SUSTAVSKO DINAMIČKI MODEL ZA UPRAVLJANJE TROŠKOVIMA ZDRAVSTVENE ZAŠTITE PRETILIH OSOBA

Prša, Mario

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:327615

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

SUSTAVSKO DINAMIČKI MODEL ZA UPRAVLJANJE TROŠKOVIMA ZDRAVSTVENE ZAŠTITE PRETILIH OSOBA

Mentor: **Student:**

Izv.prof.dr.sc. Marko Hell **Mario Prša**

Split, kolovoz, 2018.

SADRŽAJ:

1. UVOD **1**

1.1. Problem istraživanja **1**

1.2. Predmet istraživanja **3**

1.3. Ciljevi istraživanja **4**

1.4. Istraživačke hipoteze **4**

1.5. Metode istraživanja **5**

1.6. Doprinos istraživanju **5**

1.7. Struktura diplomskog rada **6**

2. Zdravstveni sustav Republike Hrvatske **7**

2.1. Organizacija zdravstvene zaštite u RH **7**

2.2. Financiranje zdravstvene zaštite **9**

2.3. Struktura osiguranika i troškova zdravstvene zaštite **10**

2.4. Financiranje i troškovi zdravstvene zaštite u EU **12**

3. Pretilost kao globalni problem **16**

3.1. Pretilost i zdravstveni problemi **16**

3.2. Trend razvoja pretilosti u svijetu **18**

3.2. Ekonomske posljedice pretilosti **21**

4. Biološko-ekonomski sustavsko dinamički model za upravljanje troškovima zdravstvene zaštite pretilih osoba **23**

4.1. Sustavska dinamika **23**

4.1.1. Metodologija sustavske dinamike 28

4.2. Programski paket Powersim **29**

4.2. Razvoj biološkog modela **32**

4.3. Razvoj financijskoj modela **42**

4.4. Analiza simulacijskih rezultata **46**

4.5. Mjere u sustavu zdravstva **47**

5. Zaključak **49**

LITERATURA **51**

POPIS TABLICA **56**

POPIS SLIKA **57**

SAŽETAK **58**

SUMMARY..... 59

1. UVOD

1.1. Problem istraživanja

U posljednja dva desetljeća problem pretilosti poprimilo je epidemiološke proporcije s kojima se suočava suvremeni svijet. Pretile osobe generiraju veće izdatke za zdravstvenu skrb nego osobe s normalnom tjelesnom težinom, te sukladno tome troškovi se povećavaju disproporcionalno s povećanjem razine indeksa tjelesne mase (u nastavku BMI) (Sassi, 2010). U sustavnom pregledu ekonomskog opterećenja pretilosti širom svijeta, rezultati govore da zemlje troše od 0,7% do 2,8% ukupnih izdataka za zdravstvenu skrb na osobe sa prekomjernom tjelesnom kilažom te da su pojedinci imali medicinske troškove 30% veće od osoba s normalnom težinom (Wang et al., 2011).

Pojam BMI (Body mass index) označava indeks tjelesne mase koje se koristi kao mjerilo u određivanju debljine prema medicinskim kriterijima. Smatra se najčešće primijenjenom kliničkom mjerom za karakterizaciju pretilosti kod pojedinaca (Suchanek et al., 2012). Razlikuju se tri kategorije BMI-a. Prva kategorija obuhvaća sve ispod 18,5 što upućuje na neuhranjenost , između 18,5 i 24,9 je granica normalnog indeksa tjelesne mase, između 25 i 30 prekomjerna tjelesna težina te iznad 30 pretilost (Flegal et al., 2013). Pretilost potiče povećan rizik od dijabetesa tipa 2, kardiovaskularnih bolesti i nekoliko oblika raka. Mnogi kronični i akutni zdravstveni poremećaji povezani s viškom tjelesne težine terete društvo , ne samo negativnim utjecajem na zdravstvenu kvalitetu života, već i zbog velikih troškova pojedinaca gledano kroz prizmu povećane zdravstvene zaštite i izgubljene produktivnosti. Medicinski troškovi uključuju i sporedne troškove obuhvaćene prekomjernom upotrebom ambulantne skrbi, hospitalizacije, lijekova, radioloških i laboratorijskih ispitivanja te dugoročne njege (Wang et al., 2011).

U 2007. godini, procijenjeno je da su u Hrvatskoj direktni (prevencija, dijagnoza, tretmani i usluge za zdravstvenu skrb pretilih osoba, hospitalizacija, liječničke usluge, lijekovi) i indirektni troškovi (bolesti i smrtnost) pretilih osoba (N=793 955) iznosili 34.934.020 € ili 256.275.970 kn[1] (Čubrilo-Turek, 2007), što je prosječno 322,78 kn po pretiloj osobi. Prema Eurostatu, u 2014. Godini, u Hrvatskoj je procijenjen broj pretilih osoba u iznosu od 18% (indeks tjelesne mase iznad 30), što je prosječno činilo 769.677 osoba koje su bile pretile, što

[1] 2007. godine (godišnji) srednji devizni tečaj Hrvatske narodne banke iznosio je 1€ = 7,336 kn (dostupno na: https://www.hnb.hr/documents/20182/33ebeea1-3d13-4a42-b0fb-87223d026703)

nas svrstava u sami vrh zemalja s brojem pretilih osoba u Europi (indeks tjelesne mase veći od 30). Istraživanja su pokazala da pretile osobe generiraju veće troškove zdravstvene zaštite što upućuje na to da se nameću kao teret razvijenim ekonomijama. Primjerice, na temelju trenda za razdoblje 1993-2008., porast pretilih u UK je iznosio 26% , a smatra se da će do 2030. godine iznositi 35-48%. U SAD-u je procijenjen rast od 32-50% do 2030. godine (King, 2011). Ovakav trend pokazuje da se i ostale zemlje svijeta susreću s povećanjem problema pretilosti, što generira visoke troškove zdravstvenog sustava.

Postoji složeni odnos između društveno-ekonomskih uvjeta i pretilosti. Vidljiva je razlika i na tržištu rada između ljudi prekomjerne i normalne tjelesne kilaže. Manja je vjerojatnost zapošljavanje pretilih osoba. Diskriminacija pri zapošljavanju, dijelom zbog očekivane niže produktivnosti, stvara sve veći broj radnika bez zaposlenja. Bitno je spomenuti i cjenovnu problematiku dostupne prehrane u današnjem načinu i stilu života. Kalorična prehrana je postala jeftina i praktična hrana dostupna gotovo svugdje i u bilo koje vrijeme, dok je priprema hrane u tradicionalnom obliku opala kao posljedica promjene načina i stila života. Smanjenje tjelesne aktivnosti na poslu, povećano sudjelovanje žena u radnoj snazi, povećanje razine stresa i nesigurnosti na poslu i dulje radno vrijeme su neki od čimbenika koji su doprinijeli, izravno ili neizravno u promjenama načina života što je stvorilo podlogu za povećani broj pretilih osoba (Sassi, 2010). Vladina politika je također igrala ulogu u „epidemiji pretilosti“. Različite fiskalne mjere, oporezivanje cijene životnih dobara, prometne politike, dovele su do povećanog korištenja javnih prijevoznih sredstava ostavljajući manje mogućnosti za tjelesne aktivnosti te stvaranje urbanih područja koje pružaju plodnu osnovu za širenje nezdravog načina života.

Vlade su ograničene u regulacijama i fiskalnim polugama zbog složenosti procesa regulatornog okvira, troškova provedbe i vjerojatnosti suočavanja s ključnim industrijama (Sassi, 2010). Ključna područja u kojma vlade očekuju doprinos industrije hrane i pića su preoblikovanje prehrambenih proizvoda, ograničavanje marketinških aktivnosti, osobito ranjivih skupina, transparentnost i informacije o sadržaju hrane. Intervencije koje su usmjerene na rješavanje pretilosti poboljšanjem prehrane i povećanjem tjelesne aktivnosti.

Tri ključna područja se nameću, uključujući zdravstvenu edukaciju i promicanje, reguliranje i fiskalne mjere te savjetovanje u primarnoj zdravstvenoj zaštiti. Sve su učinkovite te imaju povoljan troškovni učinak u odnosu na scenarij gdje se tretiraju kao kronične bolesti samo kad nastaju (Sassi, 2010). Državne intervencije dodaju godine zdravog života, čime se smanjuju

troškovi zdravstvene zaštite. Međutim, zdravstvene prednosti prevencije su takve da ljudi također žive dulje s kroničnim bolestima, a godine života dodaju se u najstarijih dobnih skupina, povećavajući potrebu za zdravstvenom skrbi. No, procjena je da se redukcija troškova može ostvariti, u najboljem slučaju od 1% ukupnog iznosa izdataka za glavne kronične bolesti. Istodobno, mnoge takve intervencije uključuju troškove koji nadilaze svako smanjenje izdataka za zdravstvo (Sassi, 2010).

Najaktualnija mjera je zdravstvena edukacija i promicanje znanja o prehrani i redukciji kalorijskog unosa. Ljudski organizam je kompleksan sustav na kojeg djeluje veliki broj vanjskih i unutarnjih faktora. Tako i na promjenu (smanjenje/povećanje) ljudske težine djeluju mnogobrojni faktori. Praktički ih je nemoguće sve obuhvatiti. Ljudski metabolizam je moguće promatrati kao sustav u kojem varijable ulaze i izlaze iz njega. Stoga i smanjenje težine je moguće prikazati sustavsko dinamičkim modelom. Dinamika sustava nudi pristup u kojem se model može koristiti za prikazivanje strukturirane stvarnosti, kako bi nam predstavio okvir za pregled korisnosti i dosljednosti (Williams i Harris, 2005).

Pristup sustavskoj dinamici temelji se na identifikaciji resursa, njihovog stanja i stopi po kojoj resursi mijenjaju svoje stanje. Resursi mogu biti materijalni, ljudski, gotovinski i sl. Stanje razine sustava može se definirati kao bilo koja akumulacija resursa koja je relevantna za svrhu modela (Pejić-Bach i Čerić, 2007). Brzina je varijabla koja pokazuje brzinu pretvaranja resursa iz stanja u stanje, tj. prosječnu brzinu promjene razine resursa u nekom vremenskom razdoblju (Zekić-Sušac, 2013).

1.2. Predmet istraživanja

Predmet istraživanja ovog rada je analiza vremenske dinamike potrebne za redukciju troškova koje generiraju pretile osobe u Hrvatskoj. Poznata istraživanja pokazala su o kakvom se iznosu radi (prosječno po osobi). Ukupno broj pretilih osoba u Hrvatskoj generira velike troškove što značajno opterećuje proračun za zdravstvo. Vremenska dinamika potrebna za rješenje individualnih problem će biti predstavljena pomoću modela sustavske dinamike u programskom paketu Powersim.

Model koji sustavno prikazuje smanjenja tjelesne težine je ono čime se bavi ovaj rad kako bi se mogle donijeti pravovremene odluke u svrhu smanjenja dodatnih troškova pretilih osoba

koje opterećuju zdravstveni sustav. Za analizu vremenske dinamike smanjenja težine, koristit će se dvodijelni model promjene težine stavljajući fokus na smanjeni kalorijski unos u odnosu na energetsku potrošnju uzimajući u obzir sve dodatne uvjete koje sustav mora zadovoljiti kako bi se smatrao realnim.

1.3. Ciljevi istraživanja

U Istraživačkom dijelu rada odgovorit će se na sljedeća znanstvena i istraživačka pitanja:

- Može li sustavsko dinamički model smanjenja težine dati okvirni pregled vremenske dinamike potrebne za djelovanje u području redukcije troškova koje generiraju pretile osobe?

1.4. Istraživačke hipoteze

H1: Sustavski pristup omogućava sintezu medicinskog i ekonomskog problema pretilosti u svrhu analize troškova zdravstvene zaštite pretilih osoba

H2: Primjena metodike sustavske dinamike omogućuje bolje upravljanje financijskim sredstvima zdravstvene zaštite pretilih osoba

Istraživačkim hipotezama se želi dokazati da je moguće pomoću sustavske dinamike upravljati troškovima zdravstvene zaštite pretilih osoba. Naime, primjena sistemskog pristupa omogućit će povezivanje različitih pogleda na sustav definirajući tako nadsustav koji obuhvaća analizu problema pretilosti kao i financijskog aspekta ovog problema. Daljnja razrada problema odnosi se na uključivanje promatranja kašnjenja efekata poduzetih mjera na financijski sustav zdravstva. U tu svrhu koristit će se metodologija sustavske dinamike.

1.5. Metode istraživanja

Prilikom izrade modela koristit će se sljedeće metode:

- **Metoda analize** je postupak znanstvenog istraživanja raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente.

- **Metoda sinteze** predstavlja postupak znanstvenog istraživanja i objašnjavanja stvarnosti spajanjem i sastavljanjem jednostavnih misaonih pojmova u složene, povezujući izdvojene elemente, pojave i procese u jedinstvenu cjelinu u kojoj su svi dijelovi povezani.

- **Metoda indukcije** je znanstvena metoda na temelju koje se analizom pojedinačnih činjenica dolazi do zaključka o općem sudu.

- **Metoda dedukcije** je postupak znanstvenog istraživanja raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente.

- **Metoda kompilacije** predstavlja metodu kojom se preuzimaju rezultati tuđih opažanja, stavova i spoznaja.

- **Metoda deskripcije** je metoda u kojoj se na jednostavan način opisuju činjenice, procesi i predmeti, bez znanstvenog tumačenje i objašnjavanja.

- **Metoda sustavske dinamike** predstavlja metodu koja se koristi kod kontinuirane simulacije sustava s povratnom spregom. Omogućuje istraživanje dinamike razvoja društvenih, tehničkih i bioloških sustava u vremenu, te analizu upravljanja tim sustavima (Zekić-Sušac, 2013).

1.6. Doprinos istraživanju

Ovim radom se želi ukazati na ekonomski i zdravstveni problem pretilih osoba koji je poprimio epidemijske razmjere s najmanje 2,8 milijuna ljudi koji umiru svake godine kao rezultat prekomjerne ili pretile težine. Ovaj problem postoji i u Hrvatskoj o kojem nema puno

saznanja u kakvoj se situaciji trenutno nalazi. Zadnja istraživanja u 2007. godini su ukazala na problem ali se nisu bavili rješenjima. Mnoga istraživanja su pokazala da pretile osobe imaju veće zdravstvene troškove nego osobe normalne tjelesne težine što utječe i na ukupni zdravstveni trošak čitave države. Iz toga proizlazi da teške bolesti na koje se ne može utjecati nemaju dovoljno sredstava za pokrivanje troškova kad je najviše potrebno. Problem pretilosti je moguće riješiti, ne gledajući samo ekonomski aspekt nego i ugrožavanje velikog broja života. Kako bi se mogao dati okvirni prikaz ovog problema izradit će se sustavsko dinamički model koji će prikazati vremensku dinamiku potrebnu za redukciju tjelesne težine i posljedično tome smanjenje troškova pretilih osoba,

1.7. Struktura diplomskog rada

Ovaj rad je podijeljen na ukupno pet cjelina.

U prvom, uvodnom dijelu rada će se postaviti problem i predmet istraživanja, ali i definirati ciljevi istraživanja, metode istraživanja, istraživačke hipoteze, doprinos istraživanju te naposljetku struktura diplomskog rada.

U drugom dijelu obradit će se sustav zdravstvenog osiguranja u Republici Hrvatskoj kako bi se utvrdila odgovornost države u pružanju zdravstvenih usluga. Također će se usporediti s pojedinim zemljama u Europi.

U trećem dijelu rada definirat će se teoretska podloga problema pretilosti kako bi se mogla razumjeti problematika kojom se radi bavi. Ukazat će se na problem pretilosti u svijetu i u Hrvatskoj.

U četvrtom dijelu će se pristupiti izradi „biološko-ekonomskog“ sustav-dinamičkog modela za potrebu upravljanja dodatnim troškovima koje generiraju pretile osobe u zdravstvenom sustavu. Pružit će se jasan uvid u sustavsku dinamiku i korištenje iste u izradi navedenog modela.

Peti dio je rezerviran za zaključna razmatranja rada. Također će na kraju biti prikazan popis korištene literature.

2. Zdravstveni sustav Republike Hrvatske

2.1. Organizacija zdravstvene zaštite u RH

Zdravstvena zaštita predstavlja ukupan društveni napor, organiziran ili ne, privatan ili javan, koji se bavi jamstvom, pružanjem, financiranjem i promicanjem zdravlja. Sastoji se od mjera, aktivnosti i postupaka za održavanje i poboljšavanje zdravlja, životnog i radnog okruženja, prava i obveza stečenih u zdravstvenom sustavu, kao i mjera aktivnosti i postupaka koji se poduzimaju u području zdravstvene zaštite za održavanje i poboljšavanje zdravlja ljudi, prevencije i kontrole bolesti, ozljeda i drugih poremećaja zdravlja; rano otkrivanje bolesti i zdravstvenog stanja, pravodobno i učinkovito liječenje i rehabilitaciju, primjenom stručnih medicinskih mjera, aktivnosti i postupaka (Donev et al., 2013).

Zdravstveni sustav se sastoji od međusobno povezanih dijelova koji imaju određene funkcije. Te funkcije uključuju nadzor, zdravstvenu službu, financiranje i upravljanje resursima. Stoga, zdravstveni sustav se može definirati kao „kombinacija resursa, organiziranja, financiranja i upravljanja koji se ogledaju u pružanju zdravstvenih usluga stanovništvu. Mnogi čimbenici izvan zdravstvenog sustava utječu na zdravlje ljudi, kao što su siromaštvo, obrazovanje, infrastruktura te šire društvene i političke okoline. Zdravstveni sustavi se može promatrati kao otvoreni sustavu zbog njihove podložnosti vanjskih utjecaja (Svjetska banka, 2007). Zdravstveni sustavi u svijetu i u Hrvatskoj imaju vitalnu i trajnu odgovornost za zdravlje ljudi tijekom životnog vijeka. Oni su ključni za zdrav razvoj pojedinaca, obitelji i društva u cjelini. Prema Svjetskoj zdravstvenoj organizaciji, svaki nacionalni zdravstveni sustav trebao bi biti usmjeren na postizanje tri opća cilja: dobro zdravlje, ispunjavanje očekivanja stanovništva i pravedna financijska alokacija (Donev et al., 2013).

Hrvatski zdravstveni sustav se temelji na načelima socijalnog osiguranja. U Republici Hrvatskoj zdravstvena zaštita se zasniva na načelima dostupnosti, pravičnosti, učinkovitosti, kvaliteti te na načelu osiguravanja sigurnosti građana pri korištenju zdravstvene zaštite. Zdravstveni sustav obuhvaća javno i privatno davanje i financiranje usluga. Ministarstvo zdravlja predstavlja tijelo koje je odgovorno za zdravstvenu politiku u zemlji, reguliranje standarda za zdravstvene usluge, programe javnog zdravstva, promicanje zdravlja, planiranje i predlaganje zakona. Za financiranje sustava zdravstva, centralno mjesto zauzima **Hrvatski zavod za zdravstveno osiguranje** i ono pokriva troškove zdravstvenih ustanova na razini od

oko 80% ukupnih troškova (Kovač, 2013). Hrvatski zavod za zdravstveno osiguranje (HZZO) pruža više vrsta zdravstvenog osiguranja. Obveznim zdravstvenim osiguranjem prema jednoj od osnova osiguranja utvrđenih Zakonom obvezne su se osigurati sve osobe s prebivalištem u Republici Hrvatskoj, te stranci s odobrenim stalnim boravkom u Republici Hrvatskoj (Narodne novine, 2008). Osim obveznog zdravstvenog osiguranja postoji i dobrovoljno zdravstveno osiguranje u obliku dopunskog, dodatnog i privatnog. Dopunskim zdravstvenim osiguranjem osigurava se pokriće dijela troškova do pune cijene zdravstvene zaštite iz obveznog zdravstvenog osiguranja. Dodatnim se osigurava viši standard zdravstvene zaštite u odnosu na propisan obvezni te veća prava u odnosu na obvezno zdravstveno osiguranje. Privatno zdravstveno osiguranje osigurava zdravstvenu zaštitu fizičkim osobama koje borave u RH, a koje se nisu obvezne osigurati sukladno Zakonom o obveznom zdravstvenom osiguranju i Zakonu o zdravstvenoj zaštiti stranaca u RH (Kovač, 2010).

U Republici Hrvatskoj zdravstvena djelatnost se obavlja na primarnoj, sekundarnoj i tercijarnoj razini te na razini zdravstvenih zavoda. Zdravstvena zaštita na primarnoj razini pruža se kroz djelatnosti (HZZO, 2018):

- opću/obiteljsku medicinu
- zdravstvenu zaštitu predškolske djece
- zdravstvene zaštitu žena
- patronažnu zdravstvenu zaštitu
- zdravstvenu njegu u kući bolesnika
- stomatološku zdravstvenu zaštitu (polivalentnu)
- higijensko-epidemiološku zdravstvenu zaštitu
- preventivno-odgojne mjere za zdravstvenu zaštitu školske djece i studenata
- laboratorijsku dijagnostiku
- ljekarništvo
- hitnu medicinsku pomoć

Zdravstvena djelatnost na sekundarnoj razini obuhvaća specijalističko-konzilijarnu zdravstvenu zaštitu i bolničku zdravstvenu zaštitu, a zdravstvena djelatnost na tercijarnoj razini obuhvaća obavljanje najsloženijih oblika zdravstvene zaštite iz specijalističko-konzilijarnih i bolničkih djelatnosti

2.2. Financiranje zdravstvene zaštite

Cilj financiranja sustava zdravstva je osiguravanje sredstava za zdravstvenu zaštitu kako bi osigurane osobe imale pristup individualnoj zdravstvenoj njezi. Zdravstveni sustav RH se temelji na kombinaciji Bismarckovog modela te Beveridgeovog modela (HZZO, 2018). Bismarckov modela je zasnovan na obaveznom, univerzalnom socijalnom osiguranju i karakterističan je za većinu zemalja kontinentalne Europe. Ovaj model funkcionira na načelima solidarnosti i uzajamnosti. Temelji se na doprinosima za zdravstveno osiguranje koji se plaćaju na osnovi rada, a zdravstvenim sustavom upravljaju interesne udruge i njihovo korporativno dogovaranje, iako pod kontrolom države. Stopu doprinosa utvrđuje vlada ili neko drugo nevladino tijelo. Ovakav model se primjenjuje u Hrvatskoj, Njemačkoj, Francuskoj, Belgiji, Austriji i Švicarskoj.

Dok se Beveridgeov model temelji na financiranju zdravstva iz poreza koji plaćaju svi građani. Tu pripadaju izravni porezi koje plaćaju pojedinci i tvrtke te neizravni porezi od prodaje roba i usluga. Država određuje koji iznos novca plaća svaki pojedinac te se na temelju ukupnog prikupljenog iznosa određuje dio koji pripada zdravstvu. Primjena ovog modela je karakteristična za skandinavske zemlje, Italiju, Grčku, Portugal, Španjolsku, Kanadu, Veliku Britaniju, Irsku, Island (Kovač, 2013).

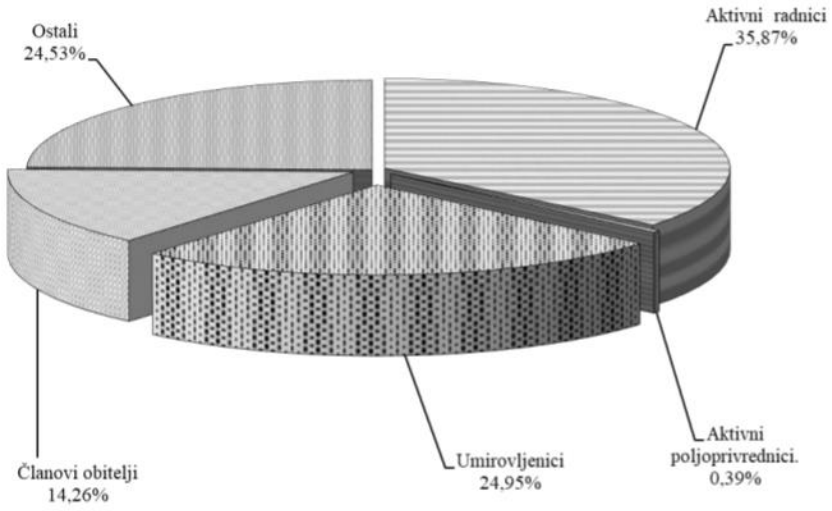
Doprinosi za obavezno zdravstveno osiguranje obvezni su za sve zaposlene osobe i poslodavce. HZZO kao dodatno pokriće nudi opciju dopunskog zdravstvenog osiguranja za fiksni iznos mjesečne naknade od 70 kuna. HZZO pokriva troškove zdravstvenih rizika u razini od 80% u okviru „košarice usluga“ obuhvaćene obveznim zdravstvenim osiguranjem, a koja podrazumijeva pravo na primarnu zaštitu, specijalističko-konzilijarnu zdravstvenu zaštitu, bolničku zdravstvenu zaštitu, uporabu lijekova koji su na listi HZZO, korištenje zdravstvene zaštite u inozemstvu, stomatološko-protetske usluge, nadomjeske, te ortopedska i druga pomagala. Ostatak troška usluga (20%) plaća osiguranik, a svota koju ne smije prijeći iznosi 2.000 kuna po bolničkom računu (HZZO, 2018)

2.3. Struktura osiguranika i troškova zdravstvene zaštite

Svi stanovnici države imaju pravo na zdravstvenu zaštitu, bilo da se radi o zaposlenim ili nezaposlenim osobama, djeci, studentima, umirovljenicima, poljoprivrednicima. Država je nužna osigurati visoku razinu usluge. Međutim, postoje države koje ne pružaju svojim građanima besplatnu zdravstvenu zaštitu. Hrvatska je među zemljama u kojoj svaki stanovnik ima pravo na besplatnu zdravstvenu zaštitu pokrivenu obveznim zdravstvenim osiguranjem koju pruža Hrvatski zavod za zdravstveno osiguranje.

U razdoblju siječanj - prosinac 2017. godine, u Hrvatskom zavodu za zdravstveno osiguranje prosječno je evidentirano 4.244.232 osobe. Prosječan broj aktivnih osiguranika je bio 1.522.335, od čega 711.610 ili 46,75% čine žene,a 53,26% ili 810.725 osoba čine muškarci.

Na slici 1. se može primijetiti da je aktivnih radnika činilo 35,87% ili 1.522.335, aktivnih poljoprivrednika 0,39% ili 19.044, umirovljenika 24,95% ili 1.062.534, članova obitelji 14,26% ili 700,109 i ostalih 24,53% ili 1.019.143 (HZZO, 2018).



Slika 1. Učešće pojedinih kategorija osiguranika u ukupnom broju osiguranika

Izvor: HZZO, www.hzzo.hr

U 2017. godini stopa doprinosa za obvezno zdravstveno osiguranje je iznosila 15% na bruto plaće, 0,50% za ozljede na radu i profesionalne bolesti, te doprinosi iz mirovina, 3% na mirovine iznad 5.664 kn, a plaća ih korisnik mirovine. Prihodi od doprinosa ostvareni su u iznosu od 19.135.183.895 kn, veći su od istih prihoda naplaćenih u prethodnoj godini za

666.503.191 kn ili za 3,61%, a prosječni mjesečni uplaćeni prihodi od doprinosa iznose 1.594.598.658 kn. Prihodi od proračuna u 2017. godini iznose 2.629.755.626 kn, ostvaraju se sukladno članku 72. i 82. Zakona o obveznom zdravstvenom osiguranju (HZZO, 2018).

Tablica 1. Rashodi – izdaci u obveznom zdravstvenom osiguranju

Izdaci za zdravstvenu zaštitu	**2016.**	**2017.**
Primarna zdravstvena zaštita	3.075.041.380	3.063.032.280
Hitna med. pomoć i sanit. prijevoz	757.632.343	783.571.253
Zdravstvena njega u kući	136.835.292	137.499.004
Hitna pomoć na držav. cestama	7.616.104	7.312.945
Cjepivo	109.916.688	96.417.688
Rano otkrivanje zloćudnih bolesti	34.175.115	29.190.516
Lijekovi na recepte	3.203.161.159	3.314.081.724
Ortopedski uređaji i pomagala	753.190.944	781.611.038
Bolnička zdravstvena zaštita	8.185.744.432	8.184.019.578
Posebno skupi lijekovi	933.513.160	1.151.376.848
Eksplantacije u bolnicama	5.379.000	5.152.350
Transplantacije u bolnicama	95.874.475	100.549.963
Intervencijska kardiologija	38.400.096	39.379.279
Intervencijska neurologija	14.610.798	18.811.210
Umjetne pužnice	2.922.864	-
Transfuzijska medicina	162.886.153	165.988.124
Medicinska oplodnja	25.329.149	26.469.990
Spec. - konzilijarna zdrav. zaštita	655.485.494	653.786.612
Zdravstvena zaštita u inozemstvu	301.886.675	255.513.893
Troškovi zdrav. zaštite - INO, privremeni boravak	418.826.419	430.967.261
Zavod za javno zdrav. i dr. progr	33.304.420	30.990.506
Z. Z. osoba čije je prebiv.nepoz.	772.487	647.715
Z. Z. hrvat. državlj. s prebival. u BiH	9.830.213	10.533.128
Inzulinske pumpe	1.499.607	1.498.938
Ukupno:	18.963.834.467	19.288.401.843
Zdrav. zaštita na radu-specifična zdravstvena zaštita	84.233.323	88.485.971
Zdrav. zaštita obv. zdrav. osig.	**19.048.067.790**	**19.376.887.814**

Izvor: HZZO, www.hzzo.hr

Tablica 2. Ukupna zdravstvena zaštita

	2016.	**2017.**
zdrav. zaš. obveznog zdrav. osiguranja	18.963.834.467	19.288.401.843
zdrav. zaštita dopunskog zdrav. osiguranja	1.212.836.553	1.211.501.783
zdrav. zaš. za ozljede na radu i prof. bolesti-specifična zdravstvena zaštita	84.233.323	88.485.971
Ukupna zdravstvena zaštita	**20.260.904.343**	**20.588.389.597**

Izvor: HZZO, www.hzzo.hr

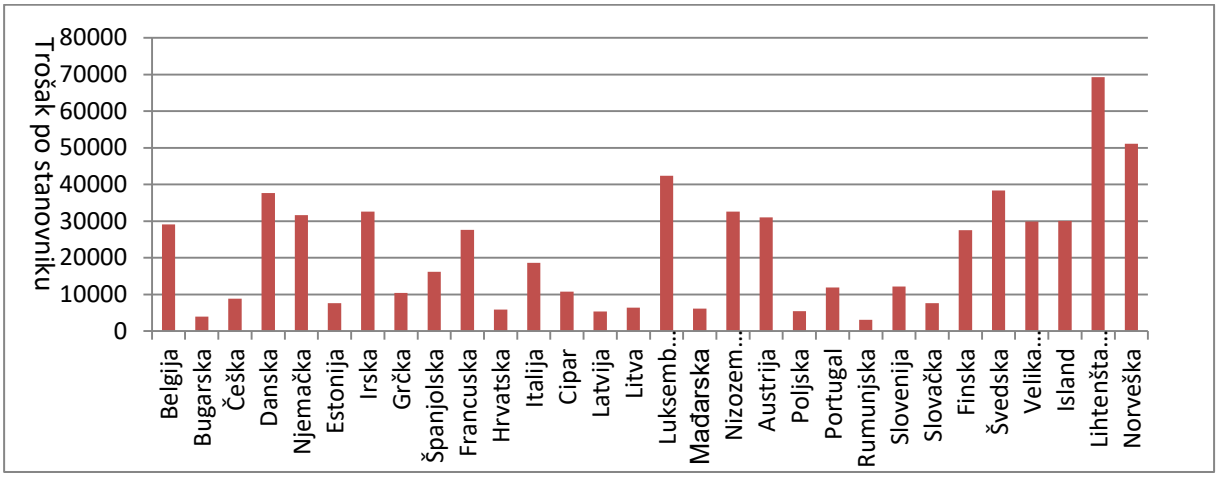
U tablici 1. se vidi da je najznačajnija stavka u zdravstvenoj zaštiti bolnička zdravstvena zaštita koja iznosi 8.184.019.578 kn što čini 42,24% ukupnih troškova zdravstvene zaštite. A slijede je primarna zdravstvena zaštita u iznosu od 3.075.041.380 kn i lijekovi na recepte u iznosu od 3.203.161.159 kn. Primarna zaštita obuhvaća ukupno 15 djelatnosti te se za svaku utvrđuje godišnja vrijednost standardnog tima prema propisanim standardima utvrđene za obavljanje zdravstvena djelatnosti (HZZO, 2018). Dok se u tablici 2. može vidjeti ukupan trošak zdravstvene zaštite koji je iznosio 20,58 mlrd. kuna, od kojih je zdravstvena zaštita obveznog zdravstvenog osiguranja u 2017. godini iznosila 19,3 mlrd. kuna (1,72% više u odnosu na 2016. godinu), zdravstvena zaštita dopunskog zdravstvenog osiguranja 1,21 mlrd. kuna (0,1% manja u odnosu na 2016. godinu), te zdravstvena zaštita za ozljede na radu u iznosu od 88 mil kuna (4,8% veća u odnosu na 2016. godinu).

2.4. Financiranje i troškovi zdravstvene zaštite u EU

Državna regulacija u državama članicama EU propisuje univerzalno zdravstveno osiguranje ili pokrivenost uslugama (Danska, Finska, Grčka, Italija, Portugal, Švedska, Velika Britanija) ili gotovo univerzalna pokrivenost (99 i 99,5% stanovništva u Austriji, Belgiji, Francuskoj, Luksemburgu, Španjolskoj i 92,2% za stanovništvo u Njemačkoj) za zdravstvenu zaštitu kroz obvezne programe. U Irskoj, univerzalna pokrivenost primarne zdravstvene zaštite odnosi se samo na skupine s niskim prihodima. U Nizozemskoj, obavezno zdravstveno osiguranje pokriva samo 60% stanovništva. Ostatak stanovništva obično je pokriven dobrovoljnim ili javnim osiguranjem (Belgija, Francuska, Njemačka, Luksemburg i Nizozemska. Zdravstvena zaštita u EU sustavima financira se općim oporezivanjem ili doprinosima za zdravstveno osiguranje (Jakubowski, 1998).

Uzimajući u obzir aspekt ekonomske održivosti, članice Europske unije imaju razloga za zabrinutost zbog zdravstvene potrošnje što generira oportunitetni trošak. Svaki euro potrošen na zdravstvenu zaštitu predstavlja jedan euro manje za potrošnju u drugim vrijednim ekonomskim područjima – edukacija, nacionalna obrana, stanovanje, slobodno vrijeme itd. Što se više troši na zdravstvenu skrb, to manje sredstava ostaje za druga područja. Postoji visoka tendecija interesa u održavanju stabilnog zdravstvenog sustava. Sve dok vrijednosti koju proizvodi zdravstvo premašuje oportunitetni trošak, rast zdravstvene potrošnje je ekonomski održiv (vrijednost koja je veća od troškova može se smatrati mjerom ekonomske

održivosti). Onda kad je oportunitetni trošak zdravstvene potrošnje prevelik, zdravstvena potrošnja postaje neodrživa. U stagnaciji ili smanjenju rasta gospodarstva, rast potrošnje u zdravstvu kao udio bruto domaćeg proizvoda , dovoljan je da se ugroze druga vrijedna područja gospodarske aktivnosti. U okolnostima gospodarskog rasta, zdravstvena potrošnja može rasti po stopi većoj od ekonomskog rasta (tj. da konzumira sve veći udio u BDP-u), bez da nužno uzrokuje smanjenje ostalih područja gospodarske aktivnosti. Zabrinutost glede održivosti sustava zdravstvenog sustava odnosi se na javne troškove zdravstva. To ne obuhvaća stavke kao što su potrošnje na privatnim tržištima zdravstvene zaštite. Struktura problema fiskalne održivosti je slična kao problem ekonomske održivosti, čak i ako su temeljni uzroci problema različiti. Stoga, zdravstvena potrošnja ima oportunitetni trošak (Thomson et al., 2009). Ako se gleda iz perspektive ulaganja u druga područja, može se reći da daljnje povećanje troškova zdravstva za posljedicu ima smanjenje sredstava koji se mogu primjerice uložiti u edukaciju i prevenciju pretilosti koja je povezana sa velikim brojem zdravstvenih problema.



Slika 2. Trošak po stanovniku u kunama (2015. godina)

Izvor: Izračun autora, www.eurostat.com

Na slici 2. je vidljivo kako je u 2015. godini najveće godišnje troškove zdravstvene zaštite po stanovniku u Europskoj uniji u imao Lihtenštajn (69.228 kuna), Norveška (51.098 kuna), a slijede ih Luksemburg (42.400 kuna) i Danska (37.677 kuna). Najmanje troškove su imali Rumunjska (3051 kuna), Bugarska (3.948 kuna) a slijede ih Latvija (5.358 kuna) i Poljska (5479 kuna). U Hrvatskoj godišnji troškovi zdravstvene zaštite po stanovniku iznose 5886 kuna.

Tablica 3. Udio zdravstvene potrošnje u BDP-u

	2013	2014	2015
Belgija	10,37	10,4	10,48
Bugarska	7,85	8,51	8,2
Češka	7,81	7,65	7,24
Danska	10,21	10,26	10,33
Njemačka	10,97	11,05	11,15
Estonija	6,02	6,21	6,51
Irska	10,42	9,91	7,76
Grčka	8,34	7,94	8,38
Španjolska	9,02	9,08	9,17
Francuska	10,93	11,06	11
Hrvatska	7,3	7,49	7,37
Italija	8,95	9,01	9
Cipar	6,91	6,79	6,77
Latvija	5,4	5,46	5,7
Litva	6,13	6,19	6,51
Luksemburg	6,55	6,27	6,05
Mađarska	7,29	7,14	7,24
Nizozemska	10,9	10,86	10,58
Austrija	10,19	10,29	10,32
Poljska	6,38	6,25	6,34
Portugal	9,09	9,02	8,97
Rumunjska	5,18	5,03	4,95
Slovenija	:	8,48	8,48
Slovačka	7,53	6,92	6,89
Finska	9,49	9,48	9,45
Švedska	11,1	11,14	11,01
Velika Britanija	9,85	9,8	9,88
Island	8,7	8,78	8,61
Lihtenštajn	5,96	5,85	6,07
Norveška	8,93	9,35	9,98

Izvor: Eurostat, www.eurostat.com

U tablici 3. su prikazani postoci troškova zdravstvene zaštite u ukupnom BDP-u zemalja Europske Unije. Najveći postotak u 2015. je imala Njemačka (11,15%), zatim Švedska (11,01%) i Nizozemska (10,58) što može upućivati da navedene zemlje najviše ulažu u zdravstvenu skrb u svojim zemljama. No, ove postoci mogu upućivati i na to da postoje najveći zdravstveni problemi u tim zemljama s obzirom na ukupnu potrošnju u BDP-u. U 2015. godini najmanji postotak zdravstvenog troška u ukupnom BDP-u ima Rumunjska (4,95%), a slijede je Latvija (5,7%) i Luksemburg (6,05%). Hrvatska se nalazi na nekoj srednjoj razini s iznosom od 7,37%.

Percentage

	Government schemes	Compulsory health insurance	Out-of-pocket	Voluntary health insurance
Germany	6,6	78,0	13,0	1,5
Denmark	84,2	0,0	13,8	2,0
Czech Republic	11,6	71,9	13,2	0,2
Sweden	83,4	0,0	15,5	0,6
Luxembourg	8,5	73,9	10,7	5,5
Netherlands	4,8	75,8	12,3	5,9
Slovak Republic	4,0	76,2	18,0	0,0
United Kingdom	79,5	0,1	14,8	3,6
Romania	14,9	64,4	19,9	0,2
EU28	**36,6**	**42,1**	**15,3**	**4,8**
France	4,1	74,5	7,0	13,7
Belgium	11,4	66,2	17,8	4,4
Austria	31,1	44,7	17,7	4,9
Italy	75,5	0,3	22,0	1,5
Estonia	9,9	65,6	22,7	0,2
Finland	62,2	13,2	19,1	2,5
Croatia	2,5	72,7	16,7	8,1
Poland	9,1	62,4	22,5	4,4
Slovenia	3,4	67,6	13,0	14,8
Spain	65,0	4,8	24,7	5,2
Ireland	69,0	0,3	15,4	12,7
Malta[1]	67,3	1,9	28,9	1,7
Lithuania	10,1	57,5	31,5	0,8
Hungary	9,4	57,6	28,4	2,6
Portugal	64,9	1,3	27,5	5,4
Latvia	59,9	0,0	38,9	0,9
Greece	28,4	31,3	35,4	3,6
Bulgaria	8,8	44,2	45,8	0,3
Cyprus	43,6	0,6	49,8	3,8
Norway	74,2	10,9	14,5	0,0
Iceland[1]	52,1	29,0	17,5	0,0
Turkey	21,3	56,3	17,7	0,0
Switzerland	18,6	46,5	26,7	7,0
FYR of Macedonia[1]	5,4	57,9	36,7	0,0
Serbia[1]	4,0	57,9	36,6	0,3
Montenegro[1]	6,1	51,0	42,8	0,0
Albania[1]	9,4	40,5	49,9	0,0

Slika 3. Zdravstvena potrošnja po tipu financiranja (2014)

Izvor: OECD Health Statistics 2016; Eurostat Database, Global Health Expenditure Database

Slika 3. prikazuje zdravstvenu potrošnju po tipu financiranja u Europi.Vidljivo je kako Njemačka prednjači u obveznom zdravstvenom osiguranju sa 78% u ukupnom trošku zdravstvene zaštite, dok Danska i Portugal uopće nemaju obvezno zdravstveno osiguranje jer kod njih prevladavaju državno financiranje i privatno. Danska je također zemlja s najvećim postotkom državnog financiranja (84,2%). Najviše iz vlastitog džepa plaćaju građani Cipra, Bugarske, Litve, Latvije, Grčke. Kod dobrovoljnog zdravstvenog osiguranja, Francuska (13,7%), Irska(12,7%) i Slovenija(14,8) imaju najveće postotke učešća u ukupnom financiranju. U Hrvatskoj zdravstveni sustav se najviše financira pomoću obveznog zdravstvenog osiguranja (72,2%), zatim plaćanje iz vlastitog džepa (16,7%), a dobrovoljno zdravstveno osiguranja iznosi 8,1%, dok je najmanji udio državnog financiranja u iznosu od 2,5% što čini najmanji postotak u čitavoj Europi (čak gledajući u odnosu na Srbiju sa 5,4%, Crnu Goru sa 6,1% i Albanija sa 9,4%).

3. Pretilost kao globalni problem

3.1. Pretilost i zdravstveni problemi

Pretilost se definira kao pretjerano visoka količina tjelesne masti ili masnog tkiva u odnosu na čistu masu (Merrill i Richardson, 2009). Složene je multifaktorske etiologije i nastaje zbog utjecaja genetskih i metaboličkih čimbenika okoliša, socijalne i kulturološke sredine te loših životnih navika. Nesrazmjer između energetskog unosa i energetske potrošnje se smatra glavnim uzrokom pretilosti. Nastanku pretilosti pogoduju različita stanja, navike ili uporaba lijekova (Viđak et al., 2017). Smatra se da povećani unos visokokalorične hrane koje obiluju mastima i rafiniranim šećerima uz smanjenu razinu tjelesne aktivnosti stvara suvišak energije koji se u obliku masti pohranjuje u tijelu. Također se jednim od uzroka pretilosti smatra otpornost na leptin. Leptin predstavlja hormon kojeg u najvećoj mjeri luči masno tkivo. Na leptin se može gledati kao signalnu molekulu koja veže svoje receptore u hipotalamusu[2] te tako održava homeostazu organizma. Utjecajem različitih mehanizama dolazi do smanjenje pohrane i pojačanog iskorištavanja masti. Kad je razina energetskih zaliha smanjenja, doći će do snižavanja razine leptina u krvi. Kod pretilih osoba, razvila se otpornost na leptin jer su kod njih vrijednosti leptina iznad ravnotežne razine (Medanić i Pucarin-Cvetković, 2012).

Pojam BMI označava indeks tjelesne mase koje se koristi kao mjerilo u određivanju debljine prema medicinskim kriterijima. Smatra se najčešće primijenjenom kliničkom mjerom za karakterizaciju pretilosti kod pojedinaca (Suchanek et al., 2012). Indeks tjelesne mase se računa stavljanjem u odnos težine i kvadrirane visine (Madden, 2006). U tablici 4. su prikazane kategorije indeksa tjelesne mase koje variraju od 18,5 do 40 i više. Pretilim osobama se smatraju svi koji imaju indeks tjelesne mase iznad 30.

[2] Hipotalamus je dio međumozga; mala skupina živčanih stanica na dnu velikog mozga. Ima trostruku ulogu u regulacijama što ih ima živčani sustav: kao glavni ganglij autonomnog živčanog sustava regulira reakcije utrobnih organa (srca, pluća, probave, krvnih žila, mokrenja); preko epifize regulira ciklus budnosti i spavanja; svojim hormonima djeluje na prednju režanj hipofize i tako utječe na sustav žlijezdi s unutarnjim lučenjem. Leksikografski zavod Miroslav Krleža. URL: http://www.enciklopedija.hr/natuknica.aspx?id=25691

Tablica 4. Kategorije indeksa tjelesne mase

	BMI (kg/m^2)
Neuhranjenost	Ispod 18,5
Normalna tjelesne kilaža	18,5 – 24,99
Prekomjerna tjelesne kilaža	25 - 30
Pretilost	30 i više
Sub-klasifikacija:	
Umjerena pretilost	30 – 34,99
Ozbiljna pretilost	35 – 39,9
Vrlo ozbiljna pretilost	40 i više

Izvor: Obesity and socio-economic groups in Europe, http://ec.europa.eu/health/ph_determinants/life_style/nutrition/documents/ev20081028_rep_en.pdf

Na psihološkoj razini, deklariranje pretilosti kao bolesti može utjecati na moralnu odgovornost pretilih osoba, ona im također može dati oznaku invaliditeta što utječe na diskriminaciju u društvu. Stoga se pretilost tretira kao faktor rizika a ne bolest (Muller i Geisler, 2017). Pretilost je povezana s listom zdravstvenih problema koji među kojima su najznačajniji (World Health Organization, 2007):

- kardiovaskularne bolesti
- razne vrste raka: endometrija, cerviksa, jajnika, prostate, dojke, debelog crijeva, rektuma, bubrega, jetre i žuči, mjehura,
- dijabetes tipa 2 i otpornost na inzulin,
- bolest bubrega na krajnjem stadiju,
- bolesti jetre,
- osteoartritisa,
- plućna embolija,
- tromboza dubokih vena,
- sindrom policističnih jajnika,
- hiperurikemija i giht,
- žučni kamenci,
- reproduktivni poremećaji,
- bol u leđima,
- astma,
- apneja,
- psihološki i socijalni problemi,

- komplikacije u trudnoći,
- komplikacije pri operaciji itd.

Procjenjuje se da je životni vijek pretile osobe 8-10 godina kraći od osoba normalne tjelesne težine (Sassi, 2010). Prekomjerna težina i pretilost odgovorni su za oko 9-12% smrti u starijim državama članicama Europske Unije te 16-20% u 12 država članica koje su se pridružile Europskoj Uniji 2004. i 2007. godine (WHO, 2014)

Prekomjerna tjelesna težina i pretilost često proizlaze iz različitih čimbenika: fizička neaktivnost, nezdrava dijeta, kao i uporaba alkohola, neki su od poznatih izvora. Ali pretilost je složenija od jednostavnog podrijetla nezdravog načina života. Postoji genetska komponenta bolesti te su medicinska istraživanja posljednjih godina napravila značajan napredak u razumijevanju njegove prirode. Tjelesna aktivnost, prehrana i alkohol su glavni čimbenici rizika koji uzrokuju nezarazne bolesti, osobito rak, dijabetes, kardiovaskularne bolesti i plućne bolesti te se procjenjuje da su nezarazne bolesti glavni uzrok gotovo 86% smrti u Europi (Erixon, 2016). Sveobuhvatno upravljanje pretilošću se može postići samo uz pomoć multidisciplinarnog tima. Liječnici imaju odgovornost prepoznati pretilost kao bolest i pomoći pretilim pacijentima odgovarajućom prevencijom i liječenjem. Liječenje treba temeljiti na dobroj kliničkoj skrbi i intervencijama na temelju dokaza (Yumuk et al., 2015) .

3.2. Trend razvoja pretilosti u svijetu

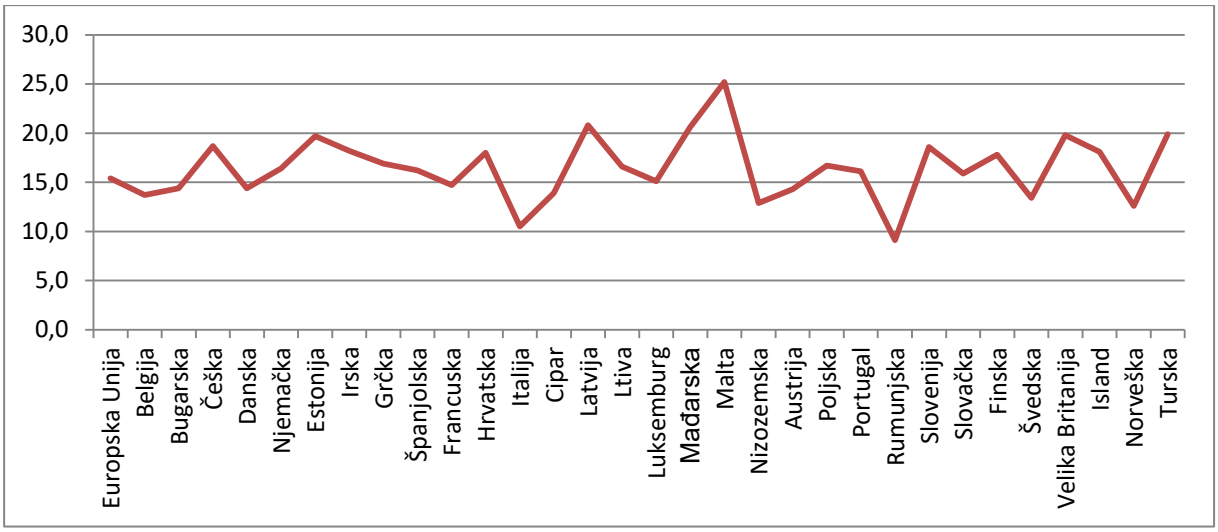
Prekomjerna tjelesna težina predstavlja jedan od najozbiljnijih javnozdravstvenih izazova 21. stoljeća za Europski kontinent (World Health organization, 2007). Može se reći da je dostigla epidemiološke proporcije i u čitavom svijetu. Procjenjuje se da 1 milijarda ljudi ima prekomjernu tjelesnu težinu, a najmanje 300 milijuna je klinički pretilo, što se nameće kao globalni teret u području kroničnih bolesti i invalidnosti. Pretilost je kompleksno stanje s ozbiljnim socijalnim i psihološkim dimenzijama koja pogađa sve socio-ekonomske grupe. Povećana konzumacija hrane s visokom razinom šećera i zasićenih masti, u kombinaciji sa smanjenom tjelesnom aktivnošću dovele su do porasta stope pretilosti, u iznosu do tri puta više u odnosu na 1980. godinu u području Sjeverne Amerike, Velike Britanije, Istočne Europe, Bliskog Istoka, Pacifičkih otoka, Australije i Kine (World Health Organization, 2003). Istraživanja su pokazala da se općenito, stopa pretilosti povećava među odraslim i djecom u gotovo svim populacijskim skupinama, ali raste najbrže za one s nižim primanjima,

nižim obrazovanjem i manjinskim etničkim skupinama. Postoji povećani rizik od prekomjerne tjelesne kilaže među ženama i djecom nižeg socioekonomskog statusa nego kod muškaraca (Robertson et al., 2007). Udio pretilosti i prekomjerne težine kod odraslih osoba povećava se u starijoj dobi u svim Europskim zemljama. Što se tiče muškaraca, postoji opći porast pretilih do 65 godina starosti. Nakon toga, rasprostranjenost se nešto smanjuje (Erixon, 2016).

Rastuća epidemija odražava duboke promjene u društvu i obrascima ponašanja zajednice. Dok su geni važni u određivanju osjetljivosti osobe dobivanja na težini, energetski balans je određen unosom kalorija i tjelesnom aktivnošću koje se mogu regulirati. Takve društvene promjene i tranzicijska prehrana u svijetu pokreću epidemiju pretilosti. Ekonomski rast, modernizacija, urbanizacija i globalizacije tržišta hrane su samo neke od sila za koje se misli da su pokretači „epidemije". S povećanjem stanovništva i dohotka, do izražaja dolaze dijete s visokim udjelom ugljikohidrata, s većim udjelom masti, zasićenih masti i šećera (World Health Organization, 2003) koje imaju negativan učinak na zdravlje i mršavljenje.

U Danskoj, Francuskoj, Italiji, Nizozemskoj, Norveškoj, Švicarskoj, Švedskoj i Velikoj Britaniji između 60% i 100% gomilanja težine pripisuje se kalorijskom suficitu više od nedostatka fizičke aktivnosti. Štoviše, u Velikoj Britaniji je zabilježeno povećanje nacionalne opskrbe kalorijama u iznosu od samo 62 kalorije po stanovniku dnevno od 1970. do 1984. u usporedbi s dodatnih 190 kalorija po stanovniku dnevno između 1985. i 2002. Ovaj skok prema povećanju unosa energije posljedica je inovacija u proizvodnji i distribuciji hrane, što dovodi do povećane ponude jeftinih, ukusnih i energetsko bogatih namirnica koje su mnogo pristupačnije i praktičnije. Zdrava hrana obično je manje prikladna, manje dostupna i skuplja (WHO, 2014). Ovakav trend povećanja kalorijskog unosa po stanovniku izazvao je niz negativnih koraka ka širenju pretilosti među odraslima ali i djecom.

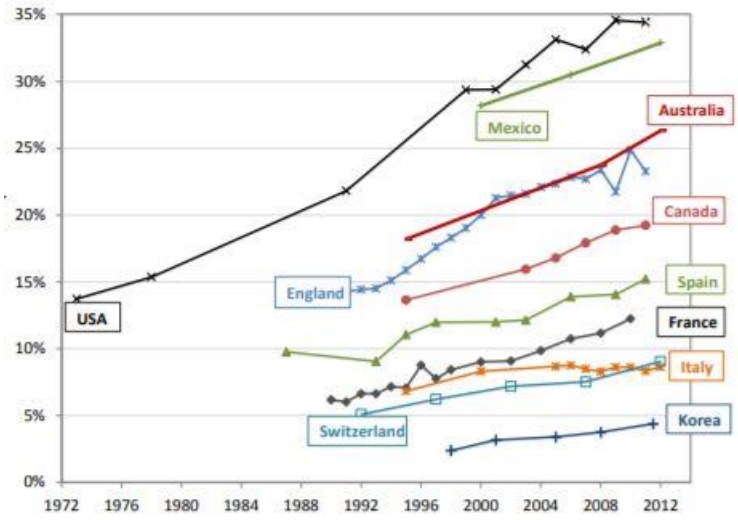
Jedan od velikih i važnih problema je i porast pretilosti djece u Europi. Dostupni podaci o raširenosti pokazuju da pedijatrijska pretilost raste, ali obrasci variraju s vremenom, dobi, spolu i zemljopisnoj regiji. Najveće stope pretilosti opažene su u zemljama Istočne i Južne Europe. Čak i unutar zemalja mogu postojati varijabilnosti u stopama pretilosti. Promjena demografskih i društvenih okolnosti vezana je za pretilost u djetinjstvu (Livingstone, 2001).



Slika 4. Indeks tjelesne mase u Europi u 2014. godini

Izvor: Eurostat, http://ec.europa.eu/eurostat/web/health/health-status-determinants/data/database

Može se reći da se sve zemlje Europe suočavaju s povećanim udjelom pretile populacije u ukupnoj populaciji što je vidljivo na slici 4. Uočljivo je kako Malta ima najveći postotak pretilih osoba u Europi i to u iznosu od 25,2%. Iza nje dolaze Latvija (20,8%) i Mađarska (20,6%). Najmanju razinu pretilih osoba ima Rumunjska 9,1% i Italija 10,5%. Hrvatska ima 18% pretilih osoba (indeks tjelesne mase veći od 30) te se nalazi u samom vrhu broja pretilih osoba u Europi što jasno pokazuje da postoji veliki problem koji generira ne samo zdravstvene probleme takvih osoba već i velike zdravstvene troškove.



Slika 5. Trend kretanja stope pretilosti u svijetu

Izvor: Organizacija za ekonomsku suradnju i razvoj , http://www.oecd.org/health/Obesity-Update-2014.pdf

Na slici 5. su prikazane stope pretilosti u svijetu. Kao što trend upućuje, stopa pretilosti se konstantno povećava u svim zemljama svijeta. Najznačajnije povećanje je vidljivo u Sjedinjenim Američkim Državama (USA), 1972. godine je iznosila približno 13,5%, dok je do 2012. godine narasla do vrtoglavih 34%. U SAD-u, više od dvije trećine odraslih je prekomjerne tjelesne kilaže ili pretile (68,5%). Također je vidljivo i povećanje pretilosti u djece. Ta stopa se utrostručila u odnosu na 1980. godinu (Trust for America's Health, 2014). Što se tiče Europskih zemalja, također su primjetna povećanja. Engleska je između 1988. i 1992. imala oko 14% pretilih, dok je 2012. godine procijenjeno kako ima približno 23%, što je povećanje od 9% u 20-ak godina.

3.2. Ekonomske posljedice pretilosti

Prekomjerna tjelesne težina i pretilost stvaraju i ekonomske posljedice. To uključuje izravne troškove zdravstvenih usluga, neizravni troškovi povezani s izgubljenom ekonomskom produktivnosti i pojedinačni troškovi (World Health Organization, 2007). Direktan trošak zdravstvene skrbi po stanovniku je manji kod osoba normalne tjelesne težine nego osoba prekomjerne/pretile tjelesne težine. Trošak za osobe prekomjerne tjelesne težine je 9,9% , a za osobe pretile tjelesne težine 42,7% veći u odnosu na osobe normalne tjelesne težine (Cuschieri i Mamo, 2016). U Europi se godišnje troši između 1,9% i 4,7% ukupnih zdravstvenih troškova na osobe prekomjerne i pretile tjelesne kilaže. Globalni ekonomski utjecaj pretilost je procijenjen na 2,0 trilijuna dolara, ili 2,8% globalnog BDP-a, što odražava činjenicu da se pretilost nameće kao teret razvijenim ekonomijama i ekonomijama u razvoju (Tremmel et al., 2017).

U Malti je procijenjeno kako se na pretilost u 2009. godini potrošilo 20 milijuna eura što je činilo 5,7% ukupnih zdravstvenih troškova čitave države. Uz sadašnji trend kretanja, godišnji zdravstveni trošak pretilosti do 2020 će dostići 27 milijuna eura. U 2012. godini je procijenjeno kako trošak pretilosti (direktni i indirektni) iznosi oko 81 mlrd. eura godišnje, što je u rangu procjene troškova pretilosti WHO-a od 2% - 8% ukupne potrošnje u 53 Europske zemlje (Cuschieri i Mamo, 2016). U 2007. godini, procijenjeno je da su u Hrvatskoj direktni (prevencija, dijagnoza, tretmani i usluge za zdravstvenu skrb pretilih osoba, hospitalizacija, liječničke usluge, lijekovi) i indirektni troškovi (bolesti i smrtnost) pretilih osoba (N=793

955) iznosili 34.934.020 € ili 256.275.970 kn[3] (Čubrilo-Turek, 2007), što je prosječno 322,78 kn po pretiloj osobi. Ukupni trošak zdravstvene zaštite 2007. godine u Hrvatskoj je iznosio 15.332.116.313 kn (HZZO, 2008) što je činilo 1,671% troška pretilosti u ukupnom trošku zdravstvene zaštite. U Njemačkoj, u 2008. godini osobe prekomjerne tjelesne kilaže su imali ukupne zdravstvene troškove u iznosu od 16,8 mlrd eura, od čega je 8,6 mlrd eura bilo vezano uz direktne troškove, što je činilo 3,27% ukupnog troška zdravstvene zaštite u Njemačkoj. Oko 73% (12,235 mlrd eura) je povezano s troškovima pretilosti (Lehnert et al., 2015).

U Italiji se procjenjuje kako osobe prekomjerne tjelesne kilaže (BMI 25-29,9) generiraju medicinske troškove u iznosu od 480 eura, pretile osobe (BMI 30 – 39,9) u iznosu od 785 eura a pretjerano pretile osobe (BMI 40+) 1550 eura (Lobstein, 2010) što zaista pokazuje da pretile osobe imaju veće godišnje medicinske troškove od osoba normalne tjelesne kilaže. U Njemačkoj su različite kategorije pretilosti imale različite troškove zdravstvene zaštite. Pretilost razine I generira 18% veće troškove, pretilost razine II 46% veće troškove i pretilost razine III 104% veće troškove od osoba normalne tjelesne kilaže (Yateset et al., 2016).

Pretilost je veliki fiskalni izazov za države jer je rast pretilosti u Europi dosegla takve razmjere da će uslijediti neizbježno povećanje troškove zdravstvene zaštite u budućnosti. Osim toga, kada je veliki udio radno sposobnog stanovništva pretilo, tu su i ekonomske posljedice zbog gubitka produktivnosti. Vidljiv je češći apsentizam pretilih osoba na poslu zbog potrebe za većom medicinskom skrbi, a njihov radni vijek završava u ranijoj dobi od drugih (Erixon, 2016).

Ne postoji sveobuhvatna strategija za smanjenje opterećenja pretilosti i ubrzano rastuće zdravstvene troškove. U studijama The Economista je nedavno istaknuto kako su kreatori politika usmjereni na sprječavanje zdravih ljudi da postanu pretili. Takvi programi su usredotočeni na životni stil koji ima važnu ulogu u sprječavanju pretilosti kod osoba s normalnom tjelesnom težinom. Međutim, politika koja se usredotočuje samo na prevenciju će zanemariti one koji su već pretjerano pretili i troškove povezane s postojećom pretilosti. Ljudi koji su već razvili pretilost ili su ozbiljne pretilosti je potrebna koordinirana intervencija s problemom (Erixon, 2016).

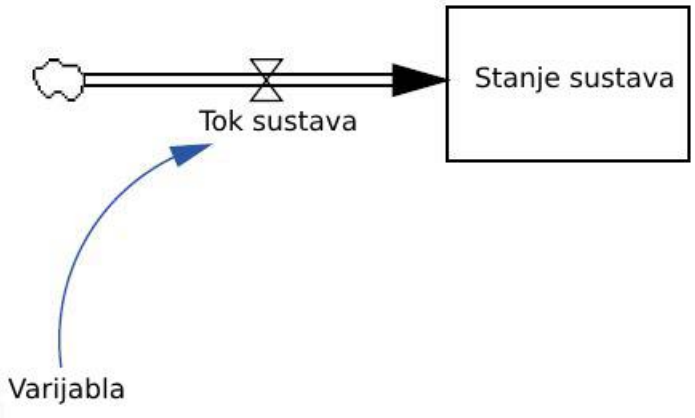
[3] 2007. godine (godišnji) srednji devizni tečaj Hrvatske narodne banke iznosio je 1€ = 7,336 kn (dostupno na: https://www.hnb.hr/documents/20182/33ebeea1-3d13-4a42-b0fb-87223d026703)

4. Biološko-ekonomski sustavsko dinamički model za upravljanje troškovima zdravstvene zaštite pretilih osoba

4.1. Sustavska dinamika

Metode i tehnike sustavske dinamike se koriste za razumijevanje i analizu ponašanja složenih sustava. Sustavska dinamika predstavlja korištenje računalne simulacije za analizu dinamičkih ponašanja struktura sustava u fizici, kemiji, tehničkim znanostima, ekologiji, poslovanju i ekonomiji te javnoj politici (Yamaguchi, 2012). Druga definicija kaže da je dinamika sustava metoda za opisivanje, modeliranje, simulaciju i analizu dinamički složenih pitanja i/ili sustava u smislu procesa, informacija, organizacijskih granica i strategija (Pruyt, 2013). Riječ „dinamika“ podrazumijeva kontinuiranu promjenu i to je ono što dinamički sustavi čine – oni se kontinuirano mijenjaju tijekom vremena. Njihov položaj, ili stanje, nije isto danas kao što je bilo jučer a i kao što će biti sutra. Korištenje sustavsko dinamičkih simulacija omogućuje nam da vidimo ne samo događaje već i obrasce ponašanja kroz vrijeme. Ponašanje sustava često proizlazi iz strukture samog sustava, i ponašanje se obično mijenja tijekom vremena. Ponekad simulacija gleda unazad, na povijesne rezultate. U drugom slučaju gledan unaprijed u budućnost kako bi predvidjela moguće buduće rezultate (Powersim Software AS, 2003).

Modelima sustavske dinamike, entiteti i događaji agregiraju se u odjeljke (eng. levels) koji su zapravo varijable stanja sustava i tokovi (eng. flows). U odjeljcima dolazi do akumulacije materijala dok su tokovi materijala i informacija između odjeljaka određeni brzinama prijelaze na koje, osim odjeljaka, utječu i pomoćne varijable (Božikov, 2002). Svi sustavi, u bilo kojem području su određeni navedenim simbolima - tok sustava i stanje sustava. Ovakvo saznanje pomaže u jednostavnijem razumijevanju svijeta u kojem živimo (Forrester, 2009). Sustavsko dinamički jezik se sastoji od četiri bloka: stanje sustava, tok sustava, varijabla i informacijska strelica što je i prikazano na slici 6. (Yamaguchi, 2012).



Slika 6. Sustavsko dinamički simboli

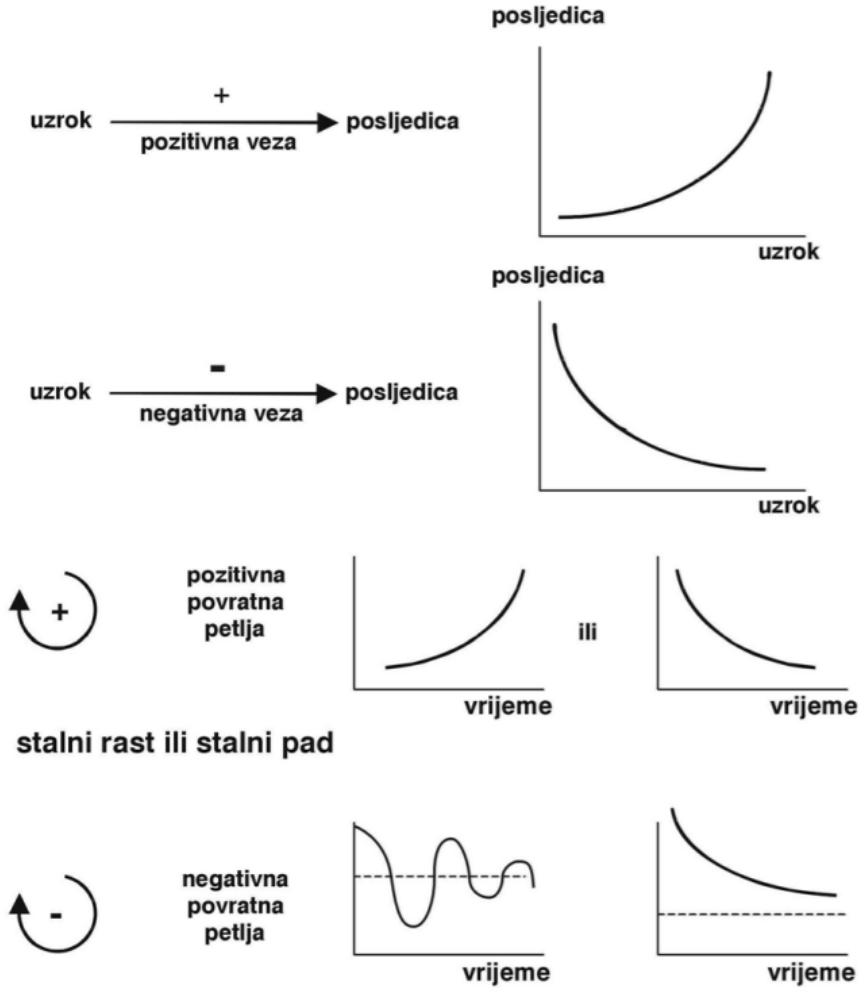
Izvor: Yamagouchi, K. (2012): Macroeconomic Dynamics – Accounting System Dynamics Approach

Sistemska dinamika se koristi dvama tipovima konceptualnih modela: dijagramima uzročnih petlji i dijagramima toka. Dijagrami uzročnih petlji prikazuju uzročno-posljedične veze među elementima sustava (Božikov, 2002). Povratna veza je zatvoreni krug uzroka i posljedica, koji utječu na to da neki početni uzrok ima indirektan efekt na samoga sebe. Razlikuje se pozitivna i negativna povratna veza što je prikazano na slici 7.

Pozitivna povratna veza znači da neki uzrok dovodi preko lanca posljedica do promjene uvijek u istom smjeru te tako utječe na sve veći daljnji stalni porast ili stalno smanjenje tog uzroka (Čerić, 1993). Strelicom se označuje smjer veze, a znak + ili – označava tu vezu kvalitativno kao pozitivnu ili negativnu (Božikov, 2002).

Negativna povratna veza znači da će neki uzrok preko lanca posljedica dovesti do promjene smjera vlastitog djelovanja. Ako uzrok poraste iznad nekog ravnotežnog stanja, povratna veza će se smanjiti taj uzrok. No, kada uzrok postanje manji od ravnotežnog stanja, tada povratna veza uzrokuje povećanje toga uzroka (Čerić, 1993). Tip povratne petlje određen je tipom uzročno-posljedičnih veza. Ako su sve uzročno-posljedične unutar jedne povratne petlje pozitivne, onda će i čitava petlja biti pozitivna. Ako u petlji ima negativnih veza, tip petlje ovisi o tome je li ukupni broj negativnih veza paran ili neparan. Ako je paran, povratna petlja će biti pozitivna, a ako je neparan povratna petlja će biti negativna. Dijagrami toka pri predstavljanju algoritma uz pomoć dijagrama koriste grafičke simbole (blokove) (Božikov, 2002). Bitna odrednica za sustavsku dinamiku je vrijeme, nepovratno protjecanje vremena. Vrijeme je jedno dimenzionalni realni broj, s početkom koji teče prema pozitivnom koordinatnom smjeru. Vrijeme se može razmotriti pomoću dva različita koncepta. Prvi

koncept definira vrijeme kao trenutak u vremenu ili točku u vremenu, dok ga drugi koncept definira kao razdoblje ili vremenski interval. Jedinice tog razdoblja mogu biti sekunde, minute, sati, tjedni, mjeseci, godine, desetljeća, stoljeća, mileniji (Yamaguchi, 2012).

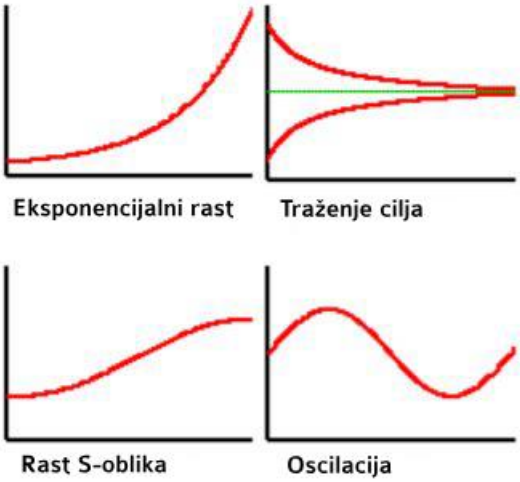


Slika 7. Pozitivna i negativna povratna petlja

Izvor: https://bib.irb.hr/datoteka/347082.modeliranje_i_simulacija_-_v2a2.pdf

Povratne veze mogu proizvesti različita ponašanja u stvarnim sustavima i simulacijama stvarnih sustava. Razlikuju se četiri karakteristična obrasca ponašanja koji su prikazani na slici 8. (Powersim Software AS, 2003):

- Eksponencijalni rast
- Traženje cilja
- Rast S-oblika
- Oscilacija



Slika 8. Obrasci ponašanja

Izvor: Powersim Software AS (dostupno na:http://homepage.cem.itesm.mx/alesando/index_archivos/DinamicaDeSistemas/Powersim_studio2003_users_manual.pdf)

Kod eksponencijalnog rasta, u početku je vidljiva mala promjena stanja sustava koja se s vremenom povećava. Traženje cilja karakterizira velika promjena stanja sustava u početku koja se s vremenom približava ciljnoj točki. Kod rasta S-oblika se može primijetiti da je u početku karakterizira rast koji se s vremenom približava točki u vremenu kojoj teži. Dok se kod oscilacije u početku značajno povećava pa se zatim značajno smanjuje pa opet raste. Kao što i sama riječ kaže, oscilacija označava dinamiku koja se ne može predvidjeti u kojem smjeru se kreće.

Kod izrade simulacijskih modela bitno je poštovati određena pravila (Božikov, 2002):

- Granica sustava s okolinom mora biti odabrana tako da sustav, odnosno njegov model, obuhvaća samo fenomene od interesa. Okolina sustava modelira se tako da se ne uključuju detalji i uzročne veze među njima, nego se daje samo njihov sažeti prikaz.
- Bitno je paziti na složenost i detaljnost modela. Model treba sadržavati samo relevantne elemente sustava. Ako je model suviše složen i detaljan, teško ih je razumjeti i vrjednovati.
- Ako se model želi pojednostavniti, bitno je paziti da se ne izbace varijable nužne za adekvatan opis sustava.

- Kako bi se model mogao lakše provjeriti i izgraditi, potrebno ga je rastaviti na više dobro definiranih i jednostavnih modula s točno određenom funkcijom.
- Kod razvoja modela se preporučuje korištenje provjerenih metoda za razvoj algoritma i programa koji će omogućiti bolje razumijevanje modela i pojedinih modula unutar modela, u svim fazama razvoja.
- Krucijalno je provjeriti logičku i kvantitativnu ispravnost modela i njegovih modula.

Svrha korištenja pristupa sustavske dinamike je mogućnost uvida u održivim i neodrživim uvjetima rada u prirodnim i društvenim sustavima. Upravo sustavska dinamika može prikazati način na koji se uvjeti održivosti mijenjaju kao odgovor na različite odluke. Tako se pruža mogućnost različitih analiza scenarija (Turina, 2009). Bitno je paziti na granice sustava i modela. Svi važni elementi sustava koji utječu na ostale dijelove sustava i također su pod značajnim utjecajem elemenata sustava trebaju biti modelirani kao endogene varijable, svi elementi koji mogu ozbiljno utjecati na sustav. Ali varijable koje nisu dovoljno pod utjecajem sustava nazivaju se egzogene varijable (Pruyt, 2013).

Simulacijski modeli se primjenjuju radi tri cilja (Božikov):

1. Istraživanje
2. Projektiranje
3. Edukacija

Kod istraživanja se provjerava hipoteza o strukturi i ponašanju sustava. Kad nismo dovoljno upoznati sa sustavom, bitno je proučiti kako taj sustav funkcionira u realnim okvirima. Model koji se napravi na temelju tog sustava služi za daljnju verifikaciju i validaciju. Projektiranje se vrši za sustava s kojima nemamo iskustva, primarno za buduće projekte. Kod simulacijskog modeliranje je potrebno predvidjeti ponašanje realnog sustava. Tada se ponašanje takvog sustava simulira s pomoću računala kako bi se mogao analizirati i ispitati njegov utjecaj u različitim okolnostima. U većini slučajeva se to radi kako bi se realni sustav reorganizirao pa provedeni simulacijski rezultati čine temelj za donošenje budućih odluka. Edukacija naglašava upoznavanje ponašanja sustava stjecanjem posrednog iskustva. Fokus na model kao edukacijskih materijal omogućuje da „učitelj“ sam kreira svoju vlastitu strategiju rješavanja problema i ispita te tako stekne „posredno“ iskustvo o promatranom sustavu. U sve tri

alternative se polazi od promatranja i proučavanja realnog sustava kako bi se stvorila apstraktna slika sustava koji se modelira.

Sustavsko razmišljanje je moćan alat jer nam pomaže da vidimo vlastite mentalne modele i kako ti modeli oslikavaju percepciju našeg svijeta. U mnogima slučajevima, teško je promijeniti objektivno gledište na mentalni model. Uvijek postoje neka uvjerenja ili stajališta koja nismo spremni promijeniti, bez obzira na to što dokazi upućuju na drugo. To uzrokuje određenu otpornost na nove koncepte. Problemi se mogu pojaviti, međutim kada se čvrsto mentalni model nalazi na putu rješenja problema. U takvim slučajevima, pridržavanje mentalnim modelima može biti ugroziti djelovanje čitave organizacije (Powersim Software AS, 2003).

4.1.1. Metodologija sustavske dinamike

Sustavska dinamika u svom metodološkom pristupu se zasniva na nekoliko koraka (Božikov, 2002):

1. Definicija cilja simulacijske studije
2. Identifikacija sustava
3. Prikupljanje podataka o sustavu i njihova analiza
4. Izgradnja simulacijskog modela
5. Izgradnja simulacijskog programa
6. Verificiranje simulacijskog programa
7. Vrjednovanje simulacijskog modela
8. Planiranje simulacijskih eksperimenata i njihovo izvođenje
9. Analiza rezultata eksperimenata
10. Zaključci i preporuke

Metodologija sustavske dinamike pruža mogućnost učenja o kompleksnim sustavima kroz kontinuirane simulacije. Kako raste kompleksnost društvenih i bioloških sustava, metodologija sustavske dinamike pridonosi razumijevanju teorije nelinearne dinamike i

povratne kontrole razvijene u matematici, fizici i inženjerstvu. Zbog takve prirode, koristi se i u ekonomiji i ostalim društvenim znanostima. Razumijevanje metodologije sustavske dinamike polazi od shvaćanja načina na koji funkcioniraju stanja sustava i tokova, gdje tokovi čine odnose između elemenata. Naglasak je na strukturi i procesima koji se odvijaju unutar te strukture. Sustavska dinamika promatra ponašanje sustava uzrokovanog njegovom strukturom (Turina, 2009). Primjenjiva je u sustavima koji se ponašanju promjenjivo kroz vrijeme, odnosno dinamičkim sustavima. Sustavska dinamika polazi od činjenice da se neka situacija može analizirati s objektivnog stajališta te da se strukture i dinamički proces stvarnog svijeta mogu ponovno kreirati kroz sistemske dijagrame i matematičke modele. Također, sustavska dinamika može pojavu objasniti endogenu, odnosno iznutra i to interakcijom varijabli unutar modela. No, to ne isključuje mogućnost uključivanja vanjskih varijabli. Ponekad se granice modela moraju proširiti da bi se razumjela cjelovita sliku unutar koje sustav postoji.

Modeliranje sustavskom dinamikom prati i određene korake (Turina, 2009):

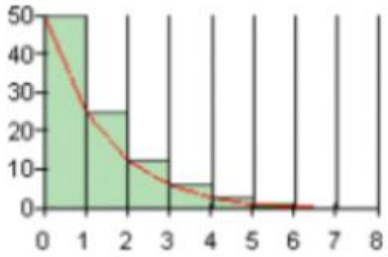
- hijerarhija strukture sustava se prikazuje pomoću dijagrama uzročne petlje
- definiraju se stanja sustava, tokovi sustava i kašnjenja
- uvođenje vanjskih varijabli u sustav omogućuje simuliranje sustava u različitim uvjetima
- rezultati simulacije se koriste u shvaćanju i definiranju međuodnosa varijabli sustava kroz vremenski tok

4.2. Programski paket Powersim

Powersim Sudio je okruženje namijenjeno modeliranju temeljeno na znanosti dinamike sustava. Studio dopušta modeliranje sustava – sa svim njihovima odnosima uzroka i posljedica, povratnim petljama i kašnjenjima na intuitivno grafički način. Koristi se za proučavanje kontinuiranog napretka u velikom broju područja poput biologije, ekonomije, fizike i ekologije. Modeliranje se vrši konstruiranjem Powersim dijagrama. To se postiže odabirom iz skupa definiranih grafičkih simbola (Karlsson i Persson, 1998). Simboli koji predstavljaju razine (stanje sustava), tokove, pomoćne varijable, konstante koriste se izradu grafičkih prikaza sustava. Tokovi i informacijske veze predstavljaju odnose i međusobne veze (Powersim Software AS, 2003).

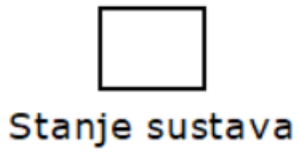
Na slici 8. je prikazano na koji način se mijenja vrijednost stanja sustava ovisno o tokovima. U integraciji neke funkcije, mjere ispod funkcije se jednostavno podijele na jednodijelne particije i zatim se zbraja površina svih particija. U Powersimu se koriste sustavi diferencijalnih jednadžbi prvog reda (Karlsson i Persson, 1998). Matematički zapis jednadžbe stanja opisan je formulom:

$$Stanje\ sustava(t) = Početno\ stanje + \sum_{i=1}^{n}[Ulaz(t_{1-1}) - Izlaz(t_{i-1}) * \Delta t \qquad (1)$$



Slika 8. Promjena stanja sustava i tokovi

Izvor: Powersim Software A (dostupno na: http://homepage.cem.itesm.mx/alesando/index_archivos/DinamicaDeSistemas/Powersim_studio2003_users_manual.pdf)



Slika 9. Grafički prikaz stanja sustava

Izvor: Izrada autora

Da bi se postigla određena razina detalja ili kako bi se lakše formulirala jednadžba protoka, ponekad je potrebno modelirati varijablu kao pomoćnu. U programskom paketu Powersim, pomoćna varijabla je prikazana u obliku kruga kao što je i vidljivo na slici 9. Pomoćna varijabla se koristi za kombiniranje ili preoblikovanje podataka. Za razliku od stanja sustava (razine) nema memoriju. Koristi se za modeliranje informacija, a ne fizički tok dobara, tako da se odmah mijenja bez odgađanja. One mogu biti ulazi u tokove, ali nikad izravno na stanje

sustava (Powersim Software AS, 2003). Pomoćna varijabla može imati bilo koji broj ulaza, dok ulazni utok može imati samo jedan ulaz. Također je definirana jednadžbama. Osim aritmetičkih operacija (+ , - , * , /) postoji velik broj funkcija koji nudi programski paket Powersim (Karlsson i Persson, 1998),



Slika 10. Grafički prikaz pomoćne varijable

Izvor: Izrada autora

Konstanta je definirana početnom vrijednošću i održava tu vrijednost kroz simulaciju, osim ako korisnik ručno mijenja vrijednost. Stoga ako primjerice konstanta ima vrijednost deset, ona će tu vrijednost zadržati tijekom čitave simulacije, neće se mijenjati ni u jednom trenutku. Njezin grafički oblik je prikazan pomoću slike 10.



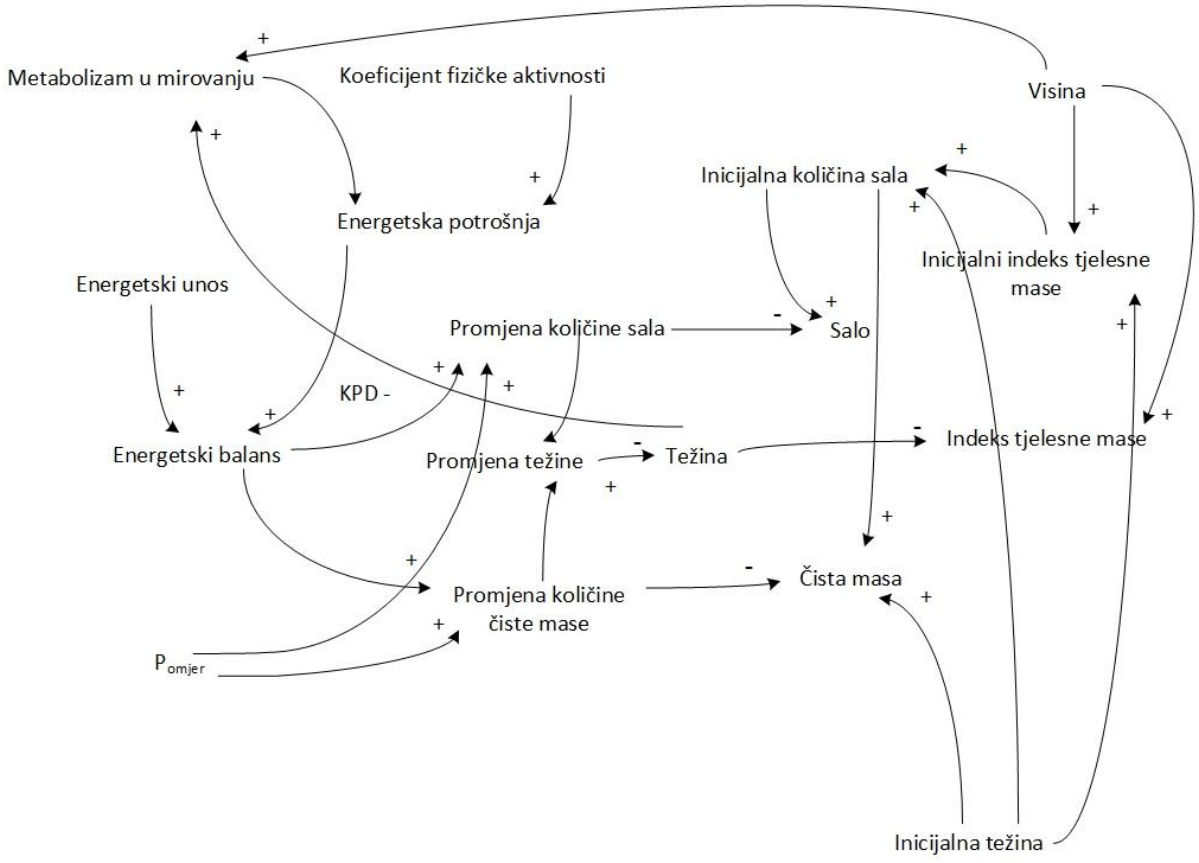
Slika 11. Grafički prikaz konstante

Izvor: Izrada autora

4.2. Razvoj biološkog modela

Kako bi model bio relevantan prvo će biti definiran cilj modela i što on treba predstavljati, te strukturni dijagram. Zatim će se identificirati granice modela i ključne varijable. Nakon toga slijedi izgradnja računalnog modela. A na kraju će se objasniti dani rezultati simulacije.

S ciljem analize vremenske dinamike potrebne za redukciju tjelesne kilaže razvijen je strukturni dijagram koji pobliže opisuje veze između varijabli u modelu i njihove ovisnosti koji je prikazan na slici 12. Centralna varijabla čija se promjena promatra je „Težina“. Ovisno o promjeni težine, mijenjat će se i indeks tjelesne mase kao pokazatelj pretilosti. Osobe indeksa tjelesne mase iznad 25 se smatraju pretilim osobama. Da bi se osoba smatrala nepretilom potrebna je redukcija tjelesne težine koju će ujedno pratiti i smanjenje indeksa tjelesne mase ispod 25.



Slika 12. Strukturni dijagram biološkog modela

Izvor: Izrada autora

Tablica 5. Varijable biološkog modela

Naziv varijable	Mjerna jedinica	Definicija	Formula	Izvor
Čista masa	Kg/dan	Čista masa se dobije kad se inicijalna težina oduzme od inicijalne razine sala, a ona uključuje masu kostiju, unutranjih organa i mišića.	Čista masa= Inicijalna težina - Inicijalna razina sala	(34)
Energetska potrošnja	Kcal/dan	Energetska potrošnja prikazuje količinu energije koje tijelo potroši tijekom jednog dana. (probava hrane, fizička aktivnost, potrošnja tijela dok miruje)	$EP(M) = Metabolizam\ u\ mirovanju * koeficijent\ fizičke\ aktivnosti$	(21)
Energetski balans	Kcal/dan	Kad je energetski unos jednak energetskoj potrošnji, tijelo se nalazi u energetskom balansu, tjelesna težina je postojana. Kad energetska potrošnja premaši energetski unos, tijelo se nalazi u stanju zvan kalorijski deficit i tada se tijelo nalazi u procesu smanjenja tjelesne težine, a kad energetski unos premaši energetsku potrošnju tijelo se nalazi u stanju kalorijskog suficita i ulazi u proces povećanja tjelesne kilaže.	Energetski balans= Energetski unos – Energetska potrošnja	(34)
Energetski unos	Kcal/dan	Energetski unos predstavlja količinu kalorija koje unosimo na dnevnoj razini u obliku proteina, ugljikohidrata i masti. Formula se temelji na Atwaterovoj metodi	EU=a1*CI(t)+a2*FI(t)+a3*PI(t)	(22)
Indeks tjelesne mase	postotak	Indeks tjelesne mase je statistički pokazatelj tjelesne težine u odnosu na visinu, koristi se kao okvirni pokazatelj debljine i pretilosti.	Indeks tjelesne mase= težina/visina^2	(19)
Inicijalna količina sala	Kg/dan	Salo se odnosi na ukupan broj lipida koji se mogu pretvoriti iz masti i drugih stanica.	$FM(M) = (3{,}76 * (BMI)(BM) - 0{,}04 * (BMI)^2(BM) - 47{,}80 * BM)/100$ $FM\ (\check{Z}) = (4{,}35 * (BMI)(BM) -$	(22)

			$0{,}05 * (BMI)^2(BM) - 46{,}24 * (BM)$)/100	
Inicijalna težina	Kg	Relativna masa tijela ili količina tvari koju ona sadrži. U radu će inicijalna težina iznositi 130 kg.	120 kg (muškarac) 102 kg (žena)	-
Inicijalni indeks tjelesne mase	N/A	Kontrolna varijabla koja se koristi u određivanju inicijalne razine sala	36,8 (muškarac) 36,8 (žena)	-
Koeficijent fizičke aktivnosti	N/A	Koeficijent fizičke aktivnosti (PAL) pokazuje udio fizičke aktivnosti u energetskoj potrošnji.	Seditarni ili slabo aktivni stil života = 1.40 – 1.69 Aktivni ili umjerno aktivni stil života= 1.70-1.99 Ubrzan stil života = 2.00-2.40	(11)
Metabolizam u mirovanju	Kcal/dan	Metabolizam u mirovanju (RMR) prikazuje broj kalorija koje tijelo troši kad se tijelo nalazi u potpunom mirovanju i predstavlja najveću komponentu energetske potrošnje.	REE_M = 10 * Težina (kg) + 6,25 * Visina (cm) – 5 * Godine (y) +5 $REE_Ž$ = 10* Težina (kg) + 6,25* Visina (cm) – 5 * Godine (y) -161	(21)
P_{omjer}	N/A	Konstanta 10,4 opisuje kako se kompozicija tijela mijenja kao funkcija početne tjelesne mase, pomnožena sa odnosom energetske gustoće čiste mase i energetske gustoće sala (Forbesova formula) P_{omjer} je parametar koji dodjeljuje postotak raspodjele energetskog (dis)balansa u obliku sala ili čiste mase .	$P_{omjer} = \frac{C}{(C + Inicijalna\ razina\ sala)}$ $C = 10{,}4 * \frac{pl}{pf}$	(22)
Promjena količine čiste mase	Kg/dan	Promjena razine čiste mase kroz period dt	dFFM=(P_{omjer}*(Energetski balans))/pl	(22)
Promjena količine sala	Kg/dan	Promjena razine sala kroz period dt	dFM=((1-P_{omjer})*(Energetski balans))/pf	(22)
Promjena težine	Kg/dan	Promjena težine je određena zbrojem promjene količine sala i promjene količine čiste mase	Promjena težine= Promjena količine sala + Promjena količine čiste mase	-
Salo	Kg/dan	Količina sala će se izračunati pomoću regresijske jednadžbe za izračun inicijalne razine	50,87 kg (muškarac) 47,1 kg (žena)	(22)

		sala što će ujedno predstavljati i polaznu vrijednost.		
Težina	Kg/dan	Ukupna težina	Težina za muškarca = 120 Težina za ženu = 102	-
Visina	cm	Udaljenost od dna stopala do vrha glave ljudskog tijela	180,5 cm (muškarac) 166,3 cm (žena)	-

Izvor: Izrada autora

Tablica 6. Notacije varijabli

Notacije	Objašenjenje
a1	Kalorijska vrijednost ugljikohidrata (4 kcal/g)
a2	Kalorijska vrijednost masti (9 kcal/g)
a3	Kalorijska vrijednost proteina (4 kcal/g)
BM	Težina
BMI	Indeks tjelesne težine
CI	Ugljikohidrati
EP	Dnevna energetska potrošnja
EU	Dnevni energetski unos
FI	Masti
FM	Salo
pf	Energetska gustoća sala; 9400 kcal/kg
PI	Proteini
pl	Energetska gustoća čiste mase; 1800 kcal/kg

Izvor: Izrada autora

Energetski unos predstavlja količinu kalorija koje unosimo na dnevnoj razini u obliku proteina, ugljikohidrata i masti (Hill et al., 2013). U radu će se njen izračun temeljiti na Atwaterovoj metodi izračuna energetskog unosa iz ugljikohidrata, masti i proteina na dnevnoj razini (izraženih u gramima) (Navarro-Barrientos et al., 2011). U radu se neće promatrati utjecaj pojedinih nutrijenata na smanjenje težine. Stoga će se kompozicija makronutrijenata temeljiti na Mediteranskoj dijeti koja dokazano ima blagotvorno djelovanje na smanjenje

faktora rizika kardiovaskularnih bolesti i dijabetesa tipa 2 (Yumuk et al., 2015). Navedena dijeta sadržava unos nutrijenata iz hrane u omjeru 35% masti, 45% ugljikohidrata i 20% proteina. Za gubitak težine se predlaže smanjenje energetskog unosa u odnosu na energetsku potrošnju za 500-1000 kcal (Yumuk et al., 2015). Vrijednost energetskog unosa će biti manja od energetske potrošnje jer je cilj postići kalorijski deficit. Kalorijski deficit će se kretati između 150 i 500 kalorija.

Energetska potrošnja predstavlja količinu kalorija koje potrošimo na dnevnoj razini. Svi živući organizmi troše energiju kako bi održali staničnu homeostazu u tijelu. Svakodnevna potrošnja energije se može podijeliti u tri dijela: **metabolizam u mirovanju** (RMR), koji prikazuje broj kalorija koje tijelo troši kad se nalazi u potpunom stanju mirovanja i predstavlja najveću komponentu energetske potrošnje (čini 60-75% energetske potrošnje), termalni efekt hrane koji uključuje probavu, apsorpciju, pohranu i transport hrane (do 10%) i fizička aktivnost, ovisno o aktivnostima koji se odražavaju na energetsku potrošnju, a odnosi se na intenzitet uobičajene tjelesne aktivnosti na dnevnoj razini (15-30%) (Speakman i Selman, 2003). Poznavanje metabolizma u mirovanju je važno za klinička ispitivanja kod definiranje odgovarajućeg prehrambenog unosa s obzirom na to da ona čini glavninu energetske potrošnje (Antunes, et al., 2005). Metabolizam u mirovanju će se izračunati pomoću Mifflin-St Jeor jednadžbe. Ova formula u obzir uzima spol, tjelesnu težinu, visinu i godine (Mifflin, 1990), a modificirati će se za koeficijent fizičke aktivnosti kako bi se predvidjela ukupna energetska potrošnja.

Koeficijent fizičke aktivnosti rangiran je od 1,4 za seditarni način života do 2,4 za ubrzan stil života (FAO/WHO/UN, 2001). Može se primijetiti da dana formula za izračun energetske potrošnje ne uzima u obzir termalni efekt hrane zbog malog udjela u energetskoj potrošnji. **Energetski balans** je stanje u kojem je energetski unos jednak energetskoj potrošnji (Hill et al., 2013). Temelji se na prvom zakonu termodinamike otvorenih sustava. Ljudsko tijelo se smatra otvorenim sustavom zato što se energija može dodati sustavu unosom toka mase u obliku hrane (Thomas et al., 2014). Prvi zakon termodinamike je univerzalan, može se primijeniti na gotovo sve procese, a kaže da se izmijenjena količina energije u obliku topline može utrošiti na promjenu unutrašnje energije i na vršenje rada (Puljak, 2009). Kad energetski unos premaši energetsku potrošnju dolazi do stanja suficitarnog energetskog balansa a posljedica je povećanje težine (tjelesne mase). Suprotno tome, kad energetska potrošnja premaši energetski unos, stanje kalorijskog deficita prevlada i posljedica tome je gubitak težine. Međutim, komponente energetskog balansa mogu biti pod utjecajem međusobnih

promjena kao posljedica pozitivnog ili negativnog energetskog balansa što sprječava promjenu u tjelesnoj masi (Hill et al., 2013).

Model se temelji na negativnoj energetskoj ravnoteži, tj. kalorijskom deficitu i smanjenju težine, stoga bitnu ulogu ima i prilagođavajuća termogeneza (adaptive thermogenesis). To je pojava u kojoj dolazi do smanjenja energetske potrošnje u mjeri većoj nego se može predvidjeti kao odgovor na promjenu u energetskom balansu (Major et al., 2007). Odnosno, kad dođe do promjene u energetskom balansu, u ovom slučaju energetski unos je manji od energetske potrošnje, tijelo će reagirati tako da će reducirati energetsku potrošnju u mjeri koja se ne može sasvim točno procijeniti. Metabolička prilagodba nastaje kad se tijelo prilagođava kalorijskom deficitu smanjenjem stope metabolizma u mirovanju (Thomas et al., 2009). Ova metabolička prilagodba je biološki smislen mehanizam preživljavanja koji štedi energiju izazvanu gladovanjem i niskoj razini energetske potrošnje. Studije izvedene na mršavim i pretilim osobama pokazale su signifikantno smanjenje u energetskoj potrošnji tijekom i poslije smanjenja tjelesne težine. Istraživanja su pokazala da već nakon dva tjedna energijskog deficita, metabolizam u mirovanju je smanjen u iznosu od 112- 152 kcal u odnosu na predviđenu razinu, a u osmom tjednu je ta razlika bila 229-145 kcal kod muškaraca i žena (Camps et al., 2013). Stoga, dolazi do smanjenja stope gubitka težine izazvane prilagodbom metabolizma na kalorijski deficit ili čak dovodi do povećanja težine iako je prvotno osoba bila u kalorijskom deficitu. Promjena metabolizma u mirovanju odnosno energetske potrošnje izazvane prilagodbom metabolizma u modelu će se prikazati pomoću TIMESTEP funkcije (Karlsson i Persson, 1998) koja dopušta definiranje vremena početka promjene za dani iznos. Smanjenje energetske potrošnje korištenjem funkcije TIMESTEP započeti će nakon 2 tjedna a bit će opisana iznosom od 132 kalorije (srednja vrijednost već navedenih iznosa) i nakon 8 tjedana u iznosu od 182 kalorije (srednja vrijednost između 145 i 229, također već navedenih iznosa).

Težina ili ukupna tjelesna težina je određena zbrojem dviju varijabli ljudske tjelesne kompozicije, sala i čiste mase (Navarro-Barrientos et al., 2011). **Promjena težine** je varijabla koja prati ukupnu promjenu težine s obzirom na promjene u količini sala i količini čiste mase. **Salo** predstavlja ukupnu količinu lipida koji se mogu pretvoriti iz masti i drugih tvari. Salo ima važnu ulogu u tijelu jer pruža najveću potencijalnu energiju tijelu, služi kao jastuk za zaštitu vitalnih organa, osigurava izolaciju od hladnoće (Abdel-Hamid, 2002). Kako bi se odredila **Inicijalna količina sala**, koristit će se regresijska jednadžba iz tablice 1. , a zatim će

se **Promjena količine sala** pratiti diferencijalnom jednadžbom (Navarro-Barrientos et al., 2011):

$$\frac{dSalo(t)}{d(t)} = \frac{(1-P_{omjer}(t))*Energetski\ balans(t)}{pF} \quad (2)$$

,gdje je $\mathbf{P_{omjer}}$ funkcija Forbesove kompozicije tijela i trenutne količine sala, a parametar pF energetska gustoća[4] jedne kile sala (9400 kcal/kg). Ova funkcija određuje raspodjelu energetske neravnoteže prema salu ili čistoj masi (Hall et al., 2009). Forbesova teorija predviđa da promjena čiste mase ovisi samo o salu (Hall, 2007). **Čista masa** obuhvaća masu kostiju, unutarnjih organa, kože, mišića i vode (Abdel-Hamid, 2002), a računa se kao razlika između inicijalne težine i inicijalne količine sala. **Promjena količine čiste mase** opisana je diferencijalnom jednadžbom (Navarro-Barrientos et al, 2011):

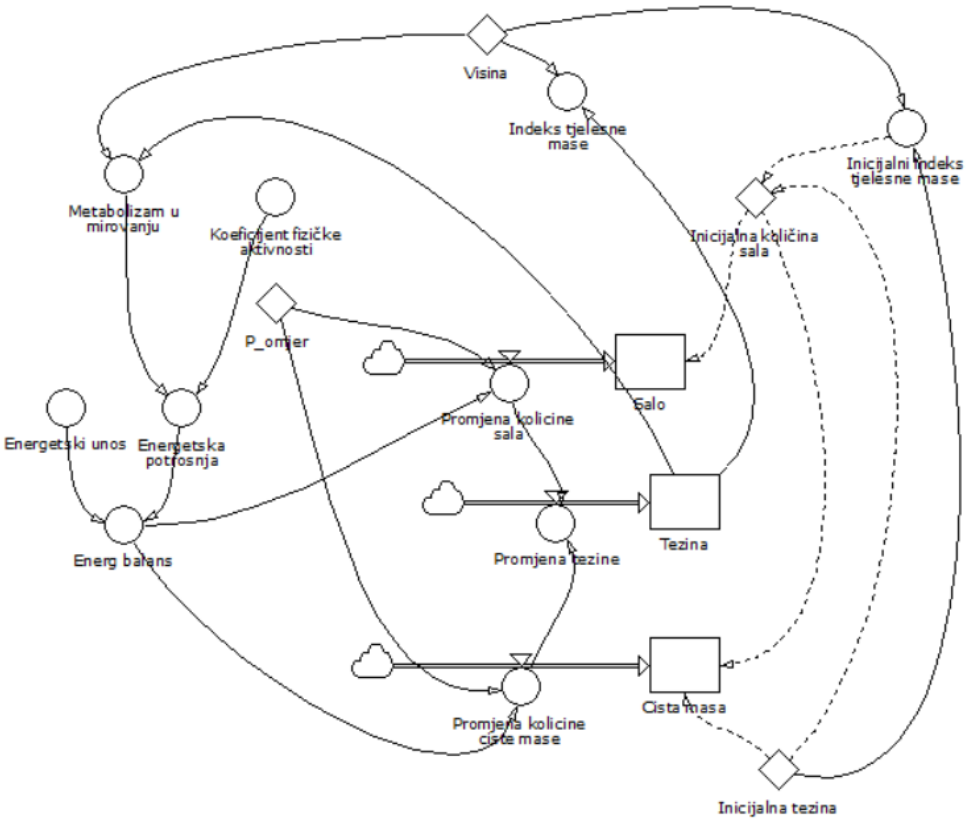
$$\frac{dČista\ masa(t)}{dt} = \frac{p_{omjer}*Energetski\ balans(t)}{pL} \quad (3)$$

, gdje pL pokazuje konstantan iznos gustoće jedne kile čiste mase (1800 kcal/kg).

Wishnofskyeva studija je pretpostavljala da se salo sastoji 87% od masnog tkiva i da ima energetsku gustoću od 8250 kcal/kg. Povećanjem ili smanjenjem težine, Wishnofsky smatra da kalorijski deficit prvenstveno dovodi do katabolizma[5] sala. Bitan aspekt Wishnofskyevog pravila u ovom kontekstu je da predviđa konstantnu energetsku gustoću gubitka težine (zaokruženo na 7700 kcal/kg) (Heymsfield et al., 2014). Stoga, ovo pravilo je netočno zato što energetski sadržaj promjene težine nije konstanta u iznosu od 7700 kcal/kg već se mijenja kroz vrijeme (Thomas et al., 2014). Stoga se primjenjuje pravilo konvencionalnog dvodijelnog modela u kojem se razlikuje energetska gustoća sala (9400 kcal/kg) i čiste mase (1800 kcal/kg) (Navarro-Barrientos et al., 2011).

[4] Energetska gustoća je količina energije (kalorija ili džula) pohranjene u određenom sustavu ili prostoru po jedinici volumena.

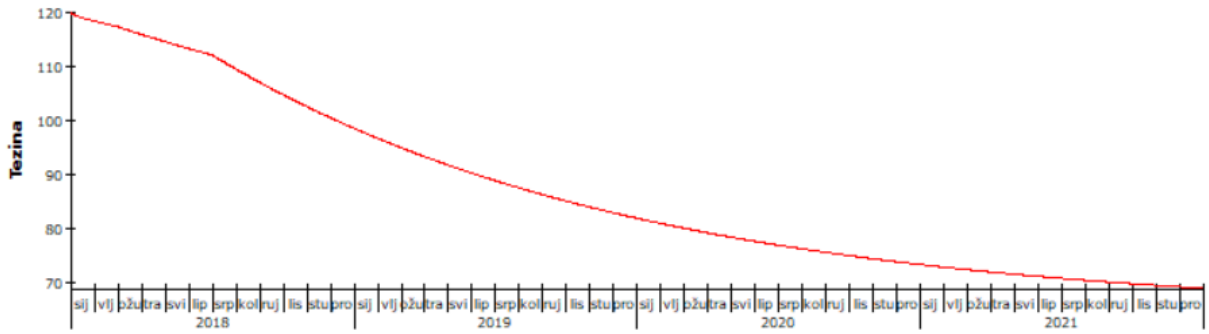
[5] Katabolizam podrazumijeva skup biokoemijskih reakcija u kojma se složeni kemijski spojevi razgrađuju u jednostavnije, oslobođajući tako u većini slučajeva kemijsku energiju i u određenoj mjeri i toplinsku energiju.



Slika 13. Biološki računalni model u Powersimu

Izvor: Izrada autora u programskom paketu Powersim

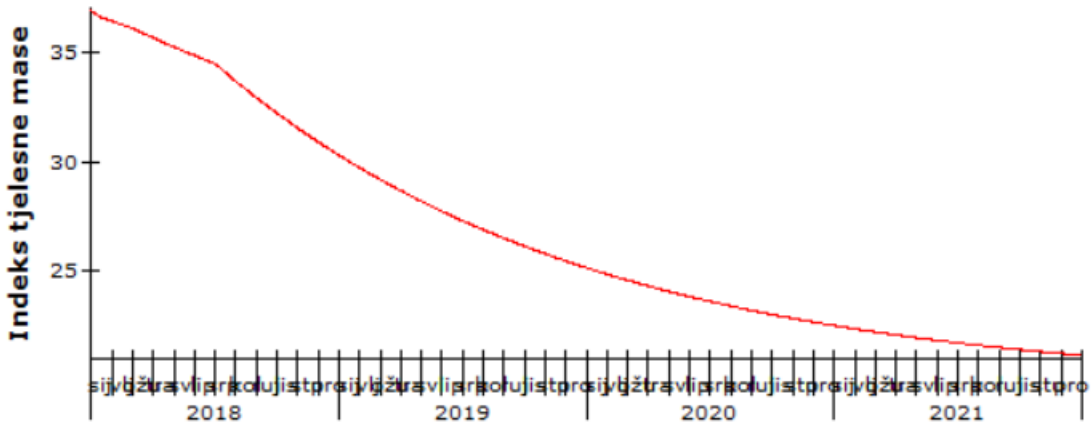
Na temelju definirane strukture sustava izrađen je računalni model pomoću programa Powersim. Računalni model sadrži varijable stanja razine sustava koje su označene kvadratom a za koje se može reći da posjeduju sposobnost „pamćenja“, varijable promjene stanja su označene manjim kružnicama spojenim na ulaz i izlaz u model, konstante su u obliku romba, a njihova mogućnost je poprimanje vrijednosti na početku i zadržavanje te vrijednosti tijekom čitave simulacije , te krugovima kojima su označene pomoćne varijable pomoću kojih se pojednostavljuje struktura modela. Na slici 13. je prikazan računalni biološki model smanjenja težine. Ovaj model ima sposobnost prikazati dinamiku smanjenja tjelesne kilaže te vremena potrebnog da se dostigne željena razina indeksa tjelesne mase. Kao što je označeno u tablici, inicijalna težina iznosi 120 kg, visina 180,5 cm kod muškaraca, što daje indeks tjelesne mase u iznosu od 36,83. Inicijalna težina kod žena je postavljana na 102 kg i visina 166,3 cm što daje indeks tjelesne mase u iznosu od 36,88 . Prema subklasifikaciji WHO-a radi se o ozbiljnoj pretilosti.



Slika 14. Vremenska dinamika za muškarca

Izvor: Izračun autora

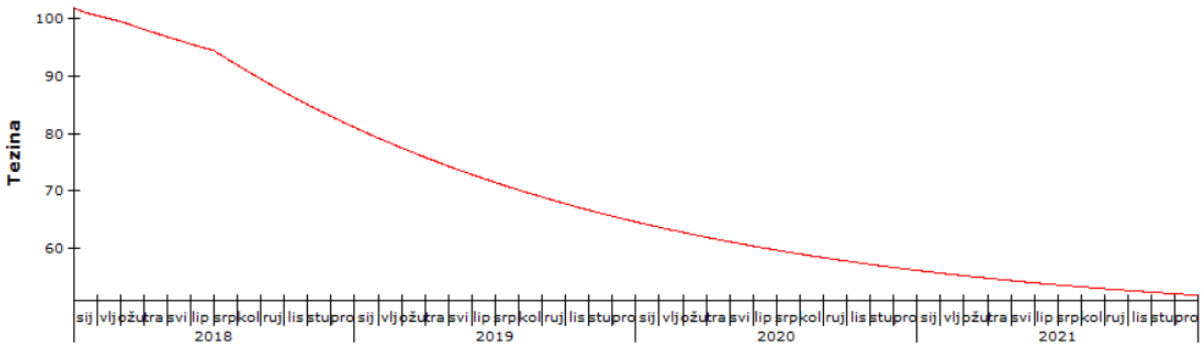
Na slici 14. simulacija pokazuje kako je potrebno 22 mjeseca da muška osoba indeksa tjelesne mase 36,8 dođe do indeksa tjelesne mase u iznosu od 25, što predstavlja gornju granicu normalnog indeksa tjelesne mase. Odnosno, dostizanjem te razine, osoba će se klasificirati kao nepretila. Takvo smanjenje težine bi utjecalo i na smanjenje troška zdravstvene zaštite te osobe. Kao što je već spomenuto u tekstu, u Hrvatskoj dodatni trošak zdravstva po pretiloj osobi iznosi 322,78 kuna. Ako osoba padne ispod indeksa tjelesne mase 25, dodatni trošak koji je generiran od strane pretile osobe bi se značajno smanjio. U prvom mjesecu 2018. godine stopa gubitka težine je veća sve dok ne počne djelovati prilagođavajuća termogeneza koja dovodi do smanjenja energetske potrošnje što dovodi do usporavanja smanjenja težine. Stoga je TIMESTEP funkcijom energetski unos smanjen za 400 kalorija nakon 2 mjeseca te dodatnih 400 kalorija nakon 6 mjeseci zbog toga što se energetska potrošnja počinje približavati energetskom unosu, što ponovno vodi većoj razini smanjenja težine ali po opadajućoj stopi.



Slika 15. Kretanje indeksa tjelesne mase kod muškarca

Izvor: Izrada autora

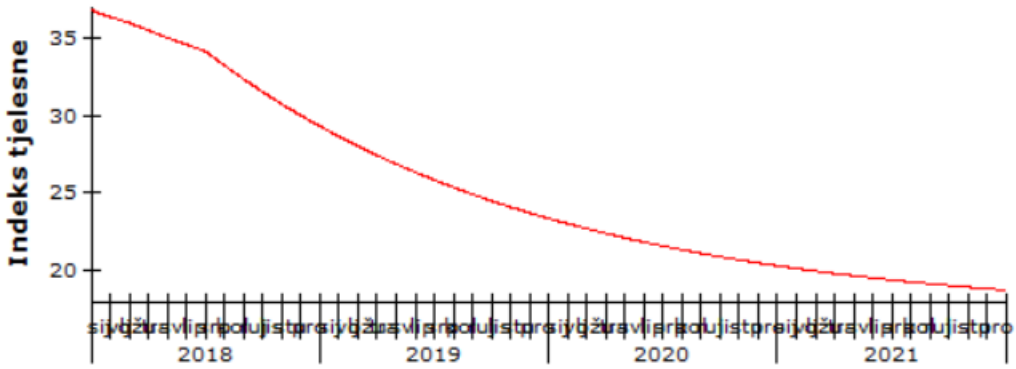
Na slici 15. je prikazan i vremenska dinamika smanjenja težine od indeksa 36,8 do indeksa tjelesne mase u iznosu od 25. Simulacija je pokazala kako je potrebno 22 mjeseca da ozbiljno pretila osoba dosegne status nepretile osobe i to gornje granice iste kategorije. Bitno je pratiti indeks tjelesne mase jer se prema WHO-u smatra jednom od najboljih mjera za karakterizaciju pretilosti. Kao što je već spomenuto, indeks tjelesne mase se izračunava stavljanjem u omjer težine i kvadrirane visine. Indeks koji se dobije pokazuje o kojoj se kategoriji radi. U ovom slučaju je postignuta redukcija indeksa tjelesne mase od ozbiljno pretile kategorije do kategorije normalne tjelesne težine.



Slika 16. Vremenska dinamika za žene

Izvor: Izračun autora

Slika 16. pokazuje vremensku dinamiku smanjenja težine kod žene. Može se primijetiti da žena dostiže iznos indeksa tjelesne mase od 25 ranije nego muškarac, i to mjesec dana ranije, odnosno nakon 21 mjesec. Također je korištena TIMESTEP funkcija za vrijeme u kojem se metabolizam prilagođava gubitku težine, te energetski unos koji je u početku bio 500 kalorija manji, no zbog djelovanja prilagođavajuće termogeneze na nepredviđenu smanjenu energetsku potrošnju, smanjen je i energetski unos dodatno u iznosu od 400 kalorija nakon 2 mjeseca te dodatno 400 kalorija nakon 6 mjeseci. Stopa gubitka težine je sve manja nakon toga razdoblja jer se tijelo prilagođava energetskom disbalansu.



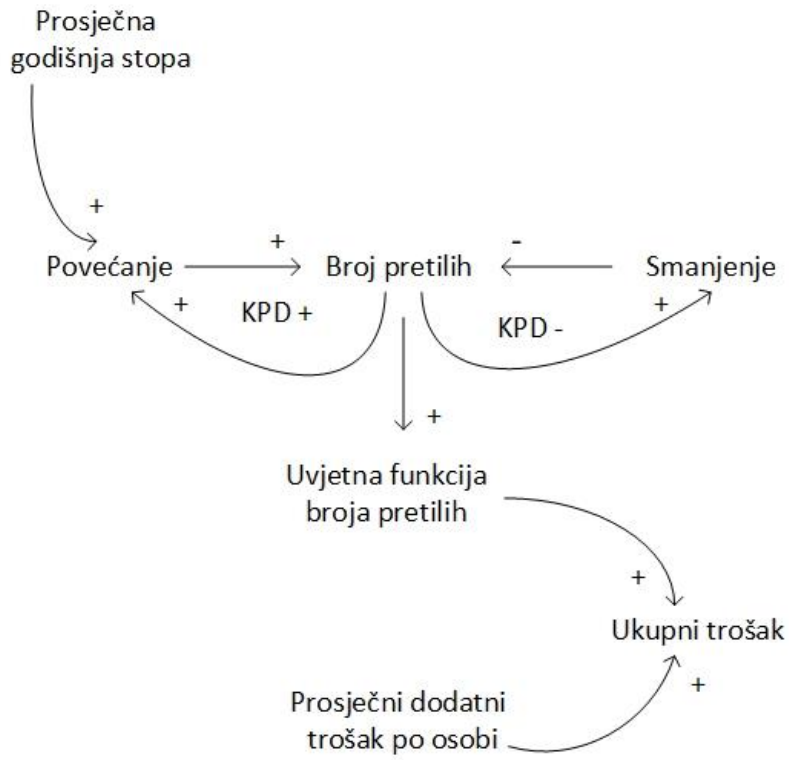
Slika 17. Kretanje indeksa tjelesne mase kod žene

Izvor: Izračun autora

Kao i kod muškaraca potreban je određen vremenski period da bi ženska osoba dosegla ciljani indeks tjelesne mase koji bi je svrstao u nepretile osobe. Simulacija provedena u programskom paketu Powersim pokazala je kako je potrebno 21 mjesec da ženska osoba indeksa tjelesne mase 36,8 dosegne ciljani indeks od 25 što je svrstava u gornju skupinu nepretilih osoba. Vremenska dinamika smanjenje indeksa tjelesne mase je vidljiva na slici 17. U početnim mjesecima 2018. godine ta stopa je nešto veća u odnosu na ostale mjesece i godine gdje se razina indeksa tjelesne mase smanjuje ali po opadajućoj stopi.

4.3. Razvoj financijskoj modela

Financijski model je opisan strukturnim dijagramom na slici 18. i prikazuje kretanje broja pretilih ovisno o tokovima smanjenja i povećanja u svrhu procjene kretanja ukupnih troškova pretilosti. Razvijen je strukturni dijagram u kojem se vide poveznice između varijabli. Nadalje će biti objašnjena svaka varijabla i njezina vrijednost. Zatim će se pristupiti izradi računalnog modela i njezinoj verifikaciji, a onda će se analizirati rezultati koje simulacija izbaci. Cilj ovog modela je pokazati vremensku dinamiku smanjenja broja pretilih u Hrvatskoj, odnosno smanjenja troškova kojeg generiraju pretile osobe. Kako se ukupni trošak pretilosti bude smanjivao, predloženim mjerama se može utjecati na izvor problema.



Slika 18. Strukturni dijagram financijskog modela

Izvor: Izrada autora

Varijabla **Broj pretilih** je stanje sustava i njena početna vrijednost iznosi 793 955 što predstavlja broj pretilih u Hrvatskoj u 2007. godini (Čubrilo-Turek, 2007). Pod utjecajem tokova sustava **Povećanje** i **Smanjenje**, njena vrijednost će se mijenjati. Prema podacima iz 2008. godine u petogodišnjem razdoblju (2003.-2008.) prosječni godišnji porast prevalencije pretilosti bio je 10,60% u muškaraca i 11,08% u žena (Medanić i Pucarin-Cvetković, 2012). Stoga je prosjek tih dvaju vrijednosti (10,84) uzet za varijablu **Prosječna godišnja stopa**. Tok **Povećanje** ovisi o prosječnoj godišnjoj stopi i broju pretilih u danom trenutku.
Povećanje = IF('Broj pretilih'<=0;0;'Broj pretilih')*'Prosječna godišnja stopa'/1<<yr>>

Korištena je IF funkcija kako povećanje nakon dužeg vremenskog razdoblja ne bi prelazilo u negativnu vrijednost.

Tok **Smanjenje** je prikazan pomoću funkcije **DELAYMTR** koja je definirana s četiri parametra: Input (varijabla čije će se kašnjenje promatrati), Delay (vrijeme kašnjenja), Order (red kašnjenja) i Initial (početni output).

Smanjenje = DELAYMTR(IF('Broj pretilih'<=0;0;'Broj pretilih');2,2<<yr>>;3;0)/1<<yr>>

U modelu se promatra kašnjenje varijable „Broj pretilih“, i to za vremenski period od 2 godine i 2 mjeseca kao što su simulacije pokazale u biološkom modelu. Koristi se kašnjenje trećeg reda, a početni output iznosi 0. Korištena je i funkcija IF. Ako je smanjenje manje od 0, funkcijom IF je definirano da joj se dodijeli nulta vrijednost kako ne bi utjecalo na stanje sustava.

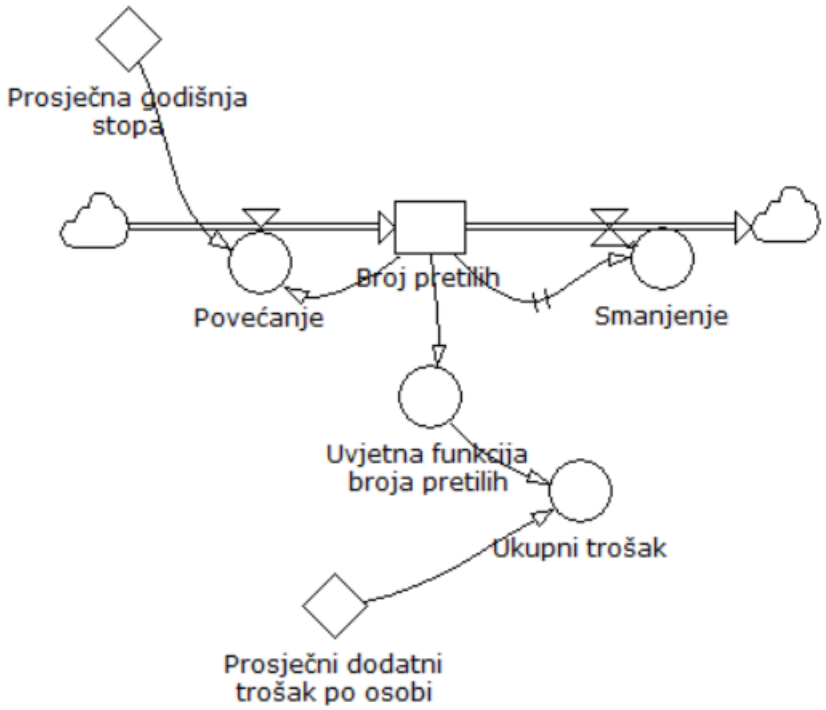
Varijabla **Uvjetna funkcija broja pretilih** je determinirana IF funkcijom jer nakon nekog vremena zbog varijable „Smanjenje“, broj pretilih prelazi u negativnu vrijednost pa da bi se spriječila ta pojava, korištena je uvjetna funkcija (IF funkcija). Ovo je jedini razlog uvođenja varijable Uvjetna funkcija broja pretilih. Na nju se može gledati kao posrednu varijablu. Ako broj pretilih padne ispod nule, tada simulacija neće ulaziti u negativnu vrijednost već će joj dodijeliti vrijednost 0, a ako ne pređe tada će poprimiti vrijednost realnog stanja sustava.

```
IF('Broj pretilih'<=0;0;'Broj pretilih')
```

U 2007. godini, procijenjeno je da su u Hrvatskoj direktni (prevencija, dijagnoza, tretmani i usluge za zdravstvenu skrb pretilih osoba, hospitalizacija, liječničke usluge, lijekovi) i indirektni troškovi (bolesti i smrtnost) pretilih osoba iznosili 34.934.020 € ili 256.275.970 kn[6] (Čubrilo-Turek, 2007). **Ukupni trošak** predstavlja ukupan dodatan trošak kojeg generiraju pretile osobe u Hrvatskoj. Njegova vrijednost je determinirana umnoškom prosječnog dodatnog troška i uvjetne funkcije pretilih osoba. **Prosječni dodatni trošak** po osobi je izračunat stavljanjem u odnos procijenjenog troška pretilih osoba u Hrvatskoj 2007. godini i ukupnog broja pretilih u 2007. godini što iznosi prosječno 322,78 kn po pretiloj osobi.

Na temelju objašnjenih varijabli izrađen je računalni model u Powersimu koji prikazuje kretanje troškova pretilih osoba ovisno o kretanju ukupnog broja pretilih osoba u Hrvatskoj. Prikazan je slikom 19. Povećanje predstavlja ulazni tok , smanjenje je izlazni tok, dok je broj pretilih stanje sustava. Prosječna godišnja stopa i prosječni dodatni trošak po osobi označavaju konstantu, dok su pomoćne varijable Uvjetna funkcija broja pretilih i Ukupni trošak.

[6] 2007. godine (godišnji) srednji devizni tečaj Hrvatske narodne banke iznosio je 1€ = 7,336 kn (dostupno na: https://www.hnb.hr/documents/20182/33ebeea1-3d13-4a42-b0fb-87223d026703)



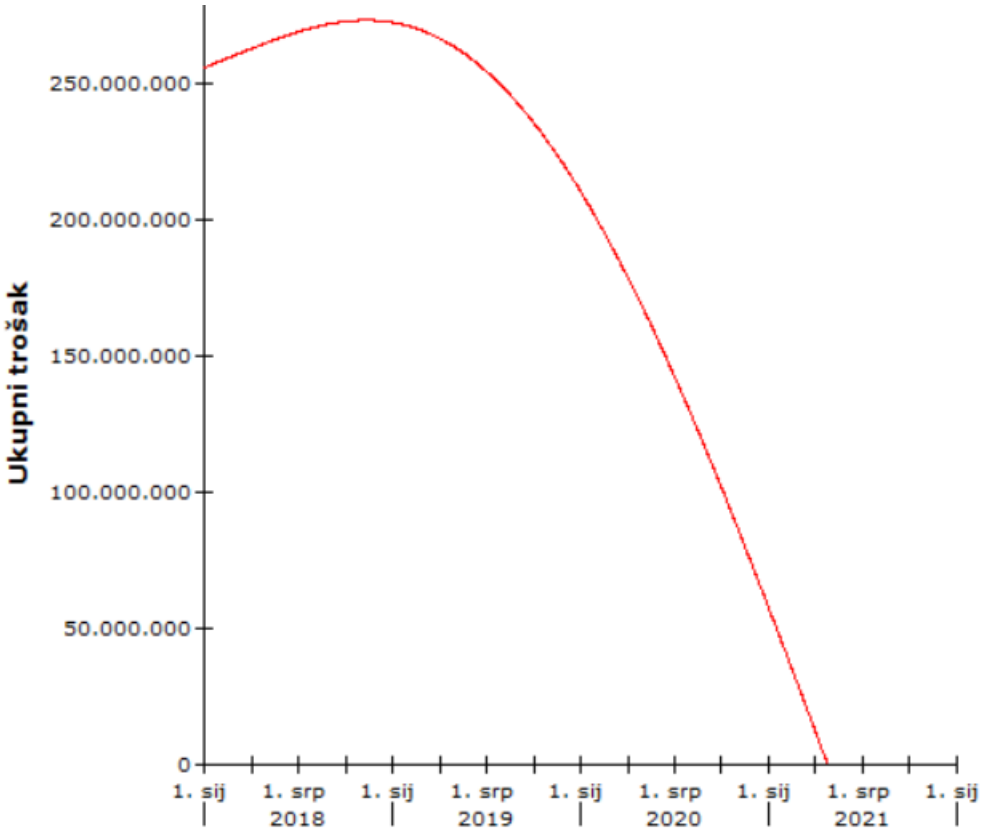
Slika 19. Financijski računalni model

Izvor: Izrada autora

Simulacije u biološkom modelu su dale važan parametar za prikaz ukupnih troškova pretilih osoba a to je vrijeme kašnjenja, odnosno vrijeme koje je potrebno da osoba iz stanja pretilosti pređe u stanje normalne tjelesne kilaže (indeks tjelesne mase 25). Iz modela je vidljivo kako je prosječno potrebno dvije godine i dva mjeseca da se postigne to stanje. Ovaj mali ali bitan podatak je dao uvertiru za simulaciju ukupnih troškova jer je korišten u funkciji DELAYMTR, tj. funkciji kašnjenja. Na slici 20. je prikazana simulacija kretanja ukupnih troškova pretilih osoba. Do 1. listopada 2019. godine pod utjecajem funkcije kašnjenja, dolazi do povećanja ukupnog broja pretilih. No, nadalje dolazi do smanjenja po većoj stopi nego što je povećanje što uzrokuje ukupno smanjenje broja pretilih a posljedično i smanjenje ukupnog dodatnog troška kojeg generiraju pretile osobe u sustavu zdravstva.

Simulacije su pokazale kako je hipotetski moguće eliminirati ukupan trošak pretilosti u roku od tri i pol godine. A svako smanjenje sredstava koje su namijenjene pretilim osobama daju mogućnost korištenja uštođenih novaca u edukacijske programe koje će osigurati da se broj pretilih značajno reducira. Ako osoba ne poznaje osnovna „pravila“ gubitka težine ona neće ni pokušati izgubiti težinu već ostaje u stanju u kojem se i nalazi, a postoji vjerovatnost da to

stanje dosegne i veće implikacije. Jedan od glavnih problema je neosviještenost o problemima koje pretilost nosi. Ulaganje u edukaciju ljudi koji su pretili prvenstveno može osigurati napredak u svim segmentima njihovog života. Nije tajna kako se pretile osobe suočavaju s diskriminacijom u društvu ali i problemima koji nose bolesti uzrokovane pretilošću. Biološki model i financijski nadmodel mogu pomoći u rješavanju ovakvih problema jedino ako su se direktno može utjecati na izvor problema – pretile osobe.



Slika 20. Vremenska dinamika ukupnih troškova

Izvor: Izračun autora

4.4. Analiza simulacijskih rezultata

Simulacije u biološkom modelu su pokazale kako je moguće dovesti osobu iz stanja pretilosti u stanje normalne tjelesne težine što je vrlo bitno za daljnja razmatranja. Kao prosjek su uzeta 22 mjeseca kao potrebna da bi se od ozbiljne pretilosti došlo do stanja nepretilosti, odnosno normalne tjelesne težine prema klasifikaciji WHO-a. Ovakva pretpostavka je hipotetska, uzeta pod savršenim okolnostima jer svaka osoba ima drugačiji metabolizam i nije moguće

analizirati svaki metabolizam odvojeno te tako donijeti generalne zaključke. Stoga se i u ovom modelu koriste određene pretpostavke koje ukazuju na pravodobno korištenje metode sustavske dinamike koja pomoću simulacija daje uvid u vremensku dinamiku. Takve pretpostavke su opisane u biološkom modelu. Ovaj model je dao važan parametar – vremensku dinamiku, korištenu u financijskom modelu kao dio funkcije kašnjenja, odnosno vremena potrebnog da osoba dosegne normalnu tjelesnu težinu. Financijski model je pokazao kako je potrebno tri i pol godine da bi se reducirao trošak kojeg stvaraju pretile osobe u Hrvatskoj. Redukcija troškova na ovom području otvara nove mogućnosti koje će biti opisane u idućem odjeljku.

4.5. Mjere u sustavu zdravstva

Kod dijagnostike pretilosti koriste se različita mjerenja kao što su mjerenje opsega struka, indeksa tjelesne mase, testiranje i analiza trenutnog stanja tijela, koštano-mišićnog sustava i slično. Ovakve mjere pomažu kod prepoznavanja pretilosti kod rizičnih osoba. Kao što je već spomenuto, pretilosti se smatra faktorom rizika a ne bolešću. Da bi se mogao liječiti faktor rizika, bitno je upoznati cjelokupnu populaciju s problemima koje pretilost nosi i kako ih liječiti. Kako bi se to postiglo, neizbježno je provesti edukaciju. Edukacija se smatra obrazovanje građana o nekom problemu.

U ovoj priči, taj problem je pretilost i posljedice koje može imati na zdravlje čovjeka. U okviru pretilosti kao javnozdravstvenog problema postoje mjere kojima se može utjecati na broj pretilih osoba. Primarna prevencija pretilosti obuhvaća mjere koji bi poticale djecu i mlade na zdrav način života što se ujedno i smatra najzahtjevnijim dijelom čitavog preventivnog programa. Sekundarna prevencija stavlja fokus na rizičnog individualca. Važno je uočiti problem prekomjerne tjelesne težine i bolesti koje taj problem vuče za sobom. Tercijarna prevencija se zasniva na multidisciplinirano pristupu i bavi se pojedinačnim razmatranjem problema pretilosti i bolesti koje su povezane s njim uz redovito antopometrijsko i biokemijsko praćenje (Medanić i Pucarin-Cvetković, 2012).

Ako se želi shvatiti izvor problema, onda se krivac mora potražiti u nesrazmjeru kalorijskog unosa i kalorijske potrošnje. Zato neke mjere i naglašavaju intervencije u liječenju pretilih osoba pomoću smanjenja kalorijskog unosa, povećane tjelesna aktivnosti i promjene u ponašanju. Razvijen je veliki broj različitih dijeta i planova prehrane, a istraživanja pokazuju

da je ključ uspješnog gubitka mase u kalorijskoj redukciji, odnosno odgovarajućem omjeru kalorijskog unosa i kalorijske potrošnje. (Viđak et al., 2017). Ovakvo shvaćanje pomaže u razvoju smjera edukacijskog djelovanja. Nije moguće osvijestiti populaciju jednostavnim upoznavanjem problema pretilosti već i njenim „rješenjem“. Upravo zato, u promicanju prevencije i liječenja pretilosti kao važnog cilja javnog zdravstva bitno je zadovoljiti sljedeće preporuke (Gonzales i Gilmer, 2006):

- Informirati i obrazovati zdravstvenu zajednicu o važnosti zdrave prehrane, tjelesne aktivnosti i zdravog načina života
- Obavijestiti i educirati zdravstvenu zajednicu o procjeni stanja težine i rizika neprikladne promjene tjelesne težine

Sve ovo ukazuje na to kako je moguće provesti opsežnu edukaciju u Republici Hrvatskoj koja može pomoći mnogim ljudima koji se bore s problemom pretilosti. Biološki i financijski model su pokazali kako nakon nekog vremena osoba može postati nepretila i trošak kojeg generira u sustavu zdravstva se može značajno reducirati. Upravo redukcija tog troška otvara prostor za ulaganje u edukaciju svih građana Republike Hrvatske, neovisno o tome jesu li pretili ili ne. Cilj je osvijestiti građane o ovom masivnom problemu s kojima se suočava suvremeni svijet.

Problem pretilost se može smanjiti jedino izravnim mjerama. Tri ključna područja se nameću, uključujući zdravstvenu edukaciju i promicanje, reguliranje i fiskalne mjere te savjetovanje u primarnoj zdravstvenoj zaštiti. Sve su učinkovite te imaju povoljan troškovni učinak u odnosu na scenarij gdje se tretiraju kao kronične bolesti samo kad nastaju (Sassi, 2010). Zdravstvena edukacija ima povoljan utjecaj na smanjenje broja pretilih osoba jer promiče znanje koje je potrebno za smanjenje tjelesne kilaže. Mnogi ljudi nisu svjesni problema kojeg generira pretilost, gledanog prije svega kao zdravstveni problem a tek onda ekonomski

5. Zaključak

U Republici Hrvatskoj financiranje zdravstvene zaštite provodi Hrvatski zavod za zdravstveno osiguranje i ono zauzima centralno mjesto u zdravstvenom sustavu. Svaka osoba u Republici Hrvatskoj plaća obavezno zdravstveno osiguranje koje mu u slučaju bolesti osigurava pokriće dijela troškova do pune cijene. Dok su neke bolesti determinirane genetskim predispozicijama, druge se pojavljuju zbog specifičnih životnih navika gdje je čovjek glavni krivac za probleme koje posljedično nastaju. Neovisno o tome zbog čega su se pojavile, pokrivene su obveznom zdravstvenom zaštitom i svaki čovjek u Hrvatskoj ima pravo na to. Tako i stanje pretilosti, iako nije okarakterizirano kao bolest već faktor rizika, generira velike financijske troškove u sustavu zdravstva u RH, kao i u čitavom modernom svijetu. Ne samo moralna, već i pravna odgovornost zdravstvenog sustava je pobrinuti se da pretile osobe dobiju punu zdravstvenu skrb za liječenje tegoba koje su nastale kao posljedica prekomjerne i pretile tjelesne težine. Prema medicinskim kriterijima, kao mjera za karakterizaciju pretilosti kod pojedinaca koristi se indeks tjelesne mase. Indeks tjelesne mase iznad 25 označava kategoriju pretilosti. Glavni krivac za stanja pretilosti se smatra nesrazmjer između kalorijskog unosa i kalorijske potrošnje, odnosno pojava svakodnevnog kalorijskog suficita što neizbježno dovodi do povećanje tjelesne težine. Pretilost vodi ka pojavi različitih bolesti, kao što su kardiovaskularne bolesti, razne vrste raka, dijabetes tipa 2, bolesti jetre, bubrega, pluća ali utječe i na psihološke i socijalne probleme. Dakle, radi se o ozbiljnom problemu koji utječe na kvalitetu ljudskih života kao i na mortalitet u Republici Hrvatskoj.

Istraživanja su pokazala kako postoji trend povećanja broja pretilih u svim zemljama Europske unije što će dovesti do problema kojim se ovaj radi dijelom i bavi, a to je generiranje enormnog financijskog troška. Sve vlade Europske unije rade na strateškim smjernicama koje bi pomogle u rješavanju ovog problema. No, sudeći po dosadašnjim rezultatima, jedini način za rješavanje ove „epidemije“ se može pronaći u edukacijskom djelovanju. Smjer djelovanja se ne može zaustaviti samo na već pretilim osobama, već mora biti usmjeren i na djecu i na odrasle koji nisu prekomjerne tjelesne težine. Vidljiv je sve veći porast pretilosti među djecom predškolske i školske dobi. Stoga, edukacija mora početi od školskih ustanova kako bi se djecu od malih nogu naučilo kakve posljedice pretilost ima na ljudski život ali i na društvo u cjelini.

Za potrebu smanjenje broja pretilih a sukladno tome i smanjenje troškova kojeg stvaraju pretile osobe, razvijen je biološko-financijski sustavko dinamički model koji simulira vremensku dinamiku potrebnu za djelovanju u području smanjenja troškova pretilosti u Hrvatskoj. Simulacije su pokazale kako je potrebno tri i pol godine da se značajno smanji broj pretilih osoba u Hrvatskoj. U 2007. godini, procijenjeno je da su u Hrvatskoj direktni (prevencija, dijagnoza, tretmani i usluge za zdravstvenu skrb pretilih osoba, hospitalizacija, liječničke usluge, lijekovi) i indirektni troškovi (bolesti i smrtnost) pretilih osoba iznosili 256.275.970 kn što je prosječno 322,78 kn po pretiloj osobi. Ukupni trošak zdravstvene zaštite 2007. godine u Hrvatskoj je iznosio 15.332.116.313 kn što je činilo 1,671% troška pretilosti u ukupnom trošku zdravstvene zaštite. Novijih istraživanja na ovom području u Republici Hrvatskoj nema, pa se vjerojatno radi o puno većem postotku troška pretilosti u ukupnom trošku zdravstvene zaštite.

Ograničenja navedenog biološkog modela je poopćavanje vremenskog roka za smanjenje tjelesne težine na sve pretile osobe u Hrvatskoj. Dakle, model daje hipotetsku mogućnost rješavanja problema pretilosti u Hrvatskoj. Iako je biološki model medicinski točan, daje vremenski okvir za djelovanje na individualca sa zadanom težinom, ne može ga se uzeti kao reprezentativnog za djelovanje u realnim okvirima. Upravo se zato sustavsko dinamički model koristi za prikazivanje strukturirane stvarnosti, kako bi nam predstavio okvir za pregled korisnosti i dosljednosti. Važan zaključak ovog rada je da se može djelovati u području rješavanja pretilosti te postoji načini da se zaustavi konstantno povećanje zdravstvenog troška pretilosti jedino ako se izravno djeluje na izvor problema, a to je zaustavljanje širenja pretilosti ali i osvještavanje pretilih osoba o problemu i rješavanju istoga. Vremenski rok koji je model dao, tri i pol godine, uštedio bi državu veliku svotu novaca. Dakle, ne bi postojale izlike državne vlasti u pronalasku novaca za rješavanje problema pretilosti. Ušteđeni novac bi se mogao ponovno iskoristiti za ulaganje u edukacijske materijale, konvencije i programe. Dok Vlada i vladine institucije ne usmjere svoje djelovanje u provedbu smjernica za rješavanje problema pretilost, ovaj problem će se nastaviti gomilati u epidemiološkim proporcijama.

LITERATURA:

[1] Božikov, J. (2002): Modeliranje i simulacija. Dostupno na: https://bib.irb.hr/datoteka/347082.modeliranje_i_simulacija_-_v2a2.pdf [Pristupljeno: 25.6.2018]

[2] Cuschieri, S., Mamo, J. (2016): Getting to grips with the obesity epidemic in Europe. SAGE Open Medicine. Volume 4: 1-6.

[3] Čerić, V. (1993): Simulacijsko modelirane. Prvo izdanje. Školska knjiga, Zagreb.

[4] Čubrilo-Turek, M., Turek, S., Narančić, N., Rudan, P. (2007): The costs of obesiy in Croatia. Atherosclerosis Supplements. Elsevier. 184-184.

[5] Donev, D., Kovacic, L., Laaser, U. (2013): Health: Systems – Lifestyle – Policies: The role and organization of health systems. A Handbook for Teachers, Researchers and Health Professionals (2nd edition) Volume I.

[6] Erixon, F. (2016): Europe's Obesity Challenge. European Centre for International political economy.

[7] FAO/WHO/UNU Expert Consulation (2001): Human energy requirement. World Health Organization. Dostupno na: http://www.fao.org/3/a-y5686e.pdf [Pristupljeno: 27.6.2018]

[8] Forrester, J. W. (2009): Some Basic Concepts in System Dynamics. Sloan School of Management. Massachusetts Institute of Technology.

[9] Gonzales, L. J., Gilmer, L. (2006): Obesity Prevention in Pediatrics: A pilot pediatric resident curriculum intervention on nutririon and obesity education and counseling. Journal of national medical association. Vol. 98, No. 9.

[10] Hrvatski zavod za zdravstveno osiguranje (2008): Izvješće o financijskom poslovanju Hrvatskog zavoda za zdravstveno osiguranje u razdoblju I. – XII. 2007. godine. Zagreb. Dostupno na: http://www.hzzo.hr/wp-content/uploads/2018/04/Izvjesce_o_poslovanju_hzzo_01122017.pdf [Pristupljeno: 23.6.2018]

[11] Hrvatski zavod za zdravstveno osiguranje (2018): Izvješće o poslovanju Hrvatskog zavoda za zdravstveno osiguranje za 2017. godinu. Zagreb. Dostupno na: http://www.hzzo.hr/wp

content/uploads/2018/04/Izvjesce_o_poslovanju_hzzo_01122017.pdf?b32def [Pristupljeno: 21.6.2018)

[12] Jabukowski, E., Busse, R. (1998): Health Care Systems in the EU – A comparative study. European Parliament. Luxembourg.

[13] Karlsson A., Persson, T. (1998): Powersim – A short introduction. Systems Analysis Group. Uppsala University. Dostupno na: https://studentportalen.uu.se/uusp-filearea-tool/download.action?nodeId=390219&toolAttachmentId=94951 [Pristupljeno: 24.7. 2018]

[14] King, D. (2011): The future challenge of obesity. The Lancet. Vol 378., pp. 741-743.

[15] Kovač, N. (2013): Financiranje zdravstva – situacija u Hrvatskoj. Pregledni članak. Ekonomski vjesnik, br. 2/2013, str. 551-563.

[16] Lehnert, T., Strealtchenia, P., Konnopka, A., Riedel-Heller, S. G., König, H. (2015): Health burden and costs of obesity and overweight in Germany: an update. The European Journal of Health Economics, Volume 16, Issue 9, pp 957-967.

[17] Livingstone, M. B. (2001): Childhood obesity in Europe: a growing concern. Public Health Nutrition, Volume 4, Issue 1a, pp. 109-116.

[18] Lobstein, T. (2010): The price of obesity. International Association for the Study of Obesity. Dostupno na: http://www.safefood.eu/SafeFood/media/SafeFoodLibrary/Documents/Professional/All-island%20Obesity%20Action%20Forum/Cost-of-Obesity1.pdf [Pristupljeno: 13.6.2018]

[19] Madden, D. (2006): Body Mass Index and the Measurement of Obesity. HEDG Working paper 06/11

[20] Medanić, D., Pucarin-Cvetković, J. (2012): Pretilost – Javnozdravstveni problem i izazov. Acta Med Croatica, 66, 347-355. Klinički bolnički centar Zagreb.

[21] Merrill, R. M., Richardson, J. S. (2009): Validity of Self-reported Height, Weight, and Body Mass Index: Findings from the National Health and Nutrition Examination Survey. Preventing Chronic Disease

[22] Mifflin, M. D., St Jeor, S. T., Hill, L. A., Scott, B. J., Daugherty, S. A., Koh, Y. O. (1990): A new predictive equation for resting energy expenditure in healty individuals. American Journal of Clinical Nutrition. 51:241-7

[23] Navarro-Barrientos, J. E., Rivera, D. E., Collins, L. M. (2011): A dynamic model for describing behaviuoral interventions for weight loss and body composition change. Taylor & Francis. Mathematical and Computer Modelling of Dynamical Systems. Vol. 17, No. 2, 183-203.

[24] Muller, M. J., Geisler, C. (2017): Defining obesity as a disease. European Journal of Clinical Nutrition, No 71, pp. 1256-1258.

[25] Narodne novine (2008): Zakon o zdravstvenoj zaštiti. Zagreb: Narodne novine br. 150/08

[26] Pejić-Bach, M., Čerić, V. (2007): Developing system dynamics models with „Step-by-step“ approach. Faculty of economics. University of Zagreb. Journal of Information and Organizational Sciences, Vol. 31. No. 1.

[27] Powersim Software AS (2003): Powersim Studio 2003 User's Guide. The Business Simulation Company

[28] Pruyt, E. (2013): Small System Dynamics Models for Big Issues: Triple Jump towards Real-World Complexity. First edition. TU Delft Library, Delft, The Netherlands.

[29] Robertson, A., Lobstein, T., Knai, C. (2007): Obesity and socio-economic groups in Europe: Evidence review and implications for action.

[30] Sassi, F. (2010): Obesity and the Economics of Prevention. OECD.

[31] Suchanek, P., Kralova Lesna, I., Mengerova, O., Mrazkova, J., Lanska, V., Stavek, P. (2012): Which index best correlates with body fat mass: BAI, BMI, waist or WHR? Neuroendocrinology Letters, Volume 33, Suppl. 2

[32] Svjetska banka (2007): Healthy Development – The World Bank Strategy for HNP Results. (dostupno na: http://siteresources.worldbank.org/HEALTHNUTRITIONANDPOPULATION/Resources/281627-1154048816360/AnnexLHNPStrategyWhatisaHealthSystemApril242007.pdf)

[33] Thomas, D. M, Martin, C. K., Heymsfield, S., Redman, L. M., Schoeller D. A., Levine, J. A. (2014): A simple model predicting individual Weight change in humans. Journal of Biological Dynamics. Vol 5, No. 6, 579-599

[34] Thomson, S., Foubister, T., Mossialos, E. (2009): Financing Health Care in The European Union. Challenges and policy responses. World Health Organization.

[35] Tremmel, M., Gerdtham, U. G., Nilsson, P. M., Saha, S. (2017): Economic Burden of Obesity: A Systematic Literature Review. Interanational Journal of Environmental Research and Publich Health.

[36] Trust for America's Health (2014): The State of Obesity: Better Policies for a Healthier America. Robert Wood Johnson Foundation.

[37] Viđak, M., Tokalić, R., Tomičić, M., Petric, D. (2017): European guidelines for obesity treatment: review. Med Fam Croat, Vol 25, No 1-2.

[38] Zekić-Sušac, M. (2013): Sistemska dinamika. Materijali sa predavanja iz kolegija Poslovne simulacije. Ekonomski fakultet Osijek. (Dostupno na: http://www.efos.unios.hr/poslovne-simulacije/wp-content/uploads/sites/180/2013/04/P6_Sistemska-dinamika.pdf)

[39] Wang, Y. C., McPherson, K., Marsh, T., Gortmaker, S. L., Brown, M. (2011): Health and economic burden of the projected obesity trends in the USA and the UK. The Lancet. Volume 378, No. 9793, pp. 815-825.King for WK Kellogg Foundation

[40] Williams, B., Harris, B. (2005): System Dynamics Methodology. Workshop organized by Eoyang, G., Wiliams, B., Harris, B.

[41] World Health Organization (2003): Global strategy on diet, physical activity and health. Obesity and overweight. WHO.

[42] World Health Organization (2007): The Challenge of obesity in the WHO European region and stretegies for response

[43] World Health Organization (2014): Obesity and inequities. Guidance for addressing inequities in overweight and obesity

[44] Yates, N., Teuner, C. M., Hunger, M., Holle, R., Stark, R., Laxy, M., Hauner, H., Peters, A., Wolfenstetter, S. B. (2016): The Economic Burden of Obesity in Germany: Results from the Population-Based KORA Studies. Obesity Facts. The European Journal of Obesity.

[45] Yumuk, V., Tsigos, C., Fried, M., Schindler, K., Busetto, L., Micic, D., Toplak, H. (2015): European Guidelines for Obesity Management in Adults. Obesity Facts. The European Journal of Obesity

POPIS TABLICA

Tablica 1. Rashodi – izdaci u obveznom zdravstvenom osiguranju 11
Tablica 2. Ukupna zdravstvena zaštita 11
Tablica 3. Udio zdravstvene potrošnje u BDP-u 14
Tablica 4. Kategorije indeksa tjelesne mase 17
Tablica 5. Varijable biološkog modela 33
Tablica 6. Notacije varijabli 35

POPIS SLIKA

Slika 1. Učešće pojedinih kategorija osiguranika u ukupnom broju osiguranika 10
Slika 2. Trošak po stanovniku u kunama (2015. godina) 13
Slika 3. Zdravstvena potrošnja po tipu financiranja (2014) 15
Slika 4. Indeks tjelesne mase u Europi u 2014. godini 20
Slika 5. Trend kretanja stope pretilosti u svijetu 20
Slika 6. Sustavsko dinamički simboli 24
Slika 7. Pozitivna i negativna povratna petlja 25
Slika 8. Promjena stanja sustava i tokovi 30
Slika 9. Grafički prikaz stanja sustava 30
Slika 10. Grafički prikaz pomoćne varijable 31
Slika 11. Grafički prikaz konstante 31
Slika 12. Strukturni dijagram biološkog modela 32
Slika 13. Biološki računalni model u Powersimu 39
Slika 14. Vremenska dinamika za muškarca 40
Slika 15. Kretanje indeksa tjelesne mase kod muškarca 41
Slika 16. Vremenska dinamika za žene 41
Slika 17. Kretanje indeksa tjelesne mase kod žene 42
Slika 18. Strukturni dijagram financijskog modela 43
Slika 19. Financijski računalni model 45
Slika 20. Vremenska dinamika ukupnih troškova 46

SAŽETAK

Suvremeni svijet se suočava s rastućom stopom broja pretilih osoba. Problem pretilosti ostavlja velike posljedice na kvalitetu života, zdravstveni sustav kao i na društvo u cjelini. Mnogi zdravstveni poremećaji povezani s viškom tjelesne težine dokazano generiraju veće financijske troškove zdravstvene zaštite od osoba normalne tjelesne težine. Republika Hrvatska je jedna od zemalja koja se suočava s ovim brzorastućim problemom bez jasno definiranih smjernica.

Problem pretilosti je povezan s nizom zdravstvenih problema kao što su kardiovaskularne bolesti, nekoliko vrsta raka, dijabetes tipa 2, psihološki i socijalni problemi. Postoje jasni pokazatelji da pretile osobe imaju veće zdravstvene troškove koje su povezane s većim indeksom tjelesne mase. Indeks tjelesne mase je medicinska mjera koja karakterizira osobu kao pretilu ili nepretilu.

Sustavskom dinamičkim programom je izrađen model koji služi za prikazivanje strukturirane stvarnosti, a sve s ciljem pregleda korisnosti i dosljednosti danog problema. U radu je izrađen sustavsko dinamički model koji simulira redukciju tjelesne kilaže, a sustavno i smanjenje financijskih troškova. Biološko-financijski sustavsko dinamički model je dao okvirni vremenski rok za djelovanje u području redukcije troškova koji se gomilaju u zdravstvenom sustavu, a vezani su uz smanjenje broja pretilih osoba. Simulacije su pokazale kako je potrebno 3 i pol godine da bi se riješio problem pretilosti u Hrvatskoj. Da bi se problem riješio, potrebno je djelovanje u području edukacije, počevši od školske dobi pa do osoba koje već imaju razvijene probleme uzrokovane prekomjernom i pretilom tjelesnom težinom, primarno podizanjem svijesti od zdravom načinu života. Jedino izravne mjere mogu utjecati na rješavanje problema pretilosti.

Ključne riječi: pretilost, sustavsko dinamički model , troškovi.

SUMMARY

The modern world is facing an increasing rate of obesity. The problem of obesity leaves a enormous consequences on the quality of life as well as society as a whole. Many health realted disorders associated with excess body weight have been proven to generate higher financial cost of health care than normal body weight individuals. The Republic of Croatia is one of the countries facing this fast-paces problem without clearly defined guidelines.

The problem of obesity is associated with a series of health problems such as cardiovascular disease, sever types of cancer, diabetes type 2, psychological and social problems. There are clear indications that obese people have higher health costs associated with a higher body mass index. The body mass index is a medical measure that characterizes a person as obese or normal weight person.

The system dynamic program has created a model that serves to show a structured reality, all with the aim of reviewing the utility and consistency of a given problem. A systematic dynamic model that simulates body weight reduction and systematic reduction of financial costs has been developed. The Biological-Financial System Dynamic Model has given a framework for action in the field of cost reduction that is accumulating in the health care system and is linked to the reduction of the number of obese people. Simulations have shown that it takes 3 and a half years to solve the problem of obesity in Croatia. To solve the problem, it is necessary to act in the field of education, starting from school age to those who already have developed problems caused by overweight and obesity, primarily by raising awareness of a healthy lifestyle.Only direct measures can affect the problem of obesity.

Key words: obesity, system dynamic, costs.