

Ocena zdravega staranja z modelom strojnega učenja

Anja Trebovac¹, Katarina Gašperlin Stepančič² Andrej Košir¹

¹Fakulteta za elektrotehniko, Univerza v Ljubljani

²IBM Slovenija d.o.o., Ameriška ulica 8, 1000 Ljubljana, Slovenia

E-pošta: andrej.kosir@fe.uni-lj.si

Assessment of healthy aging with a machine learning model

Healthy aging is becoming increasingly critical with the rising elderly population, presenting significant challenges to healthcare systems. Traditional assessment methods often fail to integrate both physiological and psychosocial factors, resulting in incomplete and less accurate predictions of healthy aging.

To address these limitations, we leverage state-of-the-art machine learning techniques to develop robust predictive models for healthy aging. Our study employs advanced algorithms like Random Forest and Gradient Boosting to analyze a comprehensive dataset encompassing a wide array of relevant indicators. This integrated approach significantly improves the accuracy of health predictions and provides deeper insights into the factors that contribute to healthy aging. By enhancing prediction precision and offering actionable insights, our work aims to inform better healthcare policies and interventions. Ultimately, this contributes to improved health outcomes and a higher quality of life for the elderly.

1 Uvod

V svetu se še naprej spreminja starostna struktura prebivalstva [1]. Ljudje živijo dlje, zato se delež starejših v celotnem prebivalstvu hitro povečuje in ta trend se bo verjetno nadaljeval [2]. Medtem ko je bilo leta 1980 na svetu 382 milijonov prebivalcev, starih 60 let in več, je bilo leta 2020 to število že več kot milijarda ljudi, do leta 2050 pa naj bi doseglo skoraj 2,1 milijarde [3]. Staranje prebivalstva je bilo zato opredeljeno kot eden od štirih globalnih demografskih megatrendov [4], dobro zdravje z blaginjo v vseh starostnih obdobjih pa je bilo priznано kot eden od ciljev v Agendi za trajnostni razvoj do leta 2030 [5].

Opredelitve zdravega staranja so različne. Med drugimi je bila opisano kot zmožnost opravljanja smiselnih dejavnosti [6], in kot splošno stanje staranja človekovega uma in telesa, ki običajno pomeni odsotnost bolezni, poškodb ali bolečin [7].

Zdravo staranje je ključnega pomena za izboljšanje kakovosti življenja starejših oseb in zmanjšanje obremenitve zdravstvenega sistema. S staranjem prebivalstva se povečuje potreba po razumevanju dejavnikov, ki vplivajo na zdravo staranje. Uporaba metod strojnega učenja v

zdravstvu omogoča analizo obsežnih podatkovnih zbirk in odkrivanje skritih vzorcev, ki lahko prispevajo k natančnejšim napovedim glede zdravja starejših. Napovedovanje zdravega staranja je pomembno, saj omogoča zgodnje odkrivanje potencialnih zdravstvenih težav in ustrezno načrtovanje preventivnih ukrepov. Razumevanje dejavnikov, ki prispevajo k zdravemu staranju, lahko pomaga pri oblikovanju učinkovitih zdravstvenih politik in programov za izboljšanje kakovosti življenja starejših oseb. [8, 9].

Problem, ki ga naslavljamo v tej raziskavi, je modeliranje zdravega staranja s postopki strojnega učenja z namenom avtomatske ocene zdravega staranja. Zakon o dolgotrajni oskrbi (ZDOsk-1) [10] predvideva individualno ceno upravičenosti do dolgotrajne oskrbe na podlagi ocene strokovnjaka v naslednjih točkah (navedeno po [10]): 1. zmožnosti gibanja v okolju, kjer zavarovana oseba prebiva, 2. kognitivnih in komunikacijskih sposobnosti, 3. vedenja in duševnega zdravja; 4. sposobnosti samooskrbe v okolju, kjer zavarovana oseba prebiva; 5. sposobnosti spoprijemanja z boleznijo in z zdravljenjem bolezni povezanih zahtev in obremenitev; 6. poteka vsakdanjega življenja in socialnih stikov; 7. sposobnosti glede aktivnosti izven domačega okolja, in 8. sposobnosti opravljanja gospodinjskih opravil v okolju, kjer zavarovana oseba prebiva.

Menimo, da lahko model ocene zdravega staranja prispeva k objektivni oceni stanja posameznika in skrajša sam postopek ocenjevanja stanja s strani človeškega strokovnjaka.

Cilj tega članka je izbor optimalne metode strojnega učenja, ki na podlagi izbranih podatkov o navadah starejšega dovolj natančno oceni njegovo zdravo staranje.

2 Trenutno stanje

V zadnjih letih je uporaba metod strojnega učenja pri ocenjevanju zdravega staranja pridobila vse bolj pomembna. V tem poglavju predstavljamo tri relevantne študije, ki prispevajo k temu področju. Študije zajemajo različne pristope in algoritme strojnega učenja, ki se uporabljajo za napovedovanje in ocenjevanje različnih vidikov staranja, od biološke starosti in kognitivnega upada do morfometrije možganov. Pregled teh študij bo osvetlil trenutne trende in dosežke ter izpostavil potencial strojnega učenja za izboljšanje kakovosti življenja starejših oseb.

Raziskava [11] iz leta 2022 se je osredotočila na primerjavo različnih modelov strojnega učenja za napovedovanje starosti možganov z uporabo morfometričnih podatkov možganov. Njihova študija je ocenila uspešnost različnih modelov, vključno s podporo vektorskih strojev, regresijo z relevantnimi vektorji in različnimi pristopi globokega učenja, pri napovedovanju starosti možganov. Rezultati so pokazali, da napredni modeli strojnega učenja lahko natančno napovedujejo starost možganov, kar je ključnega pomena za razumevanje nevrodegenerativnih procesov in razvoj zgodnjih intervencij. Naša študija prav tako uporablja strojno učenje, vendar se osredotoča na napovedovanje zdravega staranja na podlagi fizioloških biomarkerjev, kar predstavlja širšo aplikacijo metod strojnega učenja v gerontologiji.

V članku [12] so izvedli študijo z uporabo podatkov iz kitajske študije zdravja in upokojitve (CHARLS) za razvoj meritve biološke starosti (angl. Biological Aging - BA) s pomočjo strojnega učenja. Uporabili so več algoritmov strojnega učenja, kot so Gradient Boosting Regressor in Random Forest, za oceno biološke starosti na podlagi fizioloških biomarkerjev. Njihove ugotovitve so pokazale, da je model Gradient Boosting Regression dosegel najboljše rezultate, s pomembnimi povezavami med ML-BA in telesno invalidnostjo ter smrtnostjo, kar poudarja potencial metod strojnega učenja v raziskavah staranja in preventivnih zdravstvenih intervencijah. Podobno smo tudi v naši študiji z modelom Gradient Boosting dosegli zelo dobre rezultate pri napovedovanju zdravega staranja, kar dodatno potrjuje učinkovitost te metode.

Članek [13] je raziskoval napovedovalce hitrosti kognitivnega upada pri starejših odraslih z uporabo tehnik strojnega učenja. Študija, objavljena v PLOS ONE, se je osredotočila na prepoznavanje različnih biomarkerjev in življenjskih dejavnikov, ki bi lahko napovedovali kognitivni upad. Uporabili so več modelov strojnega učenja, vključno z regresijskimi modeli in nevronskimi mrežami, za analizo podatkov starejših odraslih. Izkazalo se je, da strojno učenje lahko učinkovito identificira pomembne napovedovalce in zagotovi vpogled v mehanizme, ki vplivajo na kognitivno staranje.

Pregled trenutnega stanja kaže, da strojno učenje ponuja učinkovite metode za ocenjevanje različnih vidikov staranja. Uporaba naprednih algoritmov omogoča natančno napovedovanje bioloških in kognitivnih meritev staranja. Naša raziskava potrjuje učinkovitost teh metod in njihovo široko uporabnost v področju raziskav staranja, kar predstavlja pomemben korak naprej pri razumevanju procesov staranja ter izboljšanju kakovosti življenja starejših oseb.

3 Materiali in metode

3.1 Podatki

Podatkovna množica, uporabljena v tej raziskavi, je zbral Inštitut Antona Trstenjaka za gerontologijo in medgeneracijske odnose (v nadaljevanju inštitut), slovenska nacionalna znanstvena, raziskovalna, strokovna in uporabniška institucija na področju gerontologije in dobrih medgeneracijskih odnosov v Sloveniji. Podatki so bili

zbrani z osebnimi terenskimi intervjuji v okviru neodvisne raziskave „Staranje v Sloveniji: Raziskava o potrebah, zmožnostih in stališčih slovenskega prebivalstva, starega 50 let in več“ [14].

Podatkovna množica vsebuje več kot 1000 uporabnikov, v to študijo smo jih izbrali 693, saj smo v predpripravi podatkov odstranili vse uporabnike z manjkajočimi vrednostmi. Pri tem smo vključili ključne spremenljivke, ki so opisane spodaj:

- **int_care_for_health**: namerna skrb za zdravje.
- **mental_well_being**: duševno počutje posameznika.
- **reach_purpose_and_happy**: doseganje namena in zadovoljstvo z življenjem.
- **identify_life_exp**: prepoznavanje, da drugi uporabljajo številne življenjske izkušnje/lekcije te osebe.
- **physical_act_self_assess**: samoocena fizične aktivnosti.
- **physical_org_sys_self_assess**: samoocena fizičnega zdravja glede na organske sisteme.
- **someone_to_talk**: ali ima posameznik nekoga, s katerim lahko zaupno govori o osebnih stvareh.
- **particip_in_org**: sodelovanje posameznika v organizacijah.
- **healthy_ageing**: ocena zdravega staranja.

Vse vhodne spremenljivke smo standardizirali z uporabo StandardScaler, kar pomeni, da so bile vse spremenljivke preoblikovane tako, da imajo povprečje 0 in standardni odklon 1. Za zagotovitev veljavnosti rezultatov in preprečitev uhajanja podatkov (angl. data leakage) smo podatkovno množico razdelili na učne in testne podatke. Podatke smo razdelili z uporabo funkcije `train_test_split` iz knjižnice Scikit-learn v razmerju 80:20.

Ocena zdravega staranja je ciljna spremenljivka s tremi kategorijami: 1 - slabo staranje, 2 - niti dobro niti slabo staranje, 3 - dobro staranje in predstavlja pravo vrednost razreda zdravega staranja. Določena je bila z anotacijo s strani strokovnjakov s področja gerontologije, katerij ocene so bile nato kombinirane v enotno oceno.

3.2 Modeli strojnega učenja

Za reševanje problema zdravega staranja smo uporabili naslednje tri metode nadzorovanega strojnega učenja. Za njihovo implementacijo smo uporabili knjižnico Scikit-learn (verzija 1.3.0).

K-Najbližji Sosedje (angl. K-Nearest Neighbors - KNN) je nadzorovani učni algoritem, ki klasificira podatke na podlagi bližine do najbližjih sosedov v podatkovnem prostoru [15]. Uporabili smo `n_neighbors=5`, kar pomeni, da model išče 5 najbližjih sosedov v podatkovnem prostoru za klasifikacijo podatkov.

Naključni gozdovi (angl. Random forest - RF) so sestavljeni model, ki uporablja več odločilnih dreves za izboljšanje točnosti in preprečevanje prenačenosti,

pri čemer vsako drevo temelji na vrednostih naključnega vektorja, vzorčenega neodvisno za vsa drevesa. [16] Model smo nastavili z naslednjimi hiperparametri: `n_estimators = 100`, `criterion = 'gini'`, `max_depth = 10`, `min_samples_split = 2`, `min_samples_leaf = 1`, `max_features = 'sqrt'`, `bootstrap = True`, `random_state = 42`.

Metoda Gradient Boosting - GB je metoda strojnega učenja, ki združuje napovedi več šibkih učnih modelov, običajno odločilnih dreves, zaporedno za izboljšanje točnosti. Vsak nov model je učen z uporabo prejšnjega modela in gradientnega spusta, kar postopoma zmanjšuje napake napovedi in povečuje natančnost sestavljenega modela [16]. Za GB smo uporabili naslednje hiperparametre: `n_estimators = 100`, `learning_rate=0.1`, `max_depth=3`, `min_samples_split=2`, `min_samples_leaf = 1`, `max_features='sqrt'`, `subsample = 1.0`, `random_state = 42`.

3.3 Merjenje uspešnosti modela strojnega učenja

Uspešnost modelov smo ocenili z uporabo metrik, ki nam omogočajo celovito in natančno oceno njihove učinkovitosti. Za njihovo oceno smo uporabili naključno križno preverjanje z 10-kratno križno preverjanje. V nadaljevanju so podrobneje opisane uporabljene metrike.

Natančnost (angl. Accuracy): Delež pravilno napovedanih primerov glede na skupno število primerov [17].

Priklic (angl. Recall): Delež pravilno napovedanih pozitivnih primerov glede na skupno število dejanskih pozitivnih primerov [18].

F1 (angl. F1 Score): Harmonična sredina med natančnostjo in priklicem [19].

Površina pod krivuljo (angl. Area Under the Curve - AUC): Meri celotno zmogljivost klasifikacijskega modela in daje oceno kako dobro model loči med različnimi razredi. Višja kot je AUC, boljša je zmogljivost modela pri razlikovanju med pozitivnimi in negativnimi razredi. [20]

Te metrike so ključne za razumevanje, kako dobro posamezni modeli napovedujejo izide in omogočajo primerjavo med različnimi pristopi. Z uporabo teh metrik lahko ugotovimo prednosti in slabosti vsakega modela ter izberemo najprimernejši model za našo analizo.

4 Eksperimentalni rezultati

Za napovedovanje zdravega staranja smo uporabili modele strojnega učenja, opisani v poglavju 3. Njihova uspešnost je bila ocenjena na podlagi točnosti, priklica, F1, srednje kvadratne napake (MSE) in površine pod ROC krivuljo (AUC). Rezultati so prikazani v Tabeli 1.

Uporaba metode KNN za klasifikacijo je prinesla dobre rezultate. Model je dosegel točnost 69%, priklic 68% in F1 67%. Model KNN je dosegel AUC vrednost 79%, kar pomeni, da je imel model 79-odstotno verjetnost, da pravilno razvrsti pozitivne primere višje kot negativne primere. Analiza matrike razvrščanja je pokazala, da KNN uspešno klasificira srednje vrednosti, medtem ko so napake pogostejše pri napovedovanju nizkih in visokih vrednosti.

Model RF je dosegel najboljšo točnost pri napovedovanju zdravega staranja z točnostjo 80%, priklicem 78% in F1 78%. Model RF je dosegel višjo AUC vrednost (90%) v primerjavi z KNN (72%), kar kaže na boljše zmogljivost pri razlikovanju med različnimi razredi zdravega staranja. RF je pokazal boljše rezultate pri klasifikaciji srednjih in visokih vrednosti v primerjavi s KNN, kar se kaže v manjšem številu napačnih napovedi.

Na sliki 1 so prikazane matrike razvrščanja za modele KNN in RF. Matrike razvrščanja vizualno prikazujejo uspešnost klasifikacije posameznih kategorij zdravega staranja. Diagonalni elementi (od zgoraj levo proti spodaj desno) predstavljajo pravilno klasificirane primere, medtem ko elementi izven diagonale predstavljajo napačno klasificirane primere. Iz slik je razvidno, da model RF bolje klasificira primere v primerjavi z modelom KNN, kar se odraža v višjih vrednostih na diagonali matrike.

GB je dosegel zelo dobre rezultate. Model je dosegel MSE 0,13. GB je pokazal boljše prilaganje napovedi dejanskim vrednostim pri vseh treh razredih in manjšo razpršenost napovedi v primerjavi s KNN. GB se je izkazal za bolj natančen model z manjšimi napakami napovedi in boljšo splošno zmogljivostjo.

Tabela 1: Rezultati modelov strojnega učenja razvrščanja (KNN in RF).

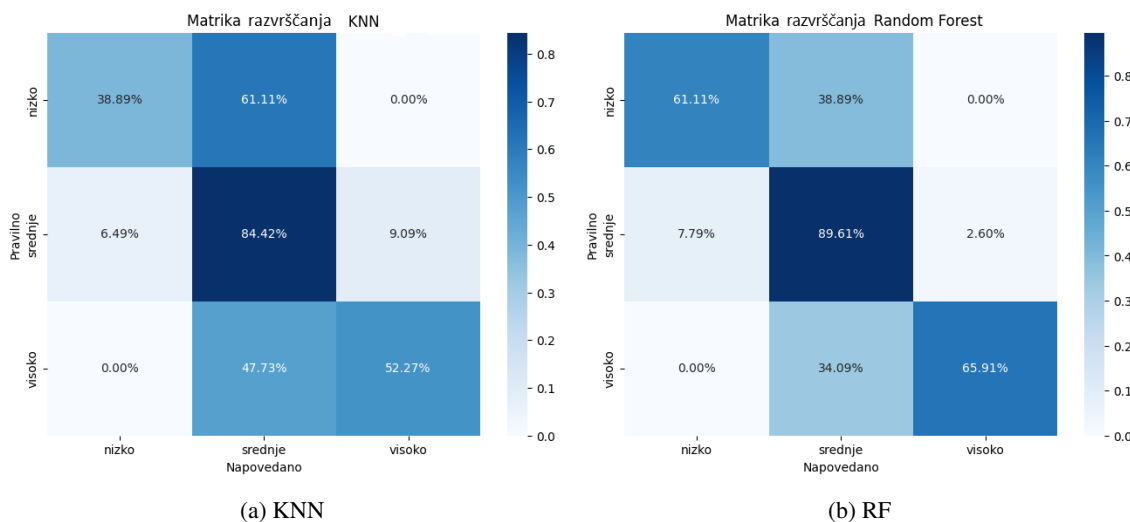
Model	Točnost	Priklic	F1	AUC
KNN	0,69	0,68	0,67	0,79
RF	0,80	0,78	0,78	0,90

5 Zaključki in razprava

V tej raziskavi smo preučevali uporabo različnih modelov strojnega učenja za oceno zdravega staranja na podlagi statičnih podatkov starejših. Naši rezultati so pokazali, da so modeli strojnega učenja, še posebej Random Forest (RF) in Gradient Boosting (GB), precej učinkoviti pri napovedovanju zdravega staranja. Model RF je dosegel najvišjo točnost (0,80).

Kljub obetavnim rezultatom ostaja več odprtih vprašanj. Uporaba strojnega učenja zahteva obsežne in kakovostne podatkovne zbirke, kar je lahko omejujoče zaradi težav z dostopnostjo in kakovostjo podatkov.

V prihodnje bo pomembno vključiti širši spekter podatkov, ki zajemajo tudi socialne in okoljske dejavnike, saj ti lahko pomembno vplivajo na zdravo staranje. Prav tako je potrebno izboljšati interpretabilnost modelov strojnega učenja, da bi bolje razumeli, kateri dejavniki najbolj vplivajo na napovedi. Raziskovanje in uporaba drugih algoritmov strojnega učenja, kot so nevronske mreže, bi lahko prinesla nove vpoglede in potencialno izboljšala natančnost napovedi. Prav tako bi bilo koristno testirati te modele v kliničnih okoljih, da se preveri njihova uporabnost in zanesljivost v praksi. Longitudinalne študije bi dodatno omogočile spremljanje sprememb v zdravju posameznikov skozi čas in prilagoditev modelov na podlagi dolgoročnih podatkov.



Slika 1: Matriki razvrščanja glede na razvrščevalnika KNN (levo) in Naključni gozdovi (RF, desno).

Naša raziskava je pokazala, da sodobne tehnologije in strojno učenje lahko bistveno prispevajo k boljšemu razumevanju zdravega staranja in izboljšanju kakovosti življenja starejših oseb. Z integracijo fizičnih in psihosocialnih dejavnikov lahko razvijemo učinkovitejše zdravstvene politike in intervencije za podporo zdravemu staranju. Nadaljnje raziskave in izboljšave modelov bodo omogočile še večjo natančnost napovedi, kar bo prispevalo k boljši kakovosti življenja starejših oseb in zmanjšanju obremenitev zdravstvenega sistema.

Zahvala

Raziskavo je podrl program P2-0246 ICT4QoL - Informacijske in komunikacijske tehnologije za kakovost življenja

Literatura

- [1] United Nations Department of Economic and Social Affairs. *World Population Ageing 2020: Highlights*. United Nations, United Nations Secretariat New York, 2021.
- [2] W. Lutz, W. Sanderson, and S. Scherbov. The coming acceleration of global population ageing. *Nature*, 451(7179):716–719, 2008.
- [3] WHO et al. Decade of healthy ageing: baseline report. 2020.
- [4] U. N. Secretary General. Review and appraisal of the programme of action of the international conference on population and development and its contribution to the follow-up and review of the 2030 agenda for sustainable development: report of the secretary-general. 2019.
- [5] S. Weiland, T. Hickmann, M. Lederer, J. Marquardt, and S. Schwindenhammer. The 2030 agenda for sustainable development: transformative change through the sustainable development goals? *Politics and Governance*, 9(1):90–95, 2021.
- [6] L. L. Bryant, K. K. Corbett, and J. S. Kutner. In their own words: a model of healthy aging. *Social science & medicine*, 53(7):927–941, 2001.
- [7] J. P. Michel and R. Sadana. "healthy aging concepts and measures. *Journal of the American Medical Directors Association*, 18(6):460–464, 2017.
- [8] E. J. Topol. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books, 2019.
- [9] World Health Organization. *Decade of Healthy Ageing: Baseline Report*. World Health Organization, 2020.
- [10] Zakon o dolgotrajni oskrbi. dostopano 19.5.2024.
- [11] Juhuyuk Han, Seo Yeong Kim, Junhyeok Lee, and Won Hee Lee. Brain Age Prediction: A Comparison between Machine Learning Models Using Brain Morphometric Data. *Sensors*, 22(20):8077, October 2022.
- [12] Xingqi Cao, Guanglai Yang, Xurui Jin, Liu He, Xueqin Li, Zhoutao Zheng, Zuyun Liu, and Chenkai Wu. A Machine Learning-Based Aging Measure Among Middle-Aged and Older Chinese Adults: The China Health and Retirement Longitudinal Study. *Frontiers in Medicine*, 8:698851, December 2021.
- [13] Maryam Ahmadzadeh, Theodore David Cosco, John R. Best, Gregory James Christie, and Steve DiPaola. Predictors of the rate of cognitive decline in older adults using machine learning. *PLOS ONE*, 18(3):e0280029, March 2023.
- [14] Jože Ramovš. *Staranje v Sloveniji: raziskava o potrebah, zmožnostih in stališčih nad 50 let starih prebivalcev Slovenije*. Inštitut Antona Trstenjaka, Slovenija, 2013.
- [15] Tavish Srivastava. Introduction to k-nearest neighbors: A powerful machine learning algorithm, 2018. dostopano 18.5.2024.
- [16] T. Hastie, R. Tibshirani, and J.H. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer series in statistics. Springer, 2009.
- [17] Sunil Ray. 8 ways to improve accuracy of machine learning models, 2024. dostopano 15.7.2024.
- [18] Purva Huilgol. Precision and recall, 2024. dostopano 15.7.2024.
- [19] Rohit Kundu. F1 score in machine learning, 2023. dostopano 18.5.2024.
- [20] Aniruddha Bhandari. Guide to auc roc curve in machine learning, 2024. dostopano 17.7.2024.