relativnim nedostatkom liječnika 20 godina kasnije (92).

Druga skupina japanskih autora (Ishikawa i sur.) upotrijebila je iste metode za projekciju broja kliničkih specijalista s ciljem izrade preporuka za upućivanje na specijalističko usavršavanje. Rezultat provedenih eksperimenata upućuje na to da će se broj liječnika povećavati tijekom promatranog razdoblja od 2008. do 2030. g., a dostatan broj bi bio dosegnut 2026. g. Definirani kriterij za prosudbu je li broj liječnika dovoljan ili ne je anketa provedena u zdravstvenim ustanovama u Japanu – oni su subjektivno procjenjivali, temeljem svakodnevne kliničke prakse, potreban broj liječnika u narednom periodu (72,93).

Španjolska je također iz suviška liječnika u jednom trenutku došla do manjka u samo nekoliko godina što je potaknulo Barbera i sur. na razvoj modela metodom sistemske dinamike za 43 medicinske specijalizacije za period od 2008. do 2025. g. Rezultat provedenih eksperimenata sugerira nedostatno povećanje broja liječnika po specijalizacijama te potrebno razmatranje povećanja upisnih kvota na medicinski fakultete i planiranje fleksibilnije imigracijske politike za liječnike iz EU i Latinske Amerike. Za opskrbu liječnicima napravljen je poseban (pod)model u kojem su liječnici podijeljeni na muške i ženske te su u obzir uzeti gotovo svi parametri kao u ovom istraživanju. Autori su dodatno u model implementirali produktivnost liječnika za koju nije pobliže objašnjeno na koji način je određena. Aktualne potrebe za liječnicima specijalistima su procijenjene na temelju podataka regionalnih zavoda za zapošljavanje o broju liječnika specijalista na burzi rada s jedne strane te nepopunjenim radnim mjestima s druge strane. S podacima koji su bili aktualni pri samom kreiranju modela simulirali su dva scenarija – jedan s umjerenim, a drugi s brzim porastom broj stanovnika. Rezultati oba scenarija ukazuju na nedostatak liječnika specijalista, ali različitom dinamikom. U slučaju umjerenog porasta broja stanovnika nedostatak od 2% u početnoj godini raste do 14,3% u završnoj godini simulacije dok je kod brzog porasta broja stanovnika taj nedostatak dvostruko veći u odnosu na ranije opisani scenarij (28,94).

Metodom sistemske dinamike razvijen je i model s ciljem optimizacije opskrbe liječnicima specijalistima u regiji *Emilia-Romagna* u Italiji za razdoblje 2011. do 2030. g. (88). Senese i sur. kreirali su model u kojem su kao parametre opskrbe uzeli diplomirane liječnike kao priljev, a umirovljenje ili odlazak iz javnog zdravstvenog sustava kao odljev istovjetno provedenom istraživanju u ovoj disertaciji. Potrebe su procijenjene pomoću demografskih projekcija, korištenja liječničkih usluga koje su prikazane brojem ambulantnih pregleda specijalista i brojem ispisanih bolesnika te brojem kreveta u javnim bolnicama. Broj

ambulantnih pregleda specijalista i broj ispisanih bolesnika su u ovom istraživanju također korišteni za procjenu opterećenja liječnika u SKZZ. Kreirana su tri scenarija usmjerena na zahtjeve (*demand*) – prvi na zahtjeve populacije, drugi na korištenje liječničkih usluga, a treći na broj kreveta i povećanje potreba za ambulantnim pregledima. Rezultat simulacije prvog scenarija daje prosječno povećanje potreba od 12% do 2030. g. u odnosu na 2011. g. Drugi scenarij rezultira najvećim povećanjem potreba, posebno za one specijalnosti koje su usmjerene na rastući dio populacije (mladi od 0 do 14 godina i stariji od 65 godina) dok se u trećem scenariju potrebe blago povećavaju.

Istom metodom je napravljena simulacija u Šri Lanki. De Silva je opskrbu liječnika izveo iz postojećeg broja liječnika, specijalizanata, stope umirovljenja te odlaska iz sustava zdravstva. Prilikom modeliranja u obzir je uzet ekonomski rast zdravstva Šri Lanke te njegov utjecaj na državni i privatni zdravstveni sektor (rast državnog sektora je procijenjen na 5%, a rast privatnog sektora na 12%). Slično simuliranim scenarijima u provedenom istraživanju u ovoj disertaciji za Šri Lanku su predviđena četiri različita scenarija (zadržavanje postojećeg stanja, povećanje upisnih kvota na medicinskim fakultetima za 200, 400 i 600 studenata godišnje) zaključeno da je postojeći broj liječnika dostatan za potrebe zdravstvenog sustava, a da je ažuriranje analiza potrebno raditi u petogodišnjim intervalima (95).

Singapurski autori Ansah et. al. izradili su model metodom sistemske dinamike za procjenu potreba za oftalmolozima od 2015. do 2040. g. Model se sastoji od tri modula: prevalencija očnih bolesti, potražnja i raspoloživa radna snaga. Rezultati četiri scenarija pokazuju da će prema svim razmatranim scenarijima starenje i rast stanovništva u Singapuru rezultirati gotovo dvostruko većim brojem stanovnika s očnim problemima te značajnim povećanjem potražnje za oftalmolozima u javnom sektoru (96). Može se pretpostaviti da bi se sličan scenarij mogao dogoditi i u Hrvatskoj, ali je teško napraviti precizan model s obzirom na to da se veliki dio oftalmoloških usluga radi privatno o čemu ne postoji kvalitetna evidencija.

Na primjeru Nizozemske moguće je analizirati primjer planiranja potreba za liječnicima opće medicine. Stručnjaci Nizozemskog instituta za istraživanje zdravstvenih sustava (*Netherlands institute for health services research - NIVEL*) su napravili simulacijski model koji je simulirao procjene potreba za doktorima medicine te nužne intervencije unutar sustava kako bi se potrebe zadovoljile. Navedeni simulacijski model nije izrađen metodom sistemske dinamike, ali je odličan primjer kako znanost i znanstvena istraživanja mogu biti ishodište za donošenje informiranih politika. Implementacija preporuka temeljenih na rezultatima

simulacijskih modela od strane donositelja politika dovela je do toga da su se u razdoblju od 2000. do 2009. g. simulirane procjene i realni brojevi kretanja broja liječnika preklopili (97).

Broj liječnika u Europi i Hrvatskoj već desetljećima kontinuirano raste. Potreba za liječnicima raste prije svega zbog produljenja životnog vijeka i starenja stanovništva. Godine 2019. Hrvatska je imala više od 800.000 stanovnika starijih od 65 godina, a procjene su da će ih 2030. g. biti gotovo milijun (98). Drugi razlog za povećanje broja liječnika je sve veća složenost i opseg zdravstvenih usluga i postupaka. Od ulaska Hrvatske u Europsku uniju 1. srpnja 2013. g., Hrvatsku je napustio 941 liječnik, a nakon nešto jačeg vala u prve dvije godine trend odlazaka se stabilizirao na prosječno 120 godišnje. Novi zabrinjavajući fenomen je rast odlazaka doktora medicine odmah nakon diplome - prema podacima HLK radi se o 108 doktora medicine koji su od pristupanja Hrvatske Europskoj uniji napustili domovinu odmah po diplomiranju, a još ih je 408 koji su napustili Hrvatsku bez završene specijalizacije (pristupljeno *Atlasu HLK* na dan 8.4.2021.g.).

Zemljopisna raspodjela javnih i privatnih pružatelja zdravstvenih usluga definirana je Mrežom zdravstvene zaštite kojoj je cilj svima osigurati jednak pristup zdravstvenoj zaštiti. Međutim, analize provedene od strane nadležnih tijela o teritorijalnoj raspodjeli zdravstvenih ustanova pokazuju da postoje velike razlike u pristupu bolnicama u svim regijama. Na primjer, preko 140.000 stanovnika južne Dalmacije mora prijeći više od 40 kilometara (zračnom linijom) da bi stigli do najbliže bolnice. To znači da većina njih treba putovati više od jednog sata automobilom do najbliže bolnice, a više od polovice njih treba putovati dulje od dva sata (16). Nadalje, gotovo sve bolnice u četiri najveća grada (Zagreb, Split, Rijeka i Osijek) imaju status bolnica tercijarne razine zdravstvene zaštite koja je najskuplja, pa stanovnici tih gradova (gotovo polovica cjelokupne populacije) ostaju bez regionalnih općih bolnica koje bi im mogle pružiti jeftiniju sekundarnu zdravstvenu zaštitu. Umjesto toga, najčešće se izravno upućuju na regionalno dostupne pružatelje usluga tercijarne skrbi. Nadalje, u bolnicama u četiri najveća grada nema jasne odvojenosti funkcija sekundarne i tercijarne skrbi koja bi odražavala pružanja tih usluga (5).

U svim zemljama Organizacije za ekonomsku suradnju i razvoj (OECD), broj liječnika po glavi stanovnika veći je u urbanim regijama (a posebno regiji glavnog grada), nego u ruralnim područjima, odražavajući sklonost liječnika radu u urbanim okruženjima sa tendencijom odabira bolničkih specijalizacija (99). Vrlo širokim i raznolikim spektrom politika zemlje članice OECD-a pokušale su doskočiti rješavanju ovog problema s nejednakim uspjesima.

Politike usmjerene na odabir studenata medicine ili mjesto osnivanja medicinskih fakulteta temelje se na dokazima da je veća vjerojatnost da će se studenti koji dolaze iz ruralnih sredina nakon završetka studija u ruralnim područjima ostati raditi tamo za razliku od onih koji su iz urbanih sredina. Australija i Japan utvrdili su upisne kvote rezervirane isključivo za studente iz ruralnih područja, ponekad popraćene i financijskom potporom, a kako bi određeno vrijeme nakon završetka studija ostali raditi u područjima u kojima nedostaje liječnika. U Japanu je 89% studenata upisanih putem navedenih kvota ostalo raditi u svojim regijama nakon završetka studija za razliku od 54% onih koji su studij upisali putem redovite upisne kvote (100,101). Norveška, Japan i Kanada su osnovale nekoliko medicinskih fakulteta u ruralnim ili udaljenijim regijama, s očekivanjima da će više studenata ostati raditi u tim regijama po završetku studija što se i dogodilo (101,102). Polašek i sur. zabilježili su kod studenata medicine zagrebačkog Medicinskog fakulteta izraženu sklonost za rad u Zagrebu nakon završetka studija najviše zbog većeg broja raznovrsnih prilika za zapošljavanje (37). S obzirom na istovjetan problem i u Hrvatskoj je potrebno poduzeti određene korake po uzoru na ranije opisane zemlje OECD-a i pozitivne prakse koje provode kako bi se potaknuo dolazak liječnika u ruralna područja i/ili područja u kojima nedostaje liječnika osobito u djelatnostima PZZ.

Osiguravanje financijskih poticaja liječnicima za rad u područjima u kojima ih nedostaje ili implementacija propisa koji smanjuju mogućnosti izbora mjesta rada su također moguća rješenja. U Njemačkoj, većina saveznih država nudi financijske poticaje za liječnike opće medicine koji otvaraju svoju ordinaciju po prvi puta u područjima u kojima nedostaje liječnika, kao i iskusnim liječnicima koji odluče preseliti svoje prakse u navedena područja; navedene mjere se kombiniraju s propisima koji ograničavaju slobodu liječnika za otvaranjem ordinacije u područjima koja su adekvatno opskrbljena liječnicima (103). Australija dugi niz godina svojom legislativom usmjerava liječnike školovane izvan Australije na rad u područjima u kojima nedostaje liječnika (104).

Mnoge zemlje promoviraju različite oblike inovacija u zdravstvu s ciljem pružanja odgovarajućih zdravstvenih usluga u područjima u kojima je liječnička skrb nedostatna. One uključuju *skill mix/task shift*, razvoj telemedicine za povezivanje pacijenata s liječnicima na daljinu kada je potrebno. Sve je veći broj inicijativa u zemljama OECD-a za bolje iskorištavanje telemedicine u unaprjeđenju dostupnosti adekvatne zdravstvene skrbi osobito u površinski velikim zemljama kao što su Kanada, Australija i Finska (99). S obzirom na specifičan geografski oblik Hrvatske koja se pruža u obliku luka te mnoštva otoka i slabije

naseljenih dijelova primjena telemedicine uvelike čini dostupnijim zdravstvenu zaštitu stanovnicima navedenih područja. U kriznim situacijama, kao što je pandemija COVID-19, potreba za razvojem i primjenom telemedicine te općenito primjena novih digitalnih tehnologije još više dolazi do izražaja (105–107).

Uz telemedicinu i tehnološki napredak u obliku umjetne inteligencije može pomoći zdravstvenim radnicima zbrinuti veći broj pacijenata te olakšati donošenje boljih dijagnostičkih odluka, poboljšati ishode liječenja i smanjiti mogućnosti medicinske pogreške. Uloga umjetne inteligencije može biti značajna i u rješavanja izazova vezanih uz ljudske resurse, kao što je zapošljavanje i odabir potencijalnih zdravstvenih radnika. Međutim, umjetna inteligencija ne obuhvaća cijeli proces liječenja: empatiju, primjerenu komunikaciju i ljudski dodir koji je itekako bitan. Ne postoji aplikacija, softver ili uređaj koji može zamijeniti osobnu vezu i povjerenje. Uloga ljudskog liječnika je neizbježna, ali umjetna inteligencija bi mogla biti vrlo koristan kognitivni asistent. Mesko i sur. smatraju da će umjetna inteligencija smanjiti troškove pružanja zdravstvene njege, čineći je bržom i učinkovitijom što dovodi do promjene u medicinskoj profesiji koja će uključivati više zadataka povezanih s kreativnošću i kritičkim razmišljanjem (108).

Visoku razinu složenosti planiranja zdravstvenih kadrova prikazali su Tomblin Murphy i sur. koji su u svom preglednom radu pokušali sintetizirati istraživanja vezana uz planiranje potreba za ljudskim resursima u zdravstvu u zemljama OECD-a sa visokim dohotkom. Premda su u istraživanje uključili 224 dokumenta, nema dovoljno podataka koji bi dali jasnu sliku o očekivanoj situaciji u budućnosti. Pristupi planiranju zdravstvenih kadrova ovise o zakonodavstvu pojedine zemlje, ciljevima zdravstvenih sustava te kontekstu u kojem se planiranje odvija. Ono što bi se moglo općenito zaključiti je da će opskrba ljudskim resursima u zdravstvu rasti u godinama koje dolaze, ali nije jasno hoće li taj porast biti dovoljan kako bi zadovoljio potrebe zdravstvenih sustava pojedinih zemalja. Neke teme se ponavljaju u gotovo svim dokumentima uključenim u istraživanje (ali niti jedan dokument ne uključuje sve nabrojano) kao npr.: starenje stanovništva i zdravstvenih radnika; promjene morbiditeta, modela pružanja zdravstvene zaštite, regulatorne strukture i tehnologije u zdravstvu; kvaliteta podataka; raspodjela resursa; interprofesionalna edukacija i suradnja; uključenost zainteresiranih dionika; ravnoteža javnog i privatnog sektora. U većini analiziranih dokumenata ne planira se prema potrebama (*needs*) i/ili zahtjevima (*demands*) nego prema opskrbi (*supply*). Naglašeno je kako se uglavnom vodi računa o promjenama (projekcijama) demografije, a ne o tome da će populacija u budućnosti imati drugačije potrebe (109).

U Hrvatskoj sustav upravljanja ljudskim resursima nije zasnovan na modelu planiranja prema potrebama, već na procjenama ili "studijama" pojedinih dionika koji nerijetko kao referentne vrijednosti uzimaju podatke iz različitih sustava, država ili modela organizacije zdravstva (90).

Ograničenja

Više je nedostataka ovako razvijenih modela i projekcija baziranih na njima među kojima su glavna dva:

i. kao polazište za simulacije i procjenu potreba u budućnosti uzimaju se projekcije broja i dobne strukture stanovništva (populacije korisnika zdravstvene zaštite), a ne buduće zdravstvene potrebe i predvidivi načini njihovog zadovoljavanja
ii. teško je ili nemoguće predvidjeti razvoj i napredak medicinske tehnologije u budućnosti pa pretpostavke (ulazni parametri) za modeliranje o napretku tehnologije ostaju ili previše konzervativne (tj. projiciraju sadašnju tehnologiju kao tehnologiju budućnosti) ili su tek nagađanja bez čvrstih uporišta (tj. uzimaju se nerealne pretpostavke).

Osim toga, dodatnu prijetnju predstavljaju nepredvidljivi i neočekivani događaji i tokovi koji se nisu mogli predvidjeti pri planiranju i izgradnji modela te zahtijevaju korekciju planova i politika tijekom njihovog provođenja. Brojni su modificirajući čimbenici koji mogu utjecati na broj i strukturu populacije (kontingenta) liječnika i predstavljaju izazove provedbi planova: od neplaniranih (ne)mogućnosti zapošljavanja uzrokovanih gospodarskom krizom ili povećane potrebe za liječnicima uslijed nastupa nepredvidljivih okolnosti (npr. pojava pandemije), preko emigracijskih i imigracijskih tokova koji mogu biti izazvani geopolitičkim promjenama (npr. pridruživanjem pojedinih država regionalnim ili globalnim zajednicama/savezima kao što je EU) i prelijevanja kadrova u druge, gospodarski atraktivnije sektore do promjena vlasničke strukture pružatelja zdravstvenih usluga i načina financiranja zdravstvene zaštite. Primjeri iz recentne prošlosti su:

i. ograničavanje zapošljavanja doktora medicine tijekom 1990-tih godina radi gospodarske krize uzrokovane Domovinskim ratom koje je rezultiralo stvaranjem „viška" tj. porastom nezaposlenosti doktora medicine,
ii. odlazak na rad u inozemstvo većeg broja ne samo mladih, tek diplomiranih liječnika, nego i iskusnih specijalista, osobito u prvim godinama nakon priključenja Republike Hrvatske Europskoj uniji 2013. g.,

iii. nedostatak specijalista određenih specijalnosti zbog povećanih potreba tijekom pandemije COVID-19 koji je, samo malim dijelom, nadoknađen angažiranjem umirovljenih specijalista.

U obzir nije uzet broj studenata medicine na studijskim programima na engleskom i njemačkom jeziku koje izvode hrvatski medicinski fakulteti, kao niti eventualni novi studijski programi. U ak. god. 2020./2021. studij medicine na engleskom jeziku Medicinskog fakulteta Sveučilišta u Zagrebu upisalo je 50 studenata, Medicinskog fakulteta Sveučilišta u Rijeci 60 studenata, Medicinskog fakulteta Sveučilišta u Splitu 50 studenata dok je upisna kvota na Medicinskom fakultetu Sveučilišta J.J. Strossmayera u Osijeku za novoosnovani studij na njemačkom jeziku 60 studenata koji će se upisati na fakultet 2021./22.

U obzir nije uzeta zemljopisna raspodjela liječnika i raspodjela prema razinama zdravstvene zaštite. Značajno ograničenje je nedostatak normativnih zahtjeva za potražnjom specijalista koji još uvijek nisu definirani u Hrvatskoj.

Rad u privatnom zdravstvenom sektoru se ne evidentira i ne registrira na jednak način kao što je to slučaj u javnom zdravstvenom sustavu što predstavlja veliko ograničenje i izazov u pokušajima kvalitetnog planiranja zdravstvenih kadrova osobito u kontekstu činjenice da dio zaposlenih u javnom zdravstvu također radi i privatno.

7. Zaključci

1. Procjena ponude, potražnje i potreba za liječnicima je složen istraživački zadatak koji zahtjeva projekciju budućih potreba stanovništva za zdravstvenim uslugama i predviđanje raspoloživosti zdravstvenih kadrova pa se u tu svrhu koriste i simulacijski modeli kako bi se temeljem rezultata simulacijskih eksperimenata omogućilo donošenje informiranih odluka o upisnim kvotama na medicinske fakultete i dinamici upućivanja diplomiranih doktora medicine na specijalističko usavršavanje.

2. U Republici Hrvatskoj postoji već tri desetljeća dugo iskustvo korištenja simulacijskih modela za procjenu ponude, potražnje i potreba za liječnicima (doktorima medicine) u budućnosti i uspješna povijest donošenja informiranih odluka o upisnoj politici na medicinske fakultete temeljem rezultata simulacijskog modeliranja. Literaturni podaci pokazuju da su mnoge najrazvijenije zemlje svijeta uključujući i vodeće zemlje Zapadne i Sjeverne Europe s dobro organiziranim zdravstvenim sustavom (Kanada, Australija, Sjedinjene Američke Države, Izrael, Japan, Južna Koreja, Velika Britanija, Njemačka, Francuska, Italija, Nizozemska, Irska, Danska, Finska i Norveška) uvelike krenule tim putem predviđanja potreba za zdravstvenim kadrovima osobito tijekom posljednjeg desetljeća, te su temeljem rezultata simulacija usvojile ili korigirale svoje politike školovanja i/ili privlačenja liječnika i drugih zdravstvenih kadrova iz inozemstva.

3. Dugoročno planiranje kadrovskih potreba treba biti utemeljeno na brojnim podacima i pretpostavkama: osim početnog broja, dobne i spolne strukture kako aktivnih liječnika tako i studenata medicine potrebno je uključiti i podatke (pretpostavke ili predviđanja) o kretanju stanovništva (korisnika zdravstvene zaštite), promjene u radnom i zdravstvenom zakonodavstvu, ali i gospodarske mogućnosti države i pojedinaca.

4. Više je nedostataka tako razvijenih modela i projekcija baziranih na njima među kojima su glavna dva: i) kao polazište za simulacije i procjenu potreba u budućnosti uzimaju se projekcije broja i dobne strukture stanovništva (populacije korisnika zdravstvene zaštite), a ne buduće zdravstvene potrebe i predvidivi načini njihovog zadovoljavanja, tj. u pravilu se često samo ekstrapoliraju sadašnje potrebe i ii) teško je ili nemoguće predvidjeti razvoj i napredak medicinske tehnologije u budućnosti pa pretpostavke (ulazni parametri) za modeliranje o napretku tehnologije ostaju ili previše konzervativne (tj. projiciraju sadašnju tehnologiju kao tehnologiju budućnosti)

ili su tek nagađanja bez čvrstih uporišta (tj. uzimaju se fiktivne pretpostavke o tehnologiji u budućnosti).

5. Osim nedostataka i nepoznanica nabrojenih u prethodnoj točki, dodatnu prijetnju predstavljaju neplanirani i neočekivani događaji i tokovi koji se nisu mogli predvidjeti pri planiranju i izgradnji modela te zahtijevaju korekciju planova i politika tijekom njihovog provođenja. Brojni su modificirajući čimbenici koji mogu utjecati na broj i strukturu populacije (kontingenta) liječnika i predstavljaju izazove provedbi planova: od neplaniranih (ne)mogućnosti zapošljavanja uzrokovanih gospodarskom krizom (i posljedične pojačane emigracije ili prelijevanja kadrova u druge, gospodarski atraktivnije sektore) ili neočekivanog povećanja potrebe za liječnicima uslijed nastupa nepredviđenih okolnosti (npr. pojava pandemije), preko emigracijskih i imigracijskih tokova koji su izazvani geopolitičkim promjenama (npr. pridruživanjem pojedinih država regionalnim ili globalnim zajednicama/savezima kao što je EU ili migracijama stanovništva kojima upravo svjedočimo) do promjena vlasničke strukture pružatelja zdravstvenih usluga i načina financiranja zdravstvene zaštite.

6. Izobrazbu liječnika specijalista treba promatrati u kontinuitetu od upisa na studij medicine do završetka specijalističkog usavršavanja kao jedinstveni proces koji je dugotrajan i skup i potrebno ga je dugoročno planirati kako bi se osigurao dovoljan broj i odgovarajuća struktura kvalificiranih kadrova za buduće potrebe zdravstvene zaštite stanovništva. Modeliranje i simulacija različitih scenarija je sredstvo koje omogućuje ispitivanje različitih pretpostavki kako o upisnoj politici i dinamici upućivanja na specijalističko usavršavanje, tako i o migracijskim tokovima te prepoznavanje dugoročnih učinaka svakog od pojedinih elemenata i njihovih kombinacija na dinamiku kretanja broja specijalista i liječnika općenito.

7. Metoda sistemske dinamike pokazala se prikladnom za modeliranje dinamike kretanja broja liječnika uključujući njihovo profesionalno napredovanje i starenje. Razvijen je višedijelni model dinamike sustava kojim su obuhvaćene sve faze (ciklusi) školovanja i rada liječnika specijalista, od upisa na studij medicine preko specijalističkog usavršavanja i radnog vijeka u zdravstvenom sustavu (ili nekom drugom sustavu koji zapošljava doktore medicine) do odlaska u mirovinu. U praksi to obuhvaća 46 i više godina životnog vijeka, a model uključuje odljev i priljev doktora medicine u/iz inozemstva. Razvijeni sveobuhvatni model je dokumentiran i javno dostupan na internetu za uporabu i eventualne izmjene parametara i ulaznih podataka te može

poslužiti kao prototip za daljnja istraživanja. (Poveznica na model: https://exchange.iseesystems.com/models/player/dankorelic/model-za-planiranje-specijalistickoga-usavrsavanja-doktora-medicine-u-rh)

8. Za razvoj modela bilo je potrebno najprije prikupiti podatke kako bi se odredilo polazno stanje i procijenili parametri modela. Korišteni su javno dostupni podaci o broju liječnika u Republici Hrvatskoj, njihovoj dobnoj strukturi i raspodjeli specijalizacija, poglavito *Demografski atlas hrvatskog liječništva* Hrvatske liječničke komore, *Zdravstveno statistički ljetopisi* Hrvatskog zavoda za javno zdravstvo, dostupni podaci Ministarstva zdravstva RH te podaci o pruženim zdravstvenim uslugama Hrvatskog zavoda za javno zdravstvo te Hrvatskog zavoda za zdravstveno osiguranje. Za dizajn scenarija i simulacijske eksperimente korišteni su podaci iz važećih strateških dokumenata koje je usvojila Vlada RH (*Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. – 2024.), Pravilnik o specijalističkom usavršavanja doktora medicine, Pravilnik o specijalističkom usavršavanju doktora medicine iz obiteljske medicine, Odluka o utvrđivanju godišnje kvote dozvola za zapošljavanje stranaca*).
9. Za izradu modela potrebno je raspolagati kvalitetnim podacima kako bi se odredilo polazno stanje i parametri modela. U Hrvatskoj su još uvijek statistički pokazatelji nedostatni te je neophodno uvođenje zdravstveno statističkog sustava koji će obuhvaćati sve relevantne parametre, kako javnog zdravstvenog sustava, tako i privatnih pružatelja zdravstvene zaštite. Prilikom proaktivnog planiranja kadrova u zdravstva u obzir je potrebno uzeti migracije (unutarnje i vanjske) te regionalnu raspodjelu liječnika. Uspostavom jedinstvenog registra liječnika u Hrvatskoj, ali i na razini Europske unije migracije bi bilo lakše pratiti i predviđati, a raspodjela liječnika unutar države bi se mogla bolje planirati što je iznimno važno za PZZ, ruralna područja, ali i balansiranje između regionalnih centara (Zagreb, Split, Rijeka, Osijek) i manjih županijskih središta.
10. Sustavno ispitivanje različitih scenarija pokazuje da je sadašnja ukupna upisna kvota na studij medicine u Republici Hrvatskoj od 590 studenata godišnje dovoljna za zadovoljenje potreba za liječnicima u budućem razdoblju do 2035. g. *Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. - 2024.)* je dobrodošao i osigurava dovoljan broj specijalizantskih mjesta za apsorpciju akumuliranog broja doktora medicine koji čekaju na specijalizaciju tijekom

petogodišnjeg razdoblja i poboljšanje dobne strukture liječnika specijalista pojedinih specijalizacija. Nakon isteka petogodišnjeg razdoblja neće biti dovoljno kandidata za tako ambiciozan plan specijalističkog usavršavanja ukoliko se ne bi povećale upisne kvote za studij medicine ili broj dolazaka doktora medicine iz inozemstva. Realnije je očekivati i preporučiti da se broj specijalizacija predviđen u narednom petogodišnjem razdoblju umanji za 20% što će se ionako spontano dogoditi zbog manjka kandidata. Štoviše, izgledno je da niti u razdoblju od 2020. do 2024. g. neće biti konzumirane sve specijalizacije, ali unatoč tome nećemo biti suočeni s manjkom liječnika specijalista jer uz pretpostavku:

- povećanja upisnih kvota na medicinske fakultete sa 590 na 650 od 2022. g. (scenarij 3) u Republici Hrvatskoj će 2031. godine biti 16.257 liječnika ukupno od čega 12.619 specijalista što će tada biti 410,1 liječnika na 100.000 stanovnika
- povećanja dolazaka doktora medicine iz inozemstva za 5 svake dvije godine (scenarij 4) u Republici Hrvatskoj će 2031. godine biti 16.193 liječnika ukupno od čega 12.619 specijalista što će tada biti 408,5 specijalista na 100.000 stanovnika
- smanjenog broj konzumiranih specijalizacija počevši od 2025. g. (scenarij 5) u Republici Hrvatskoj će 2031. g. biti ukupno 15.974 liječnika, od čega ukupno 12.469 liječnika specijalista što će tada biti 402,9 liječnika na 100.000 stanovnika

Moguće su odgovarajuće kombinacije scenarija 3, 4 i 5. Zbog niza nepredvidljivih okolnosti, dugoročna planiranje su nezahvalna; potrebno je kontinuirano adaptirati model te fleksibilno prilagođavati mjere.

8. Sažetak

Osiguranje adekvatnog i održivog broja radnika u zdravstvu, sa odgovarajućim znanjima i vještinama, ključno je pitanje zdravstvene politike širom svijeta. Cilj disertacije je razviti model za simulaciju dinamike upućivanja na specijalističko usavršavanje doktora medicine u Republici Hrvatskoj te sustavnim ispitivanjem različitih scenarija procijeniti optimalnu strategiju kojom se osigurava stabilna opskrba specijalistima različitih specijalnosti i korigira procjep između ponude i potražnje.

Za izradu simulacijskog modela i za izvođenje simulacijskih eksperimenata korišten je programski paket *Stella Architect v1.9.1* s grafičkim sučeljem za izradu i simulaciju modela metodom sistemske dinamike. Promjene u broju liječnika i njihovoj dobnoj raspodjeli projicirane su u kontekstu očekivanih budućih promjena hrvatske populacije pod različitim scenarijima koji pokrivaju razdoblje od 2020. do 2035. godine.

Razvijen je višedijelni model dinamike sustava kojim su obuhvaćene sve faze školovanja i rada liječnika specijalista, od upisa na studij medicine preko specijalističkog usavršavanja i radnog vijeka u zdravstvenom sustavu (ili nekom drugom sustavu koji zapošljava doktore medicine) do odlaska u mirovinu.

Sustavno ispitivanje različitih scenarija pokazuje da je sadašnja ukupna upisna kvota na studij medicine u Republici Hrvatskoj od 590 studenata godišnje dovoljna za zadovoljenje potreba za liječnicima u budućem razdoblju do 2035. godine.

Ključne riječi: liječnici, specijalističko usavršavanje, planiranje kadrova u zdravstvu, Republika Hrvatska, simulacijsko modeliranje, sistemska dinamika

9. Summary

Title: **Development of a model for planning of specialist education of medical doctors in Croatia**

Danko Relić, 2021

Ensuring an adequate and sustainable number of health workers, with appropriate knowledge and skills, is a key health policy issue worldwide. The aim of this thesis was to develop a model for simulating the dynamics of referral to specialist training of medical doctors in the Republic of Croatia and systematically examine different scenarios to assess the optimal strategy to ensure a stable supply of specialists in various specialties and correct the gap between supply and demand.

Stella Architect v1.9.1 software package with a graphical interface for creating and simulating models using the system dynamics method was used to create a simulation model and to perform simulation experiments. Changes in the number of physicians and their age distribution are projected in the context of expected future changes in the Croatian population under different scenarios covering the period from 2020 to 2035.

A multi-part model of system dynamics has been developed, covering all phases of education and work of specialist physicians, from enrolment in medical studies through specialist training and working life in the health system (or another system that employs physicians) to retirement.

The results of simulation modelling of different scenarios indicate that the current total enrolment quota for the study of medicine in the Republic of Croatia of 590 students per year is sufficient to meet the needs for medical doctors in the future until 2035.

Keywords: physicians, specialist education, human resources for health, Republic of Croatia, simulation modelling, system dynamics

10. Literatura

1. Zurn P, Dal Poz MR, Stilwell B, Adams O. Imbalance in the health workforce. Hum Resour Health. 2004;2:13.

2. Kabene SM, Orchard C, Howard JM, Soriano MA, Leduc R. The importance of human resources management in health care: a global context. Hum Resour Health. 2006;4:20.

3. Stordeur S, Léonard C. Challenges in physician supply planning: the case of Belgium. Hum Resour Health. 2010;8:28.

4. Dussault G, Dubois C-A. Human resources for health policies: a critical component in health policies. Hum Resour Health. 2003;1:1.

5. Bartlett W, Božikov J, Rechel B, ur. Health reforms in South East Europe. New York: Palgrave Macmillan; 2012. Str. 244.

6. Trošelj M, Čikeš N, Kovačić L, Mayer V. Liječnici specijalisti u Hrvatskoj: opći pregled, mogućnost planiranja i izobrazbe u budućnosti. Liječ Vjesn. 2003;125:281–91.

7. Stobrawa F, Bistrup R. Germany: the medical profession and the structural development of the health care system. Cah Sociol Demogr Med. 1995;35:177–88.

8. Hansluwka H, Petrinsky V. Austria: some aspects of the health workforce. Cah Sociol Demogr Med. 1995;35:189–207.

9. Mapelli V. Italy: towards privatization of employment and European qualification of health manpower. Cah Sociol Demogr Med. 1995;35:307–24.

10. Morris JN. Uses of epidemiology. Br Med J. 1955;2:395–401.

11. Cassens BJ, ur. Preventive medicine and public health. 2 izd. Baltimore : Malvern, Pa: Williams & Wilkins ; Harwal Pub. Co; 1992. Str. 497.

12. Butter I, Mej'ia A. Too many doctors!. World health forum. 1987; 8(4):494-500.

13. Trošelj M, Mayer V, Kuzman M, Tomić B. Demografske i izobrazbene značajke liječnika zaposlenih u sustavu zdravstva Hrvatske: Opći pregled. Liječ Vjesn. 2002;(124):341–6.

14. Ono T, Lafortune G, Schoenstein M. Health Workforce Planning in OECD Countries: A Review of 26 Projection Models from 18 Countries. OECD Health Working Papers [Internet]. 2013 [pristupljeno 04.06.2019.];62. Dostupno na: https://www.oecd-ilibrary.org/social-issues-migration-health/health-workforce-planning-in-oecd-countries_5k44t787zcwb-en

15. World Health Organization. Models and tools for health workforce planning and projections - Human Resources for Health Observer. [Internet] Geneva: World Health Organization; 2010- [pristupljeno 04.06.2019.]. Dostupno na:https://www.who.int/workforcealliance/knowledge/resources/models_hrh_planning/en/

16. Hrvatski Sabor. Nacionalna strategija razvoja zdravstva 2012-2020. Narodne novine 2012;116:2519.

17. Roberfroid D, Leonard C, Stordeur S. Physician supply forecast: better than peering in a crystal ball?. Hum Resour Health. 2009;7:10.

18. Adams O. Management of human resources in health care: the Canadian experience. Health Econ. 1992;1:131–43.

19. Arnold PC. More doctors, but not enough: Australian medical workforce supply 2001-2012. Med J Aust. 2006;185:182.

20. Doan BDH, Lévy D, Pavot J. Demographic forecasts of medical workforce supply in France (2000-2050). What numerus clausus for what future?. Cah Sociol Demogr Med. 2004;44:101–48.

21. Coste E, Doan BDH. Forecast of physician workforce in the 22 French regions (1998-2013). Cah Sociol Demogr Med. 2003;43:5–70.

22. Benahmed N, Alexander S, De Wever A, Deliège D. Focus on planning the supply of physicians in Belgium. Rev Med Brux. 2013;34:141–53.

23. Bellan L, Buske L, Wang S, Buys YM. The landscape of ophthalmologists in Canada: present and future. Can J Ophthalmol. 2013;48:160–6.

24. Crettenden IF, McCarty MV, Fenech BJ, Heywood T, Taitz MC, Tudman S. How evidence-based workforce planning in Australia is informing policy development in the retention and distribution of the health workforce. Hum Resour Health. 2014;3:12-7.

25. Çelik Y, Khan M, Hikmet N. Achieving value for money in health: a comparative analysis of OECD countries and regional countries: Achieving Value for Money in Health. Int J Health Plann Manage. 2017;32:279–98.

26. Van Greuningen M, Batenburg RS, Van der Velden LF. Ten years of health workforce planning in the Netherlands: a tentative evaluation of GP planning as an example. Hum Resour Health. 2012;10:21.

27. Cooper RA, Getzen TE, Laud P. Economic expansion is a major determinant of physician supply and utilization. Health Serv Res. 2003;38:675–96.

28. Barber P, López-Valcárcel BG. Forecasting the need for medical specialists in Spain: application of a system dynamics model. Hum Resour Health. 2010;8:24.

29. Greenberg L, Cultice JM. Forecasting the need for physicians in the United States: the Health Resources and Services Administration's physician requirements model. Health Serv Res. 1997;31:723–37.

30. Dall TM, Storm MV, Chakrabarti R i sur. Supply and demand analysis of the current and future US neurology workforce. Neurology. 2013;81:470–8.

31. Vlada Republike Hrvatske. Strateški plan razvoja ljudskih resursa u zdravstvu 2015-2020. Zagreb: Republika Hrvatska Ministarstvo zdravstva; 2015.

32. Rizza RA, Vigersky RA, Rodbard HW i sur. A Model to Determine Workforce Needs for Endocrinologists in the United States Until 2020. J Clin Endocrinol Metab. 2003;88:1979–87.

33. Akrap A. Demografski slom Hrvatske: Hrvatska do 2051. Bogoslovska Smotra. 2015;85(3):855–81.

34. Bagat M. Model planiranja i upravljanja ljudskim potencijalima u sustavu zdravstva u Republici Hrvatskoj [disertacija]. Zagreb: Sveučilište u Zagrebu, Medicinski fakultet; 2016.

35. Drakulić V, Bagat M, Golem AZ. Regionalna raspodjela liječnka u Hrvatskoj. Liječ Vjesn. 2009;131:301–5.

36. Bagat M, Drakulić V, Sekelj Kauzlarić K, Vlahusić A, Bilić I, Matanić D. Influence of urbanization level and gross domestic product of counties in Croatia on access to health care. Croat Med J. 2008;49:384–91.

37. Polasek O, Kolcic I, Dzakula A, Bagat M. Internship workplace preferences of final-year medical students at Zagreb University Medical School, Croatia: all roads lead to Zagreb. Hum Resour Health. 2006;4:7.

38. Pravilnik o specijalističkom usavršavanju magistara farmacije. Narodne novine 2008;73:2446.

39. Pravilnik o specijalističkom usavršavanju magistara medicinske biokemije. Narodne novine 2008;73:2448.

40. Pravilnik o specijalističkom usavršavanju doktora stomatologije. Narodne novine 2007;115:3369.

41. Pravilnik o specijalističkom usavršavanju doktora medicine. Narodne novine 2017;6.

42. Pravilnik o specijalističkom usavršavanju doktora medicine iz obiteljske medicine. Narodne novine 2017;31.

43. Pravilnik o specijalističkom usavršavanju medicinskih sestara - medicinskih tehničara. Narodne novine 2011;28.

44. Hrvatska liječnička komora. Atlas liječništva [Internet]. [citirano 14.03.2021.]. Dostupno na: http://atlas.hlk.hr:8080/atlas/

45. Granić M, Kostović I. Sadašnje stanje i persepktive Medicinskog fakulteta Sveučilišta u Zagrebu. Liječ Vjesn. 1992;114:191–6.

46. Jakšić Ž, Božikov J, Kljajić K, Pokrajac N. Medical school admission: Zagreb experience. Croat Med J. 1993;34:66–77.

47. Budak A, Božikov J. Imamo li previše liječnika u Hrvatskoj? Liječ Vjesn. 1993;115:261–7.

48. Hebrang A. Koliko liječnika treba Hrvatska? Liječ Vjesn. 1993;115:315–6.

49. Kovačić L, Šošić Z. Organization of health care in Croatia: needs and priorities. Croat Med J. 1998;39:249–55.

50. Sapunar D. Medicinski fakultet u Splitu. Pregled aktivnosti od osamostaljenja do danas. Liječ Vjesn. 2001;123:221–30.

51. Keglević MV, Balint I, Cvetković I, Gaćina A. Organizational structure of the Croatian family practice: a longitudinal study based on routinely collected data. Coll Antropol. 2014;38:11–7.

52. Zajednica zdravstvenih fakulteta SR Hrvatske. Radna grupa za procjenu potreba za zdravstvenim kadrovima te obrazovnim potrebama zdravstva u SR Hrvatskoj. Prilog raspravi o "Procjeni razvoja zdravstva i potrebama za kadrovima do 2000. godine na bazi usvojenih dokumenata strateškog razvoja zdravstva do 2000. godine i na bazi racionalnog sagledavanja razvoja zdravstva SR Hrvatske – Nacrt." Zagreb: Zajednica zdravstvenih fakulteta SR Hrvatske; 1989.

53. Poljak Ž. Hiperprodukcija liječnika u Hrvatskoj. Liječničke novine. 2000;57:6–9.

54. Hrvatski Sabor. Nacionalna strategija razvitka zdravstva 2006. - 2011. Narodne novine 2006;72:1179.

55. Pleša V. Ministarstvo unutarnjih poslova Republike Hrvatske: pismeno priopćenje. Zagreb: Sektor operativne tehnike; 2000 Aug. Report No.: 511-01-52-49976/200.

56. Bazzoli GJ, Dynan L, Burns LR, Yap C. Two decades of organizational change in health care: what have we learned? Med Care Res Rev MCRR. 2004;61:247–331.

57. Vončina L, Džakula A, Mastilica M. Health care funding reforms in Croatia: a case of mistaken priorities. Health Policy Amst Neth. 2007;80:144–57.

58. Zrinščak S. Zdravstvena politika Hrvatske. U vrtlogu reformi i suvremenih društvenih izazova. Rev Za Soc Polit. 2007;14:193–220.

59. Odluka o osnovama za sklapanje ugovora o provođenju zdravstvene zaštite iz obveznog zdravstvenog osiguranja. Narodne novine 2017;56:1235.

60. Hrvatski zavod za javno zdravstvo, Zdravstveno statistički ljetopis za 2019. godinu. Zagreb: Hrvatski zavod za javno zdravstvo; 2020.

61. Džakula A, Sagan A, Pavić N, Lonćčarek K, Sekelj-Kauzlarić K. Croatia: health system review. Health Syst Transit. 2014;16:1–162.

62. Hrvatski Sabor. Nacionalna strategija razvoja zdravstva 2012. - 2020. Narodne novine 2012;116:2519.

63. OECD/European Observatory on Health Systems and Policies. Hrvatska: pregled stanja zdravlja i zdravstvene zaštite 2019. : State of Health in the EU. [Internet] Paris: OECD Publishing; 2019. [citirano 04.06.2019.]. Dostupno na: https://www.oecd.org/health/hrvatska-pregled-stanja-zdravlja-i-zdravstvene-zastite-2019-df8b2178-hr.htm

64. Božikov J, Petrovečki M, Deželić G. Modeliranje i simulacija. U: Kern J. ur. Medicinskoinformatičke metode. Zagreb: Medicinska naklada; 2006. Str. 95–117.

65. Božikov J. Odraz višestupanjskog modela karcinogeneze na incidenciju raka u ljudskoj populaciji - primjer raka debelog crijeva. [disertacija]. Zagreb: Sveučilište u Zagrebu, Medicinski fakultet; 1997.

66. Doerr HM. Stella ten years later: A review of the literature. Int J Comput Math Learn. 1996;1:201–24.

67. Čipin I, Smolić Š, Vlah Jerić S. Demografski atlas hrvatskog liječništva. Hrvatska liječnička komora; 2017.

68. Pravilnik o načinu provođenja rada pod nadzorom doktora medicine bez specijalizacije. Narodne novine. 2019;63:1252.

69. Nacionalni plan specijalističkog usavršavanja zdravstvenih radnika za petogodišnje razdoblje (2020. - 2024.). Narodne novine. 2020;103:1938.

70. Pravilnik o specijalističkom usavršavanju doktora medicine. Narodne novine 2011;100:2057.

71. Stella Architect. isee systems; 2021.

72. Ishikawa T, Ohba H, Yokooka Y, Nakamura K, Ogasawara K. Forecasting the absolute and relative shortage of physicians in Japan using a system dynamics model approach. Hum Resour Health. 2013;11:41.

73. Budak A, Božikov J. Imamo li previše liječnika u Hrvatskoj? Liječ Vjesn. 1993;115:261–7.

74. Sheer B, Wong FKY. The development of advanced nursing practice globally. J Nurs Scholarsh. 2008;40:204–11.

75. European Commision. Slovenia : Health Care and Long-Term Care Systems. [Internet]. 2016 Oct. [pristupljeno 04.06.2019.]. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/joint-report_si_en_2.pdf

76. Pečelin S, Sočan M. Referenčne ambulante: izkušnje diplomiranih medicinskih sester. Obzornik Zdravstvene Nege . 2016;50(2). Dostupno na: https://obzornik.zbornica-zveza.si/index.php/ObzorZdravNeg/article/view/82

77. Susič AP, Klemenc-Ketiš Z. Successful implementation of integrated care in Slovenian primary care. Slov J Public Health. 2020;60:1–3.

78. Hrvatski zavod za javno zdravstvo, Zdravstveno statistički ljetopis za 1990. godinu. Zagreb: Hrvatski zavod za javno zdravstvo; 1991.

79. Hrvatski zavod za javno zdravstvo, Zdravstveno statistički ljetopis za 2017. godinu. Zagreb: Hrvatski zavod za javno zdravstvo; 2018.

80. Irving G, Reeve J. Do GPs really provide 47 minutes a year for the patient? Br J Gen Pract J R Coll Gen Pract. 2012;62:404–5.

81. Irving G, Neves AL, Dambha-Miller H, Oishi A, Tagashira H, Verho A, i sur. International variations in primary care physician consultation time: a systematic review of 67 countries. BMJ Open. 2017;7.

82. Kringos D, Boerma W, Bourgueil Y i sur. The strength of primary care in Europe: an international comparative study. Br J Gen Pract. 2013;63:742-750.

83. Hrvatski zavod za javno zdravstvo, Zdravstveno statistički ljetopis za 2010. godinu. Zagreb: Hrvatski zavod za javno zdravstvo; 2011.

84. Hrvatski zavod za javno zdravstvo, Zdravstveno statistički ljetopis za 2018. godinu. Zagreb: Hrvatski zavod za javno zdravstvo; 2019.

85. Hrvatska liječnička komora. HKL predstavila Digitalni atlas hrvatskog liječništva [Internet]. [pristupljeno 04.06.2019.]. Dostupno na: https://www.hlk.hr/hlk-predstavila-digitalni-atlas-hrvatskog-lijecnistva.aspx

86. Eurostat Statistics Explained. Healthcare personnel statistics : physicians. [Internet]. [prisupljeno 31.11.2019.]. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php/Healthcare_personnel_statistics_-_physicians

87. Relić D, Božikov J. Application of a system dynamics model in forecasting the supply and age distribution of physicians. Croat Med J. 2020;61:100–6.

88. Senese F, Tubertini P, Mazzocchetti A, Lodi A, Ruozi C, Grilli R. Forecasting future needs and optimal allocation of medical residency positions: the Emilia-Romagna Region case study. Hum Resour Health. 2015;13:7.

89. European Commission. Commision Staff Working Document on an Action Plan for the EU Health Workforce [Internet]. 2012 [pristupljeno 04.06.2019.]. Dostupno na: https://ec.europa.eu/health/sites/health/files/workforce/docs/staff_working_doc_healthcare_workforce_en.pdf

90. Stavljenić Rukavina A, Dzakula A. Strateško planiranje razvoja ljudskih resursa u hrvatskoj zdravstvenoj skrbi :završno izvješće projekta). Washington, D.C. : Svjetska banka - Međunarodna banka za obnovu i razvoj; 2014.

91. Bozikov J, Relic D, Dezelic G. Use of System Dynamics Modeling in Medical Education and Research Projects. Stud Health Technol Inform. 2018;247:830–4.

92. Takata H, Nagata H, Nogawa H, Tanaka H. The current shortage and future surplus of doctors: a projection of the future growth of the Japanese medical workforce. Hum Resour Health. 2011;9:14.

93. Ishikawa T, Fujiwara K, Ohba H, Suzuki T, Ogasawara K. Forecasting the regional distribution and sufficiency of physicians in Japan with a coupled system dynamics-geographic information system model. Hum Resour Health 2017; 15(1):1-9.

94. Gonzalez-Busto B, Garcıa R. Waiting lists in spanish public hospitals: a system dynamics approach. Syst Dyn Rev 1999; 15: 201–224.

95. De Silva D. How many doctors should we train for Sri Lanka? System dynamics modelling for training needs. Ceylon Med J. 2017;62:233.

96. Ansah JP, De Korne D, Bayer S, Pan C, Jayabaskar T, Matchar DB, et al. Future requirements for and supply of ophthalmologists for an aging population in Singapore. Hum Resour Health. 2015;13:86.

97. Van Greuningen M, Batenburg RS, Van der Velden LF. The accuracy of general practitioner workforce projections. Hum Resour Health. 2013;11:31.

98. Čipin I, Smolić Š, ur. The Economics of Agening in Croatia : research results and findings. Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet;2013.

99. OECD. Health Workforce Policies in OECD Countries: Right Jobs, Right Skills, Right Places [Internet]. OECD; 2016 [citirano 06.03.2021.]. (OECD Health Policy Studies). Dostupno na: https://www.oecd-ilibrary.org/social-issues-migration-health/health-workforce-policies-in-oecd-countries_9789264239517-en

100. Nanfcarrow SA, Moran AM, Graham I. Preparing a 21st century workforce: is it time to consider clinically based, competency-based training of health practitioners? Aust Health Rev. 2014;38:115.

101. Inoue K, Matsumoto M, Sawada T. Evaluation of a medical school for rural doctors. J Rural Health. 2007;23:183–7.

102. Øyvind A, Jørgensen E, Østerås J, Hasvold T. Medical education in Tromsø--does it secure recruitment of physicians to the northern parts of Norway?. Tidsskr Nor Laegeforen. 2004;124:2107–9.

103. Bärnighausen T, Bloom DE. Financial incentives for return of service in underserved areas: a systematic review. BMC Health Serv Res 2009;9:86.

104. Battye KM, McTaggart K. Development of a model for sustainable delivery of outreach allied health services to remote north-west Queensland, Australia. Rural Remote Health. 2003;3:194.

105. Giorgino F, Bhana S, Czupryniak L i sur. Management of patients with diabetes and obesity in the COVID-19 era: Experiences and learnings from South and East Europe, the Middle East, and Africa. Diabetes Res Clin Pract. 2021;172:108617.

106. Krznarić Ž, Bender DV, Laviano A, Cuerda C, Landi F, Monteiro R, et al. A simple remote nutritional screening tool and practical guidance for nutritional care in primary practice during the COVID-19 pandemic. Clin Nutr Edinb Scotl. 2020;39:1983–7.

107. Ćosić K, Popović S, Šarlija M, Kesedžić I. Impact of Human Disasters and COVID-19 Pandemic on Mental Health: Potential of Digital Psychiatry. Psychiatr Danub. 2020;32:25–31.

108. Meskó B, Hetényi G, Győrffy Z. Will artificial intelligence solve the human resource crisis in healthcare? BMC Health Serv Res. 2018;18:545.

109. Tomblin Murphy G, Birch S, MacKenzie A, Bradish S, Elliott Rose A. A synthesis of recent analyses of human resources for health requirements and labour market dynamics in high-income OECD countries. Hum Resour Health. 2016;14:59.

11. Životopis

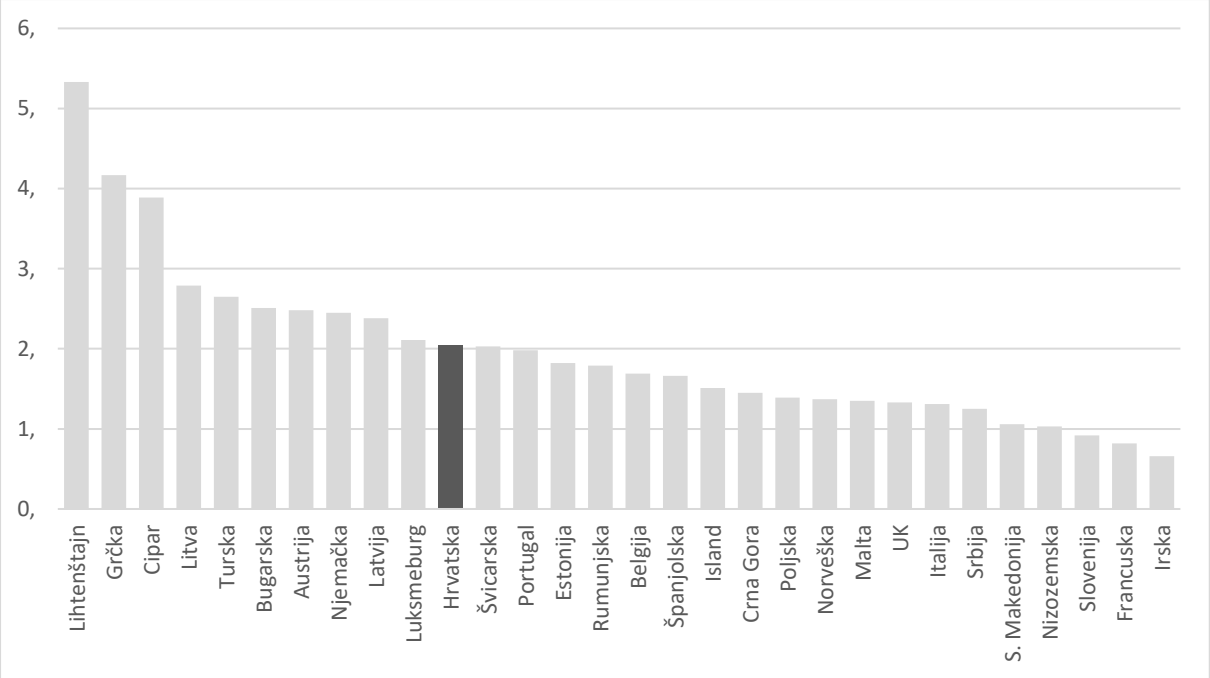
Danko Relić rođen je 1987. g. u Slavonskom Brodu gdje završava osnovnu školu „Ivan Goran Kovačić“ te klasičnu gimnaziju fra Marijana Lanosovića s pravom javnosti. Od 2006. do 2012. g. studirao je na Medicinskom fakultetu Sveučilišta u Zagrebu – dobitnik je posebne Dekanove i Rektorove nagrade. Od 2013. do 2014. g. pripravnički staž odrađivao je za Dom zdravlja Zagreb – Zapad nakon čega polaže stručni ispit za doktore medicine. Od 2014. g. do 2015. g. radi kao liječnik opće medicine u Domu zdravlja Zagreb – Centar. 2015. g. izabran je u suradničko zvanje asistenta u Katedri za medicinsku statistiku, epidemiologiju i medicinsku informatiku Medicinskog fakulteta Sveučilišta u Zagrebu te sudjeluje u izvođenju nastave preddiplomskih, diplomskih i poslijediplomskih studija. Sveučilišni poslijediplomski doktorski studij Biomedicina i zdravstvo upisao je 2015.g. Autor je i koautor više stručnih i znanstvenih radova.

Od 2015. g. predstojnik je Centra za planiranje zanimanja u biomedicini i zdravstvu Medicinskog fakulteta Sveučilište u Zagrebu. Aktivno sudjeluje u radu Centra za zdravstvenu djelatnost Medicinskog fakulteta Sveučilišta u Zagrebu. 2018. g. započeo je specijalističko usavršavanje iz obiteljske medicine.

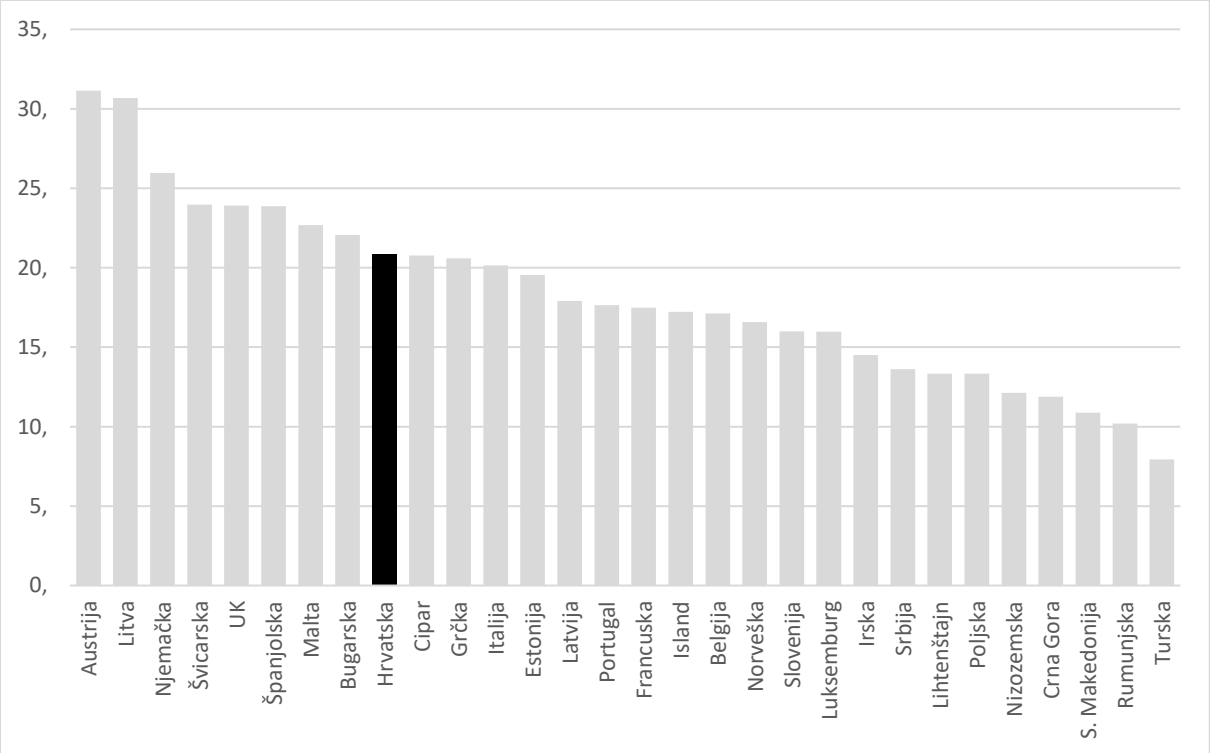
Inicijator je obnavljanja Hrvatskog društva mladih liječnika Hrvatskog liječničkog zbora u kojem je obnašao dužnost predsjednika te je jedan od osnivača Udruge narodnog zdravlja „Andrija Štampar“. Organizator je brojnih domaćih i međunarodnih simpozija i konferencija. Dobitnik je povelje Hrvatske liječničke komore za brigu o ugledu liječničkog staleža.

Prilog

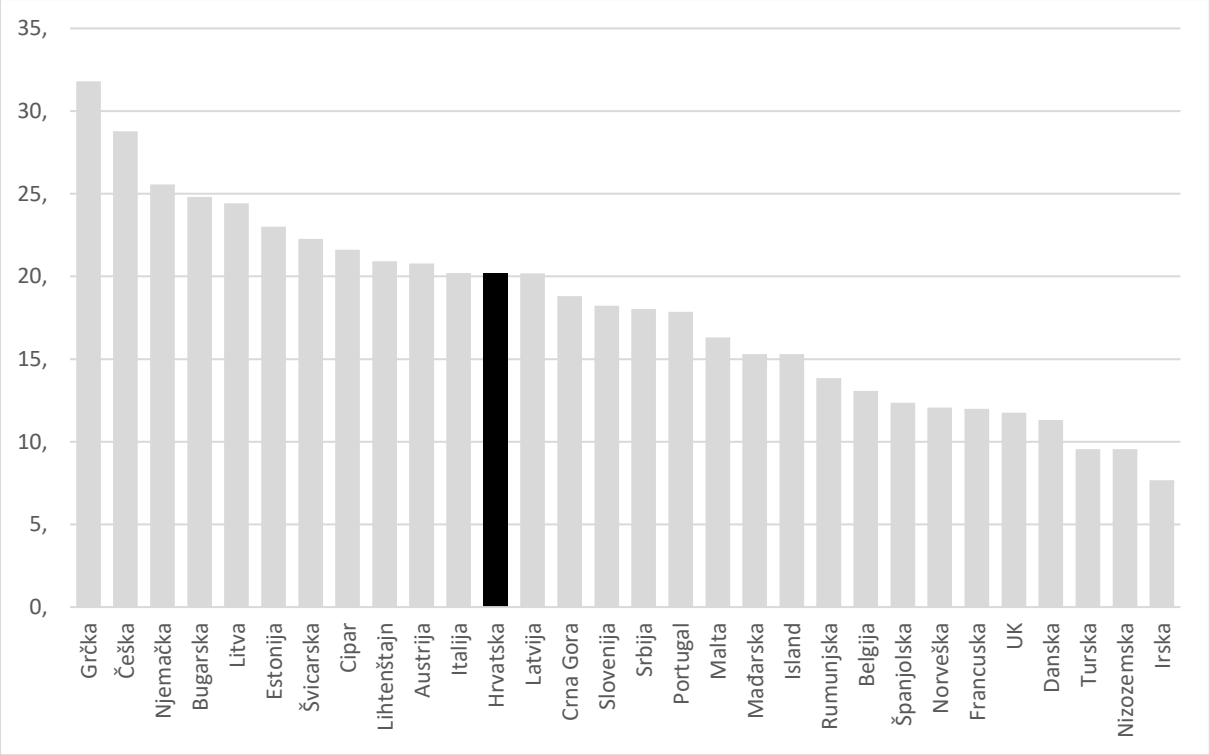
Grafički prikaz broja liječnika specijalista na 100.000 stanovnika (Izvor: Eurostat)



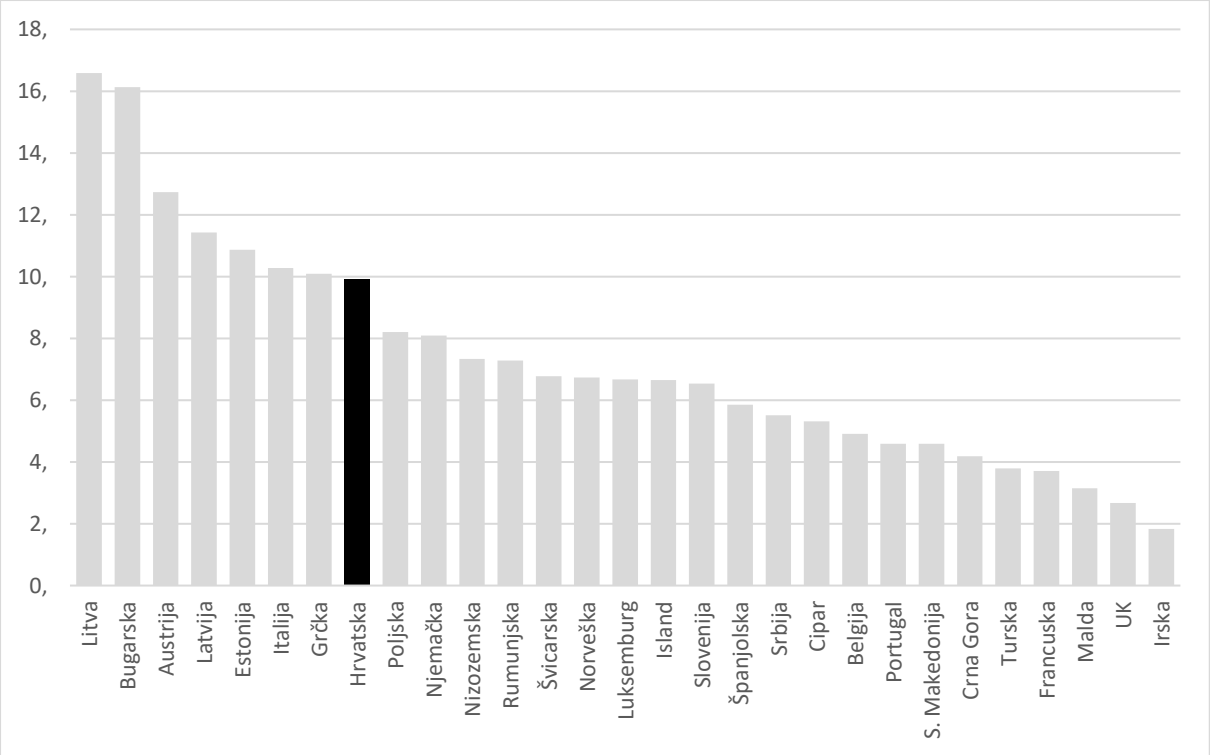
Slika P1. Prikaz broja liječnika specijalista neurokirurgije na 100.000 stanovnika (2015)



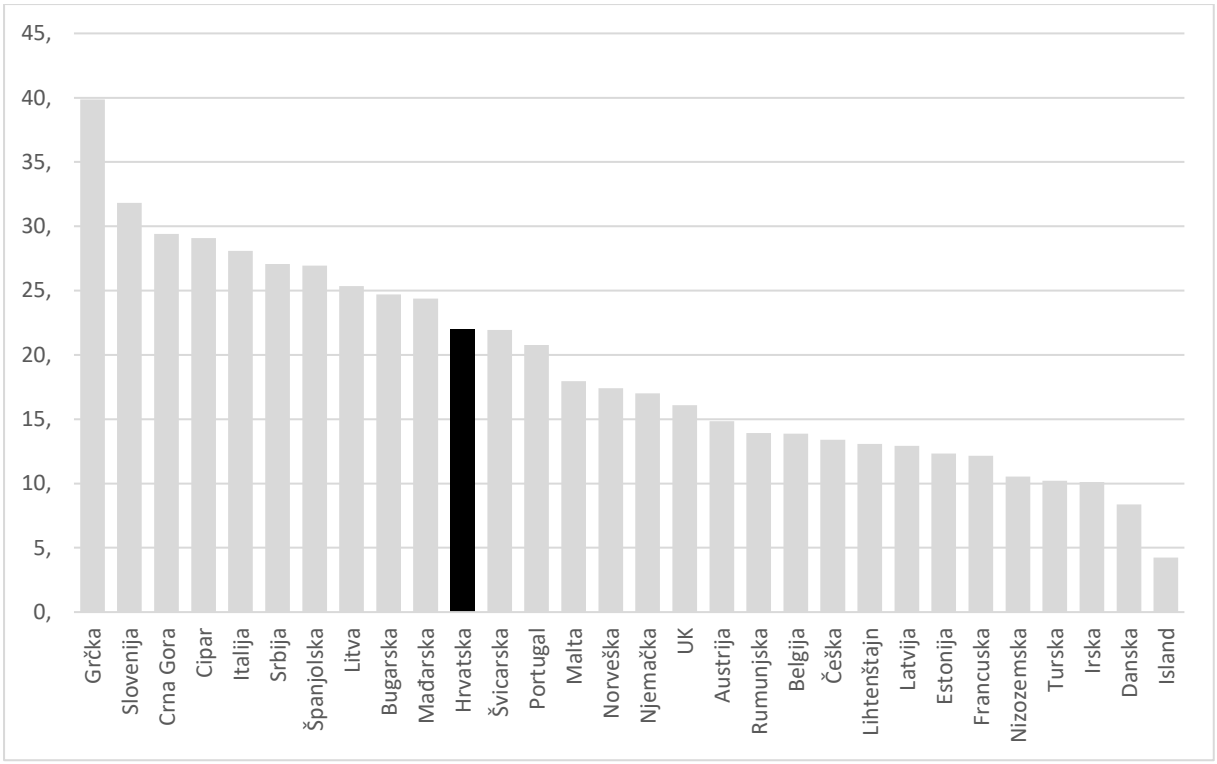
Slika P2. Prikaz broja liječnika specijalista anesteziologije, reanimatologije i intenzivnog liječenja na 100.000 stanovnika (2015)



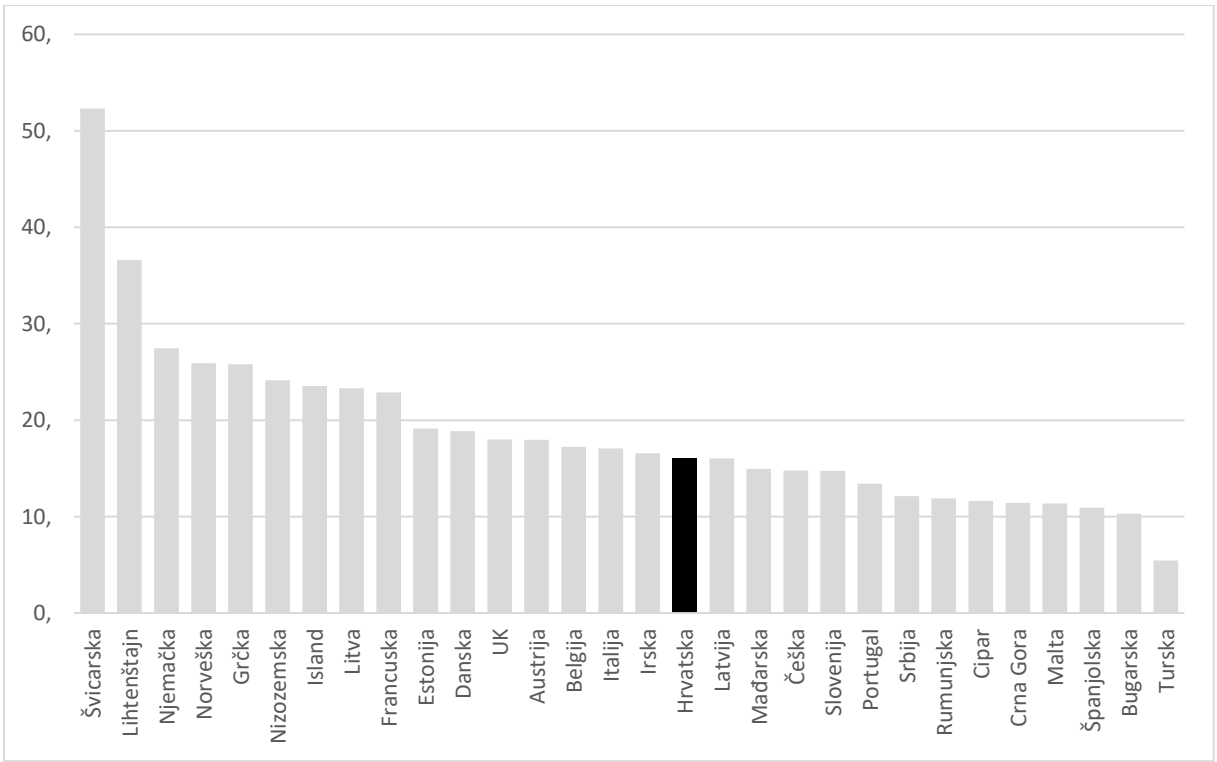
Slika P3. Prikaz broja liječnika specijalista ginekologije i opstetricije na 100.000 stanovnika (2018)



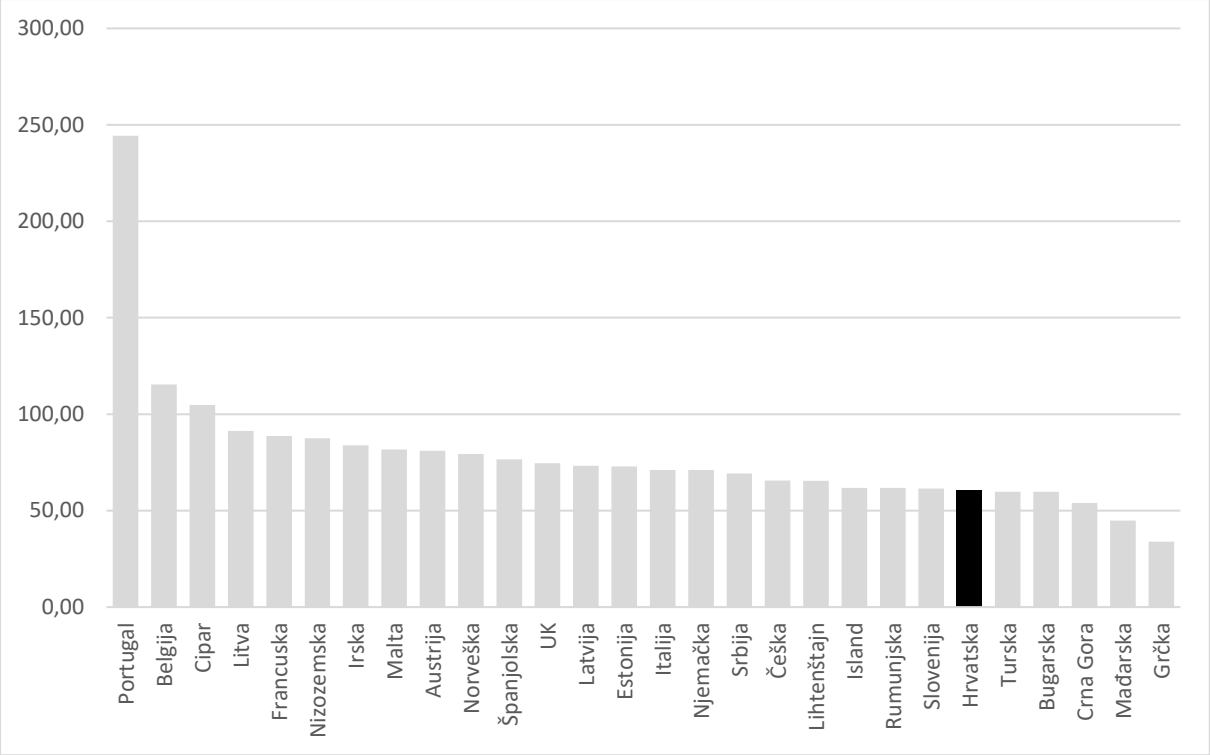
Slika P4. Prikaz broja liječnika specijalista neurologije na 100.000 stanovnika (2015)



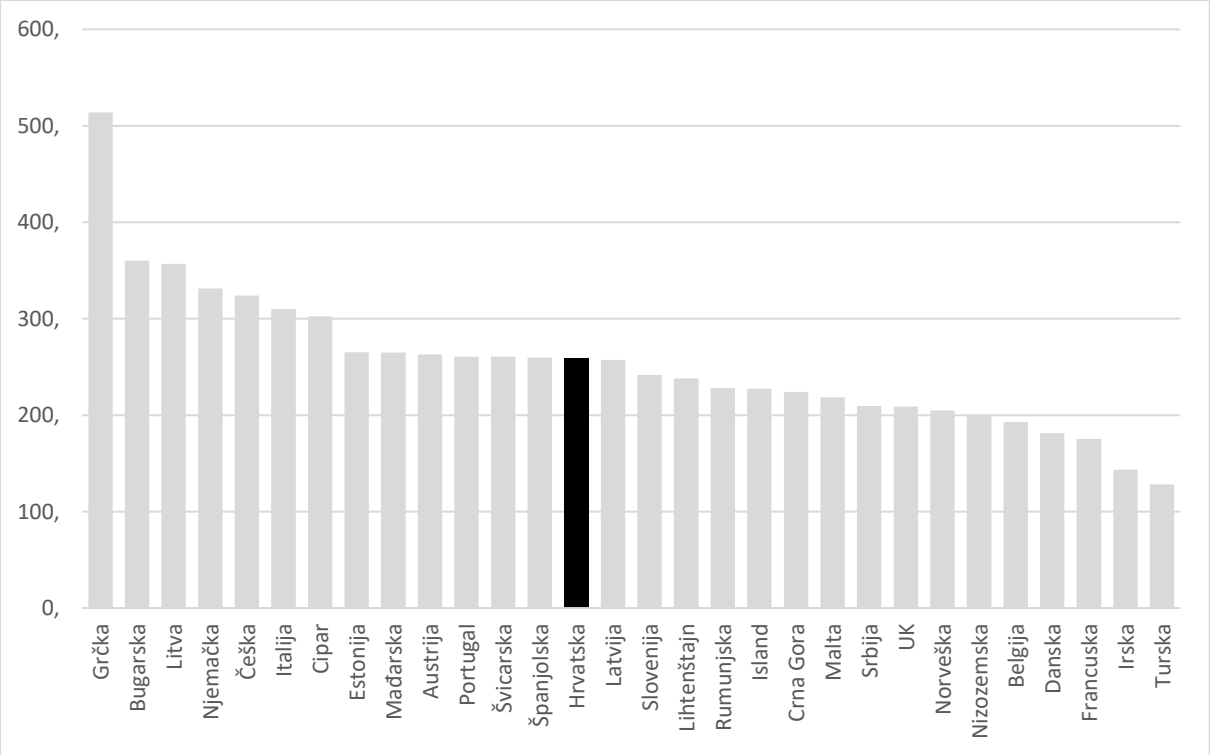
Slika P5. Prikaz broja liječnika specijalista pedijatrije (PZZ) na 100.000 stanovnika (2018)



Slika P6. Prikaz broja liječnika specijalista psihijatrije na 100.000 stanovnika (2018)



Slika P7. Prikaz broja liječnika opće/obiteljske medicine na 100.000 stanovnika (2018)



Slika P8. Prikaz broja liječnika specijalista na 100.000 stanovnika (2018)