

Modeliranje širjenja COVID-19 v Sloveniji z razširjenim SEIR modelom

Tine Koc

Mentor: izr. prof. dr. Gregor Klančar

Univerza v Ljubljani, Fakulteta za elektrotehniko

Tržaška c. 25, 1000 Ljubljana, Slovenija

tine.koc@gmail.com, gregor.klancar@fe.uni-lj.si

Modeling the spread of COVID-19 in Slovenia with the extended SEIR model

Models of the spread of an epidemic can be useful tools in dealing with and preparing measures that can have a decisive impact on the duration severity of an epidemic. With the usage of appropriate model, decision-makers can act preventively, thus significantly reducing the number of victims and the duration of restrictive measures that are put in place during the epidemic and have a major impact on people's lives. In this article a model of the spread of coronavirus disease 2019 in Slovenia using the SEIR model with certain extensions is presented. An important extension of the basic model is the ability to model and predict the number of deaths, as reducing the number of victims is certainly the most important goal when making decisions. Another important extension is vaccination modeling, which provides insight into the further course of the epidemic, and enables simulation of scenarios with different vaccines and vaccination strategies. In addition to the mentioned extensions, the article also presents the problem of insufficient data and related problems, especially the problem of estimating virus mortality.

Kratek pregled prispevka

Modeli širjenja epidemije so lahko uporabna orodja pri soočanju in pripravi ukrepov in rešitev, ki lahko odločilno vplivajo na trajanje ter resnost epidemije. Z uporabo primerne modela lahko odločevalci ravnajo preventivno in na ta način znatno zmanjšajo število žrtev ter čas trajanja omejitvenih ukrepov, ki veljajo tekom epidemije in močno vplivajo na življenje ljudi. V članku je predstavljen model širjenja koronavirusne bolezni 2019 v Sloveniji z uporabo SEIR modela z določenimi razširitvami. Pomembna razširitev osnovnega modela je zmožnost modeliranja in napovedovanja števila umrlih, saj je manjšanje števila žrtev gotovo najpomembnejši cilj pri sprejemanju odločitev. Druga pomembna razširitev pa je modeliranje cepljenja, ki omogoča vpogled v nadaljnji potek epidemije, ter simulacijo scenarijev z različnimi cepivi ter režimi cepljenja. Poleg omenjenih razširitev je v članku predstavljen tudi problem nezadostnih podatkov ter s tem povezanimi težavami, s posebnim poudarkom na težavi ocene smrtnosti virusa.

1 Uvod

Leto 2020 je svet in Slovenijo najbolj zaznamovala pandemija bolezni COVID-19. Hitro in v veliki meri nenadzorovano širjenje je imelo in do neke mere še vedno ima velik vpliv tako na stanje v družbi kot tudi na vsakodnevno življenje ljudi.

V tem članku je predstavljen model širjenja prej omenjene bolezni v družbi, natančneje v Sloveniji v letu 2020 in 2021. Z uporabo takšnega ali podobnega modela bi se lahko uspešneje spopadli z epidemijo in potencialno rešili veliko življenj. Predstavljeno je matematično ozadje modelov SIR [1] ter SEIR [2], ter lastne dodatne razširitve, ki so bile dodane z namenom izboljšanja uporabnosti modela. Najpomembnejša razširitev je gotovo modeliranje cepljenja saj ima lahko le-to odločilen vpliv na potek in trajanje epidemije. Poleg samega ogrodja modela je predstavljena tudi primerjava rezultatov, ki jih model vrne, z resničnimi podatki za obdobje od poletja 2020 do pomladi 2021.

Poseben poudarek pa je namenjen tudi težavam s katerimi se soočamo pri načrtovanju ter uporabi tovrstnih modelov. Podrobneje je predstavljen primer pomanjkljivih podatkov ter njihov vpliv na modeliranje in rezultate.

2 Zgradba modela

V splošnem lahko matematične modele širjenja bolezni razdelimo na stohastične in deterministične. Vsi modeli predstavljeni v tem članku sodijo v kategorijo stohastičnih.

2.1 SIR model

Najbolj klasičen in enostaven model je gotovo model SIR [1]. Najpogosteje se ga uporablja za enostavno modeliranje hipotetičnih epidemij. Osredotočil se bom le na model brez vitalne populacije, tj. privzamemo, da se populacija N v času opazovanja širjenja epidemije ne spremeni bistveno zaradi rojstev in

smrti. Model je sestavljen iz treh kategorij, ki jih povezujejo diferencialne enačbe. Kategorije in enačbe so naslednje: \mathbf{S} – dovzetni (susceptible), \mathbf{I} – kužni (infectious), \mathbf{R} – preboleli (recovered)

$$\frac{dS}{dt} = -\frac{\beta I S}{N} \quad (1)$$

$$\frac{dI}{dt} = \frac{\beta I S}{N} - \gamma I \quad (2)$$

$$\frac{dR}{dt} = \gamma I \quad (3)$$

V katerih β predstavlja povprečno število kontaktov na osebo na enoto časa, γ pa je faktor trajanja bolezni in je enak inverzni vrednosti števila časovnih enot trajanja bolezni. V naši študiji je časovna enota en dan.

Razvidno je, da taka oblika modela omogoča le osnovno modeliranje in ne predvideva smrtnih žrtev. Ogrodje, ki je zastavljeno z modelom SIR je naprej uporabljeno tudi v bolj kompleksnih modelih. Eden izmed takih modelov in model na katerem je zgrajen ta članke je tudi model SEIR.

2.2 SEIR model

Model SEIR je zelo podoben modelu SIR le, da dodamo kategorijo izpostavljenih (exposed) oseb. To naredimo predvsem zato, ker pri večini boleznih, in tudi pri COVID-19, oseba ne postane kužna isti dan, kot se je okužila. To modeliram z novo kategorijo, ki v bistvu predstavlja neko zakasnitev med kategorijama S in I.

$$\frac{dE}{dt} = \frac{\beta I S}{N} - \alpha E \quad (4)$$

Enačba (4) prikazuje relacijo med kategorijo dovzetnih S in kategorijo okuženih I, ki pa za razliko od tistih v kategoriji I še niso prenašalci bolezni, pač pa to postanejo po času, ki ga določimo s faktorjem α . V primeru COVID-19 je ta faktor $1/3$ [1/dan], saj je povprečna inkubacijska doba tri dni.

2.3 Razširitve SEIR modela

Poleg dodatne kategorije izpostavljenih oseb, ki jo uvedemo predvsem zaradi specifikacije bolezni, ki jo želimo modelirati, je smiselno dodati še druge razširitve

2.3.1 Umrli, hospitalizirani, intenzivna nega

Najenostavnejša, kar se tiče realizacije, je dodatna kategorija umrlih, saj je njena povezava z ostalimi kategorijami (5) odvisna le od stopnje smrtnosti, tj. samo od enega parametra. Tukaj naletimo na težavo določanja parametra ϑ , ki je podrobneje razložena kasneje.

$$\frac{dD}{dt} = \vartheta I \quad (5)$$

Poleg kategorije umrlih je smiselno dodati še kategoriji hospitaliziranih in oseb na intenzivni negi, saj so to podatki, ki jih želimo napovedovati z modelom. Podobno kot za umrle, tudi tukaj le določimo nek parameter stopnje hospitalizacije oz. sprejema na intenzivno nego, ki ga povežemo s številom trenutno okuženih oseb, tj. kategorija I.

2.3.2 Modeliranje cepljenja

Težja razširitev pa je dodajanje modeliranja cepljenja. V splošnem imamo na voljo dve možnosti in sicer t.i. pulzno cepljenje in pa cepljenje po neki časovni funkciji. V primeru pulznega cepljenja cepimo na isti dan velik delež populacije (npr. 20-30%) in potem opazujemo, kako tak drastičen in hiter padec dovzetnih vpliva na širjenje epidemije. Ker pa seveda v trenutnih razmerah to ni možno, saj enostavno ni dovolj cepiva, je smiselna strategija cepljenja po časovni funkciji, ki tudi najbolj sledi dejanskim razmeram.

V tem primeru je potrebno določiti nek vektor od začetka do konca simulacijskega obdobja, v katerem določimo, koliko oseb bo cepljenih na določen dan. Poleg tega je treba upoštevati tudi delovanje cepiva. Model je narejen za cepivo, ki potrebuje dva odmerka med katerima mora miniti določeno število dni,

ter po katerem lahko določeno število oseb odstranimo iz kategorije dovzetnih.

$$\frac{dV1}{dt} = vac1 * vac1\% - vac2 * vac2\% \quad (6)$$

$$\frac{dV2}{dt} = vac2 * vac2\% \quad (7)$$

Enačba (6) predstavlja spreminjanje števila oseb cepljenih s prvim odmerkom, enačba (7) pa z drugim. V vektorjih $vac1$ in $vac2$ je določeno dnevno število cepljenih, parametra $vac1\%$ in $vac2\%$ pa predstavljata odstotek uspešnosti cepiva.

Model cepljenja ne loči med starostnimi kategorijami kar je gotovo največja pomanjkljivost celotnega modela širjenja epidemije, saj privzamemo, da cepljenje poteka v vseh starostnih kategorijah enako, kar seveda ne drži. Zato lahko pride do napačnih napovedi predvsem umrlih in hospitaliziranih, saj cepljenje starejših oseb bistveno vpliva na število umrlih in hospitaliziranih, medtem, ko na število novo okuženih oseb na dan ne vpliva močno.

2.4 Končna oblika modela

Vse prej omenjene razširitve je potrebno le smiselno povezati in tako dobimo model, ki je bil uporabljen za namen tega članka:

$$\frac{dS}{dt} = -\frac{\beta I S}{N} + \Delta R - vac1 * vac1\% - vac2 * (vac2\% - vac1\%) \quad (8)$$

$$\frac{dE}{dt} = \frac{\beta I S}{N} - \alpha E \quad (9)$$

$$\frac{dI}{dt} = \alpha E - \gamma I - \vartheta I \quad (10)$$

$$\frac{dH}{dt} = \nu I - T_v H \quad (11)$$

$$\frac{dH_{INT}}{dt} = \epsilon I - T_\epsilon H_{INT} \quad (12)$$

$$\frac{dR}{dt} = \gamma I - \Delta R - vac1 * vac1\% - vac2 * (vac2\% - vac1\%) \quad (13)$$

Poleg enačb od (8) do (13) so v končni obliki modela uporabljene tudi enačbe (5), (6) in (7).

Enačbe v končnem modelu se zaradi razširitev nekoliko razlikujejo od osnovnih enačb predstavljenih zgoraj. Med drugim je dodana izguba imunosti Δ . Upoštevati pa je bilo potrebno tudi medsebojne vplive ter jih primerno odšteti oz. prišteti.

3 Določanje parametrov modela

Poleg sistema enačb je seveda potrebno določiti tudi parametre, ki nastopajo v njih.

3.1 Viri podatkov

Večino parametrov smo ocenili na podlagi javno dostopnih podatkov. Podatki uporabljeni v tem modelu so bili pridobljeni s spletnih strani Ministrstva za zdravje [3], NIJZ ter v veliki meri s spletnega mesta Covid-19 sledilnik [4]. Med podatki so se občasno pojavila manjša odstopanja, predvsem glede števila umrlih, ki so posledica zakasnitev pri objavljanju podatkov.

3.2 Reprodukcijsko število R_0

Najpomembnejši parameter in parameter na katerem sloni celoten model je gotovo reprodukcijsko število R_0 [5], ki pa ni neposredno povezano s kategorijo R (2.1).

$$R_0 = e^{K\tau} \quad (14)$$

$$K = \frac{\ln(2)}{T_d} \quad (15)$$

Določeno je bilo z enačbama (14) in (15), v katerih je τ čas trajanja bolezni T_d pa podvojitveni čas, ki ga določimo na podlagi stopnje rasti novo okuženih med dvema dnevoma. Za bolj robustno delovanje in za odpravo velikih skokov števila novo okuženih preko koncev tedna je v modelu uporabljeno pet dnevno drseče povprečje R_0 .


Potrebno pa se je zavedati, da je dobljen rezultat le ocena reprodukcijskega števila saj nimamo točnih podatkov koliko ljudi je bilo okuženih na določen dan, pač pa le koliko okužb je bilo zaznanih. Ta težava se izkaže za precej večjo pri določanju stopnje smrtnosti in hospitalizacije.

3.3 Stopnja smrtnosti

Stopnja smrtnosti za določen dan n je izračunana z enačbo (16).

$$\vartheta_n = \frac{\text{skupno število umrlih do dneva } n}{\text{potrjene okužbe do dneva } n - 10} \quad (16)$$

Hitro je razvidno, da je stopnja smrtnosti odvisna ne le od števila umrlih pač pa tudi od števila potrjenih okužb. Izkaže se, da se s časom stopnja smrtnosti spreminja, kar je lepo vidno na sliki 1. Razlag za to je lahko več, najbolj smiselni pa bi lahko bili, da se je spremenila struktura okuženih in posledično umrlih, drugi pa, da je bil obseg testiranja relativno manjši.



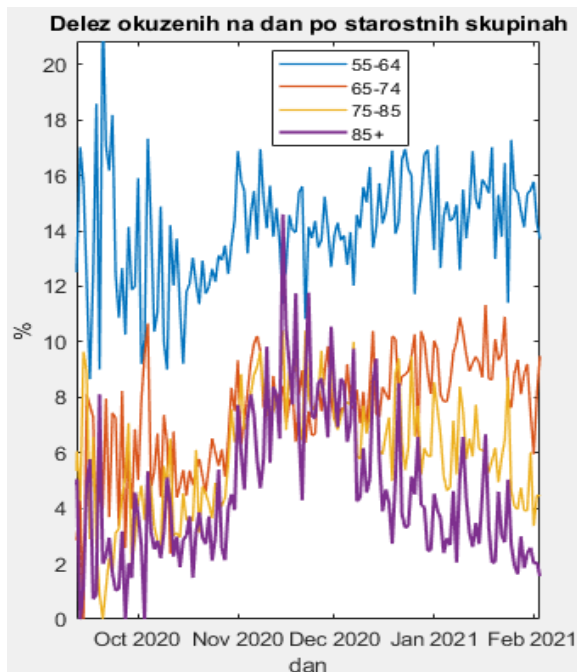
Slika 1: Spreminjanje smrtnosti

3.3.1 Spremenjena struktura umrlih

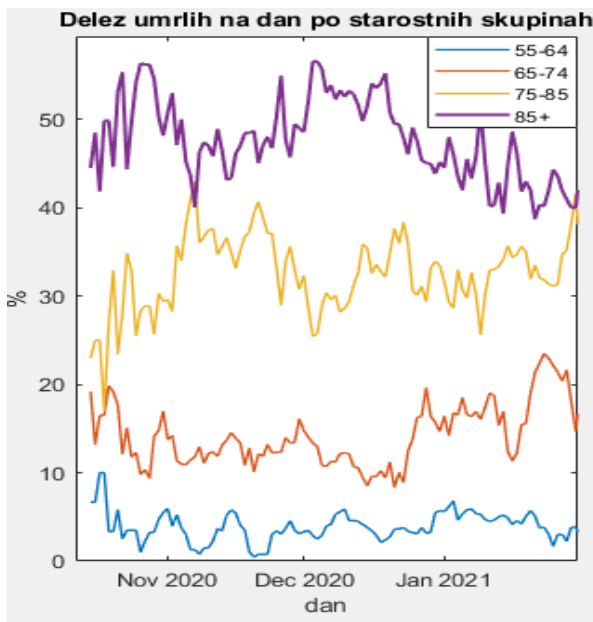
Prva razlaga je, da se je s časom spremenila starostna struktura umrlih, kar je posledično prineslo višjo smrtnost, saj je bolezen precej nevarnejša za starejšo populacijo.

Na sliki 2 je prikazan delež novo okuženih na dan glede na starostne kategorije. Vidimo lahko, da se je delež starejših od 85 let od novembra dejansko povečal iz približno 5% na 10%. Lahko sklepamo, da je to delni razlog za povečano smrtnost, a vseeno s tem povečanjem deleža ne moremo razložiti rasti stopnje smrtnosti pred tem obdobjem. Prav tako pa se je potrebno zavedati, da je bila novembra

epidemija v Sloveniji na vrhuncu in je bilo v tem času testiranje v domovih za starejše precej večje kot prej ali potem, kar lahko delno razloži povečanje deleža okuženih nad 85 let.



Slika 2: Delež okuženih po kategorijah (prikazane so samo izbrane kategorije)



Slika 3: Delež umrlih po kategorijah, drseče povprečje 5 dni, (prikazane so samo izbrane kategorije)

To lahko podpremo s sliko 3 na kateri je prikazan delež umrlih na dan po starostnih kategorijah. V primeru velikega povečanja

deleža okuženih v določeni kategoriji bi bilo smiselno pričakovati tudi povečanje deleža števila umrlih v isti kategoriji. Vendar lahko vidimo, da v času po novembru ne zaznamo velikega povečanja deleža umrlih v kategoriji nad 85 let. Iz tega lahko sklepamo, da samo sprememba strukture okuženih ni zadosten razlog za povečanje smrtnosti.

3.3.2 Manjši obseg testiranja

Druga smiselna razlaga za povečanje smrtnosti pa je, da je bilo ob hitri rasti epidemije opravljenih relativno gledano manj testov kot prej. Na ta način je bil pred jesenskim porastom števila okužb odkrit večji delež dejansko okuženih, kot kasneje. Ker pa smo še vedno zaznali vse smrti povezane s COVID-19, smrtnost navidezno zraste.

To razlago podpira tudi slika 1, na kateri je prikazano tudi število pozitivnih testov na dan. Vidimo lahko, da po hitri rasti število pozitivnih testov dolgo časa stagnira na mestu in to ravno v času hitre rasti smrtnosti. Razlaga je smiselna tudi iz čisto praktičnega vidika saj je število opravljenih testov realno omejeno glede na dostopne vire testiranja, ki se niso povečali v zadostnem obsegu.

3.3.3 Ocena smrtnosti

Za rešitev težave s spreminjanjem stopnje smrtnosti je uporabljen princip kjer je stopnja smrtnosti razdeljena v določena koledarska obdobja. Ta obdobja so različno dolga vrednost stopnje smrtnosti v njih pa prilagojena tako, da se čim bolje prilagaja izračunani stopnji smrtnosti v istem časovnem obdobju. Taka rešitev sicer ni idealna, a je vseeno zadovoljiva, kar je razvidno tudi pri rezultatih modela.

Za pretekli čas je določanje stopnje na tak način dokaj preprosto saj imamo na voljo vse podatke za njen izračun, večja težava pa nastopi pri napovedovanju stopnje za prihodnost saj nimamo podatkov na katere bi se lahko naslonili. V modelu uporabljena stopnja smrtnosti za prihodnost, je določena kot utežno povprečje stopnje smrtnosti zadnjih nekaj

obdobji za katere so še na voljo podatki. To je sicer le ocena stopnje smrtnosti, a se izkaže za sprejemljivo.

Težava sicer nastane ob večjem obsegu cepljenja, saj model ne loči med starostnimi kategorijam kot je opisano v poglavju 2.3.2.

3.4 Stopnja hospitalizacije in sprejema na intenzivno nego

Stopnjo hospitalizacije in stopnjo sprejema na intenzivno nego se izračuna na podoben način, kot smrtnost. Prav tako pa tudi pri njima naletimo na podoben težavo, kot pri smrtnosti, in sicer na spreminjanje skozi čas.

Rešitev je enaka, kot pri smrtnosti, torej uporaba končnih obdobj v katerih je stopnja določena fiksno in čim bližje dejanski stopnji v istem območju.

3.5 Ostali parametri

Parametri, ki so specifični za COVID-19 so bili določeni na podlagi do takrat znanih podatkov o bolezni. Taka parametra sta predvsem čas trajanja bolezni in dolžina inkubacijske dobe. Čas trajanja bolezni je v našem modelu določen na 10 dni, inkubacijska doba pa na 3 dni.

Prav tako je v modelu realizirana možnost izgube odpornosti po določenem času. Ta možnost je bila sicer večino časa neuporabljena, saj ni točno jasno, koliko časa je oseba odporna po preboleli okužbi in ali sploh izgubi odpornost.

4 Rezultati modela in zaključki

Vse simulacije, katerih rezultati so predstavljeni spodaj, so bile opravljene le s podatki na voljo do vključno 4.2.2021. V nekaterih simulacijah so bili uporabljeni le podatki do kakšnega drugega zgodnejšega datuma, to je tudi označeno.

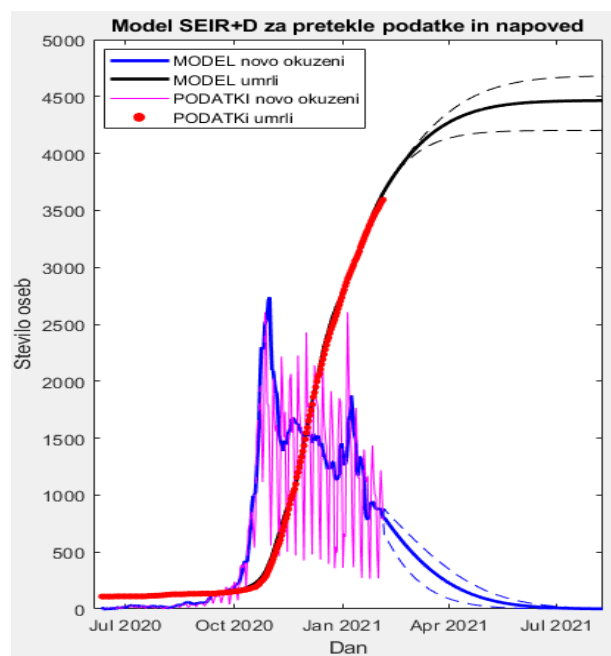
Začetni datum vseh simulacij je 11.6.2020, torej po prvem spomladanskem valu v letu 2020. Tak začetni datum je izbran zato, ker je prvi val proti drugemu valu zanemarljiv tako z

vidika skupno okuženih, kot umrlih in ga nima smisla vključevati v modeliranje drugega vala [4].

4.1 Simulacija celotnega drugega vala

Na slikah 4 in 5 so predstavljeni rezultati simulacije drugega vala od 11.6.2020 do 9.8.2021. Na sliki 4 je prikazan dnevni prirast novo okuženih in skupen seštevek umrlih. V simulaciji so bili uporabljeni podatki do vključno 4.2.2021, od tega datuma naprej pa je model izdelal napoved. S polno črto je predstavljen predviden potek epidemije v primeru, da bi R_0 ostal enak kot je bilo njegovo povprečje v zadnjih sedmih dneh, ko so podatki še na voljo. S črtkanima črtama pa v primeru, da bi padel za 20% pri spodnji črti, oziroma narasel za 10% pri zgornji.

Model, ki je podal predstavljene rezultate je predvideval tudi cepljenje. Do presečnega datuma je cepljenje skladno z realnim, od takrat naprej pa model predvidi približno 7000 cepljenih na dan, kar je precej optimistična ocena [4].




Slika 4: Rezultati modela s cepljenjem o novo okuženih in umrlih ter primerjava z dejanskimi podatki

Lepo je razvidno, da je ujemanje modela in dejanskih podatkov zelo dobro. Razlago zahteva

le krivulja, ki prikazuje dejanske podatke o dnevni novu okuženih, opaziti je izrazito spreminjanje. To spreminjanje je posledica dejstva, da je bilo testiranje ob koncih tedna bistveno manjše, kot med tednom, kar predstavlja spodnji del vijolične krivulje, zgornji del pa so v glavnem testiranja v torek, ki so bila precej nadpovprečna, saj je bilo veliko testov, ki bi sicer bili opravljeni v soboto ali nedeljo, opravljenih ob torkih.

Na sliki 5 pa so prikazani rezultati modela in dejanski podatki o številu hospitaliziranih in o številu bolnikov na enotah intenzivne terapije. Oboji rezultati so bili narejeni na istem modelu in istih parametrih kot rezultati prikazani na sliki 4.

Črčkane črte pomenijo isto kot na sliki 4.



Slika 5: Rezultati modela s cepljenjem o številu hospitalizacij in primerjava z dejanskimi podatki

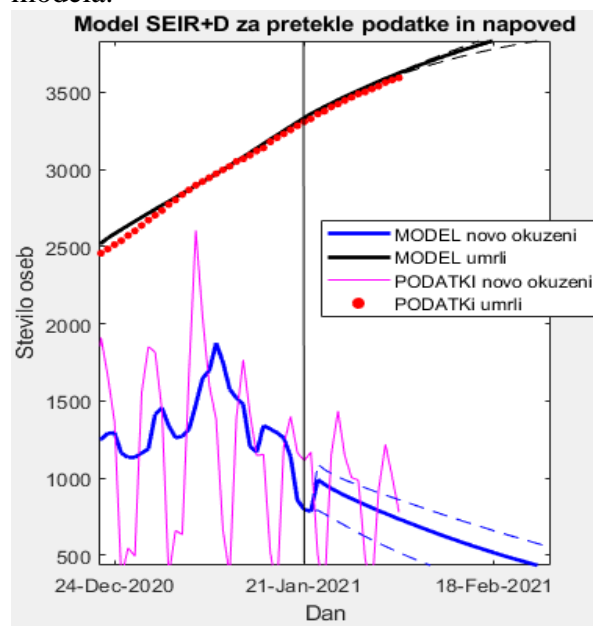
4.2 Uporaba modela za napovedovanje

Pri obeh prejšnjih slikah so bili uporabljeni vsi podatki, ki so bili na voljo v času izvajanja simulacije, zato težko ocenimo uporabnost oziroma natančnost modela. V ta namen sta v nadaljevanju predstavljena modela kratkoročne in srednjeročne napovedi pri katerih v namene simulacije uporabimo le del razpoložljivih podatkov.. Šele tako je vidna uporabna vrednost

modeliranja poteka epidemije ter tudi slabosti oziroma pasti zanašanja samo na model.

4.2.1 Kratkoročna napoved

Za razliko od prejšnjih rezultatov, so rezultati na sliki 6 pridobljeni z modelom, ki je uporabljal le podatke do 21.1.2021. Prikazani rezultati so napoved za obdobje od 21.1.2021 do 4.2.2021, dejanski podatki do istega datuma pa služijo za ugotavljanje uspešnosti modela.




Slika 6: Kratkoročna napoved (14 dni), črna navpična črta predstavlja presečni datum 21.januar 2021

Delovanje modela v danih razmerah je dokaj dobro, saj se v opazovanem času razmere v realnem svetu niso drastično in nepričakovano spremenila tako, da je model lahko dobro sledil trendu.

4.2.2 Srednjeročna napoved

Pri srednjeročni napovedi (slika 7) je presečni datum 31.december 2020. V tem primeru pa se pokažejo težave modeliranja, saj je odstopanje med modelom in dejanskimi podatki precejšnje. Razlog za to odstopanje je velik porast okužb in s tem tudi dvig R_0 zaradi spremenjenih ukrepov ob koncu leta 2020, česar model ne more predvideti. Iz tega izhaja, da je

pretirano zanašanje na model v daljšem časovnem obdobju neprimerno, saj se razmere lahko spremenijo v čisto drugo stran, ki je model nikakor ne more predvideti, saj niso odvisne od parametrov, ki jih uporablja.



Slika 7: Srednjeročna napoved (35 dni), črna navpična črta predstavlja presečni datum 31. decembra 2020

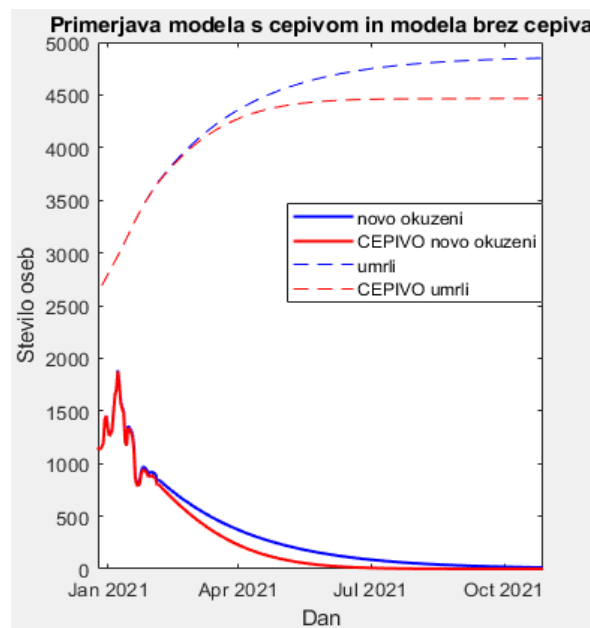
4.3 Primerjava modela s cepivom in brez cepiva

Vsi zgoraj predstavljeni rezultati so uporabljali model s cepljenjem. Na sliki 8 pa je primerjava med modelom kjer ne upoštevamo cepljenja. Razlika je manj očitna kot bi mogoče pričakovali. Največji razlog za to je, da cepljenje poteka dokaj počasi in je cepljen relativno majhen, skoraj zanemarljiv, delež populacije [4]. Potrebno se je tudi zavedati, da Evropska komisija predvideva precepljenost s 70% šele do konca poletja 2021 [6].

Glavni razlog za padec okužb pomladi leta 2021 tako ni cepivo, pač pa to, da je bilo s COVID-19 do zdaj okuženih že več kot 600.000 oseb v Sloveniji [7] kar drastično zmanjša velikost dovzetne populacije (kategorija S).

Potrebno je tudi poudariti, da predvsem število napovednih smrti pri modelu s cepljenjem ni zanesljivo zaradi že prej

omenjenega modela cepljenja, ki ne upošteva starostnih kategorij in tako ne cepi starejše populacije prioritarno, kar seveda dvigne število umrlih. Medtem, ko na rezultat napovedi števila novo okuženih to ne vpliva tako močno saj je velika večina okuženih izven kategorij za prednostno cepljenje.



Slika 8: Primerjava modelov s cepivom in brez

5 Literatura

- [1] Kermack WO, McKendrick AG (1991). "Contributions to the mathematical theory of epidemics--I. 1927". *Bulletin of Mathematical Biology*. 53 (1–2): 33–55.
- [2] SEIR and SEIRS models, Dosegljivo na <https://docs.idmod.org/projects/emod-hiv/en/latest/model-seir.html> (Dostopano 4.3.2021)
- [3] Ministrstvo za zdravje. Dostopno na <https://www.gov.si teme/koronavirus-sars-cov-2/> (Dostopano 4.3.2021)
- [4] Covid-19 sledilnik. Dostopno na <https://covid-19.sledilnik.org/sl/stats> (Dostopano 4.3.2021)
- [5] Wohl, Shirlee; Schaffner, Stephen F.; Sabeti, Pardis C. (2016). "Genomic Analysis of Viral Outbreaks". *Annual Review of Virology*. 3 (1): 173–195.
- [6] Članek o mnenju Evropske komisije. Dosegljivo na <https://www.24ur.com/novice/korona/cepljenje-evropa.html> (Dostopano 4.3.2021)
- [7] Mnenje vodje svetovalne skupine Bojane Beović. Dosegljivo na <https://www.rtvsllo.si/zdravje/novi-koronavirus/bojana-beovic-po-ocenah-je-pri-nas-covid-19-prebolelo-do-600-000-ljudi/550479> (Dostopano 4.3.2021)