

INFORMATICA MEDICA SLOVENICA



Časopis Slovenskega društva za medicinsko informatiko
Journal of the Slovenian Medical Informatics Association

LETNIK / VOLUME **27 (2022)**, ŠTEVILKA / NO. **1-2**

ISSN 1318-2129 (tiskana izdaja / printed edition)
ISSN 1318-2145 (spletna izdaja / online edition)

<http://ims.mf.uni-lj.si/>

Editor in Chief / Glavni urednik

Gaj Vidmar

Managing Editor / Odgovorna urednica

Ema Dornik

Associate Editors / Souredniki

Kevin Doughty

Malcolm Fisk

Peter Juvan

Technical and Web Editor / Tehnični in spletni urednik

Peter Juvan

Editorial Board Members / Člani uredniškega odbora

Barbara Artnik

Andreja Kukec

Brane Leskošek

Drago Rudel

Former Editors in Chief / Bivši glavni uredniki

Martin Bigec

Peter Kokol

Janez Starc

About the Journal

Informatica Medica Slovenica (IMS) is an interdisciplinary professional journal that publishes contributions from the field of medical informatics, health informatics, nursing informatics and bioinformatics. Journal publishes scientific and technical papers and various reports and news. Especially welcome are the papers introducing new applications or achievements.

IMS is the official journal of the Slovenian Medical Informatics Association (SIMIA). It is published two times a year in print (ISSN 1318-2129) and electronic editions (ISSN 1318-2145, available at <http://ims.mf.uni-lj.si>). Prospective authors should send their contributions in Slovenian, English or other acceptable language electronically to the Editor in Chief Prof. Gaj Vidmar, PhD. Detailed instructions for authors are available online.

The journal subscription is a part of the membership in the SIMIA. Information about the membership or subscription to the journal is available from the secretary of the SIMIA (Mrs. Mojca Paulin, mojca.paulin@gmail.com).

O reviji

Informatica Medica Slovenica (IMS) je interdisciplinarna strokovna revija, ki objavlja prispevke s področja medicinske informatike, informatike v zdravstvu in zdravstveni negi, ter bioinformatike. Revija objavlja strokovne prispevke, znanstvene razprave, poročila o aplikacijah ter uvajanju informatike na področjih medicine in zdravstva, pregledne članke in poročila. Še posebej so dobrodošli prispevki, ki obravnavajo nove in aktualne teme iz naštetih področij.

IMS je revija Slovenskega društva za medicinsko informatiko (SDMI). Izhaja dvakrat letno v tiskani (ISSN 1318-2129) in elektronski obliki (ISSN 1318-2145, dostopna na naslovu <http://ims.mf.uni-lj.si>). Avtorji člankov naj svoje prispevke pošljejo v elektronski obliki glavnemu uredniku prof. dr. Gaju Vidmarju. Podrobnejša navodila so dosegljiva na spletni strani revije.

Revijo prejemajo vsi člani SDMI. Informacije o članstvu v društvu oziroma o naročanju na revijo so dostopne na tajništvu SDMI (Mojca Paulin, mojca.paulin@gmail.com).

Contents

Research Papers

1 Mirza Tupkušić, Rok Blagus

Over-optimistic Assessment of the Performance of Prediction Models: An Illustration Based on the Joint Use of Sampling Techniques and Cross-Validation

14 Živa Rant, Hajdi Kosednar, Dalibor Stanimirović

The Role and Importance of the Service Desk for eHealth Solutions in Slovenian Health Care

Research Review Paper

20 Žiga Lovšin, Barbara Artnik

Data Sources on Oral Health in Slovenia

Technical Papers

27 Sara Močnik, Dejan Dinevski, Hojka Gregorič Kumperščak

The Usage of Artificial Intelligence to Diagnose and Treat Individuals with Borderline Personality Disorder

33 Mojca Dovnik, Jože Balažic, Dejan Dinevski

Potentials of Artificial Intelligence for Use in Forensic Medical Practice

SIMLA Bulletin

42 Ema Dornik, Boštjan Žvanut

MI'2022 "Decisively Digital for More Health": Report from the Meeting of the Nursing Informatics Section – SIZN 2022

Tutorial

44 Andrej Kastrin

Knowledge Networks and Their Use in Biomedicine

Vsebina

Izvirna znanstvena članka

1 Mirza Tupkušić, Rok Blagus

Preoptimistične ocene točnosti napovednih modelov: ilustracija na primeru skupne uporabe tehnik vzorčenja in navzkrižnega preverjanja

14 Živa Rant, Hajdi Kosednar, Dalibor Stanimirović

Vloga in pomen Centra za pomoč uporabnikom rešitev eZdravja v slovenskem zdravstvu

Pregledni znanstveni članek

20 Žiga Lovšin, Barbara Artnik

Viri podatkov na področju ustnega zdravja v Sloveniji

Strokovna članka

27 Sara Močnik, Dejan Dinevski, Hojka Gregorič Kumperščak

Uporaba umetne inteligence za diagnosticiranje in zdravljenje oseb z mejno osebnostno motnjo

33 Mojca Dovnik, Jože Balažic, Dejan Dinevski

Potenciali umetne inteligence za uporabo v sodnomedicinski praksi

Bilten SDMI

42 Ema Dornik, Boštjan Žvanut

MI'2022 "Odločno digitalno za več zdravja": poročilo s srečanja Sekcije za informatiko v zdravstveni negi – SIZN 2022

Študijsko gradivo

44 Andrej Kastrin

Omrežja znanja in njihova uporaba v biomedicini

Mirza Tupkušić, Rok Blagus

Preoptimistične ocene točnosti napovednih modelov: ilustracija na primeru skupne uporabe tehnik vzorčenja in navzkrižnega preverjanja

Povzetek. Napovedni modeli uporabljajo različne statistične metode za gradnjo pravil za uvrščanje enot v posamezno skupino na podlagi učnih podatkov. Podatki v praksi običajno niso primerni za postopek gradnje pravila, pač pa jih je potrebno predprocesirati. Tak primer so neuravnoteženi podatki, kjer dobimo slabo napovedno točnost za manjši razred, če se razvrščanja lotimo naivno. Z različnimi popravki podatkov se da izboljšati točnost napovednega modela. Toda pri tem je treba paziti, da delovanje razvrščevalca oziroma njegovo točnost pravilno ovrednotimo, saj v primeru napačnega ovrednotenja lahko pride do preoptimistične ocene točnosti napovednega modela. Ta problem podrobno razložimo in prikažemo dejavnike, ki vplivajo na preoptimizem pri ocenjevanju točnosti napovednih modelov. Rezultate ilustriramo na različnih primerih, kjer uporabljamo različne mere napovedne točnosti, različne metode za uravnovešenje podatkov ter različne načine navzkrižnega preverjanja. Rezultati lahko pomagajo razvijalcem napovednih modelov pri pravilnem ovrednotenju dejanske napovedne moči modela oziroma pri razumevanju in kritičnemu ovrednotenju, ali je bila ocena napovedne moči modela izvedena pravilno ali pa so rezultati zaradi napačne izvedbe preoptimistični.

Ključne besede: napovedni model; neuravnoteženi podatki; navzkrižno preverjanje; preprileganje.

Over-optimistic Assessment of the Performance of Prediction Models: An Illustration Based on the Joint Use of Sampling Techniques and Cross-Validation

Abstract. Prediction models use various statistical methods for building classification rules to classify units into pre-specified groups based on the learning data. In practice, the data are often not suitable for the chosen procedure and they need to be pre-processed before training the classifier. An important example are imbalanced data where the naïve approach can lead to poor accuracy for the minority class. Many data augmentation approaches have been developed to alleviate this issue. However, when using these techniques, one needs to be careful to correctly evaluate the performance of the classifier in terms of its predictive accuracy, because incorrect evaluation can lead to an overly optimistic estimate of the classifier's performance. We explain in detail why this happens and showcase the different contributing factors. The results are illustrated using various performance measures, various data augmentation techniques, and various cross-validation techniques. Our results can help the developers of prediction models to correctly evaluate predictive ability of the derived model, as well as to understand and critically appraise whether the predictive ability of the model was correctly estimated or the evaluation was too optimistic.

Key words: prediction models; cross-validation; rare events; overfitting.

■ **Infor Med Slov** 2022; 27(1-2): 1-13

Institucije avtorjev / Authors' institutions: Medicinska fakulteta, Univerza v Ljubljani (MT, RB); Fakulteta za šport, Univerza v Ljubljani (RB); FAMNIT, Univerza na Primorskem, Koper (RB).

Kontaktna oseba / Contact person: izr. prof. dr. Rok Blagus, MF, IBMI, Vrazov trg 2, 1000 Ljubljana. E-pošta / E-mail: rok.blagus@mf.uni-lj.si.

Prispelo / Received: 28. 11. 2022. Sprejeto / Accepted: 24. 12. 2022.

Uvod

Napovedovanje lahko definiramo kot problem ocenjevanja in odločanja na podlagi znanih podatkov.¹ V vsakdanjem življenju se vseskozi srečujemo z nalogami ali vprašanji, na katera želimo odgovoriti čim bolj pravilno. Človeški odgovori so subjektivni, zato so lahko povsem napačni. Zaradi tega postajajo računalniško izdelani napovedni modeli (angl. *prediction models*) vse bolj priljubljeni, še zlasti na področju medicine,²⁻⁷ pogosto pa se uporabljajo tudi na drugih področjih, npr. v trženju in strojništvu.⁸ V kliničnih raziskavah nas pogosto zanima verjetnost ali napoved, da bo pacient zbolel za določeno boleznijo, kako se bo odzval na zdravljenje ipd. Podobno velja na drugih področjih, npr. za odliv strank iz podjetja ali čas do okvare stroja. V medicini so napovedni modeli posebej pomembni v okviru presejalnih programov za zgodnje odkrivanje določene bolezni,⁹ na primer raka. Gradnjo oziroma razvoj napovednih modelov razdelimo v tri faze:

- faza 1: priprava podatkov;
- faza 2: gradnja/učenje razvrščevalca;
- faza 3: preverjanje točnosti razvrščevalca.

V prvi fazi pripravimo podatke za izgradnjo modela oziroma za učenje razvrščevalca (angl. *classifier*). Gradnjo razvrščevalca pogosto otežuje narava zbranih podatkov: v podatkih se lahko pojavljajo manjkajoče vrednosti, napake, osamelci, veliko število spremenljivk itd. V tem članku se bomo osredotočili na pogost problem, ko so podatki v dveh razredih neuravnoteženi (angl. *unbalanced data*),¹⁰⁻¹² se pa podobne težave pojavijo tudi v primeru nadomeščanja manjkajočih podatkov, izločanja osamelcev iz podatkov, izbiре spremenljivk za analizo ipd. O neuravnoteženih podatkih govorimo, ko se število enot med razredoma razlikuje. Na področju medicine je običajno število pacientov z določeno boleznjijo veliko manjše kot število zdravih ljudi; podobno je število strank, ki ostanejo v podjetju, praviloma veliko večje od števila strank, ki podjetje zapustijo. Razred z večjim številom enot imenujemo večinski razred (angl. *majority class*), razred z manjšim številom enot pa manjšinski razred (angl. *minority class*).

Gradnja napovednega modela na podlagi neuravnoteženih podatkov je problematična predvsem zaradi slabe napovedne točnosti v manjšinskem razredu.¹² Preprosto povedano, do tega pride, ker se razvrščevalcu, ki želi minimizirati celotno napako, izplača osredotočiti na večinski razred, posledica pa je slaba točnost za manjšinski razred. Mogoča rešitev tega problema, ki dokazano deluje dobro, so različne metode za uravnoteženje

razredov.^{10,13-17} Tovrstne metode izboljšajo napovedano točnost modela v manjšinskem razredu tako, da zmanjšajo neravnovežje v podatkih ali pa da celo izenačijo število enot v večjem in manjšem razredu.¹³ K temu lahko pristopimo na več načinov. Razreda lahko uravnovežimo z večanjem števila enot v manjšinskem razredu (angl. *oversampling*), zmanjševanjem števila enot v večinskem razredu (angl. *undersampling*) ali kombinacijo teh dveh pristopov.^{10,13} Ko smo končali prvo fazo uravnoveženja podatkov, lahko pristopimo k fazi učenja. Enote, za katere poznamo pripadnost razredu, uporabimo za izgradnjo modela ali razvrščevalca, na podlagi katerega bomo uvrščali nove enote.¹ Obstaja množica različnih razvrščevalcev.¹⁸ V ilustraciji bomo uporabili grebensko regresijo (angl. *ridge regression*),¹⁹⁻²³ so pa ugotovitve splošne in v podobni meri veljajo tudi za druge razvrščevalce. Ko razvrščevalec izgradimo in s tem končamo drugo fazo, bi seveda radi ovrednotili njegovo točnost oziroma ocenili njegovo napako. Na voljo so različne mere točnosti.²⁴ Pri izbiri ustrezne mere točnosti moramo biti previdni, še posebej, ko imamo opraviti z neuravnoveženimi podatki.²⁵ V ilustraciji bomo uporabljali ploščino pod krivuljo ROC²⁶ (mero AUC),^{24,27} točnost za manjšinski in večinski razred, njuno geometrijsko sredino (G -povprečje)²⁸ ter mero F_1 , ki se pogosto uporablajo v tem kontekstu. Idealno bi se točnost razvrščevalca ovrednotila na (veliki) neodvisni tesni množici,^{1,18} ki pa v praksi pogosto ni dostopna. Za preverjanje točnosti razvrščevalca se zato pogosto uporabi navzkrižno preverjanje s k pregibi (angl. *k-fold cross-validation – CV*) oziroma njegova različica navzkrižno preverjanje z izpustitvijo ene enote (angl. *leave-one-out CV – LOOCV*), za katero velja $k = u$, kjer je u velikost učne množice. Pisali bomo $u = m + v$, kjer je m število enot v manjšinskem razredu, v število enot v večinskem razredu in velja $m < v$.

Problem napačnega ovrednotenja točnosti napovednih modelov v različnih kontekstih (npr. v kontekstu izbiре spremenljivk v prvi fazi) je znan.^{29,30} Raziskave kažejo na nujnost pravilnega ovrednotenja točnosti delovanja razvrščevalcev: v primeru napačnega ovrednotenja je delovanje napovednega modela lahko slabše ali boljše, kot je predstavljeno. V članku bomo ilustrirali, kakšen je vpliv napačne uporabe navzkrižnega preverjanja na oceno točnosti napovednega modela ob uporabi različnih pristopov za uravnoveženje podatkov. Pokazali bomo, da napačna uporaba navzkrižnega preverjanja vodi do precenjenih mer točnosti, in prikazali različne dejavnike, ki na to vplivajo. Rezultati so pomembni, ker je bilo doslej objavljenih precej člankov, kjer je

bilo navzkrižno preverjanje izvedeno napačno (npr. v kombinaciji s prevzorčenjem³¹⁻³³), objavljene mere točnosti pa so posledično preoptimistične. Podobno tematiko smo že obravnavali,³⁴ s to razliko, da se tokrat bolj osredotočamo na oris in pomembnost posameznih dejavnikov, ki vplivajo na preoptimizem zaradi napačne uporabe navzkrižnega preverjanja, manj pa na pojasnjevanje razlogov, zakaj do tega pride. V pričujočem članku obravnavamo tudi različne mere točnosti, ki jih v prvotnem³⁴ nismo.

V nadaljevanju najprej predstavimo uporabljene metode, kjer na kratko orišemo različne pristope za uravnoteženje podatkov, uporabljeni razvrščevalci in mere točnosti. Sledi ilustracija, kjer prikažemo vpliv različnih dejavnikov na precenjenost ocene točnosti napovednega modela. Članek zaključimo s kratkim povzetkom ključnih ugotovitev.

Metodologija

V nadaljevanju bolj podrobno predstavljamo metode, ki jih kasneje v ilustraciji uporabljamo v posameznih fazah razvoja napovednega modela.

Metode za uravnoteženje razredov

V ilustraciji bomo uporabili tri različne metode uravnoteženja razredov. Pri naključnem prevzorčenju (angl. *random oversampling*) naključno s ponavljanjem izberemo $n \leq v - m$ enot iz manjšega razreda, izbrane enote kopiramo in jih dodamo v nabor podatkov.³⁵ Tako se manjšinski razred poveča za n neinformativnih enot, popolnih kopij prvotnih enot iz manjšinskega razreda. Metoda prevzorčenja torej uravnoteži razrede z znanimi enotami, zato uravnoteženi podatki ne nosijo nobene dodatne informacije kot izvorni, so le (umetno) uravnoteženi. Posledično so lahko ob uporabi napačnega pristopa navzkrižnega preverjanja iste enote uporabljene v fazi učenja in preverjanja točnosti razvrščevalca in zato zaradi problema preprileganja (angl. *overfitting*¹⁸) dobimo preoptimistično oceno točnosti. O preprileganju na primer govorimo, ko je v fazi preverjanja točnosti razvrščevalca vrednost AUC velika, a je uspešnost razvrščevalca na neznanih (novih) podatkih mnogo slabša.

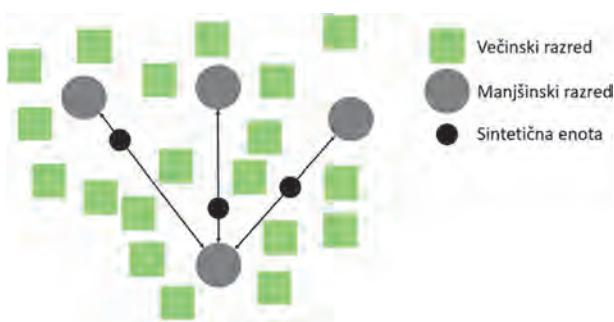
Pri naključnem podvzorčenju (angl. *random undersampling*) naključno (običajno brez ponavljanja) izberemo $n \leq m$ enot iz večinskega razreda.¹² Izbrane enote večinskega razreda združimo z enotami manjšinskega razreda v novi podatkovni okvir. Na tak način ostane število enot v manjšinskem razredu nespremenjeno, število enot v večinskem razredu pa je za $v - n$ manjše. Posledično v fazi učenja

razvrščevalca lahko izpustimo pomembno informacijo, ki se nanaša na večinski razred, kar se lahko odrazi v slabši napovedni točnosti v večinskem razredu. Izgubo informacije se lahko omili z večkratnim naključnim podvzorčenjem, kar lahko bistveno poveča točnost razvrščevalca,¹² a za namen naše analize to ni zelo pomembno, zato tega ne bomo podrobnejše obravnavali. Metoda podvzorčenja uravnoteži razrede z izgubo informacije, zato so uravnoteženi podatki manj informativni kot izvorni. Toda ker nobena enota ni podvojena, do problema preprileganja, ki nastopi pri naključnem prevzorčenju, pri naključnem podvzorčenju ni. Bi pa do podobnega problema vseeno prišlo, če so enote, ki se jih obdrži v večinskem razredu, izbere sistematicno^{36,37} (s tem se podrobnejše ne bomo ukvarjali).

SMOTE (angl. *Synthetic Minority Oversampling Technique*) je metoda kjer se hkrati podvzorči in prevzorči, pri čemer se pri prevzorčenju tvorijo sintetični podatki za manjšinski razred (v primarni definiciji je metoda SMOTE vezana le na sintetično prevzorčenje, vendar obstaja več izvedb, med katerimi se bomo osredotočili na kombinacijo prevzorčenja in podvzorčenja).¹³ S tvorjenjem sintetičnih enot metoda SMOTE pomaga pri premagovanju problema preprileganja, a ga ne odpravi povsem. V manjšinskem razredu metoda naključno izbere eno enoto x_r (angl. *random minority*), nato pa poišče njenih g najbližjih sosedov x_{gNN} (angl. *g-nearest neighbours*).³⁸ Nato izračuna razdaljo med izbrano enoto in g najbližjimi sosedi, na kateri naključno tvori eno ali več sintetičnih enot x_{new_i} ,

$$x_{new_i} = x_{r_i} + rand(0,1)(x_{gNN_i} - x_{r_i}) \quad i = 1, \dots, l \quad (1)$$

kjer $rand(0,1)$ označuje naključno vrednost iz enakomerne porazdelitve na intervalu $(0,1)$. Tako nove enote niso identične obstoječim, pač pa so njihove linearne kombinacije (slika 1). Med tvorbo novih sintetičnih enot metoda SMOTE lahko izvaja podvzorčenje.¹³ Postopek se konča, ko dosežemo želeno (ne)ravnotežje števila enot v manjšem in večjem razredu (običajno podatke povsem uravnotežimo). Ker nove (sintetične) enote niso popolnoma neodvisne od osnovnih enot (saj so tvorjene z uporabo informacij o osnovnih enotah), lahko seveda pride do problema preprileganja; o tem več kasneje.

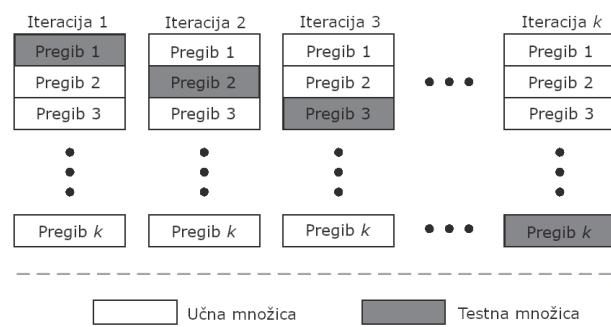


Slika 1 Načelo delovanja metode SMOTE (angl. *Synthetic Minority Oversampling Technique*).

Navzkrižno preverjanje s k pregibi

Navzkrižno preverjanje s k pregibi je ena izmed metod, ki jih lahko uporabimo za oceno razvrstitvene točnosti.¹⁸ V navzkrižnem preverjanju s k pregibi je podatkovni okvir razdeljen na k podmnožic (angl. *folds*): $k - 1$ podmnožic uporabljamo za gradnjo razvrščevalca, eno podmnožica pa za oceno njegove točnosti. Podmnožice ustvarimo tako, da je število enot v vsaki podmnožici enako in je delež enot manjšinskega in večinskega razreda v vsaki podmnožici enak kot v osnovni množici.

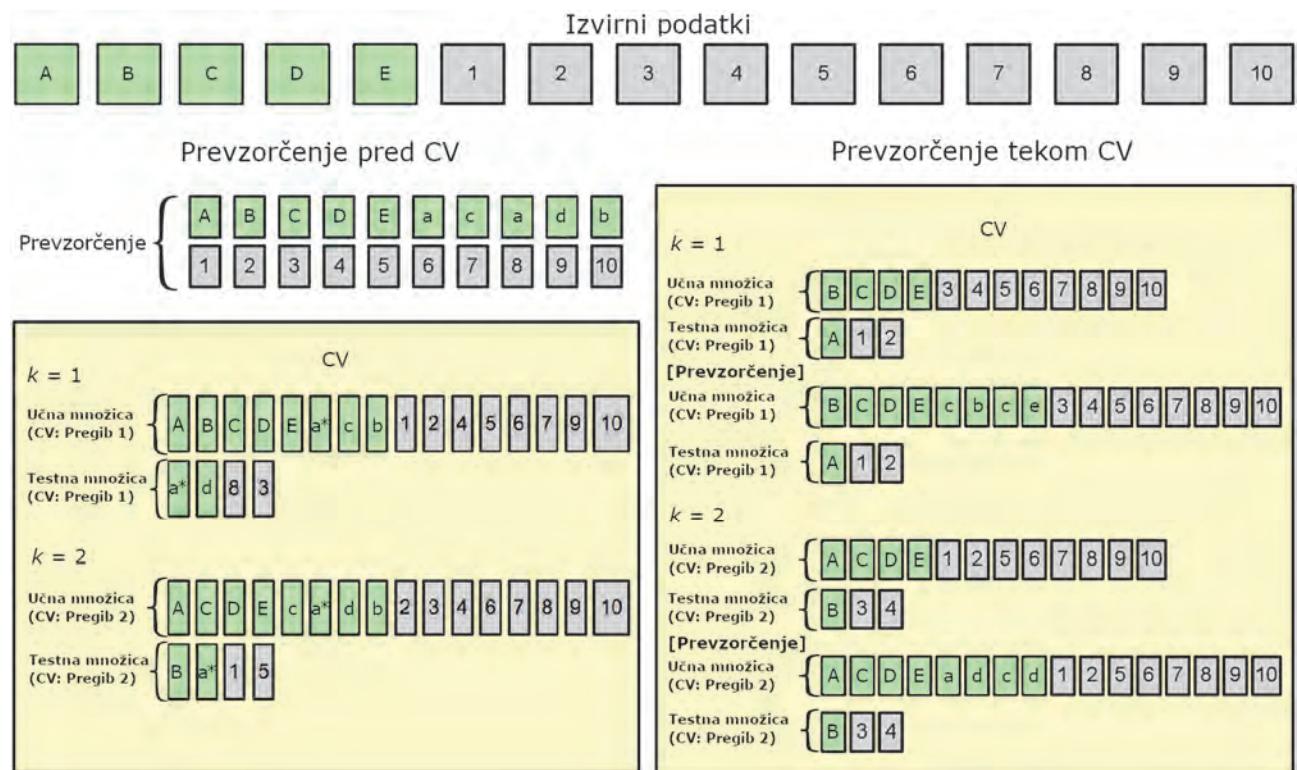
Iterativni postopek ponovimo k -krat, tako je vsaka izmed k podmnožic enkrat uporabljena kot testna množica (slika 2).²⁴ Navzkrižno preverjanje z izpustitvijo ene enote je skrajna različica navzkrižnega preverjanja s k pregibi: $u - 1$ enot uporabljamo za gradnjo razvrščevalca, eno enoto pa uporabimo za preverjanje njegove točnosti. Iterativni postopek ponovimo u -krat, tako je vsaka enota enkrat uporabljena kot testna množica. Izvedba z izpustitvijo ene enote je seveda računsko in časovno najbolj zahtevna.



Slika 2 Navzkrižno preverjanje s k pregibi.

Pri uporabi navzkrižnega preverjanja imamo dve možnosti, kako izračunati neko mero točnosti. Prva možnost je, da točnost izračunamo za vsak pregib posebej in potem povprečimo k takoj dobavljenih ocen. Druga možnost je, da vse napovedi združimo in mero točnosti izračunamo zgolj enkrat. Katera izbira je pravilna je odvisno med drugim tudi od uporabljenih mere točnosti in je še vedno predmet razprave.³⁹ Zaradi primerljivosti med različnimi oblikami navzkrižnega preverjanja bomo uporabili drugo možnost (ki je v primeru LOOCV edina možnost, če želimo oceniti AUC), za katero je sicer znano, da vodi do pristranske ocene AUC in pravilne ocene mere F_1 ,³⁹ s podrobno primerjavo obeh pristopov se ne bomo ukvarjali.

Pri skupni izvedbi navzkrižnega preverjanja in ene izmed metod uravnoteženja razredov moramo paziti, da oba postopka izvedemo pravilno. Če najprej uravnotežimo podatke, potem pa uporabimo navzkrižno preverjanje, smo slednje izvedli napačno (slika 3). Navzkrižno preverjanje je pravilno, če proces uravnoteženja podatkov izvedemo znotraj postopka navzkrižnega preverjanja. V pravilni izvedbi navzkrižnega preverjanja metode uravnoteženja razredov uporabljamo samo na učni množici, kar pomeni, da moramo uravnoteženje razredov k -krat (ozioroma v primeru LOOCV u -krat) ponoviti (slika 3).



Slika 3 Napačna (levo) in pravilna (desno) izvedba navzkrižnega preverjanja s k pregibi in naključnega prevzorčenja.

Razvrščevalec

Grebenska regresija¹⁹ je statistična metoda, s katero lahko izboljšamo točnost napovedi z zmanjšanjem ocen parametrov (t. i. krčenjem, angl. *shrinkage*).²³ Z dodajanjem penalizacijske funkcije (angl. *penalizing function*) spreminja oziroma zmanjša ocenjeno vrednost regresijskega koeficienta, s čimer poskušamo zmanjšati problem preprileganja. Splošni regresijski model lahko zapišemo v matrični obliki kot $\mathbf{Y} = \boldsymbol{\beta}\mathbf{X} + \boldsymbol{\epsilon}$, kjer so \mathbf{Y} izidi, \mathbf{X} napovedne spremenljivke, $\boldsymbol{\beta}$ regresijski koeficienti, $\boldsymbol{\epsilon}$ pa naključne napake.¹⁸ Regresijske koeficiente z grebensko regresijo dobimo tako, da rešimo optimizacijski problem

$$\boldsymbol{\beta}^{ridge} = \operatorname{argmin}_{\boldsymbol{\beta}} \left[\sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right] \quad (2),$$

kjer je λ uglaševalski parameter. Opazimo, da za $\lambda = 0$ dobimo enako rešitev, kot če uporabljamo standardna orodja (denimo metodo največjega verjetja⁴⁰), medtem ko za $\lambda = \infty$ vse ocene postavimo na nič. Parameter λ se običajno določi s navzkrižnim preverjanjem.⁴¹ Če želimo zgornji model uporabiti za (binarno) razvrščanje, moramo enotam določiti vrednost izidov, \mathbf{Y} . V našem primeru bomo enotam iz manjšinskega razreda določili vrednost 0, enotam iz večinskega razreda pa vrednost 1 (lahko bi uporabili

tudi obratno definicijo, rezultati pa bili enaki). Ko izberemo parameter λ in pridobimo ocene regresijskih koeficientov, lahko na podlagi teh ocen izračunamo verjetnost dogodka, ki jo označimo s \hat{p} . Za izračun nekaterih mer točnosti (npr. AUC) lahko \hat{p} uporabimo neposredno, medtem, ko moramo za izračun drugih mer (npr. napovedne točnosti) verjetnostno napoved spremeniti v napoved vrednosti 0 ali 1 (ki jo označimo z \hat{y}), za kar lahko uporabimo pravilo

$$\hat{y} = \begin{cases} 1 & \text{če } \hat{p} > \tau \\ 0 & \text{če } \hat{p} < \tau \end{cases} \quad (3),$$

kjer je τ prag za uvrščanje. Če velja $\hat{p} = \tau$, enoto naključno uvrstimo v enega izmed razredov. Ker (podobno kot v običajni logistični regresiji) velja, da so ocenjene verjetnosti zgoščene okrog neravnotežja v učni množici, naivna uporaba $\tau = 0,5$ za neuravnotežene podatke praviloma ni ustrezna.¹² V ilustraciji bomo zato kot prag za uvrščanje uporabljali delež dogodkov na (uravnoteženi) učni množici.

Mere razvrstitvene točnosti

Za oceno točnosti razvrščanja bomo izračunali ploščino pod krivuljo ROC (angl. *area under the curve – AUC*),²⁴ G -povprečje (angl. *G-mean*)

$$G = \sqrt{\left(\frac{TP}{TP + FN}\right)\left(\frac{TN}{TN + FP}\right)} = \sqrt{PA_1 PA_2} \quad (4).$$

kjer je TP število pravilno uvrščenih enot iz manjšinskega razreda, FN število napačno uvrščenih enot iz večinskega razreda, TN število pravilno uvrščenih enot iz večinskega razreda, FP število napačno uvrščenih enot iz manjšinskega razreda, $PA_1 = \frac{TP}{TP+FN}$ in $PA_2 = \frac{TN}{TN+FP}$ pa sta točnost za manjšinski in večinski razred, ter mero F_1

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (5).$$

Pri izračunu AUC bomo uporabljali verjetnostno napoved \hat{p} , za izračun ostalih mer pa bomo uporabljali \hat{y} , ki ga dobimo, kot je pojasnjeno zgoraj.

Implementacija metod v programskejem jeziku R

Za izvedbo metode naključnega prevzorčenja uporabljamo funkcijo **upSample(x, y, list = FALSE, yname = class)** iz paketa **caret**, kjer je **x** matrika ali podatkovni okvir vrednosti enot za vsako spremenljivko, **y** indikatorska spremenljivka, ki določi pripadnost, in argument **yname** določi ime spremenljivke, ki nam pove pripadnost posamezne enote v izhodu funkcije. Funkcija dela enako, kot je opisano v razdelku o metodah za uravnoteženje razredov: razreda uravnotežimo z naključnim dodajanjem enot manjšinskega razreda s ponavljanjem v nabor podatkov. Za izvedbo naključnega podvzorčenja uporabljamo funkcijo **downSample(x, y, list = FALSE, yname = class)**, iz paketa **caret**. Funkcija ima enake argumente kot funkcija za naključno prevzorčenje. Tudi ta funkcija deluje enako, kot je opisano zgoraj. Za izvedbo metode SMOTE uporabljamo funkcijo **SMOTE(formula, data, perc.over = 100, k = 5, perc.under = 200, ...)** iz paketa **DMwR**. Z argumentom **formula** zapišemo napovedni model, z argumentom **data** podamo originalni neuravnoteženi podatkovni okvir, z argumentom **perc.over** definiramo število dodanih sintetičnih enot, z argumentom **k** definiramo število najbližjih sosedov, z argumentom **perc.under** pa definiramo število izbrisanih enot v večinskem razredu. Funkcija vrednosti **perc.over** in **perc.under** deli s 100, dobljeni vrednosti pa določita, koliko novih enot v vsaki ponovitvi dodamo in odstranimo. Za vpogled v ostale parametre, ki jih lahko nastavimo v funkciji, priporočamo pregled dokumentacije paketa **DMwR**. Za ogled izvorne kode priporočamo ogled funkcije **SMOTE(form, data, perc.over = 200, k = 5,**

perc.under = 200, learner = NULL, ...) in **smote.exs(data, tgt, N, k)** na spletu (<https://rdrr.io/cran/DMwR/src/R/smote.R>). Funkcijo smo uporabili na dva načina: pri prvem načinu smo uporabili **perc.over = 100, perc.under = 200**; pri drugem pa **perc.over = 400, perc.under = 100**.

Za učenje razvrščevalca, ki smo ga predstavili istoimenskem razdelku, uporabljamo funkcijo **glmnet(x, y, alpha = 0, lambda, ...)** iz paketa **glmnet**. Z argumentom **x** definiramo matriko neodvisnih spremenljivk, z **y** definiramo odzivno (indikatorsko) spremenljivko in z argumentom **lambda** nastavimo vrednost parametra λ . Optimalno vrednost parametra λ določimo s pomočjo funkcije **cv.glmnet(x, y, alpha = 0, nfolds = 10, ...)**, ki določi optimalno vrednost na podlagi navzkrižnega preverjanja z 10 pregibi; ostali vhodni argumenti, **x**, **y** in **alpha**, so enaki kot pri funkciji **glmnet**. Za izračun napovedi uporabimo funkcijo **predict(ovject, s, newx, type, ...)** iz paketa **stats**. Z argumentom **object** določimo model, za katerega želimo izračunati napovedi, argument **s** določa optimalno vrednost λ , argument **newx** določa vrednosti napovednih spremenljivk in z argumentom **type** določimo tip izhoda, ki ga vrne funkcija (v našem primeru je to ocenjena verjetnost dogodka). AUC izračunamo s pomočjo funkcije **auc()** iz paketa **pROC**, meri G in F_1 mero pa izračunamo po zgoraj predstavljeni definiciji. Navzkrižno preverjanje s k pregibi in z izpustitvijo ene enote smo sprogramirali sami, kot je opisano v razdelku o navzkrižnem preverjanju.

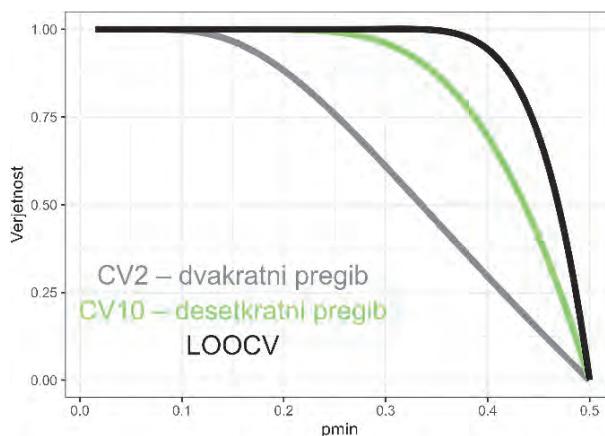
Ilustracija

Za primer naključnega prevzorčenja lahko izračunamo verjetnost, da je enota iz manjšega razreda hkrati vključena v učno in testno množico, če navzkrižno preverjanje izvedemo napačno (če navzkrižno preverjanje izvedemo pravilno, je ta verjetnost seveda nič, enako pa velja tudi za primer, ko uporabimo naključno podvzorčenje, tudi če navzkrižno preverjanje izvedemo napačno, kar smo že pojasnili). Verjetnost, da je ista enota vključena v učno in testno množico, je odvisna od števila enot v podatkovnem okvirju, deleža enot, vključenih v testno množico p_{test} , in deleža enot v manjšinski množici $p_{min} = m/u$:

$$P = 1 - \frac{\binom{u-v/m}{up_{test}-v/m}}{\binom{u-1}{up_{test}-1}} \quad (6).$$

Z manjšanjem deleža enot v manjši množici p_{min} se verjetnost povečuje (slika 4). Če imamo opravka z

neuravnoteženimi podatki (npr. $p_{min} = 0.1$), metoda prevzorčenja večkrat v podatkovni okvir doda veliko obstoječih enot, zaradi česar se bolj pogosto zgodi, da imamo pri napačnem navzkrižnem preverjanju v učni in testni množici vključene iste enote. Če je delež enot v manjši množici blizu vrednosti 0,5, metoda prevzorčenja v podatkovni okvir doda manjše število podvojenih enot, posledično se redkeje zgodi, da je v primeru napačnega navzkrižnega preverjanja ena enota vključena v učno in testno množico hkrati. Z manjšanjem deleža enot v testni množici p_{test} se verjetnost povečuje (slika 4). To pomeni, da se verjetnost povečuje z večanjem števila podmnožic k pri navzkrižnem preverjanju. Posledično ima navzkrižno preverjanje z izpustitvijo ene enote, ki predstavlja skrajni primer navzkrižnega preverjanja s k pregibom ($k = u$), pri vsakem številu enot n in p_{min} vedno največjo verjetnost. Na omenjeno verjetnost lahko vplivamo tudi s številom enot v podatkih, pri čemer se z večanjem števila enot se verjetnost zmanjšuje. Ko za prevzorčenje uporabljamo metodo SMOTE, je verjetnost, da bo ista enota vključena v testni in učni množici, seveda enaka nič, vendar pa so lahko v primeru napačne izvedbe navzkrižnega preverjanja v testni množici vključene *podobne* enote kot v učni. Spomnimo, da z metodo SMOTE ne ustvarjamo kopij enot iz manjšinskega razreda, temveč njihove linearne kombinacije, te linearne kombinacije (novi sintetični podatki) pa vsebujejo tudi informacijo, ki je vključena v osnovnih podatkih, zato ti novi podatki nikakor niso neodvisni od prvotnih.



Slika 4 Verjetnost, da je vsaj ena enota vključena v učno in testno množico, v odvisnosti od deleža enot v manjšinskem razredu (p_{min}).

Čeprav sintetične enote niso identične prvotnim, je torej v primeru napačne izvedbe navzkrižnega preverjanja v testni množici prisotna informacija, ki smo jo dobili neposredno iz učne množice, kar lahko vodi do preprileganja in preoptimistične ocene. V

nadaljevanju podrobnejše ilustriramo, kakšen je vpliv napačne izvedbe navzkrižnega preverjanja na (pre)optimistično oceno različnih mer točnosti.

V ilustraciji uporabljamo podatke, ki smo jih simulirali neodvisno iz standardne normalne porazdelitve za vse enote iz učne množice; odločitev o uporabi konkretnje porazdelitve ni bistvena, podobne ugotovitve bi veljale tudi za druge porazdelitve. V simulaciji smo spremenili število neodvisno generiranih spremenljivk p , število enot N , delež enot v manjšem razredu p_{min} in delež enot v testni množici p_{test} (preko različne izbire števila pregibov $k = 2, 10, u$ v navzkrižnem preverjanju); podatke smo simulirali stokrat in rezultati, o katerih poročamo, so povprečeni čez 100 ponovitev. Naj poudarimo, da simuliramo na način, da med razredoma dejansko ni razlike: točna vrednost AUC je enaka 0,5, $PA_1 + PA_2 = 1$ in zato $G = \sqrt{PA_1(1 - PA_1)} = \sqrt{PA_2(1 - PA_2)}$ in $F_1 = \frac{2PA_1p_{min}}{PA_1+p_{min}} = \frac{2(1-PA_2)p_{min}}{1-PA_2+p_{min}}$. Če dobimo vrednosti, ki odstopajo od pravih, točnosti napovednega modela nismo pravilno ovrednotili: če so ocene večje od pravih, smo delovanje napovednega modela precenili, če so manjše, pa podcenili. Če bi med razredoma obstajale razlike, bi bili zaključki podobni predstavljenim.

Naj na tem mestu opomnimo, da smo pri izračunu pravih mer točnosti za našo ilustracijo predpostavljali zgolj, da je razvrščevalec neinformativen, torej tak, za katerega velja $PA_1 + PA_2 = 1$. To je (malenkost) bolj splošna zahteva, kot če bi bil razvrščevalec naključen, torej tak, za katerega velja $PA_1 = PA_2 = 1/2$. Opazimo lahko, da je vsak naključen razvrščevalec tudi neinformativen, ni pa vsak neinformativen razvrščevalec tudi naključen. Ilustrirajmo to na primeru, ko se o razredu odločimo glede na metkovanca. V prvem primeru denimo, da je kovanec pošten (verjetnost grba je $1/2$), v drugem pa, da je verjetnost grba enaka $\pi \neq 1/2$. V prvem primeru bo seveda v povprečju (!) veljalo (kot vemo iz osnov verjetnosti) $PA_1 = PA_2 = 1/2$, v drugem pa $PA_1 = (\pi m)/m = \pi$ in $PA_2 = (1 - \pi)v/v = 1 - \pi$. V obeh primerih gre za neinformativen razvrščevalec, vendar pa je zgolj prvi razvrščevalec tudi naključen.

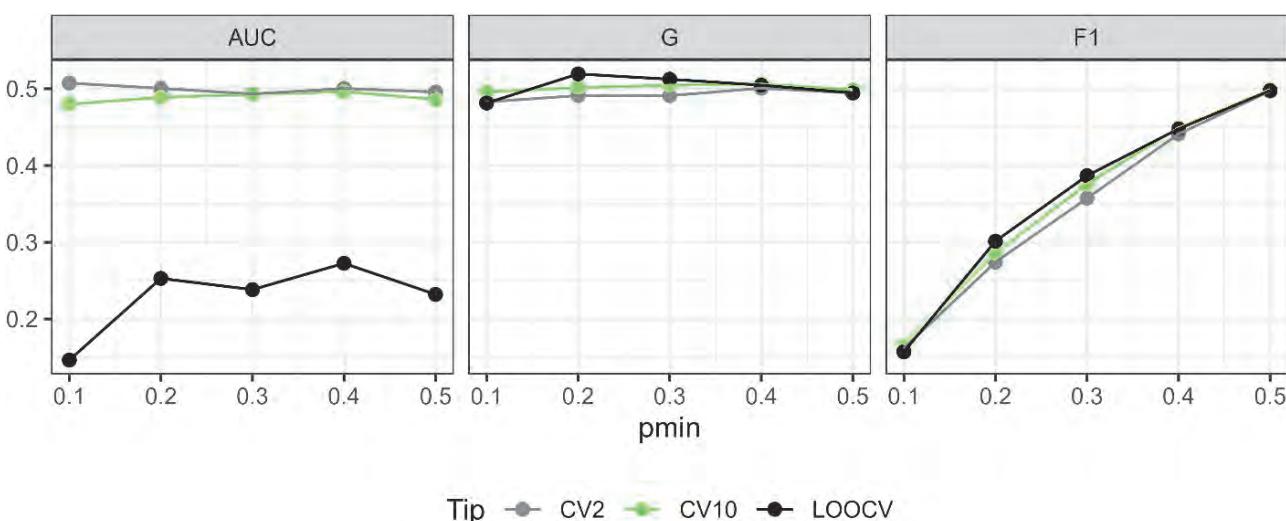
Ignoriranje problema neuravnoteženih razredov

Najprej bomo prikazali, kaj se zgodi, ko zanemarimo problem neuravnoteženih razredov, torej izpustimo prvo fazo gradnje napovednega modela. Ilustracija se nanaša na primer, ko spremenimo delež enot v manjšem razredu: $p_{min} = 0,1, 0,2, \dots, 0,5$. Ostali

parametri so nastavljeni na $N = 300$ in $p = 1000$. Rezultati so prikazani na sliki 5.

Vrednosti G -povprečja in mere F_1 so enake pravim vrednostim, saj v tretji fazi nismo naredili nobene napake, zaradi katere bi prišlo do preoptimističnih ocen. Za razliko od G -povprečja in mere F_1 pa so ocenjene vrednosti AUC ob uporabi LOOCV premajhne, do česar pride zaradi napake, ki smo jo naredili, ko smo združevali ocene različnih pregibov. Ko smo združili napovedane verjetnosti v posameznih pregibih, smo namreč združili nezdružljive ocene: združili smo ocene, ki so bile

pridobljene na učnih množicah z različnimi neravnotežji (neravnotežje je seveda drugačno, ko izpustimo enoto iz manjšinskega oziroma večinskega razreda). Ko uporabljamo $k = 2$ in $k = 10$, do tega problema seveda ne pride, ker pregibe ustvarjamamo tako, da je neravnotežje ves čas enako. Če bi pri izračunu AUC uporabljali napovedani razred (\hat{y}) in ne ocenjene verjetnosti (\hat{p}), bi bila tudi ob uporabi LOOCV za vsak p_{min} AUC pravilno ovrednotena (bila bi enaka 0,5). To je tudi razlog, zakaj sta G -povprečje in mera F_1 pravilno ocenjena tudi, če uporabimo LOOCV.

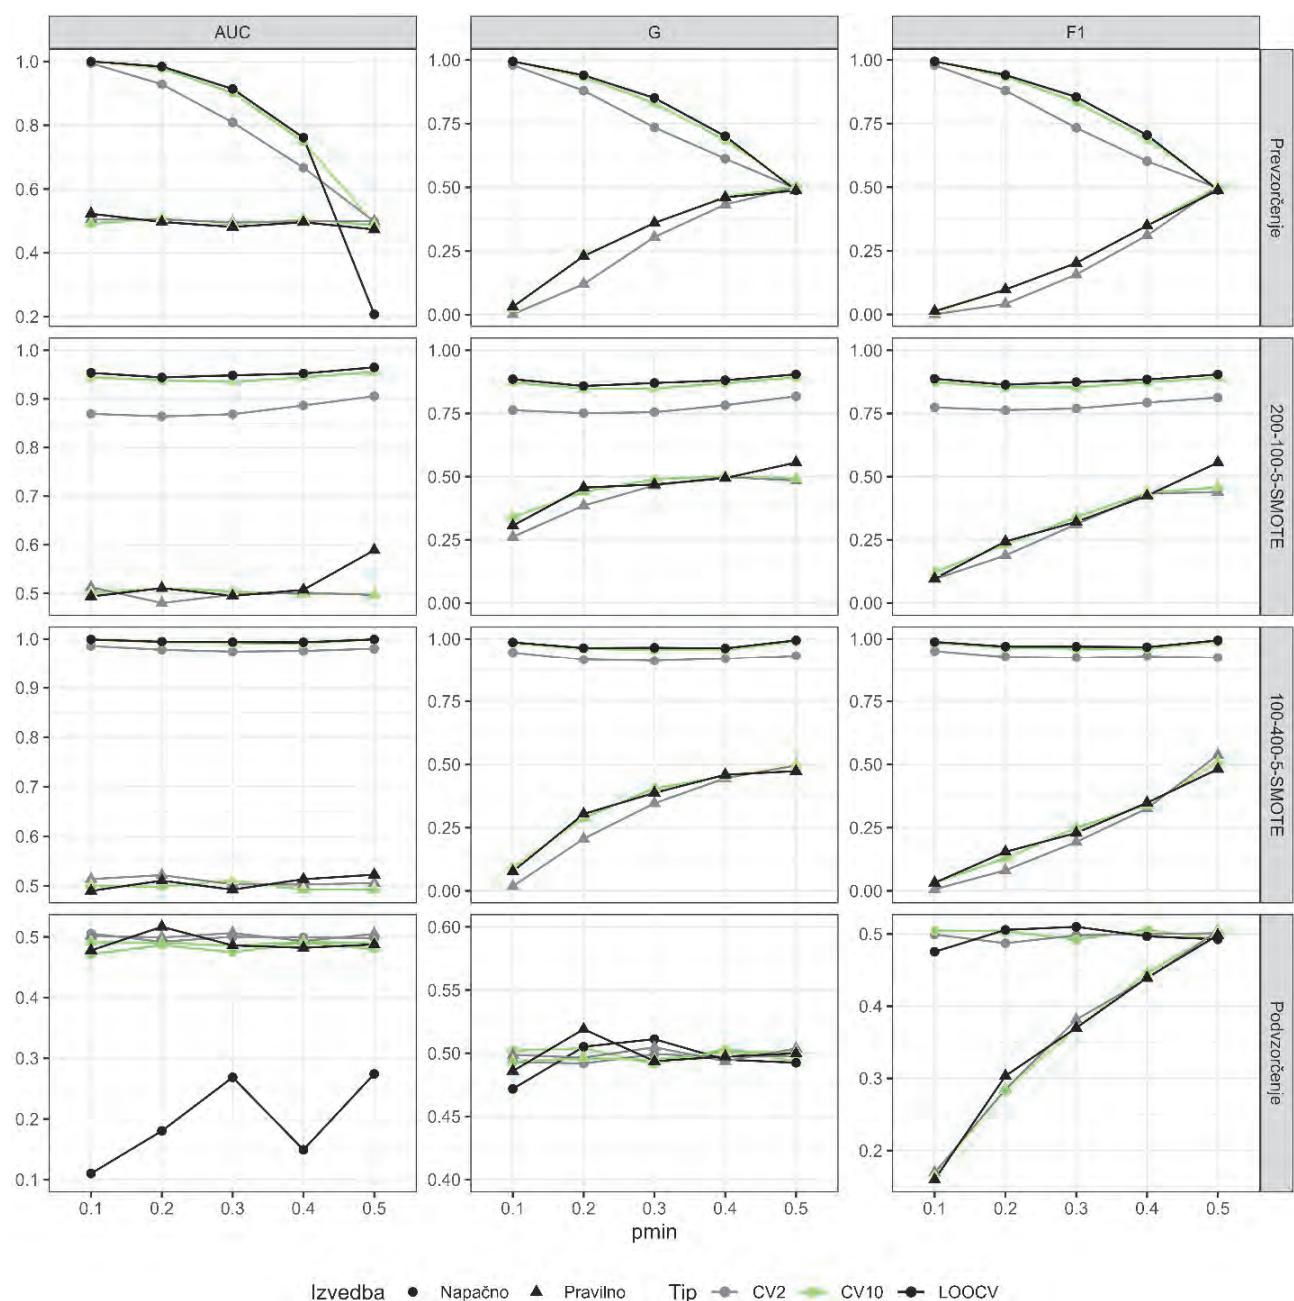


Slika 5 Navzkrižno preverjana točnost razvrščevalca za različna neravnotežja v podatkih (p_{min}).

Pojasnjimo ta problem bolj podrobno na primeru, ko velja $\lambda = \infty$ (dejansko so bile pri nas ocenjene vrednosti za λ zelo velike, kar je pričakovano, saj to pomeni, da model pravilno ugotovi, da spremenljivke niso pomembne za pojasnjevanje izida). V tem primeru je namreč ocenjena verjetnost točno enaka deležu dogodkov v učni množici.²³ To pomeni, da je enaka $\hat{p}_m = v/(v - 1)$ za vse enote iz manjšinskega razreda (ki ga kodiramo z vrednostjo 0 – nedogodek) in $\hat{p}_v = (v - 1)/(u - 1)$ za vse enote iz večinskega razreda (ki ga kodiramo z 1 – dogodek). Opazimo, da velja $\hat{p}_m > \hat{p}_v$: vse enote iz manjšega razreda so rangirane višje od enot iz večjega razreda (imajo večjo verjetnost, da spadajo v večinski razred), zato je AUC enaka nič (spomnimo se interpretacije AUC: to je verjetnost, da bo razvrščevalec naključno izbran dogodek rangiral višje kot nedogodek²⁴). Če ocenjeno verjetnost sprememimo v razred, opazimo, da vsako enoto popolnoma naključno uvrstimo v enega izmed razredov (enačba 3), posledično je AUC (v povprečju) enaka 0,5 in do problema podcenjene AUC ne pride.

Odvisnost preoptimistične ocene od deleža enot v manjšem razredu

Vsi parametri se enaki kot v prejšnjem primeru ($N = 300, p = 1000, p_{min} = 0,1, 0,2, \dots, 0,5$), le da tu uporabimo eno od treh predstavljenih metod za uravnovešenje podatkov ter primerjamo rezultate pravilne in napačne uporabe navzkrižnega preverjanja. Na sliki 6 smo prikazali razliko med pravilno in napačno izvedbo navzkrižnega preverjanja s k pregibi ($k = 2, 10$ in u), ob uporabi različnih metod za uravnovešenje podatkov, pri različni vrednosti deleža enot v manjšinskem razredu. V primeru pravilne izvedbe navzkrižnega preverjanja so vse mere pravilno ocenjene. Zanimivo, opazimo, da do podcenjenega AUC v primeru uporabe LOOCV v tem primeru ne pride. V kolikor uporabimo napačno navzkrižno preverjanje v kombinaciji s podvzorcevanjem, potem sta AUC in G -povprečje ocenjena pravilno; izjema je AUC ob uporabi LOOCV, o razlogih za to pa smo govorili že v prejšnjem primeru.

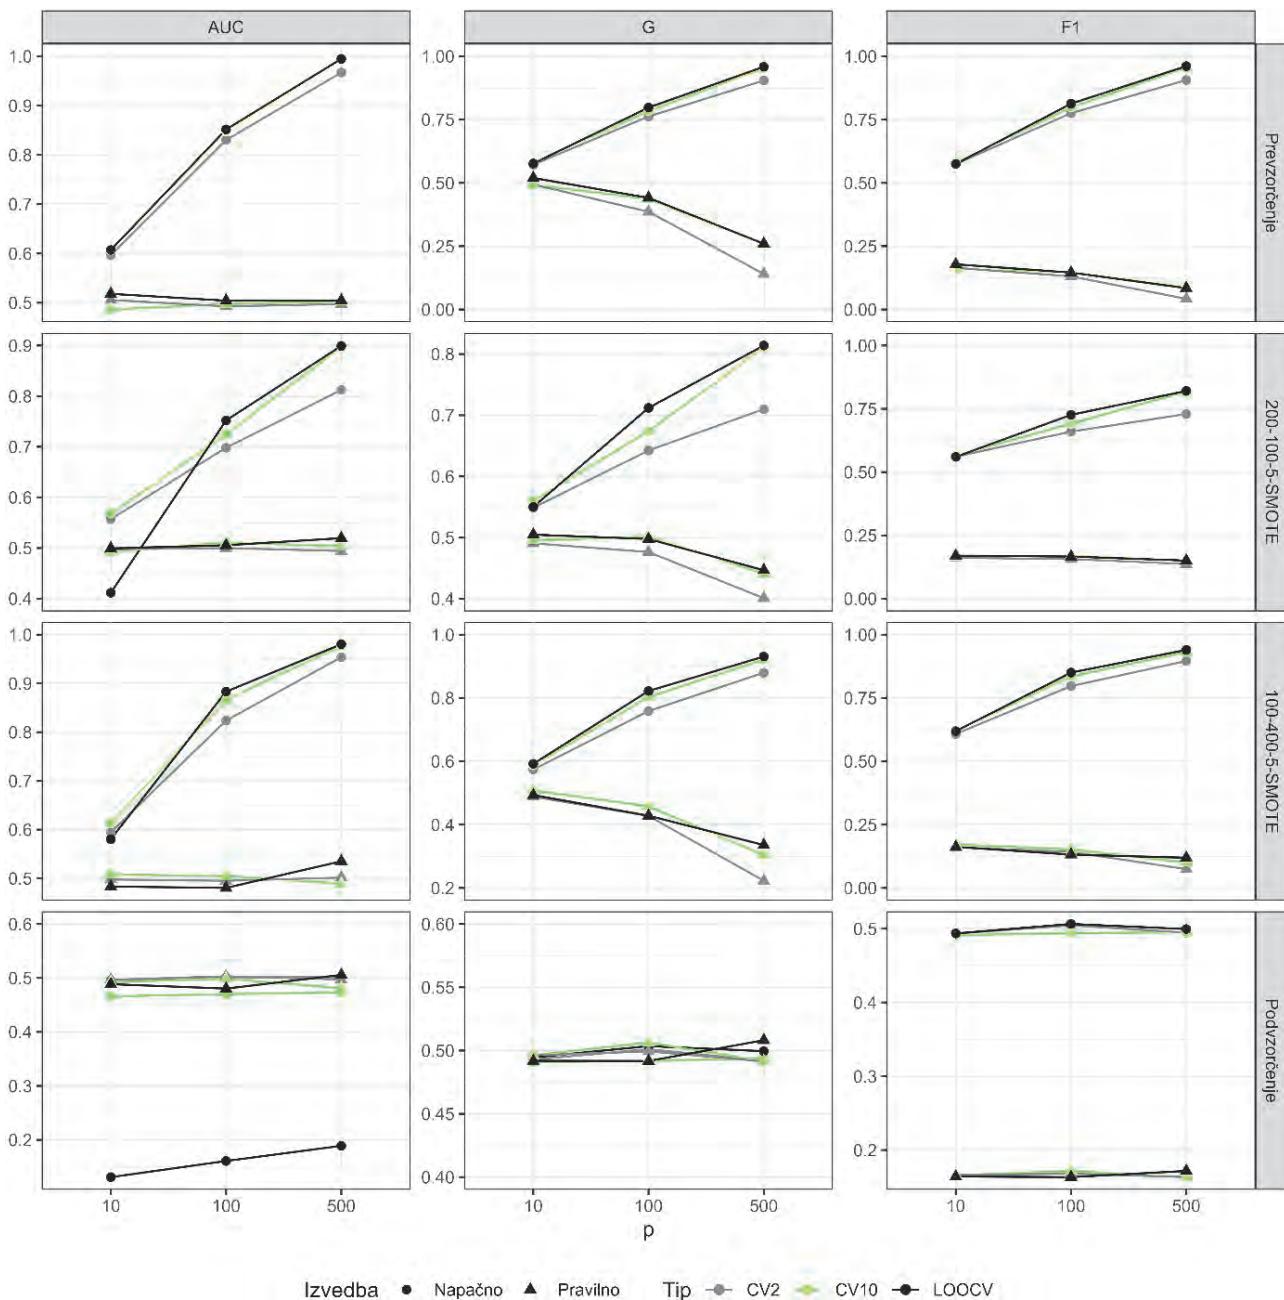


Slika 6 Navzkrižno preverjana točnost razvrščevalca v visokorazsežnem prostoru za različne velikosti manjšinskega razreda ob skupni uporabi različnih metod za uravnovešenje podatkov in različnih izvedb navzkrižnega preverjanja.

Spomnimo, s podvzorčenjem v testno množico ne uvajamo nobene informacije iz učne množice, zato je ta rezultat popolnoma pričakovan. Kljub temu, pa je F_1 mera precenjena. Pri vseh ostalih popravkih za uravnovešenje podatkov so v primeru napačne uporabe navzkrižnega preverjanja (izrazito) precenjene, še posebej, ko je neravnovežje v podatkih večje.

Odvisnost preoptimistične ocene od števila spremenljivk

V tem delu spremenjamo število spremenljivk $p = 10, 100, 500$, ostali parametri pa so $N = 500$ in $p_{min} = 0.1$, rezultati so prikazani na sliki 7. Rezultati so zelo podobni kot v prejšnjem primeru, opazimo pa, da z večanjem števila spremenljivk ocene postajajo vedno bolj precenjene. Ko se število spremenljivk povečuje, postaja problem preprileganja bolj izrazit, kar se v primeru napačne izvedbe navzkrižnega preverjanja bolj pozna na preoptimističnih oceni točnosti delovanja razvrščevalca.

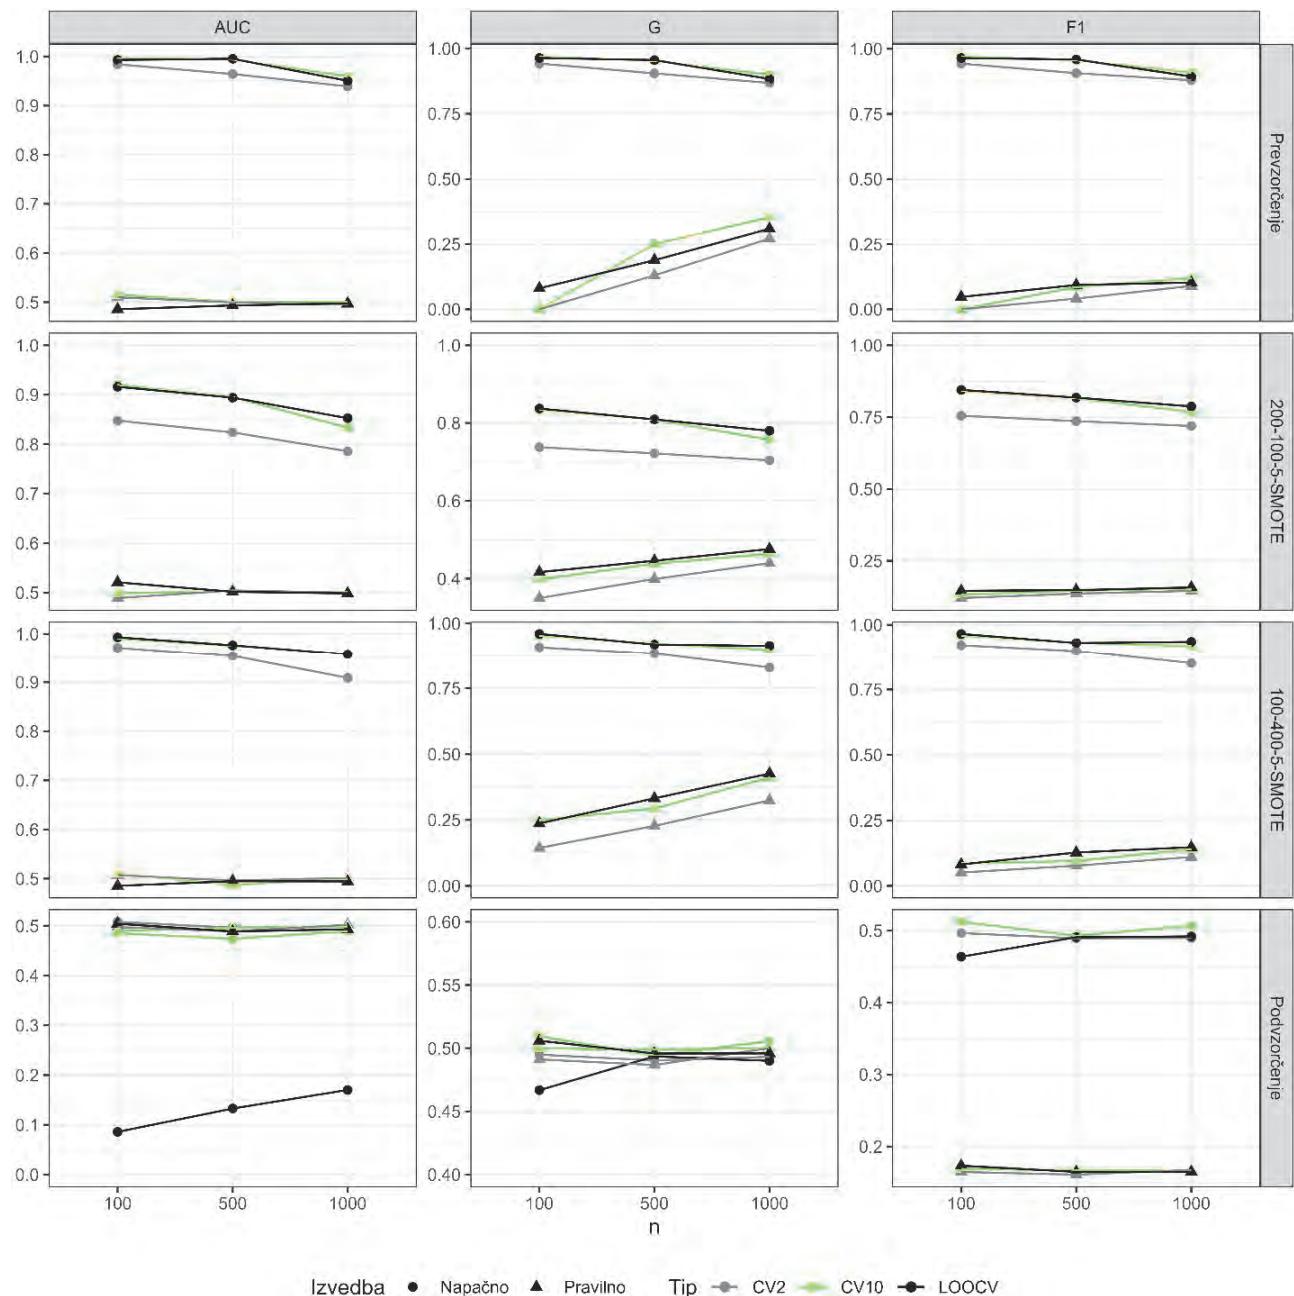


Slika 7 Navzkrižno preverjana točnost razvrščevalca za različne velikosti manjšinskega razreda ob skupni uporabi različnih metod za uravnoteženje podatkov in različnih izvedb navzkrižnega preverjanja, ko je število enot večje od števila spremenljivk.

Odvisnost preoptimistične ocene od števila enot

Tu spremenjamo število $N = 300, 500, 1000$, ostala parametra pa sta $p = 500$ in $p_{min} = 0,1$. Rezultati so prikazani na sliki 8. Podobno kot v prejšnjem primeru opazimo, da ob manjšanju števila enot v primeru

napačne izvedbe navzkrižnega preverjanja ocene postajajo vedno bolj precenjene. Razlogi so enaki kot v prejšnjem primeru: ko se velikost učne množice zmanjšuje, se problem preprileganja povečuje, kar vodi do precenjenih ocen.



Slika 8 Navzkrižno preverjana točnost razvrščevalca ob skupni uporabi različnih metod za uravnoteženje podatkov in različnih izvedb navzkrižnega preverjanja pri različnem številu enot.

Zaključek

Ocenjevanje točnosti napovednih modelov je pomemben, če ne kar najpomembnejši korak pri razvoju napovednih modelov. Pokazali smo, da v primeru napačne uporabe navzkrižnega preverjanja v kombinaciji z uporabo metod za uravnoteženje podatkov precenimo točnost napovednega modela. Naše ocene teden nakazujejo, da gre za (zelo) dober napovedni model, dejansko pa je njegovo delovanje zelo slabo. Pojasnili smo razloge za to in predstavili dejavnike, ki vplivajo na preoptimizem: delež enot v

manjšinski množici (preoptimizem se povečuje, ko se delež enot v manjšinski množici zmanjšuje), število spremenljivk (z večanjem števila spremenljivk se preoptimizem povečuje) in število enot (preoptimizem narašča z manjšanjem števila enot). Prvi dejavnik je neposredna posledica uvajanja informacije iz učne množico v testno: pri naključnem prevzorčenju v učni in testni množici nastopajo iste enote, ki jih je zaradi preprileganja precej lažje pravilno uvrstiti kot neke enote, ki jih med učenjem razvrščevalca nismo vključili v učno množico. Problem preprileganja je seveda bolj izrazit, ko je

število spremenljivk veliko in ko je število enot majhno, kar pojasnjuje druga dva dejavnika.

Pravilna izvedba navzkrižnega preverjanja je torej ključna, da se izognemo preoptimističnim ocenam in pravilno ovrednotimo moč napovednega modela. Zelo pomembno je, da so vse faze izgradnje modela (najsi gre za uravnoteženje podatkov, izbiro spremenljivk, izbiro najboljšega razvrščevalca ali nadomešanje manjkajočih vrednosti) del navzkrižnega preverjanja. V nasprotnem primeru lahko v testni množici napačno upoštevamo informacijo iz učne množice in zato preoptimistično ocenimo točnost napovednega modela.

Reference

1. Bishop CM. Pattern recognition and machine learning (information science and statistics). New York 2007: Springer.
2. Ramaswamy S, Ross KN, Lander ES, Golub TR. A molecular signature of metastasis in primary solid tumors. *Nat Genet* 2003; 33(1): 49-54. <https://doi.org/10.1038/ng1060>
3. Shipp MA, Ross KN, Tamayo P, et al. Diffuse large B-cell lymphoma outcome prediction by gene-expression profiling and supervised machine learning. *Nat Med* 2002; 8(1): 68-74. <https://doi.org/10.1038/nm0102-68> (15. 10. 2022)
4. Iizuka N, Oka M, Yamada-Okabe H, et al. Oligonucleotide microarray for prediction of early intrahepatic recurrence of hepatocellular carcinoma after curative resection. *Lancet* 2003; 361(9361): 923-929. [https://doi.org/10.1016/S0140-6736\(03\)12775-4](https://doi.org/10.1016/S0140-6736(03)12775-4) (19. 11. 2022)
5. Sotiriou C, Neo SY, McShane LM, et al. Breast cancer classification and prognosis based on gene expression profiles from a population-based study. *Proc Natl Acad Sci USA* 2003; 100(18): 10393-10398. <https://doi.org/10.1073/pnas.1732912100> (12. 10. 2022)
6. Wang Y, Klijn JG, Zhang Y, et al. Gene-expression profiles to predict distant metastasis of lymph-node-negative primary breast cancer. *Lancet* 2005; 365(9460): 671-679. [https://doi.org/10.1016/S0140-6736\(05\)17947-1](https://doi.org/10.1016/S0140-6736(05)17947-1) (12. 10. 2022)
7. Shen R, Ghosh D, Chinnaiyan A, Meng Z. Eigengene-based linear discriminant model for tumor classification using gene expression microarray data. *Bioinformatics* 2006; 22(21): 2635-2642. <https://doi.org/10.1093/bioinformatics/btl442> (10. 9. 2022)
8. Jimeno-Yepes AJ, Plaza L, Mork JG, Aronson AR, Díaz A. MeSH indexing based on automatically generated summaries. *BMC Bioinformatics* 2013; 14: 208. <https://doi.org/10.1186/1471-2105-14-208> (10. 9. 2022)
9. Štotl I, Blagus R, Urbančič-Rovan V. Individualised screening of diabetic foot: creation of a prediction model based on penalised regression and assessment of theoretical efficacy. *Diabetologia* 2022; 65(2): 291-300. <https://doi.org/10.1007/s00125-021-05604-2> (19. 11. 2022)
10. Tao D, Tang X, Li X, Wu X. Asymmetric bagging and random subspace for support vector machines-based relevance feedback in image retrieval. *IEEE Trans Pattern Anal Mach Intell* 2006; 28(7): 1088-1099. <https://doi.org/10.1109/TPAMI.2006.134> (19. 11. 2022)
11. He H, Garcia EA. Learning from imbalanced data. *IEEE Trans Knowl Data Eng* 2009; 21(9): 1263-1284. <https://doi.org/10.1109/TKDE.2008.239> (5. 9. 2022)
12. Blagus R, Lusa L. Class prediction for high-dimensional class-imbalanced data. *BMC Bioinformatics* 2010; 11: 523. <https://doi.org/10.1186/1471-2105-11-523> (13. 8. 2022)
13. Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *J Artif Intell Res* 2002; 16: 341-378. <https://doi.org/10.1613/jair.953> (5. 9. 2022)
14. Liu XY, Wu J, Zhou ZH. Exploratory undersampling for class-imbalance learning. *IEEE Trans Syst Man Cybern B Cybern* 2009; 39(2): 539-550. <https://doi.org/10.1109/TSMCB.2008.2007853> (10. 9. 2022)
15. Lin WJ, Chen JJ. Class-imbalanced classifiers for high-dimensional data. *Brief Bioinform* 2013; 14(1): 13-26. <https://doi.org/10.1093/bib/bbs006> (14. 10. 2022)
16. Galar M, Fernandez A, Barrenechea E, Bustince, H, Herrera F. A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches. *IEEE Trans Syst Man Cybern, Part C Appl Rev* 2012; 42(4): 463-484. <https://doi.org/10.1109/TSMCC.2011.2161285> (20. 10. 2022)
17. Blagus R, Lusa L. SMOTE for high-dimensional class-imbalanced data. *BMC Bioinformatics* 2013; 14: 106. <https://doi.org/10.1186/1471-2105-14-106> (17. 11. 2022)
18. Hastie T, Tibshirani R, Friedman J. The elements of statistical learning: data mining, inference, and prediction. New York 2003: Springer.
19. Hoerl AE, Kennard RW. Ridge regression: biased estimation for nonorthogonal problems. *Technometrics* 1970; 12(1): 55-67. <https://doi.org/10.1080/00401706.1970.10488634> (20. 10. 2022)
20. Schaefer RL, Roi LD, Wolfe RA. A ridge logistic estimator. *Commun Stat Theory Methods* 1984; 13(1): 99-113. <https://doi.org/10.1080/03610928408828664> (3. 11. 2022)
21. Zhu J, Hastie T. Classification of gene microarrays by penalized logistic regression. *Biostatistics* 2004; 5(3): 427-443. <https://doi.org/10.1093/biostatistics/5.3.427> (18. 11. 2022)
22. Goeman J, Meijer R, Chaturvedi N, Lueder M. *L1 (lasso and fused lasso) and L2 (ridge) penalized estimation in*

- GLMs and in the Cox model.* 2014. <http://CRAN.R-project.org/package=penalized> (20. 10. 2022)
23. Blagus R, Goeman JJ. Mean squared error of ridge estimators in logistic regression. *Stat Neerl* 2020; 74(2): 159-191. <https://doi.org/10.1111/stan.12201> (10. 9. 2022)
 24. Pepe MS. The statistical evaluation of medical tests for classification and prediction. New York 2003: Oxford University Press.
 25. Blagus R, Goeman JJ. What (not) to expect when classifying rare events. *Brief Bioinform* 2018; 19(2): 341-349. <https://doi.org/10.1093/bib/bbw107> (20. 10. 2022)
 26. Fawcett T. An introduction to ROC analysis. *Pattern Recognit Lett* 2006; 27(8): 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010> (10. 9. 2022)
 27. Perme MP, Manevski D. Confidence intervals for the Mann-Whitney test. *Stat Methods Med Res* 2019; 28(12): 3755-3768. <https://doi.org/10.1177/0962280218814556> (18. 11. 2022)
 28. Blagus R, Lusa L. Improved shrunken centroid classifiers for high-dimensional class-imbalanced data. *BMC Bioinformatics* 2013; 14: 64. <https://doi.org/10.1186/1471-2105-14-64> (3. 11. 2022)
 29. Simon R, Radmacher MD, Dobbin K, McShane LM. Pitfalls in the use of DNA microarray data for diagnostic and prognostic classification. *J Natl Cancer Inst* 2003; 95(1): 14-18. <https://doi.org/10.1093/jnci/95.1.14> (20. 10. 2022)
 30. Ambroise C, McLachlan GJ. Selection bias in gene extraction on the basis of microarray gene-expression data. *Proc Natl Acad Sci U S A* 2002; 99(10): 6562-6566. <https://doi.org/10.1073/pnas.102102699> (6. 10. 2022)
 31. Taft LM, Evans RS, Shyu CR, et al. Countering imbalanced datasets to improve adverse drug event predictive models in labor and delivery. *J Biomed Inform* 2009; 42(2): 356-364. <https://doi.org/10.1016/j.jbi.2008.09.001> (8. 10. 2022)
 32. López-de-Uralde J, Ruiz I, Santos I, et al. Automatic morphological categorisation of carbon black nano-aggregates. In: Bringas PG, Hameurlain A, Quirchmayr G (eds). *Database and Expert Systems Applications*. DEXA 2010. Lecture Notes in Computer Science, vol 6262. Berlin, Heidelberg 2010: Springer: 185-193. https://doi.org/10.1007/978-3-642-15251-1_15 (3. 11. 2022)
 33. Naseriparsa M, Kashani MM. Combination of PCA with SMOTE resampling to boost the prediction rate in lung cancer dataset. *Int J Comput Appl* 2013; 77(3): 33-38. <https://doi.org/10.5120/13376-0987> (16. 11. 2022)
 34. Blagus R, Lusa L. Joint use of over- and under-sampling techniques and cross-validation for the development and assessment of prediction models. *BMC Bioinformatics* 2015; 16: 363. <https://doi.org/10.1186/s12859-015-0784-9> (3. 11. 2022)
 35. Japkowicz N. The Class Imbalance Problem: Significance and Strategies. In: *Proceedings of the 2000 International Conference on Artificial Intelligence ICAI*, 2000.
 36. Rahman MM, Davis D. Cluster based under-sampling for unbalanced cardiovascular data. In: *Proceedings of the World Congress on Engineering*, vol. 3, London 2013: 3-5. https://www.iaeng.org/publication/WCE2013/WCE2013_pp1480-1485.pdf (3. 11. 2022)
 37. Zhang JP, Mani I. KNN Approach to unbalanced data distributions: a case study involving information extraction. In: *Proceeding of International Conference on Machine Learning (ICML 2003), Workshop on Learning from Imbalanced Data Sets*. Washington 2003: 1-7.
 38. Cover TM, Hart PE. Nearest neighbor pattern classification. *IEEE Trans Inf Theory* 1967 13(1): 21-27. <https://doi.org/10.1109/TIT.1967.1053964> (20. 10. 2022)
 39. Forman G, Scholz M. Apples-to-apples in cross-validation studies: pitfalls in classifier performance measurement. *SIGKDD Explor Newslett* 2010; 12(1): 49-57. <https://doi.org/10.1145/1882471.1882479> (10. 9. 2022)
 40. Cox DR, Hinkley DV. *Theoretical statistics*. New York 1979: CRC Press.
 41. Le Cessie S, Van Houwelingen JC. Ridge estimators in logistic regression. *J R Stat Soc Ser C Appl Stat* 1992; 41(1): 191-201. <https://doi.org/10.2307/2347628> (3. 11. 2022)

Živa Rant, Hajdi Kosednar, Dalibor Stanimirović

Vloga in pomen Centra za pomoč uporabnikom rešitev eZdravja v slovenskem zdravstvu

Povzetek. Center za pomoč uporabnikom rešitev eZdravja je ključna komponenta sistema eZdravje v Sloveniji, ki je namenjena vsem uporabnikom tega sistema. Center izvaja tri osnovne naloge. Splošna podpora vsem uporabnikom rešitev eZdravja je namenjena zdravstvenim delavcem, administrativnemu osebju, informatikom, ponudnikom programskih rešitev, pacientom in vsem drugim uporabnikom rešitev eZdravja, ki želijo prijaviti motnje v delovanju, potrebujejo pomoč ali zahtevajo informacije v zvezi z delovanjem rešitev eZdravja. Storitev elektronskega naročanja na zdravstvene storitve pomaga pacientom pri naročanju. Podpora pri priklopu v zNET je namenjena izvajalcem zdravstvene dejavnosti pri postopku vključitve v omrežje zNET. Dostopanje do pomoči je možno s spletnim obrazcem, preko elektronske pošte, pogosto zastavljenih vprašanj ali telefona. Na svoji spletni strani Center za pomoč uporabnikom objavlja obvestila, povezana z delovanjem rešitev eZdravja, in semafor o delovanju rešitev. V zadnjih dveh letih je bilo v delo Centra vključenih več novih rešitev. Uporaba je pospešeno narasla – v letu 2021 smo beležili več kot sedemkratno povečanje glede na leto 2020. Prispevek analizira delovanje Centra skozi dinamiko in vsebino obravnavanih zahtevkov in opravljenih storitev. Delovanje Centra je pomembna komponenta uspešne uporabe rešitev eZdravja v Sloveniji, kar se je še posebej izkazalo v času epidemije COVID-19.

Ključne besede: eZdravje; slovensko zdravstveno omrežje; elektronsko naročanje; pomoč uporabnikom.

The Role and Importance of the Service Desk for eHealth Solutions in Slovenian Health Care

Abstract. The eHealth Service Desk is a key component of the eHealth system in Slovenia, which is intended for all users of the system. The Service Desk performs three main tasks. General support for all users of eHealth solutions addresses health care professionals, administrative staff, information technology specialists, software solution providers, patients and all other users of eHealth solutions who wish to report malfunctions, need assistance or require information related to the functioning of the eHealth solutions. The electronic appointment for health care services helps patients to make an eAppointment for health care services. The zNET Connection Support offers help to health care providers in the process of joining the zNET network. Assistance can be accessed in several ways: via an online form, email, FAQs or phone. The Service Desk publishes notifications related to the eHealth solutions on its website and maintains a simple indicator that displays the status of eHealth solutions. During the last two years, several new eHealth solutions have been added to the Service Desk portfolio. The use has been growing rapidly in recent years, namely in 2021 we recorded a more than sevenfold increase compared to 2020. The paper analyses the operation of the eHealth Service Desk through the dynamics and content of the requests handled or services provided. The Service Desk is an important component for the successful use of eHealth solutions in Slovenia, which was particularly evident during the COVID-19 epidemic.

Key words: eHealth; Slovenian healthcare network; electronic appointment; user support.

■ Infor Med Slov 2022; 27(1-2): 14-19

Institucije avtorjev / Authors' institutions: Nacionalni inštitut za javno zdravje, Ljubljana (ŽR, HK); Fakulteta za upravo, Univerza v Ljubljani (DS).

Kontaktna oseba / Contact person: mag. Živa Rant, NIJZ, Trubarjeva cesta 2, 1000 Ljubljana. E-pošta / E-mail: ziva.rant@nijz.si.

Prispelo / Received: 27. 1. 2023. Sprejeto / Accepted: 31. 1. 2023.

Uvod

Učinkovita in celovita digitalna preobrazba slovenskega zdravstvenega sistema je ena izmed temeljnih sprememb, ki naj bi pripomogla k bolj uspešnemu spopadanju s številnimi izzivi, ki se nahajajo pred slovenskim zdravstvom. Nekatere izkušnje razvitih držav kažejo,^{1,2} da imajo uspešno izvedeni projekti digitalizacije zdravstva velik strateški pomen za nadaljnji razvoj zdravstvenega sistema, po navedbah Evropske komisije pa imajo tudi širše implikacije v smeri povečanja družbene blaginje in gospodarske rasti.³ Projekt digitalizacije slovenskega zdravstva (eZdravje), ki sledi nacionalnim in evropskim usmeritvam, je bil eden ključnih dolgoročnih ciljev javnega sektorja v Sloveniji. Upravljanje digitalnih rešitev, ki so nastale v sklopu projekta eZdravje, je konec leta 2015 prevzel Nacionalni inštitut za javno zdravje (NIJZ). Do takrat je projekt eZdravje vodilo Ministrstvo za zdravje, velik delež zagonskih sredstev pa je bil zagotovljen iz Evropskega socialnega sklada.

Pregled razmer na obravnavanem področju kaže, da težave, s katerimi se že od vsega začetka srečuje projekt eZdravje, na eni strani izhajajo iz tehnično-tehnoloških značilnosti obstoječih (večinoma razdrobljenih) zdravstvenih informacijskih sistemov (ZIS), ki so posledica neusklenjenega razvoja na področju zdravstvene informatike v zadnjih desetletjih. Na drugi strani pa gre odgovornost za obstoječe stanje pripisati predvsem odločevalskim krogom, ki so razvoj zdravstvene informatike v tem obdobju prepustili lastnim pobudam, potrebam in partikularnim interesom posameznikov na ravni zdravstvenih zavodov (ali celo oddelkov), brez enotnih strateških usmeritev. Poleg tega pristojni v tem obdobju niso uspeli spodbuditi razvoja in uresničitve projekta digitalizacije z močnejšo politično (finančno, kadrovsko, organizacijsko) podporo ter oblikovanjem konsistentne strategije na tem področju.

Posledice navedenih vzrokov se odražajo v izzivih, ki jih je NIJZ zaznal v teku dosedanjih aktivnosti za implementacijo rešitev eZdravja:

- nepripravljenost (upravljavska, tehnološka, organizacijska, procesna ipd.) določenih izvajalcev zdravstvene dejavnosti za ustrezno uporabo rešitev eZdravja;
- procesne, organizacijske, varnostne in uporabniške težave pri izvajalcih zdravstvene dejavnosti;
- neusklenjenost zdravstvene stroke pri vsebinskih vprašanjih (npr. šifrant vrst zdravstvenih storitev

(VZS), matrika dostopov v Centralni register podatkov o pacientu (CRPP));

- ozka usmerjenost posameznih deležnikov v lastno strokovno področje brez zavedanja o soodvisnosti vseh deležnikov zdravstvenega sistema;
- pomanjkanje kompetentnih strokovnjakov s področja informatike pri izvajalcih zdravstvene dejavnosti, ki bi skrbeli za ustrezno vzdrževanje in delovanje rešitev eZdravja;
- nezadostna sredstva za digitalizacijo pri izvajalcih zdravstvene dejavnosti in na NIJZ, ki skrbi za razvoj, vzdrževanje in nadgradnje centralnih nacionalnih rešitev eZdravja.

Navkljub navedenim izzivom, pomanjkanju enotnih strateških dokumentov in nezadostnemu vlaganju na področje zdravstvene informatike je v zadnjih štirih letih prišlo do velikega napredka pri razvoju in implementaciji rešitev eZdravja. V času upravljanja rešitev se je pričakovalo izkazalo, da uporabniki potrebujejo tudi pomoč pri uporabi rešitev eZdravja. Zato je bila vzpostavljena storitev Pomoč in podpora za uporabnike eZdravja. Namenjena je vsem uporabnikom rešitev eZdravja, ki želijo prijaviti motnje v delovanju, potrebujejo pomoč ali zahtevajo informacije v zvezi z delovanjem rešitev eZdravja. Skladno z navedenimi izhodišči se prispevek v nadaljevanju osredotoča na analizo delovanja Centra za pomoč uporabnikom eZdravja skozi dinamiko in vsebino obravnavanih zahtevkov oziroma storitev, ki jih izvaja.

Center za pomoč uporabnikom rešitev eZdravja

Storitev Pomoč in podpora za uporabnike rešitev eZdravja je bila zamišljena že v prvih strateških dokumentih na področju eZdravja. Od prenosa eZdravja na NIJZ konec leta 2015 postaja njena vloga vse večja. Še posebej se je to izkazalo v času epidemije COVID-19, ko običajni načini usposabljanja uporabnikov in reševanja zahtevkov niso bili mogoči, razvoj informacijskih rešitev eZdravja pa je naredil izrazit preskok.

Center za pomoč uporabnikom zagotavlja pomoč za skoraj trideset rešitev eZdravja. Ima tri osnovne naloge:

- splošno podporo vsem uporabnikom rešitev eZdravja,
- podporo pri priklopu v varno zdravstveno omrežje zNET in
- elektronsko naročanje na zdravstvene storitve.

Splošna podpora vsem uporabnikom rešitev eZdravja je namenjena zdravstvenim delavcem,

administrativnemu osebju, informatikom, ponudnikom programskih rešitev, pacientom in vsem drugim uporabnikom rešitev eZdravja, ki želijo prijaviti motnje v delovanju, potrebujejo pomoč ali zahtevajo informacije v zvezi z delovanjem rešitev eZdravja. Podpora pri priklopu v zNET izvaja pomoč izvajalcem zdravstvene dejavnosti pri postopku vključitve v varno zdravstveno omrežje zNET. Storitev elektronskega naročanja na zdravstvene storitve pomaga pacientom pri elektronskem naročanju.

Uporabniki dostopajo do pomoči preko spletne obrazca na spletni strani <https://podpora.ezdrav.si/>, preko sporočil po elektronski pošti ali s telefonskim klicem za vse rešitve eZdravja, za pomoč pri e-naročanju in za zNET. Na spletni strani <https://podpora.ezdrav.si/pogosta-vprasanja/> so objavljeni odgovori na pogosto zastavljena vprašanja.

V času epidemije COVID-19 je bila storitev razširjena tako, da je zagotavljala podporo za vrsto novih informacijskih rešitev. Za izvajalce zdravstvene dejavnosti so to pomoč za poročanje o presejalnem testiranju na COVID-19, za vnos rezultatov testov na COVID-19 v zdravstveni portal zVEM+, rešitev zVEM+ za covid vstopne točke in podpora obveščanja pacientov. Za paciente sta to digitalno covidno potrdilo (EU DCP) in prijava na cepljenje proti COVID-19. Poleg teh rešitev se zagotavlja podpora tudi za rešitev za poslovno analitiko za eNaročanje in prenaročanje pacientov na zdravstvene storitve v okviru nacionalnega razpisa.

Podporo izvaja stalna in izkušena ekipa svetovalcev, ki je specializirana za različna področja in rešitve eZdravja. Svetovalci se neprestano izobražujejo – splošno in za posamezne rešitve – ter udeležujejo predavanj, usposabljanj in delavnic. Posnetki so na voljo tudi za ponoven ogled in usposabljanje novih sodelavcev. Center za pomoč in podporo gradi bazo znanja, vzdržuje dokumentacijo in skrbi za odgovore na pogosto zastavljena vprašanja.

Center za pomoč uporabnikom na spletni strani objavlja obvestila, povezana z delovanjem rešitev eZdravja, in vzdržuje semafor o delovanju rešitev.

Metode

V prispevku predstavljamo analizo funkcionalnosti in uporabe storitve Pomoč in podpora za uporabnike eZdravja. Z raziskavo smo želeli odgovoriti na vprašanje, kako je epidemija COVID-19 vplivala na razvoj in uporabo storitve Pomoč in podpora za uporabnike eZdravja. Gre za primer agilnega razvoja

storitve, ki se je pospešeno razvijala v času epidemije, ki je bila s tega vidika posebna priložnost za razvoj. Za raziskavo smo uporabili metodologijo študije primera,^{4,5,6} ki je vključevala poglobljeno študijo področja in njeno kritično analizo. Analiza je bila na eni strani izvedena na podlagi pregleda literature s tega področja⁷ ter projektne dokumentacije in tehničnih specifikacij rešitve Pomoč in podpora za uporabnike eZdravja, na drugi strani pa na podlagi opazovanj, izkušenj ter strokovnega mnenja strokovnjakov na NIJZ, ki upravljajo z rešitvami eZdravja (tudi s storitvijo Pomoč in podpora za uporabnike eZdravja) in Centra za pomoč uporabnikom rešitev eZdravja ter dejanskih statističnih podatkov o uporabi iz administratorskega modula rešitve.⁸

Analiza funkcionalnosti in uporabe rešitve Pomoč in podpora za uporabnike eZdravja, v smislu pregleda literature s tega področja ter projektne dokumentacije in tehničnih specifikacij, je bila izvedena v prvi polovici leta 2022. Strukturirani razgovori s strokovnjaki NIJZ in pridobitev statističnih podatkov iz poslovnih in administratorskih modulov pa so bili izvedeni v obdobju od aprila do julija 2022.

Rezultati

Epidemija COVID-19 je pokazala, kako pomembna je digitalizacija zdravstva,⁹ še posebej pa je za digitalizacijo ključen obstoj nacionalnih rešitev. To se je pokazalo tudi pri razvoju rešitev eZdravja v Sloveniji. Razmere so zahtevale številne nadgradnje informacijskih rešitev, ki jih je bilo potrebno razviti in uvesti v čim krajšem času. Za nekatere cilje digitalizacije je bilo mogoče uporabiti že obstoječe rešitve s prilagoditvami, nekatere rešitve je bilo potrebno predelati, nekatere pa razviti na novo. V obdobju 2020-2021 sta se še posebej razvili rešitvi Zdravstveni portal za paciente zVEM in Centralni register podatkov o pacientih (CRPP).¹⁰

Pri portalu zVEM se je število registriranih uporabnikov v letu 2021 povečalo devetkrat (na 925 % izhodiščne vrednosti) glede na leto 2020, število obiskov pa kar dvanajstkrat (na 1273 %). Število dokumentov v CRPP se je napram letu 2019 v letu 2021 povečalo osemkrat (849 %).¹⁰

Hiter razvoj informacijskih rešitev in izredno kratek čas za uvajanje, ki ni omogočal običajnega usposabljanja uporabnikov ter reševanja zahtevkov, sta povzročila nepričakovan pritisk na Center za pomoč uporabnikom.

Podatki o uporabi kažejo na izreden porast aktivnosti v zadnjih dveh letih. Število dogodkov v letu 2021 se

je povečalo več kot sedemkrat (766 %), prav tako število sprejetih klicev (742 %), porabljen čas v pa petkrat (493 %; slika 1).

Največji porast je viden maja in junija 2021 (slika 2), kar je povezano tudi s pridobivanjem evropskih digitalnih potrdil preko portala za paciente zVEM in z vnosom cepljenj in testiranj pri izvajalcih zdravstvene dejavnosti.

V maju 2021 se je na primer 80 % do 90 % zahtevkov nanašalo na zVEM oziroma vprašanja za DCP (slika 3). Kasneje je ta delež padel.

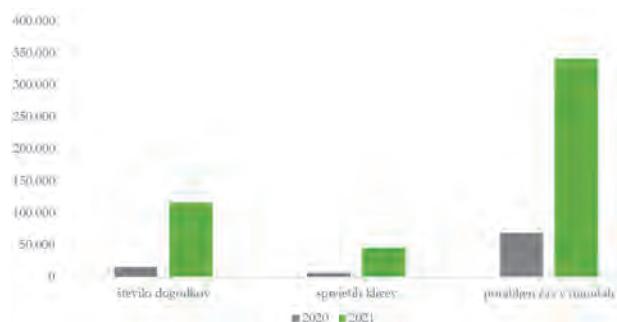
Zanimiv je tudi pogled na različno obremenitev centra za pomoč uporabnikom glede na dan v tednu in uro dneva. Podatki iz administrativnega modula kažejo, da je bilo podanih največ zahtevkov v torek (slika 4) in v urah okrog poldneva.

Eden od vzrokov za tako povpraševanje po pomoči za rešitev zVEM je zagotovo pomoč svetovalcev pri pridobivanju evropskega digitalnega covidnega potrdila (EU DCP), ki so ga zahtevala stroga pravila gibanja v Sloveniji v času epidemije COVID-19. Bistvena prednost je, da so se na strani svetovalcev na telefonske klice oglašali ljudje in ne samo odzivnik. Svetovalci so se lahko prilagodili uporabniku, njegovemu znanju, izkušnjam in ravni digitalne pismenosti. Uporabniki so tako dobili pomoč najprej pri dostopanju do rešitve zVEM, svetovalci pa so jih nato korak za korakom usmerjali do dokončne pridobitve EU DCP. Zadovoljstvo uporabnikov kažejo tudi številne pohvale, ki so jih podali.

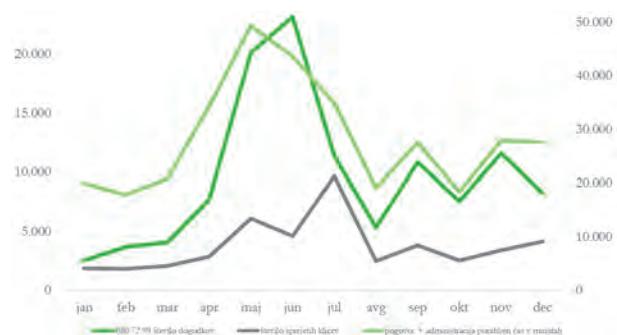
Pomoč pri naročanju je najbolj narasla maja 2021, po prvem valu epidemije COVID-19 (slika 5).

Svetovalci se pri izvajanju podpore srečujejo z mnogimi izviri in težavami. Zagotovo največjo težavo predstavlja nepredvidljivost dnevnih in mesečnih obremenitev, na kar se je težko pripraviti. Zelo se je povečalo število klicev in zahtevkov v času epidemije COVID-19, obremenitev centra za pomoč pa se močno poveča ob uvedbi novih rešitev (npr. portal zVEM, covidno potrdilo).

Ena od težav pri izvajanju storitve je veliko število klicev, ki niso povezani z rešitvami eZdravja, predvsem iskanje informacij, povezanih z epidemijo COVID-19. Taki klici povzročajo opazne obremenitve v klicnem centru in nedosegljivost klicnih številk, kar povzroča nezadovoljstvo pri tistih uporabnikih, ki pomoč dejansko potrebujejo, in morajo zato marsikdaj na pomoč čakati dlje.



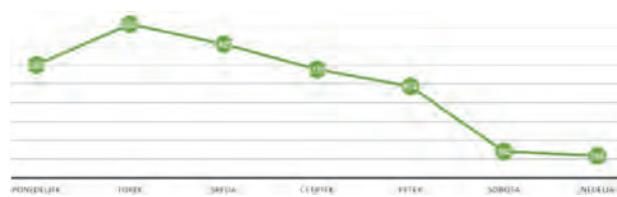
Slika 1 Podatki o uporabi pomoči uporabnikom rešitev eZdravja v letih 2020 in 2021.



Slika 2 Podatki o uporabi pomoči uporabnikom rešitev eZdravja po mesecih v letu 2021.



Slika 3 Podatki o deležu pomoči uporabnikom za rešitev zVEM v letu 2021.



Slika 4 Evidentirani zahtevki po dnevih v tednu.



Slika 5 Podatki o uporabi pomoči za e-naročanje.

V času epidemije je center za pomoč uporabnikom prejemal vprašanja, povezana z zdravjem, vprašanja o bolezni COVID-19, vprašanja o zdravljenju in zdravilih, vprašanja o cepljenju, cepivih in stranskih učinkih. Poleg tega so se pacienti obračali na klicni center z vprašanji o veljavnih ukrepih in omejitvah gibanja. S tem se je zameglil pravi namen centra za pomoč, namreč podpora uporabnikom rešitev eZdravja.

Uporabniki so potrebovali pomoč pri raznovrstnih digitalnih rešitvah v zdravstvu, od naročanja na cepljenje, naročanja na pregled, pridobivanja napotnic in receptov, dostopa do izvidov in odpustnih pisem. Vse to jih je bilo na voljo v portalu zVEM, za katerega su nujno potrebovali najprej kvalificirano digitalno potrdilo, kasneje pa SI-PASS. Svetovalci v centru za pomoč so uporabnike vodili skozi včasih res zapletene in zamudne postopke registracije v različne digitalne in spletne storitve.

Razprava

Izbira raziskovalne metode je temeljila na posebnostih raziskovalnega področja in dejству, da je celotno področje digitalizacije zdravstva v Sloveniji še vedno v razmeroma zgodnji fazi, zato obstaja le ozek krog strokovnjakov z ustreznim znanjem in izkušnjami na tem področju. Tovrsten pristop je omogočil tako vpogled v dosedanja teoretska in tehnološka izhodišča tovrstnih digitalnih rešitev kot tudi empirični pregled uporabe storitve Pomoč in podpora za uporabnike eZdravja v slovenskem zdravstvenem sistemu. Sodelovanje strokovnjakov z NIJZ in Centra za pomoč uporabnikom rešitev eZdravja pri raziskavi je poleg vpogleda v tehnološke in statistične vidike delovanja storitve omogočilo tudi kritičen in temeljiti vpogled v uporabniške vidike te storitve, saj so strokovnjaki z NIJZ in Centra za pomoč uporabnikom rešitev eZdravja dobro seznanjeni z uporabniškimi izkušnjami pacientov in zdravstvenih delavcev na terenu ter njihovim zadovoljstvom z rešitvami eZdravja.

Prispevek se osredotoča na storitev Pomoč in podpora za uporabnike eZdravja predvsem zaradi njene pomembnosti tako za paciente kot tudi za zdravstvene delavce. Sinteza ugotovitev iz literature, uporabniških funkcionalnosti, statističnih poročil ter stališč strokovnjakov z NIJZ in Centra za pomoč uporabnikom rešitev eZdravja omogoča oblikovanje verodostojnih in na preverljivih podatkih temelječih zaključkov glede izpostavljenih raziskovalnih ciljev.¹¹ Uporaba takega metodološkega okvira, vključujuč kombinacijo različnih pristopov ter tehnik zbiranja podatkov, je zagotovila verodostojnost analize funkcionalnosti storitve.¹² Celovita analiza podatkov, pridobljenih iz raznoterih virov in strukturiranih razgovorov s strokovnjaki NIJZ in Centra za pomoč uporabnikom rešitev eZdravja je v sklepnji fazi raziskave zagotovila osnovo za interpretacijo podatkov ter oblikovanje zaključkov glede raziskovalnih izhodišč prispevka.¹³

Zaključek

Nacionalne rešitve eZdravja v Sloveniji so od zaključka projekta leta 2015 doživele izjemen razvoj. Še posebej je bil ta razvoj pospešen v času epidemije COVID-19. Poleg razvoja rešitev se je več kot desetkrat povečala tudi njihova uporaba. V tem obdobju so se razkrile pomanjkljive kompetence uporabnikov informacijskih rešitev, od najosnovnejše uporabe računalniške in telekomunikacijske opreme preko računalniške in informacijske pismenosti do uporabe računalniških rešitev samih. Zato se je v tem času izredno povečala tudi potreba po uporabi Centra za pomoč uporabnikom rešitev eZdravja, ki je s svojim delom marsikateremu uporabniku omogočal uporabo digitaliziranih rešitev. Pokazalo se je tudi, da je potrebno izboljšati digitalno kulturo v zdravstvenih ustanovah in digitalne kompetence vseh zaposlenih v zdravstvu na eni strani in pacientov oziroma prebivalstva na drugi strani.

Epidemija COVID-19 je pokazala izjemen pomen digitalnih rešitev v zdravstvu. Tudi zato bo v prihodnje potrebno vložiti veliko naporov in sredstev za ohranitev spodbudnega razvojnega trenda in nadaljnje povečanje uporabe rešitev eZdravja.

Reference

1. Bokolo AJ. Application of telemedicine and eHealth technology for clinical services in response to COVID-19 pandemic. *Health Technol (Berl)* 2021; 11(2): 359-366.
<https://doi.org/10.1007/s12553-020-00516-4> (1. 12. 2022)
2. Arcury TA, Sandberg JC, Melius KP, et al. Older Adult internet use and ehealth literacy. *J Appl Gerontol* 2020;

- 39(2): 141-150.
<https://doi.org/10.1177/0733464818807468>
(10. 12. 2022)
3. Communication from the Commission to the European Parliament, the European Council, the Council, the European Economic and Social Committee and the Committee of the Regions on enabling the digital transformation of health and care in the Digital Single Market; empowering citizens and building a healthier society. SWD (2018) 126 final. Brussels 2018: European Commission.
<https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52018DC0233&format=EN> (10. 12. 2022)
4. Yin RK. *Case study research and applications: design and methods* (6th ed.). Thousand Oaks 2018: Sage Publications.
5. Kljajić Borštnar M. *Raziskovanje informacijskih sistemov*. Kranj 2021: Fakulteta za organizacijske vede.
6. Myers MD, Avison DE (eds.). *Qualitative research in information systems: a reader*. London 2002: SAGE Publications.
7. Lee WL, Lim ZJ, Tang LY, Yahya NA, Varathan KD, Ludin SM. Patients' technology readiness and ehealth literacy: implications for adoption and deployment of ehealth in the covid-19 era and beyond. *Comput Inform Nurs* 2021; 40(4): 244-250.
<https://doi.org/10.1097/CIN.0000000000000854>
(25. 11. 2022)
8. Statistika zahtevkov na Prvem nivoju podpore uporabnikom eZdravja. Ljubljana 2021: Nacionalni inštitut za javno zdravje.
9. Rant Ž, Stanimirović D, Janet J. Razvoj portala zVEM in Centralnega registra podatkov o pacientu. In: Šprajc P, Maletič D, Pavlović N et al. (eds). *41. mednarodna konferenca o razvoju organizacijskih znanosti: izravnivi družbe za priložnosti organizacij: konferenčni zbornik*. Maribor 2022: University of Maribor, University Press; 873-884.
<https://doi.org/10.18690/um.fov.3.2022.63>
(25. 11. 2022)
10. Lindgren BM, Lundman B, Graneheim UH. Abstraction and interpretation during the qualitative content analysis process. *Int J Nurs Stud* 2020; 108: 103632.
<https://doi.org/10.1016/j.ijnurstu.2020.103632>
(7. 12. 2022)
11. Sim J, Waterfield J. Focus group methodology: some ethical challenges. *Qual Quant* 2019; 53(6): 3003-3022.
<https://doi.org/10.1007/s11135-019-00914-5>
(7. 12. 2022)
12. Thomas G. *How to do your case study*. Thousand Oaks, CA 2021: Sage Publications.
13. Stanimirović D, Matetić V. *Can the COVID-19 pandemic boost the global adoption and usage of eHealth solutions?* J Glob Health 2020; 10(2): 0203101.
<https://doi.org/10.7189/jogh.10.0203101>
(10. 12. 2022)

Žiga Lovšin, Barbara Artnik

Viri podatkov na področju ustnega zdravja v Sloveniji

Povzetek. Na področju ustnega zdravja se za različne namene beležijo različni podatki, med drugim za oceno stanja ustnega zdravja prebivalstva in potreb po zdravljenju, za načrtovanje preventivnih programov ter za spremljanje delovanja sistema zobozdravstvenega varstva. V Sloveniji obstaja več razpršenih virov in načinov zbiranja podatkov. Namen tega članka je identificirati in na enem mestu zbrati in prikazati vire, ki vsebujejo ključne podatke o ustnem zdravju v Sloveniji. Vire podatkov razdelimo na primarne in sekundarne. Primarni viri v zobozdravstvu se nadalje lahko delijo na podatke raziskav in podatke iz poročanja, na klinične in neklinične podatke ter na podatke glede na populacijsko skupino (otroci, mladostniki, odrasli). Sekundarne vire podatkov najdemo v različnih slovenskih in mednarodnih publikacijah ter podatkovnih zbirkah, ki podatke pridobivajo iz enega ali več primarnih virov. V prihodnje je na področju ustnega zdravja v Sloveniji na nacionalni ravni potrebno vzpostaviti zbiranje, digitalizacijo in sistematizacijo kliničnih podatkov ter vpeljati kontinuirano zbiranje in analiziranje nekliničnih podatkov.

Ključne besede: ustno zdravje; zobozdravstvo; viri informacij; viri podatkov; podatkovne zbirke.

Data Sources on Oral Health in Slovenia

Abstract. In the field of oral health, various data are recorded for different purposes, including the assessment of oral health status and treatment needs of the population, planning prevention programmes, and monitoring the functioning of the dental care system. In Slovenia, there are several scattered sources and methods of data collection. The aim of this article is to identify, assemble and present in one place the sources that contain key data on oral health in Slovenia. Data sources can be divided into primary and secondary ones. Primary data sources in dentistry can be further divided into research and report data, clinical and non-clinical data, and data by population groups (children, adolescents, adults). Secondary data sources can be found in various Slovenian and international publications and databases that draw data from one or more primary sources. In the future, it is necessary to establish the collection, digitisation and systematisation of clinical oral health data in Slovenia at the national level, and to introduce continuous collection and analysis of non-clinical data.

Key words: oral health; dentistry; information sources; data sources; databases.

■ **Infor Med Slov** 2022; 27(1-2): 20-26

Institucije avtorjev / Authors' institutions: Nacionalni inštitut za javno zdravje, Ljubljana (ŽL); Medicinska fakulteta, Univerza v Ljubljani (B.A).

Kontaktna oseba / Contact person: doc. dr. Barbara Artnik, dr. dent. med., spec., Katedra za javno zdravje, Medicinska fakulteta, Univerza v Ljubljani, Zaloška 4, 1000 Ljubljana, Slovenija. E-pošta / E-mail: barbara.artnik@mf.uni-lj.si.

Prispevo / Received: 27. 1. 2023. Sprejeto / Accepted: 31. 1. 2023.

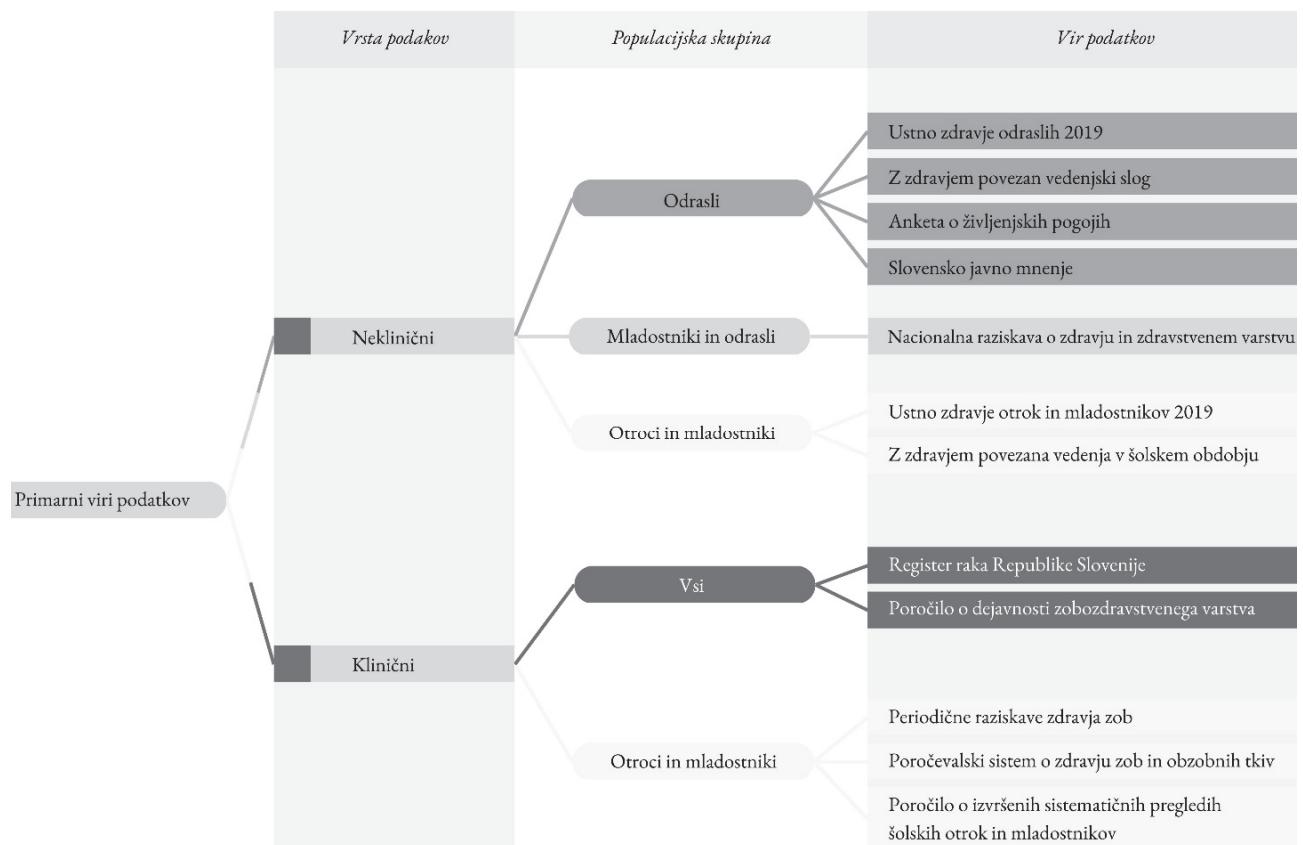
Uvod

Kakovostni in ažurni podatki so ključen del katerekoli stroke. Na področju ustnega zdravja se med drugim beležijo podatki za oceno stanja ustnega zdravja prebivalstva in potreb po zdravljenju, za načrtovanje preventivnih programov ter za spremljanje delovanja sistema zobozdravstvenega varstva.¹ V več novejših mednarodnih publikacijah pozivajo k boljšemu nacionalnemu sistematskemu zbiranju podatkov.²⁻⁴

Trenutno v Sloveniji ni celostnega sistematičnega zbiranja podatkov o stanju ustnega zdravja in

zobozdravstvene oskrbe.² Pomanjkanje podatkov za določene populacijske skupine in raznolikost obstoječih podatkov zato nakazujeta potrebo po organiziranem in sistematičnem spremeljanju področja ustnega zdravja v Sloveniji.⁵

Vendarle pa obstaja na področju ustnega zdravja v Sloveniji več razpršenih virov in načinov zbiranja podatkov. Namen tega članka je identificirati in na enem mestu zbrati ter prikazati vire, ki vsebujejo ključne podatke o ustnem zdravju v Sloveniji.



Slika 1 Razdelitev kliničnih in nekliničnih primarnih virov podatkov v zobozdravstvu glede na populacijske skupine.

Primarni viri podatkov

Primarne vire podatkov v zobozdravstvu lahko razdelimo na klinične in neklinične (slika 1).

Podatki iz raziskav

Ustno zdravje otrok in mladostnikov 2019 je znanstvena monografija na osnovi presečno pregledne epidemiološke raziskave, ki je zajela neklinični del kazalnikov po metodologiji projekta Evropskega globalnega razvoja kazalnikov ustnega zdravja (angl. *European Global Oral Health Indicators Development Project – EGOHID*) za otroke in

mladostnike v Sloveniji. Vključuje podatke o ustni higieni in uporabi fluoridov, prehrani, obiskih pri zobozdravniku, zobozdravstveni vzgoji in preventivi, zobozdravstveni preventivi v času nosečnosti, dostopnosti do zdravstvenih storitev in kakovosti življenja v povezavi z ustnim zdravjem.⁶

Ustno zdravje odraslih 2019 je znanstvena monografija na osnovi presečno pregledne epidemiološke raziskave, ki je zajela neklinični del kazalnikov po metodologiji EGOHID za odraslo populacijo v Sloveniji. Vključuje podatke o ustni higieni in uporabi fluoridov, prehrani, obiskih pri zobozdravniku, brezzobnosti, protetičnih

pripomočkih, dostopnosti do zdravstvenih storitev, kakovosti življenja v povezavi z ustnim zdravjem ter samooceno ustnega zdravja.⁷

Obe publikaciji izpostavljata, da v Sloveniji na nacionalni ravni nimamo podatkov o potrebah in zahtevah po zdravljenju na področju ustnega zdravja.

Z zdravjem povezana vedenja v šolskem obdobju (angl. *Health Behaviour in School Aged Children – HBSC*) je raziskava, ki poteka vsaka štiri leta v organizaciji Svetovne zdravstvene organizacije (SZO) za evropsko regijo. V Sloveniji je bila izvedena v letih 2002,⁸ 2006,⁹ 2010,¹⁰ 2014¹¹ in 2018. Tarčna populacija je reprezentativni vzorec učencev in dijakov, starih 11, 13, 15 in 17 let.¹² Raziskava vključuje vprašanje o pogostnosti ščetkanja zob.

Z zdravjem povezan vedenjski slog v okviru programa CINDI (angl. *Countrywide Integrated Noncommunicable Disease Intervention*). CINDI je mednarodni program, ki deluje v okviru SZO in je namenjen ohranjanju in krepitvi zdravja ter preprečevanju kroničnih nenalezljivih bolezni pri odraslih.¹³ V Sloveniji se raziskave izvajajo vsaka štiri leta (2001,¹⁴ 2004,¹⁴ 2008,¹⁴ 2012,¹⁵ 2016,¹⁶ 2020¹⁷) in v zvezi z ustnim zdravjem vključujejo vprašanja o pogostosti čiščenja zob, številu manjkajočih zob in pogostosti obiska zobozdravnika v zadnjih 12 mesecih.

Nacionalna raziskava o zdravju in zdravstvenem varstvu (angl. *European Health Interview Survey – EHIS*). Namen te raziskave pri prebivalcih Slovenije, starih 15 let in več, je oceniti njihovo zdravstveno stanje, življenjski slog, povezan z zdravjem, in pogostost uporabe različnih zdravstvenih storitev. V Sloveniji je bila raziskava izvedena trikrat, v letih 2007,¹⁸ 2014¹⁹ in 2019.²⁰ Glede ustnega zdravja vključuje podatka o zadnjem obisku pri zobozdravniku in neizpolnjenih potrebah po zobozdravstveni oskrbi zaradi finančnih razlogov.

Anketa o življenjskih pogojih (angl. *European Union Survey on Income and Living Conditions – EU-SILC*) je raziskava EU o dohodkih in življenjskih razmerah. Prikazuje neizpolnjene potrebe ljudi po zobozdravstvenem pregledu v zadnjih 12 mesecih in razloge za neobisk zobozdravnika.² Podatki se zbirajo vsako leto od leta 2012 naprej.²¹

Periodične raziskave zdravja zob z indeksom KEP, ki nam pove povprečno število zaradi kariesa zbolelih (K), izdrtil (E) in popravljenih (P) stalnih zob pri posamezniku. Gre za klinične raziskave, izvedene po metodologiji SZO²² v letih 1987,²³ 1993,²⁴ 1998,²⁵ 2003,²⁶ 2008,²⁷ 2013²⁸ in 2017.²⁹ Na začetku so se

raziskave izvajale pri starostnih skupinah 6, 12, 15, 18 in 35–44 let ter pri starejših od 65 let, od leta 1998 pa le še pri 12-letnikih.²⁹

Slovensko javno mnenje. Raziskava, ki se izvaja vsako leto od leta 1968, je v letih 1981,³⁰ 1994,³¹ 1999³² in 2001³² vsebovala tudi vprašanja o zobozdravstvu. Vprašanja so naslavljala zadovoljstvo z delovanjem zobozdravstvene službe, potrebo po oskrbi pri zasebnem zobozdravniku, podkupovanje v zdravstvu, redno obiskovanje zobozdravnika, čakalne vrste in čas čakanja v ambulanti.

Podatki iz poročanja

Evidenčni obrazec za zdravstvenovzgojno delo (obrazec 8,74) vsebuje podatke o številu izvajalcev, številu udeležencev in izvedenih programov zobozdravstvene vzgoje. Poročevalci so vsi izvajalci zdravstvenovzgojne dejavnosti v zdravstvenih ustanovah, podatki se zbirajo enkrat letno. Podatke za celotno Slovenijo zbira Nacionalni inštitut za javno zdravje (NIJZ), ki vsako leto pripravi podatke za Zdravstveni statistični letopis.^{33,34}

Poročilo o izvršenih sistematičnih pregledih šolskih otrok in mladostnikov (obrazec 8,288) vsebuje podatke o kariesu 1. in 2. stopnje pri otrocih in mladostnikih. Poročevalci so vsi javni in zasebni izvajalci zobozdravstvenega varstva otrok, podatki se zbirajo enkrat letno. Podatke za celotno Slovenijo zbira NIJZ, ki vsako leto pripravi podatke za podatkovni portal NIJZ.³⁵

Poročilo o dejavnosti zobozdravstvenega varstva (Obrazec 8,294) vsebuje podatke o številu preventivnih, kurativnih in specialističnih obiskov ter številu opravljenih storitev (restavracije, endodontija, parodontija, kirurgija, protetika, ortodontija, druge storitve). Poročevalci so vsi javni zdravstveni zavodi (zdravstveni domovi) in zasebni izvajalci zobozdravstvenega varstva, ki opravljajo zobozdravstveno dejavnost v Republiki Sloveniji. Podatki se zbirajo enkrat letno, objavljeni so na podatkovnem portalu NIJZ in v Zdravstvenem statističnem letopisu Slovenije.³⁶

Register izvajalcev zdravstvene dejavnosti in delavcev v zdravstvu (RIZDDZ) spremja tudi število zobozdravnikov in zobozdravnikov specialistov v Sloveniji. Register upravlja in ga sproti posodablja NIJZ.³⁷

Poročevalski sistem je med letoma 1984 in 2000 beležil klinične podatke o **zdravju zob** (z indeksom KEP) in **obzobnih tkiv**. Osnovan je bil na

vsakoletnih zobozdravstvenih pregledih otrok in mladostnikov.³⁸⁻⁴⁰

Register raka Republike Slovenije (RRRS) je eden najstarejših populacijskih registrov raka v Evropi.⁴¹ Beleži vse primere raka v Sloveniji in tako vključuje tudi vse vrste raka ustnega predela.⁴² Podatki so dostopni prek portala SLORA, vsako leto pa izide tudi letno poročilo Rak v Sloveniji.⁴³

Sekundarni viri podatkov

Slovenski viri

Zdravstveni statistični letopis Slovenije je letna publikacija NIJZ, ki med drugim zbira in ureja tudi z ustnim zdravjem povezane podatke. Viri podatkov za publikacijo so obrazec 8,294 (število preventivnih, kurativnih in specialističnih obiskov; število opravljenih storitev), dosedanji način vodenja podatkov o zunajbolnišničnih obravnavah ZUBSTAT (zbirka zunajbolnišnične zdravstvene statistike; obiski v specialistični ambulantni dejavnosti za oralno kirurgijo), RIZDDZ (število izvajalcev zobozdravstvene dejavnosti) in Statistični urad Republike Slovenije (SURS; izdatki za zobozdravstveno varstvo).^{34,44} ZUBSTAT z letosnjim letom prehaja v spletni portal eSZBO.⁴⁵

Podatkovni portal NIJZ vključuje podatke iz obrazca 8,74 (zobozdravstvena vzgoja), obrazca 8,288 (zdravstveno stanje šolskih in otrok in mladostnikov – karies 1. in 2. stopnje), obrazca 8,294 (število preventivnih, kurativnih in specialističnih obiskov) ter RIZDDZ (število zobozdravnikov in zobozdravnikov specialistov).⁴⁶

Zdravje v občini je projekt, ki predstavlja vir informacij o ključnih kazalnikih zdravja v slovenskem prostoru, ki ga pripravlja NIJZ v sodelovanju z drugimi organizacijami. Informacije o zdravju prebivalstva so predstavljene na ravni Slovenije, statističnih regij, upravnih enot in občin.⁴⁷ V zvezi z zobozdravstvom zajema podatke o čiščenju zob, ki jih pridobiva iz raziskav CINDI.⁴⁸

Tuji viri

Eurostat je statistični urad EU, ki zagotavlja statistične podatke na evropski ravni. V svoji podatkovni zbirki vključuje podatke o številu aktivnih zobozdravnikov (vir podatkov je NIJZ)⁴⁹ in podatke o neizpolnjenih potrebah po zobozdravstvenem varstvu (vir podatkov je anketa o življenjskih pogojih (angl. *European Union Statistics of Income and Living Conditions* – EU-SILC).²¹

OECD Health Statistics je spletna podatkovna zbirka Organizacije za gospodarsko sodelovanje in razvoj, ki zajema zdravstvene podatke, vključno s podatki o številu zobozdravnikov (aktivnih, licenciranih in delujočih v praksi) v Sloveniji. Vir podatkov je NIJZ.^{50,51}

Krovni evropski kazalniki zdravja (angl. *European Core Health Indicators* – ECHI) so nastali na podlagi dolgoročnega sodelovanja med državami EU in Evropsko komisijo in služijo za zagotavljanje primerljivosti zdravstvenih informacij in znanja za spremljanje zdravja na ravni EU.⁵² Zobozdravstveno varstvo pokriva dva kazalnika, in sicer pod zaporedno št. 72 (delež oseb, ki so bile pri zobozdravniku ali ortodontu v zadnjih štirih tednih; vir podatkov je EHIS)⁵³ ter pod zaporedno št. 80 (delež oseb z neizpolnjenimi potrebami po zobozdravstvenih storitvah zaradi finančnih razlogov, čakalnih dob ali razdalj; vir podatkov je EU-SILC).⁵⁴

Študija o globalnem bremenu bolezni (angl. *Global Burden of Disease Study* – GBD). Upravlja jo Inštitut za zdravstvene meritve in vrednotenja (angl. *Institute for Health Metrics and Evaluation* – IHME) Univerze v Washingtonu v ZDA in prikazuje podatke o bremenu bolezni v 195 državah sveta. Podatki so standardizirani po določenih metodah in prikazani grafično glede na umrljivost, manjzmožnosti prilagojena leta življenja (angl. *disability-adjusted life years* – DALY) ali izgubljena leta zdravega življenja zaradi manjzmožnosti (angl. *years lived with disability* – YLD). Viri podatkov za ustno zdravje v Sloveniji so publikacije Rak v Sloveniji, raziskava HBSC ter nekatere druge ankete in znanstveni članki.⁵⁵

Evropski svet nacionalnih predstavnikov za zobozdravstvo (angl. *The Council of European Chief Dental Officers* – CECDO). Pobuda za zbiranje podatkov s strani CECDO se je začela z namenom obravnavanja pomanjkanja celovitih podatkov o sistemih ustnega zdravstvenega varstva. Od leta 2013 CECDO zbirajo informacije v zvezi s številom zobozdravnikov, zobozdravstvenim izobraževanjem, stroški in kazalniki ustnega zdravja v državah članicah EU ter Islandiji, Lichtenštajnu, Norveški in Švici, vendar se podatki ne posodablajo redno in sistematično.² Viri podatkov za Slovenijo niso navedeni, razen za indeks KEP, katerega vir je članek iz leta 2000.⁵⁶

Podatkovna zbirka CAPP (angl. *WHO Oral Health Country/Area Profile Programme*) je vzpostavljena v podporo Globalnemu programu za ustno zdravje SZO (angl. *WHO Global Oral Health Programme*) za spremljanje ustnega zdravja. Zbirajo se podatki o

indeksu KEP, CPI (angl. *Community Periodontal Index*), brezzobosti, raku in kadrovskih virih.⁵⁷ Viri podatkov za Slovenijo niso navedeni, poleg tega tudi niso popolni in posodobljeni.⁵⁸

Podatkovna zbirka HFA-DB (angl. *European Health for All Database*). Na tem portalu SZO zasledimo podatke o številu zobozdravnikov v Sloveniji (vir podatkov: RIZDDZ, NIJZ)⁵⁹ ter številu diplomantov dentalne medicine (vir podatkov: Zdravstveni statistični letopis Slovenije, NIJZ).⁶⁰ Podatki so sicer stari, zadnji so iz leta 2014. Podatkovna zbirka je v preteklosti vsebovala tudi podatke o indeksu KEP (vir za Slovenijo so bile periodične raziskave indeksa KEP po metodologiji SZO²²), a niso več dostopni.

Zaključek

Ustno zdravje je del splošnega zdravja, vendar so bolezni ustne votline, ki jih je mogoče preprečiti, med najpogostejšimi zdravstvenimi stanji v Evropi in tudi v Sloveniji.^{2,61} Za boljše oblikovanje zdravstvenih politik glede preventivnih programov, zdravljenja in sistema zdravstvenega varstva je potreben celostni pristop, ki vključuje tudi sistematično zbiranje ustreznih podatkov, tako kliničnih kot nekliničnih. Danes se zdravstvenih izidov ne vrednoti več samo z ozdravitvijo, temveč tudi z vplivom na kakovost življenja.^{1,62} Potreben je torej celostni pristop, ki upošteva tudi z ustnim zdravjem povezano kakovost življenja (angl. *oral health-related quality of life* – OHRQoL).⁶³ V tem pogledu je v prihodnje na področju ustnega zdravja v Sloveniji na nacionalni ravni potrebno vzpostaviti zbiranje, digitalizacijo in sistematizacijo kliničnih podatkov s sodobnimi kazalniki, na primer za ocenjevanje prisotnosti kariesa z ICDAS^{64,65} (angl. *International Caries Detection and Assessment System*), ter vpeljati kontinuirano zbiranje in analiziranje nekliničnih podatkov, ki se je začelo leta 2019.^{6,7}

Zahvala

Raziskavo je finančno podprla Javna agencija za raziskovalno dejavnost Republike Slovenije (ARRS) (P3-0429, Slovenski raziskovalni program za celostno obravnavo raka SLORAPro).

Reference

- Bourgeois DM, Llodra JC, Norblad A, Pitts NB (eds.). A selection of essential oral health indicators. Recommended by European Global Oral Health Indicators Development Project, Chapter 5. In: Bourgeois DM (ed.). *Health surveillance in Europe. European Global Oral Health Indicators Development Project. Final report 2003-2005*. Lyon 2005: Community Action Programme on Health Monitoring, European Commission, Health and Consumer Protection Directorate-General. https://ec.europa.eu/health/ph_projects/2002/monitoring/fp_monitoring_2002_frep_03b_en.pdf (21. 1. 2023)
- Winkelmann J, Gómez Rossi J, van Ginneken E. Oral health care in Europe: Financing, access and provision. *Health Syst Transit* 2022; 24(2): 1-176.
- Platform for Better Oral Health in Europe. *Why Oral Health Matters? Policy recommendations to improve oral health in the EU*. <http://www.oralhealthplatform.eu/news/platform-launches-manifesto-in-european-parliament/> (21. 1. 2023)
- Watt RG, Daly B, Allison P et al. Ending the neglect of global oral health: time for radical action. *Lancet* 2019; 394(10194): 261-272. [https://doi.org/10.1016/S0140-6736\(19\)31133-X](https://doi.org/10.1016/S0140-6736(19)31133-X) (21. 1. 2023)
- Ministrstvo za zdravje. *Strategija ustnega zdravja v Republiki Sloveniji za obdobje 2020-2030*. Ljubljana 2022: Ministrstvo za zdravje. <https://www.gov.si/novice/2022-05-26-ni-zdravja-brez-ustnega-zdravja/> (21. 1. 2023)
- Artnik B, Ranfl M, Blatnik J, Magajna A, Rostohar K. *Ustno zdravje otrok in mladostnikov*, 2019. *Nacionalna raziskava o ustnem zdravju otrok in mladostnikov v Sloveniji leta 2019*. Ljubljana 2020: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/publikacija_otroci_ustno_zdravje.pdf (21. 1. 2023)
- Artnik B, Ranfl M, Blatnik J, Magajna A, Rostohar K. *Ustno zdravje odraslih*, 2019. *Nacionalna raziskava o ustnem zdravju odraslih v Sloveniji leta 2019*. Ljubljana 2020: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/ustno_zdravje_oodraslih_koncna_splet_0.pdf (21. 1. 2023)
- Stergar E, Scagnetti N, Pucelj V. *Z zdravjem povezano vedenje*. Ljubljana 2006: Inštitut za varovanje zdravja Republike Slovenije. https://nijz.si/wp-content/uploads/2022/07/hbsc_2002.pdf (21. 1. 2023)
- Jeriček H, Lavtar D, Pokrajac T. *Z zdravjem povezano vedenje v šolskem obdobju*. Ljubljana 2007: Inštitut za varovanje zdravja Republike Slovenije. https://nijz.si/wp-content/uploads/2022/07/hbsc_2006.pdf (21. 1. 2023)
- Jeriček Klanšek H, Roškar S, Koprivnikar H, Pucelj V, Bajt M, Zupanič T. *Neenakosti v zdravju in z zdravjem povezanih vedenjih slovenskih mladostnikov*. Ljubljana 2011: Inštitut za varovanje zdravja Republike Slovenije. https://nijz.si/wp-content/uploads/2022/07/hbsc_2010_0.pdf (21. 1. 2023)
- Jeriček Klanšek H, Bajt M, Drev A, Koprivnikar H, Zupanič T, Pucelj V. *Z zdravjem povezana vedenja v šolskem obdobju med mladostniki v Sloveniji. Izvedki mednarodne raziskave HBSC*, 2014. Ljubljana 2015: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/hbsc_2015_e_verzija30_06_2015.pdf (21. 1. 2023)
- Jeriček Klanšek H, Roškar M, Drev A, Zupanič T, Prelec Poljanšek P. *Z zdravjem povezana vedenja v šolskem*

- obdobju med mladostniki v Sloveniji. Izsledki mednarodne raziskave HBSC, 2018.* Ljubljana 2019: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/hbsc_2019_e_verzija_obl.pdf (21. 1. 2023)
13. CINDI Slovenija. *CINDI v Sloveniji.* http://cindi-slovenija.net/index.php?option=com_content&task=view&id=167&Itemid=84 (21. 1. 2023)
 14. Maučec Zakotnik J, Tomšič S, Kofol Bric T, Korošec A, Zaletel Kragelj L. *Zdravje in vedenjski slog prebivalcev Slovenije. Trendi v raziskavah CINDI 2001-2004-2008.* Ljubljana 2012: Inštitut za varovanje zdravja Republike Slovenije. https://nijz.si/wp-content/uploads/2022/07/zdravje_in_vedenjski_slog_p_rebivalcev_slo_2011-2004-2008.pdf (21. 1. 2023)
 15. Tomšič S, Kofol Bric T, Korošec A, Maučec Zakotnik J. *Izzivi v izboljševanju vedenjskega sloga in zdravja. Desetletje CINDI raziskav v Sloveniji.* Ljubljana 2014: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/izzivi_desetletje_cindi_14.pdf (21. 1. 2023)
 16. Vinko M, Kofol Bric T, Korošec A, Tomšič S, Vrdelja M. *Kako skrbimo za zdravje? Z zdravjem povezan vedenjski slog prebivalcev Slovenije 2016.* Ljubljana 2018: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/07/kako_skrbimo_za_zdravje_s_plet_3007_koncna.pdf (21. 1. 2023)
 17. Zupanič T, Korošec A. *Z zdravjem povezan vedenjski slog 2020, Prva objava.* Ljubljana 2021: Nacionalni inštitut za javno zdravje. https://www.nijz.si/sites/www.nijz.si/files/uploaded/podatki/podatkovne_zbirke Raziskave/CINDI/cindi2020_prava_objava.pdf (21. 1. 2023)
 18. Božič A, Zupanič T. *Zdravje in zdravstveno varstvo v Sloveniji.* Ljubljana 2009: Statistični urad Republike Slovenije. <https://www.stat.si/doc/pub/zdravje%20in%20zdravstve%20varstvo-slo.pdf> (21. 1. 2023)
 19. Nacionalni inštitut za javno zdravje. *Anketa o zdravju in zdravstvenem varstvu.* Ljubljana: Nacionalni inštitut za javno zdravje. <https://podatki.nijz.si/docs/EHIS.pdf> (21. 1. 2023)
 20. Nacionalni inštitut za javno zdravje. Nacionalna raziskava o zdravju in zdravstvenem varstvu (EHIS 2019). <https://nijz.si/podatki/podatkovne-zbirke-in-raziskave/nacionalna-raziskava-o-zdravju-in-zdravstvenem-varstvu-ehis-2019/> (21. 1. 2023)
 21. EUROSTAT. Self-reported unmet needs for dental examination by sex, age, main reason declared and groups of country of birth (HLTH_SILC_31). https://ec.europa.eu/eurostat/databrowser/view/hlth_si_lc_31/default/table?lang=en (21. 1. 2023)
 22. World Health Organization. *Oral health surveys: basic methods (4th ed.).* Geneva 1997: World Health Organization. <https://apps.who.int/iris/bitstream/handle/10665/41905/9241544937.pdf?sequence=1&isAllowed=y> (21. 1. 2023)
 23. Vrbič V, Vulović M, Rajić Z et al. Oral Health in SFR Yugoslavia in 1986. *Community Dent Oral Epidemiol* 1987; 16: 286-288. <https://doi.org/10.1111/j.1600-0528.1988.tb01776.x>
 24. Vrbič V. Oral health in Slovenia, 1987-1993. *Community Dent Oral Epidemiol* 1996; 24: 364-365. <https://doi.org/10.1111/j.1600-0528.1996.tb00878.x>
 25. Vrbič V. Upadanje zobnega kariesa v Sloveniji v obdobju 1987-1998. *Zobozdrav Vestn* 1999; 54(2): 39-43.
 26. Vrbič V, Premik M. Caries decline among 12-year-old children in Slovenia, 1987-2003. *J Dent Res* 2004; 83(Special Issue A): 789.
 27. Vrbič V. Zobno zdravje pri 12-letni mladini v Sloveniji, 1987-2008. *Zobozdrav Vestn* 2008; 63(4-5): 169-171.
 28. Vrbič V. Zobno zdravje pri 12-letni mladini v Sloveniji (1987-2013). *Zobozdrav Vestn* 2014; 69: 74-80.
 29. Vrbič V, Vrbič M, Petersen PE. Epidemiology of dental caries and disease prevention among 12-year-olds in Slovenia over thirty years (1987-2017). *Oral Health Prev Dent* 2020; 18(1): 185-96. <https://doi.org/10.3290/j.ohpd.a44309>
 30. Toš N. *Vrednote v prehodu I. Slovensko javno mnenje 1968-1990.* E-Vrednote I. Ljubljana 2021: Univerza v Ljubljani, Fakulteta za družbene vede, IDV, CJMMK. <https://www.cjm.si/wp-content/uploads/2021/10/VREDNOTE-1-WEB.pdf> (21. 1. 2023)
 31. Toš N. *Vrednote v prehodu II. Slovensko javno mnenje 1990-1998.* E-vrednote II. Ljubljana 2021: Univerza v Ljubljani, Fakulteta za družbene vede, IDV, CJMMK. <https://www.cjm.si/wp-content/uploads/2022/04/VREDNOTE-2-WEB.pdf> (21. 1. 2023)
 32. Toš N. *Vrednote v prehodu III. Slovensko javno mnenje 1999-2004.* E-vrednote III. Ljubljana 2021: Univerza v Ljubljani, Fakulteta za družbene vede, IDV, CJMMK. <https://www.cjm.si/wp-content/uploads/2021/10/VREDNOTE-3-WEB.pdf> (21. 1. 2023)
 33. Nacionalni inštitut za javno zdravje. *Evidenca zdravstvenovzgojnega dela (ZV).* Ljubljana: Nacionalni inštitut za javno zdravje. https://podatki.nijz.si/docs/6h_Zdravstvenovzgojna_dejavnost_Metodolo%C5%A1ka_pojasnila_NIJZ.pdf (21. 1. 2023)
 34. Nacionalni inštitut za javno zdravje. *Zdravstveni statistični letopis Slovenije.* <https://nijz.si/podatki/zdravstveni-statisticni-letopis-slovenije/> (21. 1. 2023)
 35. Nacionalni inštitut za javno zdravje. *Poročilo o izvršenih sistematičnih pregledib šolskih otrok in mladostnikov.* Ljubljana: Nacionalni inštitut za javno zdravje. https://podatki.nijz.si/docs/Sistematika_%C5%A1olskih_ otrok_in_mladih_do_dopolnjenega_19._leta_starosti_MP_2021.pdf (21. 1. 2023)
 36. Nacionalni inštitut za javno zdravje. *Poročilo o dejavnosti zobozdravstvenega varstva (NIJZ 54).* Ljubljana: Nacionalni inštitut za javno zdravje. https://podatki.nijz.si/docs/6_6m_ZOBJE_2016.pdf (21. 1. 2023)

37. Nacionalni inštitut za javno zdravje. *Izvajalci zdravstvene dejavnosti.* <https://nijz.si/podatki/izvajalci-zdravstvene-dejavnosti/> (21. 1. 2023)
38. Premik M. Zdravstveno stanje zob in ustne votline pri šoloobveznih otrocih v SR Sloveniji: ugotavljanje, spremeljanje in načrtovanje: doktorska disertacija. Ljubljana 1988: Univerza v Ljubljani, Medicinska fakulteta.
39. Premik M, Artnik B. Otroško zobozdravstvo v pogledu javnega zdravja v Sloveniji. In: Gregorič A (ed.). XVIII. srečanje pediatrov v Mariboru. *Zbornik Maribor, 11. in 12. april 2008.* Maribor 2008: Univerzitetni klinični center: 119-122.
40. Artnik B, Kosem R. Zdravje ustne votline otrok in mladostnikov nekoč in danes. In: Matič L, Fink A, Vettorazzi R (eds.). *Strokovno srečanje Ustna nega - vloga zdravstvene nege za zdravje ustne votline, 22. 4. 2009, Ljubljana.* Ljubljana 2009: Zbornica zdravstvene in babiške nege Slovenije, Sekcija medicinskih sester v vzgoji in izobraževanju: 23-30.
41. Zadnik V, Gašljević G, Hočevar M et al. *Rak v Sloveniji 2019.* Ljubljana 2022: Onkološki inštitut Ljubljana, Epidemiologija in register raka, Register raka Republike Slovenije. https://www.onko-i.si/fileadmin/onko/datoteke/rrs/lp/Letno_porocilo_2019.pdf (21. 1. 2023)
42. Blatnik J, Zadnik V, Artnik B. Rak ustnega predela v Sloveniji v letih 1985-2014. *Zdrav Vestn* 2019; 88(11-12): 493-508. <https://doi.org/10.6016/ZdravVestn.2845>
43. Onkološki inštitut Ljubljana. *Register raka Republike Slovenije in drugi registri.* <https://www.onko-i.si/rrs> (21. 1. 2023)
44. Zaletel M, Vardič D, Hladnik M. *Zdravstveni statistični letopis Slovenije 2020.* Ljubljana 2022: Nacionalni inštitut za javno zdravje. https://nijz.si/wp-content/uploads/2022/03/zdravstveni_statisticni_letopis_2020.pdf (21. 1. 2023)
45. Nacionalni inštitut za javno zdravje. *Spremljanje zunajbolnišničnih obravnav (SZBO).* <https://nijz.si/podatki/podatkovne-zbirke-in-raziskave/spremljanje-zunajbolnišnicnih-obravnav-szbo/> (21. 1. 2023)
46. Nacionalni inštitut za javno zdravje. *Podatkovni portal.* <https://podatki.nijz.si/pxweb/sl/NIJZ%20podatkovni%20Oportal/> (21. 1. 2023)
47. Zdravje v občini. *O zdravju v občini.* <https://obcene.nijz.si/vsebine/strani/o-zdravju-po-obcini/> (21. 1. 2023)
48. Zdravje v občini. *Kazalnik K2.8 Umivanje zob.* <https://obcene.nijz.si/kazalniki/K2.8> (21. 1. 2023)
49. EUROSTAT. *Health care staff. Dentists.* 2021: EUROSTAT. https://ec.europa.eu/eurostat/cache/metadata/Annexe_s/hlth_res_esms_an2.pdf (21. 1. 2023)
50. OECD. Stat. *Health care resources: dentists.* <https://stats.oecd.org/Index.aspx?QueryId=30177> (21. 1. 2023)
51. OECD. *OECD Health Statistics 2022. Definitions, sources and methods. Practising dentists (ISCO-08 code: 2261).* 2022: OECD. <https://stats.oecd.org/fileview2.aspx?IDFile=dcc2ea1-1b9a-4ca6-8651-8abfa8da199c> (21. 1. 2023)
52. Evropska komisija. *Krovni evropski kazalniki zdravja.* https://health.ec.europa.eu/indicators-and-data/european-core-health-indicators-echi_sl (21. 1. 2023)
53. Evropska komisija. *ECHI Data Tool, Metadata: Indicator HIHSI058 - Selected outpatient visits: self-reported visits.* <https://webgate.ec.europa.eu/dyna/echi/?indlist=72> (21. 1. 2023)
54. Evropska komisija. *ECHI Data Tool, Metada: Indicator HIHSI059 - Equity of access to dental care services.* <https://webgate.ec.europa.eu/dyna/echi/?indlist=80b> (21. 1. 2023)
55. Institute for Health Metrics and Evaluation. *Global Burden of Disease (GBD).* <https://www.healthdata.org/gbd/2019> (23. 1. 2023)
56. The Council of European Chief Dental Officers. *CECDO Database.* <https://cepdo.org/oral-healthcare/cepdo-database/> (23. 1. 2023)
57. Malmö University Oral Health Country/Area Profile Project. *Oral Health Country/Area Profile Project.* <https://capp.mau.se/> (21. 1. 2023)
58. Malmö University Oral Health Country/Area Profile Project. *Country Areas: Slovenia.* <https://capp.mau.se/country-areas/slovenia/> (21. 1. 2023)
59. WHO European Health Information Gateway. *Indicators: Dentists (PP) per 100.000.* https://gateway.euro.who.int/en/indicators/hfa_509-5300-dentists-pp-per-100-000/ (21. 1. 2023)
60. WHO European Health Information Gateway. *Indicators: Dentists graduated per 100.000.* https://gateway.euro.who.int/en/indicators/hfa_532-5440-dentists-graduated-per-100-000/ (21. 1. 2023)
61. Institute for Health Metrics and Evaluation. *GBD Results Tool.* <https://vizhub.healthdata.org/gbd-results/> (21. 1. 2023)
62. Bourgeois DM, Llodra JC, Nordblad A, Pitts NB. Report of the EGOHID I Project. Selecting a coherent set of indicators for monitoring and evaluating oral health in Europe: criteria, methods and results from the EGOHID I project. *Community Dent Health* 2008; 25(1): 4-10. <https://www.cdhjournal.org/issues/25-1-march-2008/142-report-of-the-egohid-i-project?downloadarticle=download> (21. 1. 2023)
63. Gift HC, Redford M. Oral health and the quality of life. *Clin Geriatr Med* 1992; 8(3): 673-683.
64. Ismail AI, Sohn W, Tellez M et al. The International Caries Detection and Assessment System (ICDAS): an integrated system for measuring dental caries. *Community Dent Oral Epidemiol* 2007; 35: 170-178.
65. Sebastian ST, Johnson T. International Caries Detection and Assessment System (ICDAS): an integrated approach. *Int J Oral Health Med Res* 2015; 2(3): 81-84.

Sara Močnik, Dejan Dinevski, Hojka Gregorič Kumperščak

Uporaba umetne inteligence za diagnosticiranje in zdravljenje oseb z mejno osebnostno motnjo

Povzetek. Umetna inteligenca prevzema pomembno mesto v zdravstvu, pri čemer je najpogosteje uporabljeno strojno učenje. Na področju psihiatrije opažamo strm porast raziskav o uporabi strojnega učenja predvsem z namenom objektivizacije postavljanja psihiatričnih diagnoz in personalizacije zdravljenja. Mejna osebnostna motnja je huda, obremenjujoča in razmeroma pogosta duševna motnja, prizadeti posamezniki pa bi imeli pomembne koristi od zgodnje postavitve diagnoze in optimalnega zdravljenja. Članek predstavlja najnovješe raziskave s področja diagnosticiranja in zdravljenja mejne osebnostne motnje s pomočjo umetne inteligence.

Ključne besede: umetna inteligenca; strojno učenje; psihiatrija; mejna osebnostna motnja.

The Usage of Artificial Intelligence to Diagnose and Treat Individuals with Borderline Personality Disorder

Abstract. Artificial intelligence is gaining an important role in health care, with machine learning being the most commonly used approach. In the field of psychiatry, we are witnessing a sharp increase in research on the use of machine learning, primarily for the purpose of objectifying psychiatric diagnostics and personalising the treatment. Borderline personality disorder is a severe, burdensome and relatively common mental disorder. The affected individuals would benefit substantially from early diagnosing and optimal treatment. The article presents the latest research in the field of diagnostics and treatment of borderline personality disorder with the help of artificial intelligence.

Key words: artificial intelligence, machine learning; psychiatry, borderline personality disorder.

■ Infor Med Slov 2022; 27(1-2): 27-32

Institucije avtorjev / Authors' institutions: Zdravstveni dom Velenje (SM); Medicinska fakulteta, Univerza v Mariboru (SM, DD, HGK); Univerzitetni klinični center Maribor (HGK).

Kontaktna oseba / Contact person: Sara Močnik, Zdravstveni dom Velenje, Vodnikova 1, 3320 Velenje, Slovenija. E-pošta / E-mail: sara.mergole@student.um.si.

Prispelo / Received: 23. 12. 2022. Sprejeto / Accepted: 8. 1. 2023.

Uvod

Psihiatrične motnje predstavljajo veliko breme za bolnike, saj pogosto povzročajo invalidnost ali prezgodnjo smrt, bremenijo pa tudi družbo – njihova obravnava je dolgotrajna in draga. Kljub pomembnim napredkom raziskav s psihiatričnega področja v zadnjih letih, bi si strokovnjaki žeeli hitrejšega napredka na področju zaznavanja in zdravljenja psihiatričnih motenj. Kljub večjemu številu uveljavljenih strukturiranih in polstrukturiranih intervjujev trenutni pristopi pri diagnosticiranju in zdravljenju duševnih motenj še vedno v veliki meri slonijo na nestrukturiranem psihiatričnem intervjuju in subjektivni oceni duševnega stanja.¹ Upad duševnega zdravja, vpliv le-tega na bolnike in družbo ter pomanjkanje ustrezno izobraženega zdravstvenega osebja so nakazali potrebo po uporabi umetne inteligence (UI) za identifikacijo oseb z visokim tveganjem za razvoj psihiatričnih motenj ter kot pomoč pri nudenju ustreznih psihosocialnih intervenc in drugih terapevtskih ukrepov za preprečevanje pojava teh motenj in zdravljenje bolnikov.²

Mejna osebnostna motnja (MOM) je duševna motnja, za katero ocenjujejo, da prizadene 2 % splošne odrasle populacije,³ in močno obremenjuje bolnika, njegovo družino in zdravstveni sistem. Povezana je s številnimi slabimi izidi, vključujoč nižjo stopnjo izobrazbe in slabše poklicne dosežke, manj dolgotrajnih partnerskih zvez in prijateljskih odnosov, več konfliktov v partnerskem odnosu, tvegano spolno vedenje, slabo socialno podporo, nižje zadovoljstvo z lastnim življenjem in pogostejo uporabo javnih zdravstvenih storitev. Pri osebah z MOM opazimo značilno moteno uravnavanje čustev, izkriviljeno in nestabilno samopodobo in moteno funkcioniranje v medosebnih odnosih. Do nedavnega je veljalo, da se MOM ne da zdraviti. Trenutno bistveni del zdravljenja predstavlja psihoterapija, farmakološko zdravljenje je indicirano le za sočasne psihiatrične motnje, ki potrebujejo zdravljenje z zdravili že same po sebi, ali kadar je ob izjemnem poslabšanju duševnega stanja krizna intervenga v obliki psihosocialne podpore nezadostna.⁴

Poleg raznolikih simptomov MOM psihoterapijo otežujejo tudi osebnostne značilnosti bolnikov. Težave v medosebnih stikih povzročijo, da se upirajo terapiji, dvomijo v terapevta, sabotirajo zdravljenje. Zelo pogosto psihoterapijo na lastno željo predčasno zaključijo. Psihoterapevtsko zdravljenje MOM je dolgotrajno in drago, zaradi dolgih čakalnih vrst, pomanjkanja usposobljenega osebja in "težavnosti" pacientov pa so le-ti iz zdravstvenega sistema pogosto izločeni. Z UI podprtta terapija bi lahko predstavljala

dodatek k terapiji z osebnim stikom in potencial za izboljšanje dolgoročnega izida zdravljenja.⁵

Umetna inteligencia v psihijiatriji

Umetna inteligencia se v zdravstvu vedno pogosteje uporablja, uspešno na primer v onkologiji, radiologiji in dermatologiji. Primeri njene uspešne uporabe so analiza podatkov iz elektronskih zdravstvenih kartotek, analiza (iskanje vzorcev) radioloških slik, nadzorni sistemi z uporabo senzorjev ter analiza podatkov iz družbenih omrežij.²

UI v psihijiatriji pomeni uporabo naprednih računalniških tehnik in algoritmov za diagnosticiranje, preprečevanje in zdravljenje duševnih motenj.¹ Njena uporaba na področju duševnega zdravja je trenutno skromna. Razlogi za to so občutljiva narava podatkov, pridobljenih med interakcijo med bolnikom in terapevtom, razmeroma majhno število razpoložljivih podatkov za učenje in zelo raznoliki diagnostični kriteriji v aktualnem Diagnostičnem in statističnem piročniku za duševne motnje Ameriškega psihiatričnega združenja (Diagnostic and Statistical Manual of Mental Disorders, DSM-5). Obdelava podatkov in klinično odločanje sta v psihijiatriji veliko kompleksnejša kot nekatere druge specifične in objektivne naloge v zdravstvu (npr. identifikacija tumorja na sliki), ki jih že lahko opravi UI.²

Področje duševnega zdravja se močno opira na vzpostavitev dobrega terapevtskega odnosa. Njegovo omejitev predstavlja količina časa, ki ga osebje lahko nameni posameznemu bolniku. UI lahko ponudi razbremenitev osebja na področjih, kjer osebni stik ni nujen in s tem omogoči osredotočenost psihiatra, psihologa in drugih članov strokovnega tima na bolj empatično obravnavo – v tem smislu bi UI celo lahko naredila psihatrijo bolj »človeško«. Področja, ki bi jih lahko prevzela UI, so podatkovno vodenje zdravstvenih kartotek in njihovo posodabljanje ter pridobivanje pomembnih informacij iz drugih razpoložljivih virov. Cilji uporabe UI v psihijiatriji so odkrivanje motenj že v prodromalni fazì, personalizacija zdravljenja in opolnomočenje bolnikov pri sodelovanju v zdravljenju.²

Strojno učenje in procesiranje naravnega jezika

Strojno učenje je najpogosteje uporabljen oblika UI v zdravstvu. Za učenje, ocenjevanje in predvidevanje izidov prihodnjih dogodkov uporablja podatkovno vodene algoritme. Od tradicionalnih statističnih pristopov se razlikuje v marsičem: hipoteze praviloma ustvarja in jih ne preverja; ima manj predpostavk v

primerjavi s strogimi predpostavkami, potrebnimi za statistično sklepanje; bolj je osredotočeno na napovedi in prepoznavanje vzorcev kot na ocenjevanje vnaprej izbranih parametrov.²

UI lahko uspešno obdeluje masivne podatke (angl. *big data*). Podzvrst strojnega učenja, imenovana globoko učenje (angl. *deep learning*), se v psihijiatriji uporablja predvsem za podporo diagnostiki demence – bolezni, za katero so na področju psihijiatrije na voljo največje podatkovne zbirke. Kot rešitev za pomanjkanje velikih podatkovnih zbirk s področja psihijiatrije se ponuja učenje s prenosom znanja (angl. *transfer learning*), ki ponudi prednaučene algoritme kot začetne točke za analizo novih podatkov.²

Procesiranje naravnega jezika vključuje različne metode: prepoznavava govora, sentimentalna, leksična in semantična analiza govora in prepoznavava optičnih znakov za prenos besedila iz nestrukturiranega v strukturiran format za nadaljnje analize. Navedene metode so za področje psihijiatrije še posebej pomembne, saj sta jezik in govor primarna vira informacij za postavljanje diagnoz in zdravljenje psihijiatričnih motenj. Zapisi nestrukturiranih psihijiatričnih ocen (psihijiatrična anamneza in status) so enostavno dostopni, poceni in nudijo veliko uporabnih informacij.²

Pomoč pri postavljanju diagnoze in zdravljenju

Sistemi UI lahko pri postavljanju diferencialne diagnoze pomagajo na več načinov:

- izboljšajo razlikovanje med diagnozami s podobno začetno klinično sliko in različnimi pristopi zdravljenja (npr. razlikovanje med depresivno epizodo bipolarne motnje in unipolarno depresijo na podlagi slikanja možganov);
- pomagajo pri identifikaciji novih podtipov bolezni (npr. endofenotipi shizofrenije, podtipi depresije na osnovi slikanja možganov);
- iz neobičajnih podatkov in podatkovnih virov zgradijo modele – združevanje podatkov iz elektronskih zdravstvenih kartotek, nosljivih senzorjev, govora, objav v družbenih medijih, nevrofizioloških in slikovnih podatkov (RTG, CT, MR, ...) ter genetike v modele za obravnavo duševnih motenj (npr. uporaba slik, objavljenih na družbenem omrežju, za določanje tveganja za depresijo).

UI lahko upošteva tako genetske kot okoljske dejavnike tveganja, kar je pomembno pri kompleksni bio-psihosocialni naravi psihijiatričnih motenj.²

UI lahko psihijiatrično zdravljenje podpre na več načinov:

- predvidevanje odziva na zdravljenje, s čemer se izognemo sodelovanju v kliničnih študijah, ki so za pacienta neučinkovite, invazivnim in dragim elektrostimulacijam možganov in zamudnim psihoterapijam (npr. odziv na zdravljenje z antidepresivom glede na dosežke na kliničnem vprašalniku in EEG posnetek);
- predvidevanje pojava resnih neželenih učinkov (npr. tveganje za ledvično insuficienco pri zdravljenju z litijem glede na podatke iz elektronske zdravstvene kartoteke);
- gradnja novih teoretičnih modelov patofiziologije bolezni (npr. določitev časovnice poteka bolezni in razvoja sprememb možganov od prodroma preko prve psihoze do shizofrenije);
- določanje genetskih vzorcev, značilnih za različne psihijiatrične motnje;
- določanje potencialnih novih zdravil z uporabo simulacije in podatkovno vodenih pristopov.²

Mejna osebnostna motnja

Klinična slika

Spekter znakov MOM je zelo širok in se lahko tekom življenja pri posamezniku spreminja. Simptomatika MOM je najočitnejša na treh področjih: intenzivno čustvovanje z močnimi nihanji, vključujoč impulzivnost; nestabilna in spreminjača se samopodoba; in težave v medosebnih odnosih. Pri osebah z MOM se pogosteje kot v splošni populaciji pojavljajo nekatera disfunkcionalna vedenja: ponavljajoče samopoškodovalno vedenje, kronične samomorilne misli, agresivni izbruhi in preobčutljivost na zavrnitev. Simptomi se prvič pojavijo v adolescenci, dosežejo vrh v pozni adolescenci in zgodnji odrasli dobi, kasneje se praviloma postopno umirajo.⁴

Diagnosticiranje

Pomembno je na diagnozo posumiti že v zgodnji adolescenci in poiskati osebe s povisanim tveganjem za razvoj MOM. Ob akutni krizni situaciji je, če pacient zaradi MOM še ni bil obravnavan, pomembno izvesti potrebno diagnostiko. Večini pacientov z MOM postavitev diagnoze predstavlja bistveno olajšanje, saj si z njo razložijo svoje vedenje in pretekle življenske izkušnje. Postavljena diagnoza je pogoj za pričetek ustrezne psihoedukacije in zdravljenja.⁴

Zdravljenje

Pomembno je, da z zdravljenjem MOM začnemo kar se da hitro, da preprečimo potencialno kronifikacijo motnje. Zdravljenje v prvi vrsti predstavljajo psihosocialne intervence. Poleg bistvene psihoterapije so pomembni tudi preventiva pri osebah s povišanim tveganjem za razvoj MOM, individualni načrti za ravnanje ob krizah, vključitev pomembnih drugih, osredotočenost na funkciranje osebe izven zdravljenja, šola za starše, pomoč Centra za socialno delo itd. Glavni oblici psihoterapije, ki se uporabljalata pri zdravljenju MOM, sta dialektična vedenjska terapija in na mentalizaciji temelječa terapija.⁴

Akutno zdravljenje MOM vključuje akutne psihosocialne intervence in uporabo psihofarmakoterapije.⁴ Pogosto so predpisana različna psihotropna zdravila, čeprav nimajo uradne indikacije za zdravljenje MOM (angl. *off-label medication use*).⁶ Količina dokazov o učinkovitosti razpoložljive psihofarmakoterapije je omejena. Trenutne raziskave ne podpirajo uporabe zdravil ob odsotnosti komorbidnih psihiatričnih bolezni. V primerjavi s placeboom naj bi imela zdravila minimalen do ničen učinek na jakost simptomov MOM, samopoškodovalno vedenje, s samomorom povezane izide ter psihosocialno funkcioniranje. Dokazi z nizko stopnjo gotovosti kažejo na manj težav v medosebnih odnosih po uporabi antipsihotikov ali stabilizatorjev razpoloženja, pri uporabi antidepresivov pa je ta učinek minimalen do ničen.⁶ Bistveno je, da pacienta motiviramo za zdravljenje in ga spodbudimo, da si poišče psihoterapevtsko podporo. V idealnih javnozdravstvenih okoliščinah bi osebi z MOM takoj bilo omogočeno specifično psihoterapevtsko in psihiatrično zdravljenje, ki bi intenzivno potekalo vsaj šest mesecev. Bolnišnično zdravljenje MOM ni priporočljivo; če je nujno, mora biti čim krajše.⁴

Uporaba umetne inteligence pri obravnavi oseb z mejno osebnostno motnjo

Diagnosticiranje mejne osebnostne motnje

Osebe z MOM pogosto dobijo napäčno diagnozo ali je sploh nimajo, zato večkrat zamudimo optimalen čas za pričetek zdravljenja. Avtomatsko presejanje elektronskih zdravstvenih kartotek je ena izmed možnosti za zgodnjo identifikacijo oseb z MOM. Osnovano je na algoritmu, ki vključuje na pravilih osnovano izbiro in strojno učenje. Algoritem najprej izbere potencialne bolnike glede na sočasne bolezni in simptome, pogosto povezane z MOM, nato pa

predvidi, ali je pri posamezniku bolj verjetno, da motnjo ima ali je nima.⁷ Druga možnost uporabe UI za zgodnje odkrivanje oseb z MOM vključuje uporabo razvrščanja z algoritmom naključnih gozdov (angl. *random forest classification*). Algoritem je izluščil značilke čustvovanja pri osebah s postavljenou diagnozo MOM z 81 % točnostjo.⁸

Z metodo strojnega učenja, regularizirano regresijo, lahko identificiramo najpomembnejše dejavnike tveganja za razvoj MOM. Tako zgrajen model vključuje 19 dejavnikov tveganja; simptomi depresije in anksioznosti, samokontrola, strogo kaznovanje ter slabo socialno in šolsko funkcioniranje so se izkazali za najbolj kritične.⁹

Povsem objektivno klinično orodje za postavitev diagnoze MOM ne obstaja. Opisana je uporaba strojnega učenja, natančneje prepoznavanja vzorcev in metod razvrščanja, za izluščenje značilk iz funkcijskega magnetnoresonančnega slikanja (nenormalna možganska aktivnost v izbranih regijah ob odzivih na izraze obraza) za prepoznavo MOM. Predlagani pristop je dosegel 94 % točnost pri razlikovanju 21 oseb z MOM od 10 zdravih oseb.¹⁰

Mnoge raziskave so že potrdile morfološke spremembe možganov pri osebah z MOM. Opisano je razlikovanje oseb z MOM od zdravih s kombinacijo avtomatiziranih morfometričnih orodij za merjenje kortikalne debeline in razvrščanja z uporabo metode podpornih vektorjev. Pristop vključuje izbiro značilk za identifikacijo regij z največjim potencialom za razlikovanje. Opisano bi lahko slikanje možganov vključilo v diagnostiko različnih psihiatričnih motenj.¹¹

Razlikovanje bipolarne motnje od mejne osebnostne motnje je pogosta diagnostična dilema, saj se njuni simptomi pogosto prekrivajo. Pri obeh opazimo disforično razpoloženje, samomorilnost in samopoškodovalno vedenje, impulzivnost – najpogosteje zapravljanje – in spolno dezinhibiranost ter zlorabo alkohola in prepovedanih drog. Predvsem na osnovi impulzivnosti lahko osebo z MOM hitro označimo kot manično ali hipomanično. Na podlagi strojnega učenja je mogoče uspešno razlikovati med temo motnjama.¹²

Zdravljenje mejne osebnostne motnje

V literaturi je predstavljena uporaba UI v obliki procesiranja naravnega govora kot dodatka k dialektični vedenjski terapiji ali na mentalizaciji temelječi terapiji, pa tudi drugim, pri MOM redkeje uporabljenim terapijam. Pri tem lahko navidezni agent nudi podporo pri mentalizaciji in bolnika z

usmerjenimi vprašanji vodi skozi psihoterapevtsko seanso. Dodatno lahko prepozna bolnikova čustva, izbiro besed, negativno razmišljanje, zmožnost samokontrole itd. ter v skladu s tem usmerja potek seanse.⁵

Le približno polovica oseb z MOM se dobro odzove na ustrezeno obliko psihoterapije, ki je sicer težko dostopna in draga. Razmeroma nizek delež uspešnosti bi lahko dvignili, če bi poznali objektivne napovedne dejavnike za izboljšanje simptomov po terapiji. Z uporabo strojnega učenja je mogoče iskati klinične značilnosti, ki bi lahko napovedale izboljšanje ali poslabšanje resnosti motnje in impulzivnosti oseb z MOM po skupinski dialektični vedenjski terapiji. Izbrana metoda je uspešno identificirala 34 pomembnih napovednih dejavnikov za resnost motnje in 17 za impulzivnost. Takšna metoda bi lahko predstavljala osnovo za personalizirano zdravljenje MOM.¹³

Znižanje tveganja za čustveno krizo pri osebah z MOM je možno doseči z zdravljenjem osnovne čustvene disregulacije in/ali s terapevtsko podporo med krizo (npr. s telefonskim klicem), toda tak pristop ni učinkovit, saj porablja veliko človeških virov in finančnih sredstev. Terapevtska računalniška aplikacija bi lahko predstavljala način za reševanje potreb po dodatni terapiji oseb z MOM med samo krizo. Mobilna aplikacija B-RIGHT, osnovana na psihoterapevtskih algoritmih UI, se poslužuje dialektične vedenjske terapije, ki je bila uspešna pri zmanjšanju zlorabe prepovedanih drog in samopoškodovalnega vedenja brez samomorilnega namena ter pri zniževanju averzivne napetosti. Bolniki so bili z uporabo aplikacije v smislu omilitve simptomov zelo zadovoljni.³

Razprava

Pregled aktualnih raziskav z obravnavanega področja razkriva potencial za povezovanje metod umetne inteligence in kliničnega dela psihiatrov ter drugih sodelujočih v obravnavi oseb z mejno osebnostno motnjo. Pomembno omejitev pri obravnavi razpoložljive literature predstavlja omejitev izključno na mejno osebnostno motnjo; zelo verjetno bi bilo tudi dela s področja drugih osebnostnih motenj ali drugih področij psihiatrije možno in smiselnopraktično aplicirati na obravnavo mejne osebnostne motnje.

Literatura torej v splošnem podpira smiselnost razvoja na umetni inteligenci osnovanih intervenc za diagnosticiranje in zdravljenje psihiatričnih motenj. Poleg očitnega prenosa opravljanja rutinskih nalog iz zdravnika na intelligentna orodja in posledične

razbremenitve ter večje osredotočenosti na odnos med zdravnikom in bolnikom so njihove pomembne prednosti tudi dejstvo, da nekateri bolniki ob še vedno močno prisotni stigmatizaciji svoje težave lažje zaupajo računalniku kot zdravniku, izogibanje negativnemu transferju ob stiku bolnika s terapeutom ter enostaven in hiter dostop do terapije.^{1,5} Ker je ustrezeno zdravljenje MOM v mnogih okoljih težko dostopno, je potrebna usmeritev v razvoj konceptov zdravljenja s kratkimi programi za samopomoč pri osebah z blago obliko MOM in v zagotavljanje kompleksnejših in daljših obravnav s strani strokovnjakov za osebe s hujšimi oblikami.⁴

Umetna inteligenco je osnovana na človeški inteligenci in lahko marsikatero nalogo opravi hitreje in bolje kot človek. Z nadaljnimi izboljšavami se bo morda nekoč razvila v superinteligenco. Kljub temu, da lahko ponovi marsikatero človeško inteligentno sposobnost, kot so hitrost obdelave podatkov, spomin, sklepanje, vidno-prostorske sposobnosti, slušno procesiranje in povezava znanja z razumevanjem, pa umetna inteligenco ni sposobna sočutnih in pravičnih odločitev. Ni sposobna upoštevati raznolikosti med ljudmi, različnih perspektiv, etike in morale. Vse to govorita v prid potrebe po nadgradnji umetne intelligence v umetno modrost, ki bo lahko omogočila bolj sočutno in etično oskrbo raznolikih skupin ljudi.² Kljub velikim obetom in pričakovani rasti uporabe različnih oblik umetne intelligence v raznolikih zdravstvenih situacijah je skrb, da bi robot ali algoritem v celoti prevzel delo psihiatra ali psihologa, odveč. Pričakovati je in dobrodošel bo prenos monotonih, obremenjujočih in ponavljajočih se vsakodnevnih nalog na UI, ki bi lahko vodil do višje učinkovitosti in manjše možnosti napak pri zdravljenju.

Reference

1. Fakhoury M. Artificial intelligence in psychiatry. *Adv Exp Med Biol* 2019; 1192: 119-125. https://doi.org/10.1007/978-981-32-9721-0_6
2. Lee EE, Torous J, De Choudhury M, et al. Artificial intelligence for mental health care: clinical applications, barriers, facilitators, and artificial wisdom. *Biol Psychiatry Cogn Neurosci Neuroimaging* 2021; 6(9): 856-864. <https://doi.org/10.1016/j.bpsc.2021.02.001>
3. Frias Á, Palma C, Salvador A, et al. B-RIGHT: usability and satisfaction with a mobile app for self-managing emotional crises in patients with borderline personality disorder. *Australas Psychiatry* 2021; 29(3): 294-298. <https://doi.org/10.1177/1039856220924321>
4. Bohus M, Stoffers-Winterling J, Sharp C, Krause-Utz A, Schmahl C, Lieb K. Borderline personality

- disorder. *Lancet* 2021; 398(10310): 1528-1540. [https://doi.org/10.1016/S0140-6736\(21\)00476-1](https://doi.org/10.1016/S0140-6736(21)00476-1)
5. Szalai J. The potential use of artificial intelligence in the therapy of borderline personality disorder. *J Eral Clin Pract* 2021; 27(3): 491-496. <https://doi.org/10.1111/jep.13530>
 6. Stoffers-Winterling JM, Storebø OJ, Pereira Ribeiro J, et al. Pharmacological interventions for people with borderline personality disorder. *Cochrane Database Syst Rev* 2022; 11(11): CD012956. <https://doi.org/10.1002/14651858.CD012956.pub2>
 7. Zang C, Goodman M, Zhu Z, et al. Development of a screening algorithm for borderline personality disorder using electronic health records. *Sci Rep* 2022; 12(1): 11976. <https://doi.org/10.1038/s41598-022-16160-z>
 8. Deb K, De H, Chatterjee SS, Pal A. Studying borderline personality disorder using machine learning. In: *16th International conference on ubiquitous information management and communication (IMCOM)*. Seoul, Korea: 2022: IEEE: 1-6, <https://doi.org/10.1109/IMCOM53663.2022.9721800>
 9. Beeney JE, Forbes EE, Hipwell AE, et al. Determining the key childhood and adolescent risk factors for future BPD symptoms using regularized regression: comparison to depression and conduct disorder. *J Child Psychol Psychiatry* 2021; 62(2): 223-231. <https://doi.org/10.1111/jcpp.13269>
 10. Xu T, Cullen KR, Houri A, Lim KO, Schulz SC, Parhi KK. Classification of borderline personality disorder based on spectral power of resting-state fMRI. *Annu Int Conf IEEE Eng Med Biol Soc* 2014; 2014: 5036-5039. <https://doi.org/10.1109/EMBC.2014.6944756>
 11. Sato JR, de Araujo Filho GM, de Araujo TB, Bressan RA, de Oliveira PP, Jackowski AP. Can neuroimaging be used as a support to diagnosis of borderline personality disorder? An approach based on computational neuroanatomy and machine learning. *J Psychiatr Res* 2012; 46(9): 1126-1132. <https://doi.org/10.1016/j.jpsychires.2012.05.008>
 12. Bayes A, Spoelma MJ, Hadzi-Pavlovic D, Parker G. Differentiation of bipolar disorder versus borderline personality disorder: a machine learning approach. *J Affect Disord* 2021; 288: 68-73. <https://doi.org/10.1016/j.jad.2021.03.082>
 13. Jiménez S, Angeles-Valdez D, Rodríguez-Delgado A, et al. Machine learning detects predictors of symptom severity and impulsivity after dialectical behavior therapy skills training group in borderline personality disorder. *J Psychiatr Res* 2022; 151: 42-49. <https://doi.org/10.1016/j.jpsychires.2022.03.063>

Mojca Dovnik, Jože Balažič, Dejan Dinevski

Potenciali umetne inteligence za uporabo v sodnomedicinski praksi

Povzetek. Raziskovanje možnosti, ki jih umetna inteligenca ponuja za reševanje različnih problemov v medicini, predstavlja zelo aktualno področje znanosti. Na področju sodne medicine, ki je izrazito vizualna veja medicine tako na makroskopski kot na mikroskopski ravni, so posebej obetavne konvolucijske nevronske mreže, ki imajo odlično sposobnost prepoznavne in kategorizacije slikovnega materiala. Specialistu sodne medicine so lahko v pomoč pri ugotavljanju vzrokov smrti, identifikaciji, interpretaciji strelnih ran, določanju časa nastopa smrti in pri kliničnem delu. Vendar pa so metode umetne inteligence na področju sodne medicine v različnih fazah zrelosti za uporabo v realnih delovnih okolišinah. V splošnem so še posebej uporabne za pregled kompleksnih baz podatkov, ko je potrebno izluščiti določen podatek ali opozoriti na določeno podrobnost, ki bi se lahko izkazala za pomembno pri končni odločitvi oziroma diagnozi. Interpretacija zaključkov algoritmov umetne inteligence pa ostaja v domeni specialista sodne medicine. Umetno inteligenčni sistemi imajo tudi slabosti, njihova vpeljava v vsakodnevno delo pa na področju sodne medicine predstavlja še posebej kompleksno nalogu, saj ocena relevantnosti uporabe in sprejemanje takšnega načina dela ni odvisna zgolj od zdravnikov, temveč tudi od sodnikov ter odvetnikov, žrtev in storilcev kaznivih dejanj.

Ključne besede: umetna inteligenca; sodna medicina; identifikacija; čas smrti; kremenaste alge; strelne rane.

Potentials of Artificial Intelligence for Use in Forensic Medical Practice

Abstract. The potential of artificial intelligence to solve various problems in medicine is an intensively researched area of science. Convolutional neural networks, which have an excellent ability to recognize and categorize imagery, are especially promising in the field of forensic medicine, which is a particularly visual branch of medicine at both the macroscopic and microscopic level. They can be helpful to the forensic medicine specialist in determining causes of death, identification of human remains, interpretation of gunshot wounds, estimating post-mortem interval, and in clinical work. However, artificial intelligence methods in forensic medicine are at various stages of maturity for use in real-world work situations. In general, they are particularly useful in reviewing complex databases, extracting specific information or pointing out a particular detail that may prove important to the final decision or diagnosis. However, the interpretation of the conclusions of artificial intelligence algorithms is left to the forensic medical specialist. Artificial intelligence systems also have weaknesses, and their introduction into the daily work of forensic medicine is a particularly complex task, since the assessment of the relevance of the use and the acceptance of such a way of working depends not only on medical doctors, but also on judges and lawyers, victims and offenders.

Key words: artificial intelligence; forensic medicine; identification; post-mortem interval; diatoms; gunshot.

■ **Infor Med Slov** 2022; 27(1-2): 33-41

Institucije avtorjev / Authors' institutions: Univerzitetni klinični center Maribor (MD); Medicinska fakulteta Ljubljana, Univerza v Ljubljani (JB); Medicinska fakulteta Maribor, Univerza v Mariboru (DD).

Kontaktna oseba / Contact person: Mojca Dovnik, dr. med., UKC Maribor, Ljubljanska ulica 5, 2000 Maribor, Slovenija. E-pošta / E-mail: mojca.dovnik@student.um.si.

Prispelo / Received: 30. 1. 2023. Sprejeto / Accepted: 31. 1. 2023.

Uvod

Raziskovanje možnosti, ki jih umetna inteligenca (UI; angl. *artificial intelligence*) ponuja za reševanje različnih problemov v medicini, predstavlja zelo aktualno in pomembno področje znanosti. UI se ukvarja s tako imenovanimi »mislečimi stroji«. Predstavlja teorijo in razvoj računalniških sistemov, ki so sposobni opravljati naloge, za katere bi sicer bila potrebna človeška inteligenca, kot so vidno zaznavanje, prepoznavanje govora in odločanje. Umetnointeligenčni sistemi so sposobni učinkovitega pregledovanja masivnih podatkov (angl. *big data*) in njihovega razvrščanja. Ena izmed vej UI je strojno učenje (angl. *machine learning*). Obsega različne tehnike analize vhodnih podatkov in odločanja, pri čemer se praviloma zanaša na posredovanje programerja pri razumevanju vhodnih podatkov. Globoko učenje (angl. *deep learning*) je metoda strojnega učenja, ki omogoča reševanje kompleksnih problemov in za svoje delovanje ne potrebuje človekovega posredovanja. Definiranje značilnosti, ki so potrebne za končni odločitveni proces, pri globokem učenju ni potrebno, temveč gre za avtomatski proces oziroma sposobnost samostojnega učenja. Globoko učenje posnema delovanje človeških možganov in je zasnovano na nevronske mrežah. Natančneje so konvolucijske nevronske mreže (angl. *convolutional neural networks*) tiste, ki imajo odlično sposobnost prepoznavane in kategorizacije slikovnega materiala. Za svoje delovanje uporabljajo principe linearne algebре, predvsem matrično množenje za prepoznavanje vzorcev v slikah.^{1,4}

Konvolucijske nevronske mreže so že pokazale velik potencial za uporabo v diagnostiki in obravnavi različnih bolezenskih stanj in so obetavne tudi na področju sodne medicine, ki je izrazito vizualna veja medicine tako na makroskopski kot na mikroskopski ravni. Sodna medicina s posredovanjem medicinskih ugotovitev pravnim in drugim pristojnim oblastem sodeluje v razrešitvah kazenskih in civilnih zadev. Temeljno opravilo specialista sodne medicine vključuje obdukcije umrlih sumljivih smerti, ki so v zvezi ali posledica kaznivega dejanja. Prav tako je pomembno delo na področju izvedenstva v kazenskih, civilnopravnih ter zavarovalniških zadevah, mriškopregledna služba, histološka dejavnost, forenzična genetika, forenzična toksikologija in antropologija, katastrofna služba ter klinična forenzična medicina. Metode UI so na področju sodne medicine v različnih fazah zrelosti za uporabo v realnih delovnih okoliščinah. Večinoma gre za fazo intenzivnega raziskovanja, s tem pa razvoja in preverjanja veljavnosti številnih modelov za uporabo.

V nadaljevanju so opisani primeri uporabe UI na področju tanatologije in klinične forenzične medicine, ki so do sedaj pokazali največji potencial.^{5,6}

Identifikacija trupel ali delov trupel

Pozitivna identifikacija mrtvih na podlagi medicinsko relevantnih značilnosti je mogoča s pomočjo neprimerjalnih tehnik, kjer gre za določitev osnovnih značilnosti trupla (tj. spola, starosti, višine, teže in indeksa telesne mase) ali primerjalnih tehnik, kjer pa gre za iskanje ujemanja med posmrtnimi ostanki in informacijami in dokumenti živih za katere predvidevamo, da bi lahko bili med umrli. Značilnosti na katere se je mogoče upreti in tehnike, ki se bodo uporabile za določitev identitete, so v veliki meri odvisne od ohranjenosti trupla. Obstajajo različne možnosti vključevanja umetne inteligence tako v neprimerjalne kot tudi v primerjalne tehnike identifikacije.^{5,6}

Neprimerjalne tehnike identifikacije

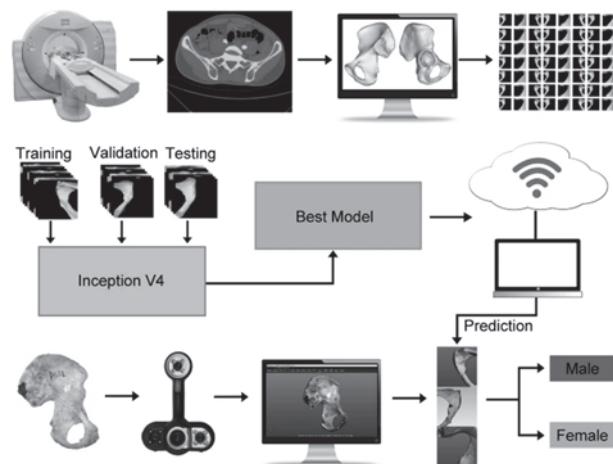
UI se na področju neprimerjalnih tehnik identifikacije največkrat uporablja za določanje spola in starosti trupla na podlagi rentgenskih slik (npr. ortopantomogramov), nekatere novejše metode za določanje spola pa temeljijo tudi na razlikah v možganskih značilnostih, prikazanih s pomočjo magnetne resonance. Nekatere metode se uporabljajo tudi za rekonstrukcijo obraza na podlagi zobozdravstvenih značilnosti.^{5,7}

Uporaba raznih 3D in slikovnih tehnik (računalniške tomografije, magnetne resonance, skenerjev, ipd.) v sodnomedicinskih postopkih identifikacije je sicer dobrodošla, vendar ena sama tehnika običajno ne zadošča za določitev spola žrtve, še posebej skeletiziranega trupla. Kombinirana uporaba navedenih tehnik je predvsem s finančnega vidika zaenkrat nesprejemljiva, zato se v sodni medicini poslužujemo osnovne DNK genotipizacije (določitev osnovnega genetskega profila), ki združuje tudi fenotip in je zaenkrat tudi najnatančnejša in cenovno sprejemljiva metoda za določanje spola neznanega, predvsem skeletiziranega trupla.

Določanje spola neskeletiziranih trupel običajno temelji na zunanjem pregledu trupla, v primeru skeletiziranih posmrtnih ostankov pa na morfoloških značilnostih ter morfometriji lobanje, medenice ter dolgih in nekaterih drugih kosti. Določanje starosti je težavnejše od določanja spola neskeletiziranega trupla in gre običajno za grobo oceno z ozirom na barvo las, elastičnost kože, stanje zobovja, morebitno prisotnost

senilnega obroča na robu roženice in prisotnost različnih stopenj degenerativnih aterosklerotičnih sprememb arterij. Eden izmed bolj natančnih pokazateljev starosti je ocena osifikacijskih jeder in stopnje fuzije epifiz. Po zaključku razvoja skeleta in zobovja obstaja manj zanesljivih znakov, ki bi bili uporabni za oceno starosti, zato ostaja določanje biološke starosti odraslih okostnjakov ena izmed najtežjih nalog na področju forenzične antropologije.⁵

Različni modeli UI lahko pripomorejo k odločitvi glede spola in starosti skeletnih ostankov. Eden izmed takih modelov za določanje spola skeletnih ostankov je prikazan na sliki 1. Temelji na virtualnih 3D rekonstrukcijah medenice, izoblikovanih na osnovi slikovnega materiala, pridobljenega z računalniško tomografijo (CT). Algoritem se je izkazal za učinkovitejšega od človeka v pravilni določitvi spola navideznih 3D rekonstrukcij medenice dejanskih skeletnih ostankov. Te rekonstrukcije so ustvarili s pomočjo ročnega 3D optičnega čitalca. Čeprav je uporaba CT povezana z visokimi stroški nakupa opreme in njenega vzdrževanja in zahteva specializirano strokovno znanje; tak model konvolucijske nevronske mreže, ki ga je mogoče uporabiti na prenosnih napravah ob dostopu do 4G/5G omrežja, veliko obeta na področju določanja spola skeletnih ostankov na samem kraju zločina oziroma najdbe ostankov.⁸



Slika 1 Primer modela umetne inteligence za določanje spola skeletnih ostankov.

Problem v slovenskem prostoru predstavlja tudi dejstvo, da obe Medicinski fakulteti nista del zdravstvenega sistema po analogiji univerzitetnih klinik (Nemčija, Švica) in je tako sodelovanje z radiološkimi inštituti in oddelki bolnišnic ter obeh Univerzitetnih kliničnih centrov praktično nemogoče. Trenutno edini Inštitut za sodno medicino na Medicinski fakulteti v Ljubljani pa si modernih

slikovnih tehnik razen prenosnega rentgenskega aparata ter skenerja iz finančnih razlogov ne more samostojno privoščiti, zato je primoran pri svojem delu uporabljati konvencionalne metode in tehnike.

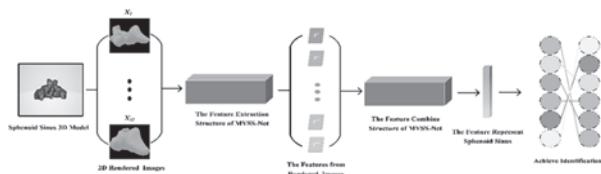
Primerjalne tehnike identifikacije

Umetna inteligenca je lahko v pomoč na področju genetike pri analizi kompleksnih genetskih profilov, v forenzični antropologiji v procesu kraniofacialne superprojekcije ali v forenzični odontologiji za klasifikacijo različnih posegov na zobovju ali prepoznavo določenih značilnosti zobovja (npr. avtomatsko analizo dentalnih rentgenskih slik). Trenutno se umetna inteligenca že uporablja v procesu identifikacije žrtev množičnih nesreč in je bila vključena v ta proces pri strmoglavljenju letala MH17 v Ukrajini leta 2014, letalski nesreči v Tripoliju leta 2010 in cunamiju na Tajske leta 2004. Specialist sodne medicine se v primeru množične nesreče srečuje s številnimi žrtvami. Nekatere izmed njih lahko identificira s pomočjo primerjave obrazu s sliko na potnem listu, najdenem na kraju nesreče. Poškodbe pa so lahko zelo hude in zaradi tega je tak način identifikacije ni mogoč. V tem primeru bi lahko zdravnik uporabil umetno inteligenco za izluščenje relevantnih značilnosti iz slike obrazu, programska oprema pa bi nato te podatke primerjala z zbirkijo že identificiranih obrazov. Rezultate ujemanja bi nato zdravnik ustrezno ovrednotil in odločil o morebitnih dodatnih metodah, ki bi bile potrebne za identifikacijo.⁵

Pri uporabi tovrstnih algoritmov umetne inteligence so strokovnjaki pri identifikaciji žrtev letalske nesreče in cunamija naleteli na velik problem, saj večina predhodno fotografsko obdelanih obrazov žrtev ni bila na razpolago, oziroma so bili fotografiski posnetki za tovrstno delo neuporabni.

Specialist sodne medicine se v procesu identifikacije osredotoča na različne značilnosti trupla. Pomembna je predvsem prepoznavna prstnih odtisov, analiza dednega materiala in ocena zobovja. Manj pogosto analizira anatomske in biološke značilnosti sfenoidalnega ali frontalnega sinusa, ki pa so prav tako edinstvene in se lahko uporabijo za identifikacijo posameznikov. Primer metode UI za identifikacijo posameznikov, ki temelji na oceni značilnosti 3D modelov sfenoidalnih sinusov, rekonstruiranih na osnovi CT slikovnega gradiva, je prikazan na sliki 2. Algoritem je sposoben izluščiti relevantne geometrijske značilnosti sfenoidalnega sinusa neidentificirane osebe in jih primerjati s slikovnim gradivom iz drugega obdobja (tj. zaživljenjskimi CT posnetki sfenoidalnega sinusa). Metoda se opira na

človeka zgolj v procesu 3D rekonstrukcije sfenoidalnega sinusa.⁹



Slika 2 Primer modela umetne inteligence za identifikacijo.

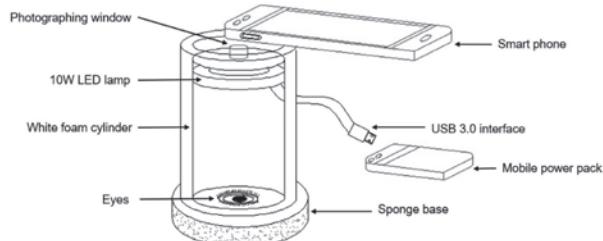
Določanje časa nastopa smrti

Metode UI se za določanje časa nastopa smrti opirajo predvsem na podatke, pridobljene z zunanjim pregledom trupla, zakonitosti forenzične entomologije in biokemije ter na spremembe telesne temperature trupla. Raziskujejo se načini za avtomatizirano določanje časa nastopa smrti na podlagi posmrtnih fotografij z določanjem stopnje motnosti roženice, na podlagi rezultatov biokemijske analize očesne vodice (predvsem koncentracije K⁺) ali na podlagi mikrobioma in za določanje starosti in vrste forenzično pomembnih žuželk na podlagi spektrogramov ali fotografij. Prav tako se razvijajo metode UI, ki posredno prispevajo k določitvi časa nastopa smrti, npr. z oceno temperature okolice.^{5,10}

Metode za določanje časa nastopa smrti zaenkrat ne dopuščajo avtomatizacije, ker je za postmortalni interval potrebno upoštevati več različnih metod in tehnik. Avtomatizirana bi zaenkrat lahko postala normogramska metoda uporabe temperature jeder trupla (Hensgejev normogram), ki ga je mogoče z ustreznim računalniškim programom avtomatizirati. Metoda daje zaenkrat najbolj sprejemljiv postmortalni interval.

Po smrti roženica pomotni in se naguba zaradi postopne degeneracije in nekroze roženičnih celic, neenakomerne zadebelitve strome in izhlapevanja vode. Običajno specialist sodne medicine s prostim očesom oceni stopnjo motnosti roženice in ugotovitve zapiše v obducijski izvid. Vendar pa v tem primeru ne gre za objektivno kvantifikacijo in zato je ocena časa nastopa smrti na podlagi teh ugotovitev zelo nezanesljiva. Raziskovalci so zato razvili metode UI za izboljšanje zanesljivosti ocene časa nastopa smrti na podlagi značilnosti roženice trupla. Primer predstavlja naprava (angl. *Corneal-Smart Phone*), ki omogoča fotografiranje in digitalno analizo pridobljenega slikovnega materiala ter oceno časa nastopa smrti, prikazana na sliki 3. Gre za prenosno napravo, sestavljeno iz pametnega telefona in nastavka, ki zagotavlja enakomerno osvetlitev in s tem

ustrezno kakovost slik za nadaljnjo analizo, ki jo opravi aplikacija na telefonu. Sistem je sposoben avtomatske prepoznavne relevantnih značilnosti na slikah in ocene časa nastopa smrti, ki se nato prikaže na zaslonu telefona.¹¹



Slika 3 Shematski prikaz naprave za fotografiranje roženic trupel na terenu (angl. *Corneal – Smart Phone*).

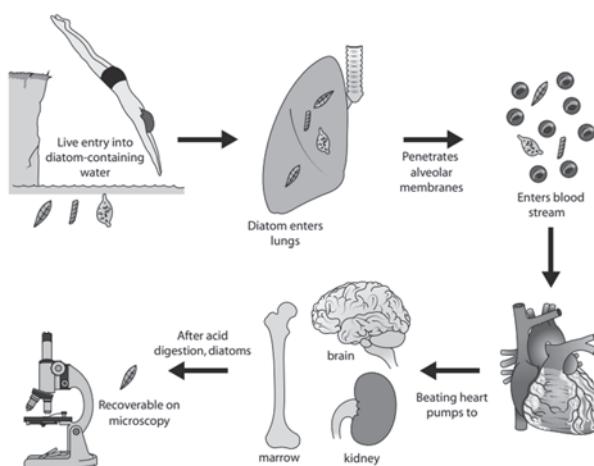
Ugotavljanje vzroka smrti

Metode UI so lahko v pomoč tudi pri ugotavljanju vzroka smrti. Lahko temeljijo na podatkih iz obducijskih zapisnikov, zdravniških potrdil o smerti in poročil o vzroku smrti, dokumentih s kliničnimi podatki o posamezniku ali na drugih analitičnih podatkih in so usmerjene predvsem na ovrednotenje verjetnosti za posamezni vzrok smrti. Lahko temeljijo tudi na analizi posmrtnega slikovnega gradiva in so v pomoč pri iskanju radioloških značilnosti, povezanih s posameznim vzrokom smrti (npr. zgostitve mlečnega stekla z zadebelitvijo acinarne in lobularne intersticije na CT slikah utopljencev). Eden izmed najbolj obetajočih načinov vključevanja teh metod v sodnomedicinsko praksu je uporaba metod UI v diagnostiki utopitve s testom na prisotnost kremenastih alg.^{5,12}

Kremenaste alge ali diatomeje so enocelične alge s silicijevim eksoskeletom. V primeru utopitve predrejo alveolarne stene, nato po vstopu v krvni obtok in se prenesejo tudi do oddaljenih organov, kot so možgani, ledvice, jetra in kostni mozek. Po obdelavi vzorcev organov, odvzetih med obdukcijo, z žveplovo ali dušikovo kislino se visoko odporni eksoskelet kremenastih alg ohrani in ga je mogoče prepoznati pod mikroskopom. Alternativno se organizmi lahko določajo tudi iz krvi. Zaradi možnosti izgube kremenastih alg med pripravo preparatov za analizo po klasičnih metodah in v izogib lažno negativnim rezultatom se lahko kemijska digestija organskih snovi zamenja tudi z mikrovalovno digestijo, centrifugiranje z vakuumsko filtracijo, klasično svetlobno mikroskopiranje pa z vrstičnim elektronskim mikroskopiranjem.^{2,6,13,14}

Če je bilo truplo zgolj odvrženo v vodo, lahko kremenaste alge kljub temu pasivno poniknejo v pljuča, vendar pa jih v tem primeru ne bo mogoče najti v oddaljenih organih, kar bi bila posledica odpovedi cirkulacije že pred stikom z vodo. Zaradi tega test s kremenastimi algami predstavlja eno od možnosti za diagnosticiranje utopitve (slika 4) in je še posebej uporaben pri močno gnilobno spremenjenih truplih.⁶

Ocenjujejo, da obstaja več kot 20.000 različnih vrst kremenastih alg. V splošnem oligohalofilne diatomeje živijo v sladkovodnih območjih, mezo- in polihalofilne pa v slani oziroma morski vodi. Posamezne živijo le v točno določenem habitatu z določeno količino hranil, svetlobe, mineralno sestavo, temperaturo in globino. Populacije kremenastih alg so zato raznolike in dinamične oziroma odvisne od okoljskih sprememb na določenem območju. Z ekološko tipizacijo kremenastih alg, njihovo kvantifikacijo in primerjavo vzorcev tkiv in vzorcev vode je tako mogoče oceniti tudi lokacijo utopitve (npr. v primerih, ko je vodni tok truplo naplavil na oddaljeno mesto). Učinkovitost določanja lokacije utopitve pa je odvisna tudi od vzpostavljanja podatkovnih zbirk, v katerih bi bili zbrani profili kremenastih alg v vodnih virih na določenem območju v določenem mesecu ali letnem času, da bi z njimi lahko primerjali profile kremenastih alg iz vzorcev tkiv trupel.^{6,13}



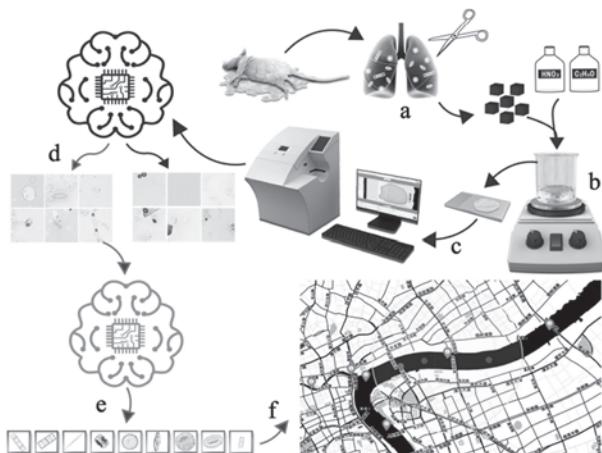
Slika 4 Načelo uporabnosti kremenastih alg pri opredelitvi utopitve kot vzroka smrti.

Test s kremenastimi algami za potrditev utopitve pa ima tudi nekatere slabosti. Kremenaste alge so prisotne praktično povsod, ne le v vodnih virih, temveč tudi v zraku in zemlji. Nahajajo se v hrani, npr. v morskih sadežih, pa tudi nekateri pogosto uporabljeni minerali in drugi proizvodi, kot je npr. kreda, vsebujejo diatomejam podobne materiale. Kremenaste alge bi lahko oddaljene organe dosegle

tudi preko vstopa v cirkulacijo iz prebavnega trakta. Zaradi tega je zanesljivost testa s kremenastimi algami še vedno sporna. Potrebno je upoštevati okoliščine smrti ter kvantitativno razliko v številu kremenastih alg, določenih v truplih utopljencev, v primerjavi z drugimi trupli. Test s kremenastimi algami specialistom sodne medicine ostaja v pomoč pri določitvi utopitve kot vzroka smrti, vendar ni primeren kot dokaz na sodišču.⁶

Verjetnost za lažno pozitivne rezultate testa na prisotnost kremenastih alg v oddaljenih organih zaradi kontaminacije pred ali po smrti se lahko zmanjša z natančno kvalitativno in kvantitativno analizo. Ker pa je določanje morebitne prisotnosti kremenastih alg v izbranih vzorcih utrudljivo, časovno zahtevno in drago ter pogosto zahteva specifično znanje taksonomije, so bili razviti visoko učinkoviti, hitri in objektivni umetnointeligenčni sistemi za avtomatizirano prepoznavo in razvrščanje posameznih vrst kremenastih alg. Temeljijo na kombinaciji globoke konvolucijske nevronске mreže s sposobnostjo prepoznavne in kategorizacije slikovnega materiala z digitalno patologijo, ki ponuja platformo, preko katere je mogoče digitalno pregledovati, upravljati, deliti in analizirati mikroskopske preparate.^{2,13}

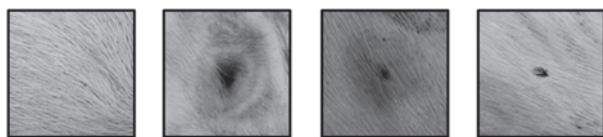
Na sliki 5 je prikazan primer strategije umetnointeligenčnega sistema za mikroskopsko identifikacijo skeleta kremenastih alg na digitaliziranih mikroskopskih preparatih. Iz tkivnih vzorcev se po obdelavi s kislinami pripravijo mikroskopski preparati, ki jih je nato potrebno digitalizirati z optičnim bralnikom. Model konvolucijske nevronске mreže prepozna kremenaste alge iz vzorcev tkiv (ali vzorcev vode) in jih nato tudi razvrsti, kar omogoči sklepanje na mesto utopitve (primerjava profila specifičnih diatomej v vzorcih tkiv in vzorcih vode).¹³



Slika 5 Primer strategije umetnointeligenčnega sistema za mikroskopsko identifikacijo skeleta kremenastih alg.

Interpretacija strelnih ran

Balistika je veda, ki se ukvarja z gibanjem, obnašanjem in učinkom izstrelkov in zajema tudi balistiko rane, tj. preučevanje gibanja izstrelka po prodoru v človeško tkivo. Interpretacija strelnih ran s strani specialista sodne medicine pomembno prispeva k rekonstrukciji dogajanja v času streljanja, kar je v javnem interesu in ima seveda tudi pravne posledice. Zaradi tega morajo biti zaključki glede tipa orožja in izstrelka, strelne razdalje in smeri strela čim bolj natančni. Modeli UI so lahko v pomoč pri interpretaciji strelnih ran, npr. pri oceni strelne razdalje na podlagi fotografij rane. Na sliki 6 so prikazani primeri strelnih ran. Od leve proti desni prva slika predstavlja negativno kontrolo; druga slika rano po strelu iz absolutne bližine z vidno sledjo cevi in strelno rano, ki je večja od kalibra izstrelka zaradi delovanja smodniških plinov; tretja slika rano po strelu iz bližine z vidno sledjo plamena, dimnim kolobarjem in tetovažo; četrta slika pa rano po strelu iz razdalje, kjer dopolnilnih faktorjev ne najdemo. Različni tipi strelnih ran imajo torej različne vizualne značilnosti, kar je osnova modelov UI za določanje oddaljenosti strela.^{6,15}

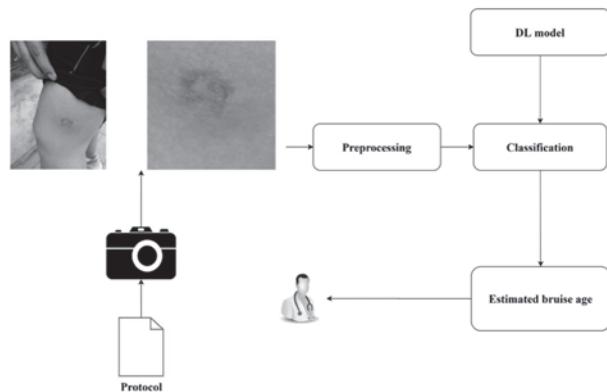


Slika 6 Reprezentativni primeri strelnih ran, nastalih po streljanju z različnih strelnih razdalj.

Klinična forenzična medicina

Klinična forenzična dejavnost vključuje telesne pregledе živih preiskovancev in izvajanje drugih preiskav, potrebnih za oceno starosti, mentalnega

stanja ali stopnje telesnih poškodb posameznikov. Metode UI zaenkrat niso vključene v delo specialista sodne medicine na tem področju, kljub temu pa se številne raziskave ukvarjajo s potencialnimi možnostmi za njihovo uporabo, še posebej na področju forenzične psihijatrije. Metode UI so lahko v pomoč tudi pri pregledu žrtev spolnega nasilja z avtomatsko razvrstitevijo kolposkopskih slikovnih izvidov. Tako bi npr. specialist sodne medicine lahko žrtev pregledal z digitalnim kolposkopom, povezanim z računalnikom. Vsakič bi posneto sliko pregledal umetnointeligenčni sistem na računalniku in prepoznal ter izpostavil poškodbe, vidne na sliki, ki bi jih nato specialist sodne medicine ustrezno ovrednotil glede na relevantnost za opredelitev posilstva. Prav tako bi bila možna avtomska ocena starosti podplutb na osnovi fotografij (slika 7). Podplutbe so namreč krvavitve pod površino kože, ki nastanejo zaradi udarca s topim predmetom in so na površini vidne kot obarvanje kože, ki se spreminja s časom in je lahko opazno tudi po 30 dneh po poškodbi.^{5,16}



Slika 7 Primer modela umetne inteligence za avtomatsko oceno starosti podplutb.

Virtopsijsa

Skupaj s klinično radiologijo se razvija tudi področje forenzične radiologije. Večrezinski računalniški tomograf, magnetna resonanca in 3D skeniranje se v nekaterih primerih kombinirajo s klasičnimi obdukcijami za dokumentiranje poškodb na objektiven in neinvaziven način. Radiološke metode so se za prepoznavanje nekaterih poškodb skeleta in tkiv izkazale kot boljše v primerjavi s klasično obdukcijo. Trirazsežni pristopi imajo potencial tudi za oblikovanje animacij, ki lahko pripomorejo k boljšemu razumevanju dinamičnega nastanka določenega vzorca poškodb, s tem pa k oceni verjetnosti, da je bila določena poškodba povzročena z določenim predmetom (možna je npr. primerjava telesnih poškodb s poškodbami na vozilu v primeru prometnih nesreč).¹⁷⁻¹⁹

Uvajanje novih metod v sodnomedicinsko prakso pa je prineslo tudi potrebo po ustreznih podatkovnih zbirki za shranjevanje forenzičnih radioloških in patoloških ugotovitev v digitalni standardizirani obliki, ki so registriranim uporabnikom ves čas na voljo za ogled in medsebojno primerjavo z namenom ovrednotenja navideznega pristopa k pregledu trupla (t. i. virtopsije) glede na trenutno uveljavljen zlati standard klasične obdukcije. Takšna podatkovna zbirka je tudi vir informacij za raziskovalne in učne namene, sredstvo za zbiranje, arhiviranje in posredovanje medicinskih podatkov na anonimen način zaradi sodelovanja in izmenjave izkušenj med institucijami na nacionalni in mednarodni ravni (telemedicina) ter orodje za spremljanje kakovosti dela.

V Švici so razvili metodo centraliziranega upravljanja s podatki (preko osrednjega strežnika), ki od končnega uporabnika ne zahteva nakupa, nameščanja ali vzdrževanja nobene specializirane programske ali strojne opreme. Omogoča hitro in enostavno deljenje ustreznih protokolov številnim uporabnikom, medtem ko se dostop do podatkov in njihova analiza opravlja centralno. Na ta način je mogoče bolj enostavno vzpostavljanje različnih registrov. Dodatno lokalni internetni strežnik deluje kot filter med uporabnikom in centralno podatkovno zbirko oziroma omogoča, da vsak inštitut dostopa do sistema preko lastne spletne strani ter tako ohranja kontrolo in odgovornost za občutljive medicinske podatke. Samo anonimizirani podatki se posredujejo do osrednjega strežnika. Takšna podatkovna zbirka torej pomembno prispeva tudi k uveljavljanju virtopsije v sodnomedicinsko prakso, saj omogoča neposredno primerjavo radioloških in patoloških podatkov ter s tem določanje ločljivosti in občutljivosti posamezne metode za prepoznavo različnih značilnosti trupla.¹⁹

Razprava

Z napredkom informacijske tehnologije, računalniških sistemov in dostopnostjo do obširnih podatkovnih zbirk so se v zadnjem desetletju pokazale številne potencialne možnosti uporabe metod UI na področju sodne medicine. Predvsem gre za metode s sposobnostjo reševanja določenih nalog na podlagi prepoznavanja vzorcev v kopici različnih vrst podatkov (številskih vrednosti, slikovnega gradiva, poročil, videoposnetkov in grafikonov), kar omogoča širšo uporabno vrednost teh metod, npr. prepoznavo različnih anomalij na posmrtnem slikovnem gradivu. Vendar pa določen model UI lahko opravlja zgolj točno določeno naložo (npr. model za določanje starosti posameznika ne more določati tudi spola ali uporabljati kakršnihkoli drugih podatkov, ki niso bili

vključeni v proces učenja brez posredovanja človeka).⁵

Metode UI so lahko kljub temu na različne načine v pomoč specialistu sodne medicine pri njegovem delu, npr. ugotavljanju vzrokov smrti, identifikaciji, interpretaciji strelnih ran, določanju časa nastopa smrti in pri kliničnem delu. Zaenkrat je po poročanju v literaturi identifikacija žrtev množičnih nesreč edino področje sodne medicine, kjer se UI že uporablja. Najnaprednejši tovrstni sistemi so že nekaj časa v praksi švicarskih sodnomedicinskih inštitutov, kjer se največ ukvarjajo z virtopsijo, ki bi naj sčasoma nadomestila klasično avtopsijo. Pri tem uporabljajo številne tehnike in računalniške programe, ki pa brez izkušenega človeškega strokovnega potenciala ne dajejo pričakovanih rezultatov (postmortalna računalniško tomografska angiografija, 3D računalniška obdelava trupla, jemanje bioloških vzorcev po načinu igelne biopsije, MRI slikovna obdelava).

Toda avtomatizacija bi tudi na drugih področjih bistveno pospešila sicer časovno zahtevne, kompleksne in utrudljive naloge ter prihranila administrativno delo. Avtomatizirana prepoznavna in razvrščanje kremenastih alg in njihova primerjava med vzorci tkiv in vode prima veliko prednosti pred ročnim pregledovanjem mikroskopskih preparatov in njihovo medsebojno primerjavo. Prav tako so umetnointeligenčni sistemi sposobni pravilne prepoznavne manjših ostankov kremenastih alg, ki bi jih človek običajno spregledal, kar zmanjšuje verjetnost za lažno negativne rezultate. Pri tem pa bo v prihodnosti potrebno zagotoviti, da je algoritem UI dovolj fleksibilen in sposoben prepoznavati nove vrste kremenastih alg, na katere še ni naletel, oziroma bo potrebno sprotno učenje algoritma z novimi podatki o novih vrstah za zagotavljanje ustrezone natančnosti in pravilnosti prepoznavne.^{2,3,5,14}

Ena od pomajkljivosti obstoječe sodnomedicinske metodologije na področju določanja biološkega profila trupla ali njegovih ostankov je subjektivnost. Zanesljivost rezultata, ki temelji na makroskopski analizi, je namreč odvisna od izkušenosti opazovalca. Izkušnje pa je težko kvantificirati, kar lahko predstavlja problem v pravnem okolju, ko je nujna tudi natančna opredelitev verjetnosti za napako pri predstavljenih dokazih ozirom izvedenskem mnenju. Metode UI lahko pripomorejo k objektivizaciji in povečajo zanesljivost omenjenih metod, še posebej kadar gre za analizo subtilnih razlik npr. v obliki črevnice in spodnje čeljustnice pred puberteto in določanju spola na podlagi teh razlik.³

Metode UI so uporabne v procesu odločanja in se v določenih nalogah izkažejo celo za učinkovitejše in natančnejše od človeka. Avtomatsko definiranje značilnosti, ki so relevantne za končno odločitev, npr. o starosti skeletnih ostankov na podlagi zobovja, omogoča premostitev določenih slabosti obstoječih metod na določenem področju. Omeji lahko naključne napake, ki so posledica človekove utrujenosti, trenutnega čustvenega stanja ali drugih motenj. Model, ki deluje na ta način, lahko hkrati analizira več različnih struktur in značilnosti ter upošteva tudi dodatne, na katere se do sedaj v študijah še niso osredotočali.^{3,7,10}

Za doseganje zadovoljive točnosti pa mora biti na voljo osnovna podatkovna zbirka z zadostno količino podatkov, ki se lahko uporabi za učenje algoritma, ter ustrezna strojna in programska oprema. Velikokrat take podatkovne zbirke v našem okolju še ne obstajajo (npr. nimamo zbirke, kjer bi bile zbrane vse vrste kremenastih alg v slovenskih vodnih virih v različnih letnih časih, ki bi lahko predstavljale reprezentativne podatke za učenje algoritmov). Najprej bi bilo potrebno vzpostaviti te zbirke s podatki, zbranimi v enotnem formatu. Problem predstavlja tudi nezmožnost razumevanja in analiziranja delovanja UI v celoti (npr. ni natančno pojasnjeno, kako model UI na osnovi konvolucijskih nevronskih mrež, ki je sposoben ocene višine posameznika glede na antropometrične meritve, dejansko interpretira te meritve in poda končno oceno, kar je povezano s kompleksno arhitekturo konvolucijskih nevronskih mrež). Potrebno je upoštevati tudi stroške nakupa in vzdrževanja potrebne opreme. Ker v veliki meri temelji na slikovnem gradivu, dodatna slikovna diagnostika predstavlja dodatni strošek, ki ga v primeru klasične obravnave s strani specialista ni. Prav tako je zanesljivost končnega rezultata, ki ga poda algoritem UI, odvisna od kakovosti slikovnega gradiva, kar je lahko problem pri fotografirjanju (npr. roženice ali strelnih ran) na terenu. Zaradi tega je potrebno pozornost usmeriti tudi na zagotavljanje enakovrednih pogojev za fotografiranje (npr. kot je to zagotovljeno pri roženičnem pametnem telefonu).^{2,3,5,8,14}

V splošnem je UI na področju sodne medicine še posebej uporabna za pregled kompleksnih zbirk podatkov, ko je potrebno izluščiti določen podatek ali za opozarjanje na določeno podrobnost, ki bi se lahko izkazala za pomembno pri končni odločitvi oziroma diagnozi. Interpretacija zaključkov algoritmov UI pa ostaja v domeni specialista sodne medicine.⁵

Zaključek

Glede na trenutna prizadevanja za vključevanje metod UI v medicinsko stroko in številne raziskave na tem področju, bo UI v prihodnosti najverjetneje našla svoje mesto tudi v vsakodnevni sodnomedicinski praksi. Vendar pa na področju sodne medicine to predstavlja še posebej kompleksno naložbo, saj ocena relevantnosti uporabe in sprejemanje takšnega načina dela ni odvisna zgolj od zdravnikov, temveč tudi od sodnikov ter odvetnikov, žrtev in storilcev kaznivih dejanj. Vsako novo metodo mora pravosodje najprej priznati kot relevantno in verodostojno metodo, ki omogoča objektivne verodostojne materialne dokaze v kazenskih in civilno pravdnih zadevah, za kar običajno preteče veliko časa. UI predstavlja orodje za pridobivanje informacij, ki se nato na sodišču uporabijo v argumentih in kot dokazno gradivo, zato mora biti ustreznost in neomajnost rezultatov vsakega takega orodja sistematično preverjena. Prav tako morajo biti algoritmi z vključevanjem UI neoporečni tudi v etičnem smislu (npr. ne sme biti nobenega suma, da je z uporabo algoritma prišlo do spolne ali rasne diskriminacije). Neoporečnost uporabljenih algoritmov mora biti zagotovljena na vseh področjih medicine, vendar pa so v pravnem kontekstu le-ti še pogosteje predmet kritike in dvomov.²⁰

Reference

1. Lidströmer N, Aresu F, Ashrafiān H. Basic concepts of artificial intelligence: primed for clinicians. In: Lidströmer N, Ashrafiān H (eds.). *Artificial intelligence in medicine*. Cham 2022: Springer; 3-20.
2. Zhou Y, Zhang J, Huang J, et al. Digital whole-slide image analysis for automated diatom test in forensic cases of drowning using a convolutional neural network algorithm. *Forensic Sci Int* 2019; 302: 109922. <https://doi.org/10.1016/j.forsciint.2019.109922>
3. Ortega RF, Irurita J, Campo EJE, Mesejo P. Analysis of the performance of machine learning and deep learning methods for sex estimation of infant individuals from the analysis of 2D images of the ilium. *Int J Legal Med* 2021; 135(6): 2659-2666. <https://doi.org/10.1007/s00414-021-02660-6>
4. Burger G. *Definicije in algoritmi umetne inteligence*. https://www.dihslovenia.si/assets/images/DIH_Slovenia_Definicije_in_algoritmi_umetne_inteligence.pdf (22. 11. 2022)
5. Tournois L, Lefèvre T. AI in forensic medicine for practicing doctor. In: Lidströmer N, Ashrafiān H (eds.). *Artificial intelligence in medicine*. Cham 2022: Springer; 1777-1786.
6. Saukko P, Knight B. *Knight's forensic pathology* (4th ed.). Boca Raton 2015: CRC Press.
7. Han M, Du S, Ge Y, et al. With or without human interference for precise age estimation based on

- machine learning? *Int J Legal Med* 2022; 136(3): 821-831. <https://doi.org/10.1007/s00414-022-02796-z>
8. Cao Y, Ma Y, Vieira DN, et al. A potential method for sex estimation of human skeletons using deep learning and three-dimensional surface scanning. *Int J Legal Med* 2021; 135(6): 2409-2421. <https://doi.org/10.1007/s00414-021-02675-z>
 9. Wen H, Wu W, Fan F, et al. Human identification performed with skull's sphenoid sinus based on deep learning. *Int J Legal Med* 2022; 136(4): 1067-1074. <https://doi.org/10.1007/s00414-021-02761-2>
 10. Sharma R, Diksha, Bhute AR, Bastia BK. Application of artificial intelligence and machine learning technology for the prediction of postmortem interval: a systematic review of preclinical and clinical studies. *Forensic Sci Int* 2022; 340: 111473. <https://doi.org/10.1016/j.forsciint.2022.111473>
 11. Zheng J, Huo D, Wen H, Shang Q, Sun W, Xu Z. Corneal-Smart Phone: a novel method to intelligently estimate postmortem interval. *J Forensic Sci* 2021; 66(1): 356-364. <https://doi.org/10.1111/1556-4029.14611>
 12. Homma N, Zhang X, Qureshi A, et al. A Deep learning aided drowning diagnosis for forensic investigations using post-mortem lung ct images. *Annu Int Conf IEEE Eng Med Biol Soc* 2020; 2020: 1262-1265. <https://doi.org/10.1109/EMBC44109.2020.9175731>
 13. Zhang J, Zhou Y, Vieira DN, et al. An efficient method for building a database of diatom populations for drowning site inference using a deep learning algorithm. *Int J Legal Med* 2021; 135(3): 817-827. <https://doi.org/10.1007/s00414-020-02497-5>
 14. Yu W, Xue Y, Knoops R, et al. Automated diatom searching in the digital scanning electron microscopy images of drowning cases using the deep neural networks. *Int J Legal Med* 2021; 135(2): 497-508. <https://doi.org/10.1007/s00414-020-02392-z>
 15. Oura P, Junno A, Junno JA. Deep learning in forensic gunshot wound interpretation-a proof-of-concept study. *Int J Legal Med* 2021; 135(5): 2101-2106. <https://doi.org/10.1007/s00414-021-02566-3>
 16. Tirado J, Mauricio D. Bruise dating using deep learning. *J Forensic Sci* 2021; 66(1): 336-346. <https://doi.org/10.1111/1556-4029.14578>
 17. Thali MJ, Yen K, Schweitzer W, et al. Virtopsy, a new imaging horizon in forensic pathology: virtual autopsy by postmortem multislice computed tomography (MSCT) and magnetic resonance imaging (MRI): a feasibility study. *J Forensic Sci* 2003; 48(2): 386-403.
 18. Thali MJ, Braun M, Buck U, et al. VIRTOPSY: scientific documentation, reconstruction and animation in forensic: individual and real 3D data based geo-metric approach including optical body/object surface and radiological CT/MRI scanning. *J Forensic Sci* 2005; 50(2): 428-442.
 19. Aghayev E, Staub L, Dirnhofer R, et al. Virtopsy - the concept of a centralized database in forensic medicine for analysis and comparison of radiological and autopsy data. *J Forensic Leg Med* 2008; 15(3): 135-140. <https://doi.org/10.1016/j.jflm.2007.07.005>
 20. Lefèvre T. Artificial intelligence in forensic medicine. In: Lidströmer N, Ashrafi H (eds.). *Artificial Intelligence in Medicine*. Cham 2022: Springer; 1767-1773.

Ema Dornik, Boštjan Žvanut

MI'2022 "Odločno digitalno za več zdravja": poročilo s srečanja Sekcije za informatiko v zdravstveni negi – SIZN 2022

MI'2022 "Decisively Digital for More Health": Report from the Meeting of the Nursing Informatics Section – SIZN 2022

Tradicionalno srečanje članov Sekcije za informatiko v zdravstveni negi (SIZN), ki deluje pri Slovenskem društvu za medicinsko informatiko (SDMI), je potekalo 11. novembra 2022 v Termah Zreče kot "hibridni" dogodek. Letos smo lahko – z enoletno zamudo – tudi fizično obeležili 20. obletnico delovanja SIZN. Programski in organizacijski odbor sta nas presenetila s tortama, s katerimi smo lahko obeležili ta jubilej (slika 1).



Slika 1 Torti ob 20-letnici delovanja SIZN.

Obsežen programski sklop je postregel s 17 predavanji v treh sklopih. Ponosni smo, da je bil en sklop v celoti namenjen študentom, ki kažejo na svetlo bodočnost SIZN. Večina predavateljev je predavala v živo, trije so svoje prispevke predstavili preko spleteta.

Slišali smo zanimive vsebine, ki jih navajamo po vrstnem redu v programu:

- Vladislav Rajkovič: Digitalne kompetence v zdravstvene nege v luči umetne inteligence
- Jožica Čehovin Zajc, Marija Milavec Kapun: SmartNurse: kaj se lahko naučimo, ko učimo
- Tina Kamenšek, Marija Milavec Kapun: GenoNurse – mednarodno partnerstvo za izboljšanje kompetenc študentov zdravstvene nege na področju genomike
- Nino Fijačko, Gregor Štiglic, Lucija Gosak: Percepcija uporabe navidezne resničnosti za učenje temeljnih postopkov oživljanja odrasle osebe pri študentih zdravstvene nege: študija uporabnosti
- Jerneja Meža, Barbara Smrke: Obrnjeno učenje v okviru študijskega programa Zdravstvena nega
- Maja Drešček Dolinar, Nataša Mlinar Reljić, Barbara Donik, Gregor Štiglic: E-učenje študentov zdravstvene nege v času pandemije COVID-19
- Darja Fridau, Cvetka Krel, Sebastjan Bevc: Vključitev negovalnih diagnoz NANDA-I v elektronski zdravstveni zapis
- Cvetka Krel, Dominika Vrbnjak, Gregor Štiglic, Sebastjan Bevc: Vsebinska veljavnost slovenske različice vprašalnika »Vprašalnik za merjenje uporabe, kakovosti in zadovoljstva z elektronskim zdravstvenim zapisom z vidika medicinskih sester«

- Samanta Mikuletič, Boštjan Žvanut: Informacijska varnostna kultura med zaposlenimi v zdravstveni negi: rezultati preliminarne študije
- Aljaž Bajc, Neža Jarc: Organizacija informatike v Covid enoti intenzivne terapije
- Mihael Nedeljko, Boris Miha Kaučič: Uporaba informacijsko komunikacijske tehnologije pri starejših odraslih zmanjšuje socialno izolacijo in izboljšuje kakovost življenja
- Anže Mihelič, Boštjan Žvanut, Simon Vrhovec: Pametne naprave v pomoč starejšim odraslim
- Nives Matko, Marizela Nuhanović, Megi Trojar: Ocena tveganja za nastanek razjede zaradi pritiska
- Tjaša Ulčnik, Rok Škedelj: Model za oceno ustreznosti perfuzorja
- Maša Zapušek, Klara Vrtačnik: Ocena ogroženosti dializnega bolnika
- Alen Lončar, Marija Milavec Kapun: Uporabnost aplikacije NurseCal za izračun odmerkov in pretočnosti zdravil
- Uroš Višič: Digitalizacija zdravstveno-vzgojnih vsebin Sole za starše v času pandemije Covid-19

Povzetki in prispevki predstavitev so objavljeni v zborniku srečanja.

Zaključek

Ob zaključku rednega letnega strokovnega srečanja je potekal sestanek članov SIZN, kjer je predsednik sekcije izr. prof. dr. Boštjan Žvanut podal poročilo o delu SIZN za leto 2022, prav tako so bile opredeljeni načrti in usmeritve za nadaljnje delo SIZN.

Program srečanja je bil tudi v tem v letu posredovan v evalvacijo za licenčne točke Zbornice zdravstvene in babiške nege Slovenije – Zveze strokovnih društev medicinskih sester, babic in zdravstvenih tehnikov Slovenije (Zbornice-Zveze). Komisija za oceno ustreznosti stalnega strokovnega izpopolnjevanja, imenovana s strani Zbornice-Zveze, je programu SIZN 2022 dodelila 6 licenčnih točk za pasivne udeležence in 10 licenčnih točk za aktivne udeležence.

Zaključki srečanja in ključne ugotovitve se nanašajo na dopolnjevanje kompetenc s področja zdravstvene nege, ki jih zahteva uporaba sodobnih IKT rešitev, in pomen pedagoškega dela na tem področju ter razvoj IKT rešitev za učenje in poučevanje (navidezna resničnost, obrnjeno učenje), izpostavili pa smo tudi pomen usposabljanja pacientov na področju informacijske in zdravstvene pismenosti. Člani SIZN smo si enotni, da je potrebno spodbujati uvajanje IKT rešitev, ki dejansko podpirajo delo v zdravstveni negi, zato je potrebno medicinske sestre vključiti v načrtovanje IKT sistemov. Informacijski varnosti je treba dati posebno pozornost zaradi vse bolj zahtevne zaščite osebnih in občutljivih podatkov pacientov.

Zahvala

Hvaležni smo vsem članom SIZN za skupno rast, podporo in zaupanje. Zahvaljujemo se avtorjem, ki so s svojimi prispevki aktivno sodelovali na srečanju, ter vsem članom SIZN, ki sodelujejo v naših aktivnostih. Iskrena hvala SDMI, ki je omogočilo naše srečanje.

- **Infor Med Slov** 2022; 27(1-2): 42-43



Andrej Kastrin

Omrežja znanja in njihova uporaba v biomedicini

Povzetek. Učno gradivo celovito predstavi področje proučevanja omrežij znanja. Omrežje znanja je formalno definirano kot heterogeno omrežje, sestavljeno iz vozlišč in povezav različnih semantičnih tipov. Na kratko je predstavljena zgodovina raziskovanja omrežij znanja, formalna definicija in temeljne lastnosti. Predstavljeni so primeri uporabe omrežij znanja na področju biomedicine, vključno s pregledom virov podatkov, metodami konstrukcije omrežja (luščenje entitet/relacij, normalizacija in integracija omrežij) ter reprezentacijskim učenjem nad njimi.

Ključne besede: reprezentacija znanja; semantična mreža; biomedicina; viri podatkov; besedilno rudarjenje; algoritmi.

Knowledge Networks and Their Use in Biomedicine

Abstract. The tutorial provides a comprehensive introduction to the field of knowledge networks. Knowledge network is defined as a heterogeneous network consisting of nodes and relations of different semantic types. The history of knowledge networks research, formal definition, and basic properties are briefly presented. Examples of the application of knowledge networks in the biomedical domain are provided, including possible data sources, construction methods (entity/relationship extraction, normalisation, and network integration), and representation learning.

Key words: knowledge representation; semantic network; biomedicine; data sources; text mining; algorithms.

 Infor Med Slov 2022; 27(1-2): 44-50

Uvod

Odgovor na vprašanje, kaj je znanje, ni preprost. Že bežen pregled literature razkriva paletu različnih opredelitev pojma. V nadaljevanju bomo privzeli preprosto definicijo, da je znanje skupek urejenih informacij, ki nam omogočajo razumevanje obravnavanega pojava.

Najbrž se bo vsakdo strinjal, da je ustrezен način organizacije znanja ključen, da uspešno opravimo dano nalogu. Študent, ki se na zahteven izpit pripravlja sistematično in za ponavljanje uporablja različne miselne sheme, bo predvidoma dosegel boljši uspeh kot njegov kolega, ki je študijsko gradivo le bežno pregledal. Bolj učeno lahko rečemo, da je študentov uspeh povezan z uspešnostjo njegove reprezentacije oz. predstavitev znanja. Boljša kot bo predstavitev znanja v študentovem spominu, bolje ga bo ta razumel, laže ga bo dopolnjeval in o njem bolj poglobljeno razmišljal. Tako osvojeno znanje bo tudi bolj modularno, saj bo lahko posamezne dele uporabil kot gradnike, na osnovi katerih bo razširjal svoje vedenje v druge problemske domene.

Tematika predstavitev znanja je danes v središču pozornosti na področjih kognitivne znanosti in umetne inteligentnosti. Če vzamemo v roke sodoben učbenik kognitivne psihologije¹ ali umetne inteligentnosti,² ugotovimo, da so vsebine, povezane s področjem reprezentacij znanja, praviloma obravnavane v samostojnem poglavju. Na podoben način kot v človekovih možganih je potrebno za uspešno reševanje nalog predstaviti znanje tudi stroju. Poznamo več različnih pristopov k reprezentaciji znanja. Tako ločimo med predstavitevami s (i) pravili, (ii) semantičnimi mrežami, (iii) scenariji oz. skripti ter (iv) okviri. Med njimi je najbrž najbolj znana semantična mreža. To je preprost model za reprezentacijo znanja, človeku je lahko razložljiv, enostavno ga je predstaviti tudi računalniku. Opisemo jo z množico entitet in množico relacij med njimi; vsako entiteto običajno opremimo s seznamom lastnosti, ki jo natančneje določajo, pomen relacije pa predstavimo z njenim tipom.

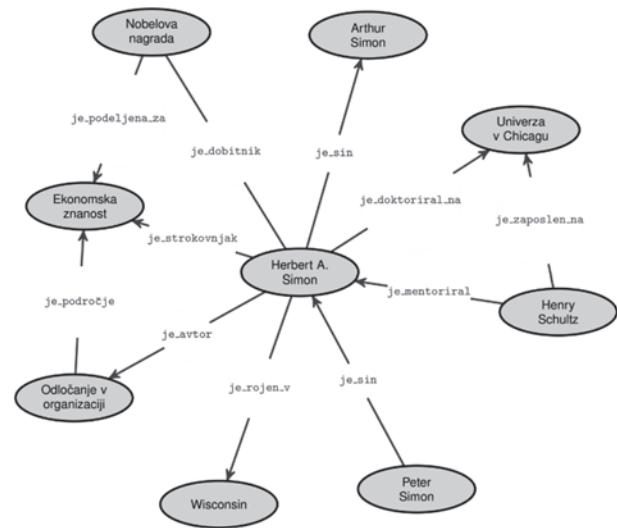
To gradivo ima dva namena. Prvič, v slovenščini želimo predstaviti nekaj osnovnih konceptov, na katerih gradi sodobno proučevanje omrežij znanja, zlasti na področju biomedicine in znanosti o živem. In drugič, čim več bralcev želimo spodbuditi, da tudi sami pokukajo v svet raziskovanja omrežij. Zato mu ponujamo nekaj kazalcev, ki mu utegnejo priti prav pri nadaljnjem študiju. Jedro gradiva predstavljajo trije razdelki, v katerih obravnavamo podatkovne vire, postopek gradnje omrežja ter osvetlimo pristop, ki

omogoča enostavno transformacijo relacijskega podatkovja v obliko, ki je primerna za zagon različnih metod statističnega učenja. Zaključimo s pregledom najpomembnejših izzivov za prihodnost.

Omrežje znanja

Za razumevanje notacije v nadaljevanju moramo na hitro ponoviti oziroma vpeljati nekaj osnovnih pojmov iz teorije grafov. Graf je matematična struktura, s katero predstavimo množico entitet in v kateri so izbrane dvojice entitet medsebojno povezane. Entitetu upodobimo z vozliščem (angl. *node*), relacijo med dvema entitetama pa bodisi z usmerjeno (angl. *ar*) bodisi neusmerjeno (angl. *edge*) povezavo. Omrežje je graf, opremljen s podatki.

Besedno zvezo "omrežje znanja" danes povezujemo s širokim naborom aktivnosti. Neposredno se z omrežjem znanja srečujemo ob pregledovanju Wikipedie, uporabi Twitterja ali pri načrtovanju novega biooznačevalca za Alzheimerjevo bolezni. Primer je prikazan na sliki 1.



Slika 1 Izsek iz omrežja znanja Nobelovega nagrajenca Herberta A. Simona (1916–2001), pionirja sodobnega pojmovanja umetne inteligentnosti.

Enoznačne definicije pojma "omrežje znanja" v literaturi ne bomo našli. Paulheim³ ponuja seznam kriterijev, na podlagi katerih presojamo, ali dejansko obravnavamo omrežje znanja. Najpomembnejša med njimi sta:

- posamezne elemente realnosti (tj. entitete) ter interakcije med njimi (tj. relacije) lahko predstavimo s pomočjo grafa;
- poznamo t. i. metashemo, na osnovi katere lahko opredelimo dovoljene tipe relacij med entitetami.

Ehrlinger in Wöß⁴ pravita, da je omrežje znanja "namenjeno integraciji informacij v ontologijo in omogoča luščenje novega znanja". Wang in sodelavci⁵ pa eksplizitno definirajo omrežje znanja kot heterogeno omrežje, v katerem lahko vozliščem in povezavam določimo različne tipe.

V tem gradivu bomo omrežje znanja formalno definirali z množico trojčkov $\langle \text{glava}, \text{relacija}, \text{rep} \rangle$ oz. kraje $\langle h, r, t \rangle$, s katerimi opišemo relacijo r med začetno entitetom h in končno entitetom (ali atributom) t . Krajsa oblika izhaja iz prvih črk angleških izrazov *head*, *relation* in *tail*. Ločimo dva tipa trojčkov: z njimi lahko (i) opišemo relacijo med entitetama, tj. $\langle \text{entiteta}_1, \text{relacija}, \text{entiteta}_2 \rangle$, ali (ii) entiteto opremimo z atributom in pripadajočo vrednostjo, tj. $\langle \text{entiteta}, \text{atribut}, \text{vrednost} \rangle$. Trojček

(H. A. Simon, področje dela, umetna inteligentnost)

je torej prvega tipa, saj vzpostavlja relacijo med dvema entitetama, trojček

(Univerza v Ljubljani, št. študentov, 39.010)

pa entitetu Univerza v Ljubljani razširi z atributom, na podlagi katerega dobimo informacijo o številu vpisanih študentov. Formalno bomo omrežje znanja predstavili kot $G = (E, R, A, V, T^R, T^A)$, kjer je E množica entitet, R množica relacij, A množica atributov in V množica vrednosti atributov. Relacije med pari entitet bomo potem takem predstavili z množico $T^R \subseteq E \times R \times E$, z množico $TA \subseteq E \times A \times V$ pa analogno množico entitetam pripisanih atributov.

Na področju biomedicine je bilo prvo odmevno omrežje znanja predstavljeno pred poldrugim desetletjem, ko so Belleau in sodelavci⁶ podatke iz prosto dostopnih podatkovnih zbirk – pretežno s področja bioinformatike – prepisali iz klasične tabelarne oblike v zapis RDF (angl. *Resource Description Framework*). Za ilustracijo so v tabeli 1 povzete osnovne lastnosti nekaterih najpogosteje uporabljenih omrežij znanja na področju biomedicine.

Tabela 1 Osnovne lastnosti nekaterih najpogosteje uporabljenih omrežij znanja na področju biomedicine.

Omrežje	Št. entitet	Št. relacij	Št. tipov entitet	Št. tipov relacij	Posodobitev
Hetionet	$47 \cdot 10^3$	$2,3 \cdot 10^6$	11	24	2017
DRKG	$97 \cdot 10^3$	$5,9 \cdot 10^6$	13	107	2000
BioKG	$105 \cdot 10^3$	$2 \cdot 10^6$	10	17	2017
PharmKG	$8 \cdot 10^3$	$501 \cdot 10^3$	3	29	2017
OpenBioLink	$185 \cdot 10^3$	$4,8 \cdot 10^6$	7	30	2017
Clinical Knowledge Graph	$19 \cdot 10^6$	$217,3 \cdot 10^6$	36	47	2017

Viri podatkov

Kakovostni viri podatkov so za gradnjo omrežja znanja ključnega pomena. Sledi pregled treh skupin podatkovnih virov, ki so bili doslej uporabljeni pri izdelavi omrežij znanja na področju biomedicine. To so (i) ontologije in terminologije, (ii) zdravstveni ipd. zapisi in (iii) obstoječe zbirke podatkov.

Ontologije in terminologije

Nujen (seveda pa ne zadosten) pogoj za reševanje nalog, povezanih s strojno obdelavo besedil, je zbirka pojmov, ki posamezen termin preslika v ustrezno pojmovno oznako. Na področju biomedicine in znanosti o živem to nalogu opravlja sistem UMLS (angl. *Unified Medical Language System*), ki ga sestavljajo tri komponente (slovenske ustreznice in pojasnila k posameznim komponentam podaja Vintar⁷):

1. Metatezaver (angl. *Metathesaurus*) – v trenutni različici je sestavljen iz približno 4,5 milijona strokovnih pojmov in okrog 17 milijonov izrazov, izluščenih iz 159 virov v različnih jezikih (npr.

kontroliranih geslovnikov in klasifikacijskih sistemov, kot so MeSH, SNOMED CT, ICD-10, DSM-IV in Gene Ontology);

2. Semantično omrežje (angl. *Semantic Network*) – omrežje trenutno sestavlja 127 semantičnih tipov (tj. pojmovnih kategorij) in 54 semantičnih relacij (tj. pomenskih razmerij), ki jih lahko vzpostavimo nad semantičnimi tipi;
3. Zakladnica besedišča (angl. *SPECIALIST Lexicon*) – slovar izrazov z različnimi besednimi oblikami, oblikoslovnimi lastnostmi in lemami.

Zdravstveni zapisi

Druga skupina virov združuje podatkovja, ki jih glede na stopnjo urejenosti poznamo pod oznako nestrukturirani podatki. Najpogosteje so to (elektronski) zdravstveni zapisi, povzetki kliničnih raziskav in laboratorijski izvidi. V tem okviru gre izpostaviti omrežje znanja, zgrajeno nad elektronskimi zdravstvenimi zapisi več kot 260 tisoč pacientov, ki omogoča pregledovanje omrežja po tipih izluščenih entitet (bolezen, zdravilo, postopek

obravnave in uporabljen pripomoček).⁸ Na podobnem obsegu zapisov so omrežje znanja zgradili tudi Rotmensch in sodelavci,⁹ ki so ugotovili visoko stopnjo točnosti avtomatskega luščenja trojčkov v primerjavi z domenskim ekspertom. Zhao in sodelavci¹⁰ poročajo, da se omrežje znanja, zgrajeno na osnovi kliničnih zapisov, ponaša s topološkimi lastnostmi, ki so sicer značilna za kompleksna omrežja (npr. majhen premer omrežja, brezlestvičnost in visoka stopnja gručenja).

Obstoječe zbirke podatkov

V to skupino sodijo bibliografski viri in druge sorodne zbirke podatkov. Med bibliografskimi zbirkami prvenstvo zaseda zbirka MEDLINE/PubMed, ki trenutno obsega več kot 35 milijonov bibliografskih zapisov, s povprečnim dnevnim priastom okrog 3000 zapisov. Zbirka je prosto dostopna in enostavno strojno berljiva, kar je bržkone glavni razlog, da jo za preizkušanje novih metod besedilnega rudarjenja uporabljajo številni raziskovalci. Prvi resen poskus preslikave celotne zbirke MEDLINE/PubMed v strukturirano obliko predstavlja izgradnja omrežja SemKG. Avtorji so uporabili vrsto prosto dostopnih orodij, s katerimi so iz množice slabih 23 milijonov povzetkov izluščili približno milijon entitet in več kot 14 milijonov relacij. Tako entitete kot posamezne relacije so opremili s semantičnimi tipi oz. tipi semantične relacije. Obseg omrežja so kasneje pomembno razširili, ko so v omrežje dodali tudi avtorje sestavkov z ustrezno razdvojenimi imeni, imena institucij, na katerih so zaposleni, ter raziskovalne projekte, pri katerih sodelujejo.¹¹

Pandemija covid-19 je pustila sled tudi v objavi množice orodij in zbirk za rudarjenje besedil. Od začetka pandemije je raziskovalna skupnost gradila korpusa znanstvenih sestavkov s tematiko novega koronavirusa, med katerimi gre izpostaviti CORD-19¹² in LitCovid.¹³ Oba korpusa sta temeljna kamna, na osnovi katerih je bilo zgrajeno – in nedavno objavljeno – omrežje CovidPubGraph, ki ponuja trenutno najbolj celovit pregled vedenja o virusu SARS-CoV-2.¹⁴ Trenutna različica omrežja je sestavljena iz več kot 268 milijonov trojčkov.

Gradnja omrežja znanja

Gradnja omrežja znanja je povezana s številnimi metodološkimi izzivi in zahteva interdisciplinarna znanja. V nadaljevanju izpostavimo tri korake, s katerimi se srečamo v postopku konstrukcije slehernega omrežja: (i) luščenje entitet in relacij; (ii) normalizacijo terminov ter (iii) integracijo in zlivanje znanja.

Luščenje entitet in relacij

Osnovno orodje za besedilno rudarjenje biomedicinskih besedil je MetaMap, ki deluje kot označevalnik biomedicinskih izrazov in omogoča, da prosto besedilo (npr. naslov in/ali povzetek zapisa MEDLINE/PubMed) preslikamo v ustrezno pojmovno oznako (t. i. biomedicinski koncept) iz metatezavra UMLS.¹⁵ V tem koraku še ničesar ne vemo o pomenskem razmerju med dvema izluščenima konceptoma. Slednjemu je namenjeno orodje SemRep za procesiranje naravnega jezika, ki na osnovi leksikalnih pravil in zgoraj omenjenega semantičnega omrežja iz sistema UMLS identificira tudi pomensko razmerje med obema konceptoma.¹⁶ Alternativno orodje je PKDE4J, ki je prav tako namenjeno luščenju biomedicinskih entitet in relacij, a zahteva ročno dodajanje terminoloških slovarjev.¹⁷ Pred kratkim so bila raziskovalni skupnosti ponujena tudi orodja za luščenje entitet, ki temeljijo na modelu globokih nevronskih mrež, npr. HunFlair¹⁸ in BERN2.¹⁹ Ti orodji se v primerjavi s prej omenjenima SemRep in PKDE4J ponašata s pomembno višjima merama natančnosti in prikaza. Na voljo je tudi že nekaj aplikacij globokega učenja za luščenje relacij, a so prilagojene le za kitajščino.²⁰ Nemalo težav na področju globokega učenja povzroča slaba interpretabilnost rezultatov, saj algoritmi nevronskih mrež v dobrši meri delujejo po principu črne škatle. Smiselna razlagal rezultatov je zato – v primerjavi s sistemmi, ki temeljijo na leksikalnih pravilih – pogosto nemogoča.

Normalizacija terminov

V avtomatiziranem postopku gradnje omrežja znanja je poleg gole prepoznavne entitete pomemben korak tudi normalizacija, ki različne jezikovne različice, sinonime in izpeljanke poveže z eno entiteto. S problemom normalizacije se v biomedicinskih besedilih najpogosteje srečamo pri obravnavi imen in simbолов genov (npr. različne simbole in termine, kot so IL12, IL-12 in interleukin 12, je potrebno preslikati v pomensko entiteto Interleukin-12). Še pred nedavnim se je normalizacija v pretežni meri opravljala s pomočjo sistema UMLS in geslovnika MeSH. Danes lahko v ta namen uporabimo označevalnik PubTator.²¹

Integracija in zlivanje znanja

V postopku gradnje omrežja znanja razlikujemo med integracijo in zlivanjem podatkov. Pojem "integracija" se nanaša na povezovanje različnih podatkovnih zbirk, s pojmom "zlivanje" pa merimo na dopolnjevanje modalnosti podatkov. Dober primer integrativnega pristopa h gradnji omrežja znanja je

storitev PreMedKB.²² Razpršenosti in heterogenost biomedicinskih zbirk pogostokrat botruje situaciji, ko "zaradi dreves ne vidimo gozda" in onemogoča celosten vpogled v mehanizme delovanja kompleksnih, multifaktorskih bolezni in načine njihovega zdravljenja. Z orodjem PreMedKB so avtorji pokazali, da lahko z razmeroma preprosto uporabo metapodatkovnih shem in sistema UMLS integriramo večje število sicer heterogenih zbirk podatkov.

Uporaba omrežij znanja

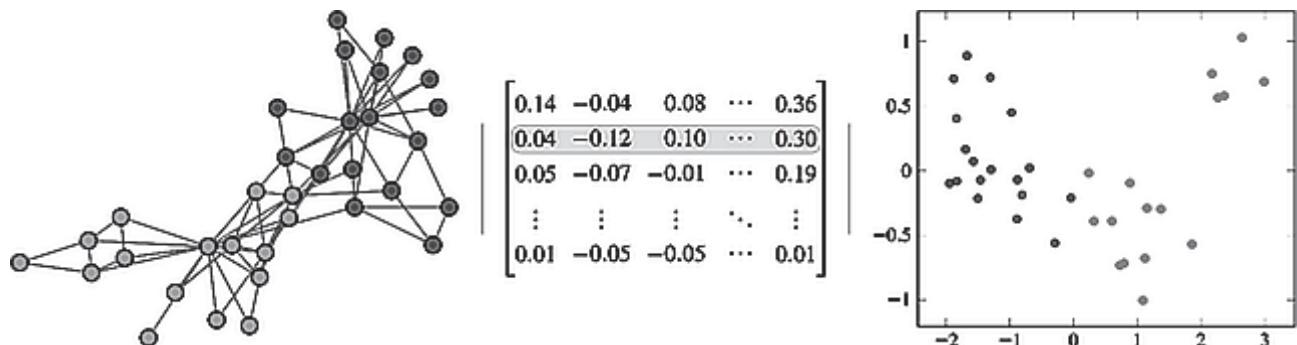
Omrežja so kompleksne strukture, predvsem ki jih ni lahko razumeti in interpretirati. V skupnosti, ki se ukvarja z analizo omrežij, se je pred dobrima dvema desetletjema poročilo – v zadnjem desetletju pa močno intenziviralo – področje reprezentacijskega učenja, ki omogoča enostavno preslikavo relacijskega podatkovja v vektorsko obliko (govorimo o t. i. vložitvi omrežja), ki ohrani karseda veliko strurnih lastnosti izvornega omrežja.

Na področju analize kompleksnih omrežij sta v vrsti različnih pristopov k reprezentacijskemu učenju, najpogosteje uporabljeni algoritmi DeepWalk in node2vec. Osnovna ideja vložitve posameznih vozlišč je ilustrirana na sliki 2. Algoritem DeepWalk vložitev vozlišč opravi na osnovi modela skip-gram s pribrezanimi slučajnimi sprehodi,²⁴ node2vec pa z maksimizacijo pogojne verjetnosti nad sosedstvi vozlišč.²⁵ Dober vpogled v različne družine pristopov k reprezentacijskemu učenju nad homogenimi omrežji nudita pregledna članka.^{5, 26}

Spomnimo se, da lahko s heterogenim omrežjem predstavimo različne tipe relacij med vozlišči.²⁷ Ustrezen pristop za reprezentacijsko učenje nad omrežjem znanja mora zato upoštevati tako tip entitete kot tip relacije. Paleta možnosti za obravnavo vložitev omrežja znanja je široka. Chang in sodelavci²⁸ so orali ledino in predlagali arhitekturo globokega

učenja za obravnavo heterogenih interakcij v omrežju. Odmeven je bil tudi prispevek avtorjev algoritma metapath2vec, ki za okolico vozlišč najprej prešče z vnaprej definiranimi vzorci slučajnih sprehodov, nato pa pripravi vložitev s pomočjo modela skip-gram.²⁹ Pregled literature razkrije tri družine algoritmov za reprezentacijsko učenje nad omrežji znanja:³⁰ (i) modeli translacije v vektorskem prostoru; (ii) semantični modeli in (iii) modeli na osnovi globokih nevronskih mrež.

- Osnovna zamisel modelov, ki temeljijo na konceptu vzporednega premika v vektorskem prostoru je, da v trojčku $\langle b, r, t \rangle$ relacijo r obravnavamo kot translacijo iz izhodiščnega vozlišča b v končno vozlišče t , torej $b + r \equiv t$. Njenostavnejši algoritem TransE vektorsko vložitev vozlišč in povezav pripravi na osnovi modela nevronske mreže, v katerem minimiziramo kriterijsko funkcijo $f(b, r, t) = \|h + r - t\|$.³¹ TransE odpove v primeru večrelacijskega omrežja (tj. v kardinalnostih ena-proti-mnogo in mnogo-proti-mnogo). To pomanjkljivost odpravlja model TransR, v katerem entitete in relacije vlagamo v ločena latentna prostora.³²
- Osnova semantičnih modelov je koncept razdalje. Algoritem RESCAL je bil razvit na predpostavki, da sta si entiteti podobni, če se s podobnimi entitetami povezujeta s podobnimi relacijami. V to družino spadata še algoritma DistMult³³ in ComplEx.³⁴
- Tretja družina algoritmov za reprezentacijsko učenje nad omrežji znanja temelji na pristopu globokih nevronskih mrež. V tem okviru omenjamo dva konvolucijska modela, ConvE³⁵ in ConvKB.³⁶ Njuna glavna slabost je, da pri pripravi vložitev posamezne trojčke obravnavata ločeno. Pomanjkljivost lahko odpravimo z vključitvijo mehanizma pozornosti, na katerem je osnovan model HRGAT.³⁷



Slika 2 Vložitev vozlišč homogenega omrežja. Vozlišča omrežja (levo) predstavimo v vektorski obliki (sredina), pri čemer težimo k ohranitvi kar največ njihovih (strukturnih) lastnosti. Število vrstic matrike ustreza številu vozlišč omrežja. Osenčeno je predstavljena vektorska vložitev za izbrano vozlišče. Dolžino vektorjev v praksi izberemo na podlagi kompromisa med natančnostjo reprezentacije in sprejemljivo kompleksnostjo. Končno lahko nad matriko vložitev uporabimo nalogi primeren postopek statistične analize. Za grafični prikaz smo matriko vložitev dodatno skrčili z analizo glavnih komponent. Opazimo, da sta skupnosti vozlišč v omrežju (levo) lepo razvidni tudi v prostoru, ki ga razpenjata le prvi dve glavni komponenti (desno).

Zaključek

Predstavljeni pregled področja omrežij znanja nikakor ni izčrpen. Upamo pa, da ponuja dovolj celovit vpogled v to obširno tematiko. Različne načine predstavitev znanja smo naslovili le bežno; z golj toliko, da smo poudarili dolgo preteklost raziskav na tem področju. Prav tako smo navedli le tiste vire podatkov, ki jih najpogosteje navaja znanstvena literatura. Pri tem smo namenoma – zaradi aktualnosti – poudarili gradnjo omrežij iz nestrukturiranih podatkov. Obravnava reprezentacijskega učenja bi zahtevala samostojen prispevek, zato vabimo bralce, da sežejo po dodatni literaturi.

Zahvala

Prispevek je nastal v okviru raziskovalnega projekta J5-2552, ki ga financira Agencija za raziskovalno dejavnost Republike Slovenije. Posebna zahvala – za potrpežljivost in vsebinske pripombe – gre glavnemu uredniku.

Reference

- McBride DM, Cutting JC, Zimmerman C. *Cognitive psychology: theory, process, and methodology* (3rd ed.). Thousand Oaks 2023: Sage.
- Russell SJ, Norvig P. *Artificial intelligence: a modern approach* (4th ed.). Hoboken 2020: Pearson.
- Paulheim H. Knowledge graph refinement: a survey of approaches and evaluation methods. *Semant Web* 2017; 8(3): 489-508. <https://doi.org/10.3233/SW-160218>
- Ehrlinger L, Wöß W. Towards a definition of knowledge graphs. In: Martin M, Cuquet M, Folmer E (eds.). *SEMANTiCS (posters, demos, SuCCESs) 2016*. Leipzig 2016: CEUR-WS.org; 4. <https://ceur-ws.org/Vol-1695/paper4.pdf>
- Wang Q, Mao Z, Wang B, Guo L. Knowledge graph embedding: a survey of approaches and applications. *IEEE Trans Knowl Data Eng* 2017; 29(12): 2724-2743. <https://doi.org/10.1109/TKDE.2017.2754499>
- Belleau F, Nolin MA, Tourigny N, Rigault P, Morissette J. Bio2RDF: towards a mashup to build bioinformatics knowledge systems. *J Biomed Inform* 2008; 41(5): 706-716. <https://doi.org/10.1016/j.jbi.2008.03.004>
- Vintar Š. Označevanje in odkrivanje pomenskih razmerij v medicinskih besedilih. *Infor Med Slov* 2005; 10(1): 9-18.
- Finlayson SG, LePendu P, Shah NH. Building the graph of medicine from millions of clinical narratives. *Sci Data* 2014; 1(1): 140032. <https://doi.org/10.1038/sdata.2014.32>
- Rotmensch M, Halpern Y, Tlimat A, Horng S, Sontag D. Learning a health knowledge graph from electronic medical records. *Sci Rep* 2017; 7(1): 5994. <https://doi.org/10.1038/s41598-017-05778-z>
- Zhao C, Jiang J, Xu Z, Guan Y. A study of EMR-based medical knowledge network and its applications. *Comput Methods Programs Biomed* 2017; 143: 13-23. <https://doi.org/10.1016/j.cmpb.2017.02.016>
- Xu J, Kim S, Song M, et al. Building a PubMed knowledge graph. *Sci Data* 2020; 7(1): 205. <https://doi.org/10.1038/s41597-020-0543-2>
- Wang LI, Lo K, Chandrasekhar Y et al. CORD-19: the COVID-19 open research dataset (v4). *arXiv* 2020: 2004.10706. <https://doi.org/10.48550/arXiv.2004.10706>
- Chen Q, Allot A, Leaman R et al. LitCovid in 2022: an information resource for the COVID-19 literature. *Nucleic Acids Res* 2023; 51(D1): D1512-D1518. <https://doi.org/10.1093/nar/gkac1005>
- Pestryakova S, Vollmers D, Sherif MA et al. COVIDPUBGRAPH: a FAIR knowledge graph of COVID-19 publications. *Sci Data* 2022; 9(1): 389. <https://doi.org/10.1038/s41597-022-01298-2>
- Aronson AR. Effective mapping of biomedical text to the UMLS Metathesaurus: the MetaMap program. *Proc AMIA Symp* 2001: 17-21. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC224366/>

16. Rindflesch TC, Fiszman M. The interaction of domain knowledge and linguistic structure in natural language processing: interpreting hypernymic propositions in biomedical text. *J Biomed Inform* 2003; 36(6): 462-477. <https://doi.org/10.1016/j.jbi.2003.11.003>
17. Song M, Kim WC, Lee D, Heo GE, Kang KY. PKDE4J: entity and relation extraction for public knowledge discovery. *J Biomed Inform* 2015; 57: 320-332. <https://doi.org/10.1016/j.jbi.2015.08.008>
18. Weber L, Sänger M, Münchmeyer J, Habibi M, Leser U, Akbik A. HunFlair: an easy-to-use tool for state-of-the-art biomedical named entity recognition. *Bioinform* 2021; 37(17): 2792-2794. <https://doi.org/10.1093/bioinformatics/btab042>
19. Sung M, Jeong M, Choi Y, Kim D, Lee J, Kang J. BERN2: an advanced neural biomedical named entity recognition and normalization tool. *Bioinform* 2022; 38(20): 4837-4839. <https://doi.org/10.1093/bioinformatics/btac598>
20. Yang Y, Lu Y, Yan W. A comprehensive review on knowledge graphs for complex diseases. *Brief Bioinformatics* 2023; 24(1): bbac543. <https://doi.org/10.1093/bib/bbac543>
21. Wei C-H, Allot A, Leaman R, Lu Z. PubTator Central: automated concept annotation for biomedical full text articles. *Nucleic Acids Res* 2019; 47(W1): W587-W593. <https://doi.org/10.1093/nar/gkz389>
22. Yu Y, Wang Y, Xia Z et al. PreMedKB: an integrated precision medicine knowledgebase for interpreting relationships between diseases, genes, variants and drugs. *Nucleic Acids Res* 2019; 47(D1): D1090-D1101. <https://doi.org/10.1093/nar/gky1042>
23. Nelson W, Zitnik M, Wang B, Leskovec J, Goldenberg A, Sharan R. To embed or not: network embedding as a paradigm in computational biology. *Front Genet* 2019; 10: 381. <https://doi.org/10.3389/fgene.2019.00381>
24. Perozzi B, Al-Rfou R, Skiena S. DeepWalk: online learning of social representations. In: Krishnapuram B et al. (eds.). *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining – KDD '14*. New York 2014: Association for Computing Machinery; 701-710. <https://doi.org/10.1145/2623330.2623732>
25. Grover A, Leskovec J. Node2vec: scalable feature learning for networks. In: Krishnapuram B et al. (eds.). *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York 2016: Association for Computing Machinery; 855-864. <https://doi.org/10.1145/2939672.2939754>
26. Yi, H-C, You Z-H, Huang D-S, Kwok CK. Graph representation learning in bioinformatics: trends, methods and applications. *Brief Bioinformatics* 2022; 23(1): bbab340. <https://doi.org/10.1093/bib/bbab340>
27. Shi C, Li Y, Zhang J, Sun Y, Yu PS. A survey of heterogeneous information network analysis. *IEEE Trans Knowl Data Eng* 2017; 29(1): 17-37. <https://doi.org/10.1109/TKDE.2016.2598561>
28. Chang S, Han W, Tang J, Qi G-J, Aggarwal CC, Huang TS. Heterogeneous network embedding via deep architectures. In: Cao L (ed.). *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York 2015: Association for Computing Machinery; 119-128. <https://doi.org/10.1145/2783258.2783296>
29. Dong Y, Chawla NV, Swami A. Metapath2vec: scalable representation learning for heterogeneous networks. In: Matwin S, Yu S. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining – KDD '17*. New York 2017: Association for Computing Machinery; 135-144. <https://doi.org/10.1145/3097983.3098036>
30. Ji S, Pan S, Cambria E, Marttinen P, Yu PS. A survey on knowledge graphs: representation, acquisition, and applications. *IEEE Trans Neural Netw Learn Syst* 2022; 33(2): 494-514. <https://doi.org/10.1109/TNNLS.2021.3070843>
31. Bordes A, Usunier N, Garcia-Durán A, Weston J, Yakhnenko O. Translating embeddings for modeling multi-relational data. In: Burges CJC et al. (eds.). *NIPS'13: Proceedings of the 26th International Conference on Neural Information Processing Systems – Volume 2*. Austin 2013: AAAI Press; 2787-2795. <https://dl.acm.org/doi/10.5555/2999792.2999923>
32. Lin Y, Liu Z, Sun M, Liu Y, Zhu X. Learning entity and relation embeddings for knowledge graph completion. *Proceedings of the AAAI Conference on Artificial Intelligence* 2015; 9(1): 2181-2187. <https://doi.org/10.1609/aaai.v29i1.9491>
33. Yang B, Yih W-T, He X, Gao J, Deng L. Embedding entities and relations for learning and inference in knowledge bases. *arXiv* 2015: 1412.6575. <https://doi.org/10.48550/arXiv.1412.6575>
34. Trouillon T, Welbl J, Riedel S, Gaussier E, Bouchard G. Complex embeddings for simple link prediction. In: Balcan MF, Weinberger KQ (eds.). *ICML'16: Proceedings of the 33rd International Conference on Machine Learning – Volume 48*. New York 2016: JMLR.org; 2071-2080. <https://proceedings.mlr.press/v48/trouillon16.html>
35. Dettmers T, Minervini P, Stenetorp P, Riedel S. Convolutional 2D knowledge graph embeddings. *Proceedings of the AAAI Conference on Artificial Intelligence* 2018; 32(1): 1811-1818. <https://doi.org/10.1609/aaai.v32i1.11573>
36. Nguyen DQ, Nguyen TD, Nguyen DQ, Phung D. A novel embedding model for knowledge base completion based on convolutional neural network. In: Walker M, Ji H, Stent A (eds.). *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers)*. New Orleans 2018: Association for Computational Linguistics; 327-333. <https://doi.org/10.18653/v1/N18-2053>
37. Zheng S, Rao J, Song Y et al. PharmKG: a dedicated knowledge graph benchmark for biomedical data mining. *Brief Bioinformatics* 2021; 22(4): bbaa344. <https://doi.org/10.1093/bib/bbaa344>