

Napovedovanje prihodnje rasti intrakranialnih anevrizem

Žiga Bizjak, Žiga Špiclin

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška c. 25, 1000 Ljubljana, Slovenija
E-pošta: ziga.bizjak@fe.uni.lj.si

Povzetek. Intrakranialne anevrizme (IA) so pogosta vaskularna patologija, ki se ob rupturi v polovici primerov konča s smrtjo. Tveganje za rupturo je precej večje, če IA raste in se njena oblika spreminja, zato je cilj te študije razviti in vrednotiti napovedne modele prihodnje rasti IA, in sicer glede na njeno morfologijo iz izhodiščne slike. V tej študiji je ekspert glede na izhodiščno in kontrolno CTA ali MRA angiografsko sliko razvrstil 44 IA med rastoče in stabilne (25/19). Za učenje napovednih modelov smo iz izhodiščne slike izločili trigonometrične mreže IA in okoliškega ožilja ter uveljavljene morfološke parametre, kot so višina, površina, volumen, razmerje med višino in širino vratu IA ter indeks nesferičnosti. Omenjene parametre smo uporabili kot vhod v uni- in multivariatne samoučeče modele razvrščevalnikov IA glede na prihodnjo rast, izločeno trigonometrično mrežo pa kot vhod v model PointNet++, osnovan na nevronske mreži. Slednji je pri štirikratnem navzkrižnem vrednotenju dosegel natančnost 0,82 (občutljivost 0,96 in specifičnost 0,63), medtem ko je bilo razvrščanje z uni- in multivariatnimi modeli slabše, in sicer z natančnostjo 0,63 oziroma 0,68. Uspešno razvrščanje rastočih IA s predlaganim modelom Point-Net++ lahko ključno pripomore k objektivnemu odločanju o primernem času in načinu zdravljenja IA.

Ključne besede: intrakranialna anevrizma, rast, ruptura, morfologija, napovedni model

Predicting a future growth of intracranial aneurysms

Intracranial aneurysms (IAs) are a common vascular pathology associated with rupture risk, an event that is fatal in half of the cases. The IA growth is considered as an announcement of the rupture risk. The aim of this study was to develop and evaluate prediction models of a potential IA growth based on its baseline morphology. CTA and MRA follow-up angiograms of 39 patients with 44 IAs are classified by an expert into growing and stable (25/19). From the angiograms, the vascular surface meshes are extracted and the IA shape was characterized by the established morphologic features, such as the IA height, surface area, volume, height to the neck-width aspect ratio and non-sphericity index. The features characterizing the IA baseline are used to predict a future IA growth using uni- and multi-variate machine learning based models, while a deep learning model based on PointNet++ input the raw meshes. In a cross-validation experiment, the latter achieves better accuracy of 0.82 (sensitivity=0.96 and specificity=0.63) compared to 0.63 and 0.68 of the uni- and multi-variate models, respectively. Following the above, the PointNet++ model can be used as an efficient tool in objective decision-making about an optimal time and method on of IA treatment.

Keywords: Intracranial aneurysm, growth, rupture, morphology, prediction model.

1 UVOD

Intrakranialna anevrizma (IA) je pogosta cerebrovaskularna patologija, saj ima od 2 do 8 % splošne

populacije vsaj eno nerupturirano IA [1]. Večina IA ne rupturira v življenju posameznika, v primeru rupture pa povzroči subarahnoidno krvavitev, ki se v 50 % primerov konča s smrtjo.

Mogoča načina zdravljenja IA sta znotrajzilno (*angl. coiling*) in zunajzilno zdravljenje (*angl. clipping*). Oba tipa imata več kot 10 % možnosti zapletov med operacijo [2], s starostjo pa se možnost zapletov še poveča [3], [4]. Možnost spontane rupture majhnih IA je 0,8 % (manjše od 3,9 mm), 1,2 % za srednje IA (4 do 10 mm), 7,1 % za velike (10 do 25 mm) ter 43,1 % za ogromne anevrizme. Kadar je verjetnost zapleta med operacijo večja kot možnost spontane rupture, je priporočeno operacijo odložiti in medtem s slikovnimi preiskavami spremljati rast anevrizme. Končna odločitev o načinu zdravljenja pa je v praksi pogosto odvisna od zdravnikove subjektivne odločitve brez objektivne analize tveganja rupture IA. Tat lahko temelji na morfologiji IA in hemodinamični analizi. Uporaba takih analiz bi lahko povečala objektivnost in standardizirala postopek odločanja o primernem času in načinu zdravljenja IA.

Na podlagi kliničnih in slikovnih podatkov je bilo identificiranih več kvantitativnih napovednih meritev tveganja za rupturo IA. Na primer, točkovnik ELAPSS [5] uporabi podatke o bolnikovi starosti, kraju bivanja, lokaciji anevrizme, velikosti in obliki ter morebitne predhodne rupture za izračun napovedi tveganja rupture.

Velikost anevrizme lahko h končni vrednosti ELAPSS doprinese tudi 55 % vseh točk. V poznejših raziskavah se je pokazalo, da je ta doprinos prevelik [6], [7] in da je smiselno prerazporediti utežitve točkovnika.

Nedavna študija je pokazala, da tudi majhne anevrizme rupturirajo [9], kar nakazuje potrebo po metodi za identifikacijo majhnih anevrizem, ki so nagnjene k rasti. V študiji [10], ki je vključevala 382 bolnikov, so avtorji pokazali, da velikost anevrizme ni signifikantna meritev za napovedovanje rasti IA. V drugi študiji [11] je bilo pokazano, da lahko z uporabo NSI napovemo rast anevrizme (AUC = 0,72), medtem ko so parametri HMAX, V, AR in SA dosegli AUC vrednosti blizu 0,5, kar pomeni, da so te napovedi naključne in zato neuporabne.

Neyazi in sod. [8] so analizirali 21 različnih morfoloških parametrov, med katerimi so se maksimalna višina (HMAX), volumen (V), površina anevrizme (SA), razmerje višine in preseka vratu (AR – *angl. aspect ratio*), volumen najmanjše ovojnice (*angl. convex hull*), indeks nesferičnosti (NSI) in gama izkazali za signifikantne univariatne napovedne meritve. Najboljšo napoved so dosegli z uporabo multivariatnega modela (AUC = 0,75). Ta raziskava je pokazala, da lahko multivariatni modeli, ki združujejo univariatne morfološke meritve IA, bolje napovejo rast IA kot univariatni modeli in so vredni nadaljnjega raziskovanja.

Hipoteza te študije je, da lahko iz morfologije IA (velikost, oblika ...), ki je opisana s trigonometrično mrežo, uspešno napovemo rast IA. Preizkusili in ovrednotili smo uveljavljene metode in predlagali novo metodo za napovedovanje prihodnje rasti intrakranialnih anevrizem, ki temelji na globokem učenju. Glavni doprinos je uporaba metode, zasnovane na mreži PointNet++ [12], ki ima kot vhod točkovni oblak anevrizme in okoliškega ožilja, torej točke iz trigonometrične mreže, pridobljene iz izhodiščne 3D-angiografske slike, kot rezultat pa vrne latentni vektor

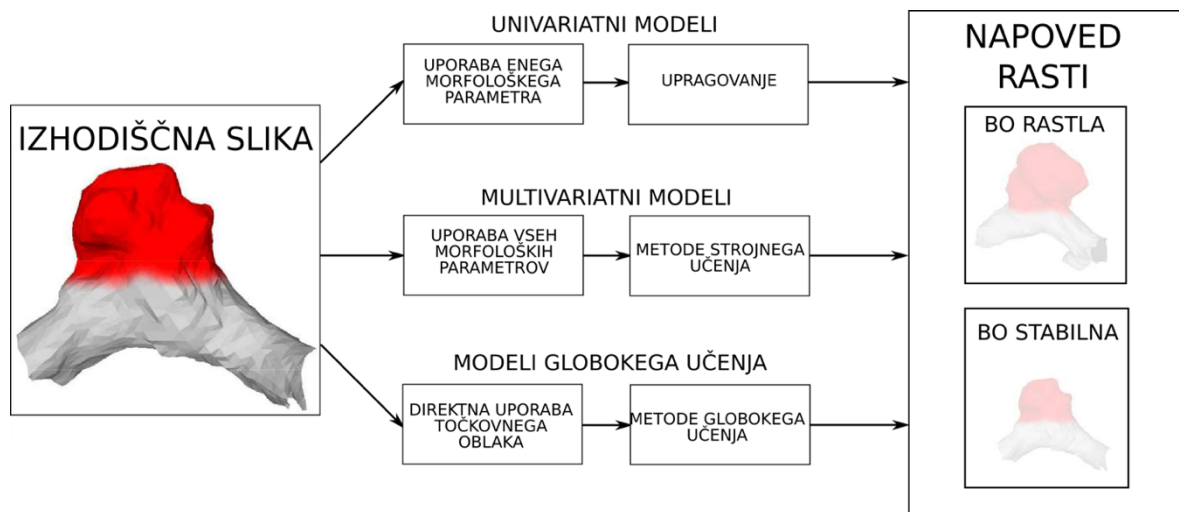
značilnic [13], ki razločuje med stabilnimi in rastočimi IA.

2 METODOLOGIJA

Na voljo smo imeli 39 parov izhodiščnih in kontrolnih angiografskih slik glave, vsak od slikanih bolnikov pa je imel najmanj eno nerupturirano IA. Izhodiščna in kontrolna slika sta bili iste modalitete (obe CTA ali TOF-MRA). CTA slike so bile zajete na oddelku za radiološke znanosti Ronald Reagan, Medicinski center Univerze v Kaliforniji, Los Angeles, medtem ko so bili pari MRA slik pridobljeni iz javno dostopne zbirke izziva ADAM (<http://adam.isi.uu.nl/>). CTA-slike so bile velikosti 512 x 512 x 60–140 z ločljivostjo 0,4 x 0,4 x 0,5–0,8 mm, TOF-MRA-slike pa velikosti 560 x 560 x 140 z ločljivostjo 0,35 x 0,35 x 0,5 mm. Med zajemom izhodiščne in kontrolne slike je minilo najmanj 6 mesecev. Rezultati te študije niso vplivali na zdravljenje bolnikov.

V slikah 39 bolnikov (15 moških in 24 žensk) smo našli skupaj 44 IA. Področje zanimanja v vsaki sliki (anevrizma in okoliško ožilje) smo izločili in strukture opisali s trigonometrično mrežo. Velikost IA je bila od 1,4 do 12,2 mm s srednjo vrednostjo 5 mm, kar nakazuje, da je bila večina IA srednje velikosti. Vsaka IA je bila označena kot *stabilna* ali *rastoča* glede na očno primerjavo poravnane izhodiščne in kontrolne slike. Med 44 anevrizmami jih je ekspert z dolgoletnimi izkušnjami 25 označil kot rastoče in 19 kot stabilne.

Kot napovedne modele smo testirali tri različne pristope, to so: (i) univariatni modeli, ki temeljijo na eni meritvi, in pripadajoči na prazni vrednosti, (ii) multivariatni modeli, ki temeljijo na strojnem učenju, in (iii) modeli, ki temeljijo na globokem učenju. Modeli se razlikujejo glede na kompleksnost in tudi glede na vhodno informacijo. Pri univariatnih in multivariatnih modelih se kot vhodni podatki uporabijo že uveljavljene meritve, kot



Slika 1: Napoved prihodnje rasti lahko temelji na izhodiščni morfologiji IA, pri čemer smo testirali tri različne pristope.

so HMAX, V, SA, NSI in AR, ki so bile določene samodejno z analizo trigonometrične mreže IA iz izhodiščne slike, medtem ko pri modelu globokega učenja kot vhodni podatek uporabimo koordinate vseh točk te trigonometrične mreže.

Univariatni modeli uporabljajo upragovanje meritev, kot so HMAX, V, SA, NSI in AR, za ločevanje med stabilnimi in rastočimi IA. Ta pristop temelji na predvidevanju, da je posamezna meritev sposobna razločiti med stabilnimi in rastočimi IA. Za vsako meritev smo preizkusili prazne vrednosti med minimalno in maksimalno vrednostjo in izbrali prag pri maksimalni točnosti.

Različne morfološke meritve opisujejo različne lastnosti IA, zato je smiselna uporaba multivariatnih modelov, ki kot vhod sprejmejo vse te meritve in samodejno utežijo prispevek posamezne meritve h končnemu razvrščanju. V okviru te študije smo preizkusili dva modela, tj. razvrščanje z naključnimi drevesi (RF – *angl. random forests*) [14] in večplastnim perceptronom (MLP – *angl. multilayer perceptron*) [15]. Model RF je sestavljen iz več binarnih odločitvenih dreves iz več naključno izbranih podmnožic vhodnih meritev. Uporabili smo 100 dreves, vsak z globino 3 za učenje razvrščevalnika. Model MLP je oblikovan kot hierarhični niz linearnih razvrščevalnikov, vsak z nelinearno aktivacijo. Razvrščevalnik MLP je imel dve skriti plasti, vsako s po 100 nevroni, učenje je potekalo z algoritmom LBFGS in učno konstanto 10^{-4} . Vhodne meritve v modela RF in MLP so bile: HMAX, V, SA, NSI in AR.

Najnovejši pristopi, ki temeljijo na globokem učenju, omogočajo avtomatsko razvrščanje neposredno na trigonometričnih mrežah. V tej študiji smo uporabili PointNet++ [12], ki kot vhod sprejme koordinate točk $p_i = [x_i, y_i, z_i]^T$ na trigonometrični mreži in normale teh točk glede na mrežo $n_i = [n_{x,i}, n_{y,i}, n_{z,i}]^T$; $i = 1, \dots, N$. Sledi torej, da je vhod v mrežo matrika $6 \times N$. Iz vsake izločene trigonometrične mreže smo enakomerno vzorčili $N = 2048$ točk, tako za učenje razvrščanja kot za napovedovanje. Kot napako za učenje smo uporabili negativni logaritem verjetnosti napake (*angl. negative log likelihood loss*), ki smo ga minimizirali z uporabo SGD z momentom 0,9 in učno konstanto 0,005. Gradient za učenje se je izračunaval na paketih po 32 vhodnih vzorcev, število ponovitev učenja pa je bilo 200. Model PointNet++ smo učili in testirali na dva različna načina: (i) vhodni podatki so vključevali koordinate IA in okoliškega ožilja, (ii) vhodni podatki so vključevali le koordinate IA.

Za modele RF in MLP smo uporabili implemetacije v knjižnici Scikit-Learn [16], medtem ko smo za PointNet++ uporabili implementacijo avtorjev [12].

3 POSKUSI IN REZULTATI


Vseh 44 IA je bilo uporabljenih za primerjavo univariatnih in multivariatnih modelov ter modelov globokega učenja. Testirali smo 5 univariatnih modelov, torej po en model za vsako meritev (HMAX, SA, V, NSI in AR), dva multivariatna modela in dva modela globokega učenja. Zaradi maloštevilnih podatkov smo pri modelih RF, MLP in PointNet++ uporabili štirikratno navzkrižno vrednotenje, kar pomeni, da smo podatke razdelili na štiri skupine anevrizem, kjer je bila vsaka skupina sestavljena iz 11 naključnih izbranih anevrizem. Razmerje med rastočimi in stabilnimi anevrizmami je bilo podobno med vsemi skupinami. Pri vsakem navzkrižnem vrednotenju izbranega modela smo tri skupine uporabili za učenje in eno za testiranje in vrednotenje. Za lažjo primerjavo smo rezultate, pridobljene iz testnih skupin posameznega štirikratnega navzkrižnega vrednotenja, združili in izračunali točnost, občutljivost in specifičnost rezultatov na vseh 44 IA.

Za vsak model smo izračunali krivuljo ROC in AUC (površino pod krivuljo ROC). Poleg tega smo poročali o najvišji doseženi natančnosti razvrščanja ter pripadajoči občutljivosti in specifičnosti.

Rezultati razvrščanja IA med stabilne in rastoče v vseh 44 primerih IA za pet univariatnih modelov in tri za modele, ki temeljijo na učenju, so povzeti v tabeli 1. Univariatni modeli so v splošnem dosegali slabše rezultate kot multivariatni modeli, ki so temeljili na učenju. Univariatni modeli so dosegali točnost med 0,54 in 0,63 ter vrednosti AUC med 0,52 in 0,62. Najboljši univariatni model je temeljil na meritvi NSI in dosegel točnost 0,63 in AUC 0,62.

Tabela 1: Rezultati posameznih metod za napovedovanje prihodnje rasti anevrizem. Najboljši rezultati so označeni z **odebeljenim tiskom**.

Model	AUC	točnost	občutljivost	specifičnost
NSI	0,62	0,63	0,89	0,29
HMAX	0,52	0,54	0,36	0,80
AR	0,52	0,56	0,88	0,15
V	0,48	0,58	0,48	0,78
SA	0,48	0,56	0,36	0,84
RF	0,66	0,68	0,63	0,66
MLP	0,62	0,64	0,71	0,55
PointNet++ (dome)	0,72	0,77	0,80	0,63
PointNet++	0,795	0,82	0,96	0,63



Slika 2: Krivulje ROC vseh testiranih modelov za napovedovanje prihodnje rasti anevrizem.

Podobne rezultate dobimo, če uporabimo model MLP (točnost 0,64 in AUC 0,62). Ob uporabi RF so bili rezultati nekoliko boljši, saj smo dobili točnost 0,68 in AUC 0,66.

Pri uporabi modela PointNet++, ki je temeljil na globokem učenju, kjer kot vhodne podatke uporabimo koordinate IA in okoliškega ožilja, smo dobili točnost 0,82 in AUC 0,795. Če smo uporabili le koordinate IA kot vhod v model, smo dobili točnost 0,77 in AUC 0,715. V nadaljevanju se pri navedbi modela PointNet++ sklicujemo na model, ki temelji na globokem učenju in kot vhodne podatke uporablja koordinate IA in okoliškega ožilja. Glede na preostale modele je PointNet++ dosegel tudi najvišjo občutljivost 0,96 in dobro specifičnost 0,63. Nekateri modeli so sicer dosegli boljšo specifičnost, vendar ob precej manjši občutljivosti. Krivulje ROC vseh modelov so prikazane na sliki 2.

4 RAZPRAVA

V tej študiji smo objektivno in primerjalno ovrednotili uveljavljene in nove modele za napovedovanje rasti IA. Študija je med prvimi, ki uporablja modele globokega učenja za napovedovanje prihodnje rasti IA. Poleg tega smo model globokega učenja primerjali s tradicionalnimi metodami, ki temeljijo na učenju, in tistimi z upravljanjem izmerjenih morfoloških meritev, kar je najbližje trenutni klinični praksi.

Z uporabo globokega učenja smo uspešno napovedali prihodnji razvoj 37 od 44 IA, ki smo jih imeli na voljo v tej študiji. Visoka občutljivost 0,96 nakazuje, da je ta model sposoben zaznati tiste anevrizme, ki so nagnjene k rasti (24 od 25 anevrizem pravilno razvrščenih). Specifičnost je bila zmerna (0,63), tj. pravilno smo identificirali 13 od 19 stabilnih IA.

Univariatni modeli niso pokazali dobre napovedne vrednosti, z izjemo NSI, ki je imel srednje dobro napovedno vrednost (AUC 0,62), razmeroma visoko občutljivostjo (0,89), a precej nižjo specifičnost (0,29). Univariatni modeli V, SA, AR in HMAX so imeli krivuljo ROC blizu diagonale prostora ROC, ki predstavlja naključno razvrščanje. Oba multivariatna modela, RF in MLP, sta dosegla točnost 0,68 in 0,64, kar je boljši rezultat kot najboljši univariatni model NSI (0,63). Majhna izboljšava je posledica boljšega razmerja med občutljivostjo in specifičnostjo. Slabše rezultate univariatnih in multivariatnih modelov glede na modele globokega učenja lahko pripišemo tudi neupoštevanju okoliškega ožilja pri univariatnih in multivariatnih modelih.

Model PointNet++ je dosegel pomembno boljše rezultate od vseh drugih testiranih modelov, še posebno pri razvrščanju razreda rastočih IA. Predlagani model je izboljšal do zdaj najboljši rezultat iz članka [11], kjer so dosegli AUC 0,721 (predlagani model je dosegel AUC 0,795). Velika prednost modela PointNet++ je, da ima kot vhod tako IA kot okoliško ožilje. Rezultati kažejo, da okoliške žile nosijo pomembno informacijo glede prihodnje rasti IA. To se predvsem kaže v slabši zmogljivosti razvrščanja tistega modela PointNet++, ki kot vhodne podatke uporablja le koordinate IA. Na osnovi tega rezultata bi bilo smiselno vključiti tudi univariatne morfološke parametre za karakterizacijo okoliškega ožilja, kot so razmerje med velikostjo IA in premerom žile, vstopni kot žile v IA ipd. [17], vendar menimo, da so take meritve pregrebe in nezmožne celovito izluščiti pomembne informacije za prihodnjo rast IA. Namreč, ni smiselno pričakovati, da bi se take morfološke meritve lahko primerjale z modelom globokega učenja, kot je PointNet++, ki avtomatsko izloči pomembno informacijo za dano nalogo razvrščanja.

Čeprav je spremljanje IA priporočeno za manjše anevrizme, pa se na žalost še ne uporablja pogosto v klinični praksi. Klinična praksa je namreč naklonjena čimprejšnjemu kirurškemu zdravljenju IA, zato je razpoložljivost longitudinalnih slikovnih preiskav zelo redka, te pa so podlaga za razvoj pričujočih modelov. Kar zadeva klinično uporabo, je pravilno razvrščanje IA glede na tveganje za prihodnjo rast pomembno pri odločanju med kirurškim posegom in longitudinalnim slikovno podprtim spremljanjem. Menimo, da lahko predlagana metoda v klinični praksi močno spremeni in izboljša postopek upravljanja tveganj in poteka zdravljenja bolnikov z IA, in sicer z omogočanjem razločevanja med bolniki z večjim oz. manjšim tveganjem rupture na podlagi napovedi rasti IA iz slikovne preslikave. Poleg tega lahko razpoložljivost takšnih prognostičnih orodij privede do širšega kliničnega sprejemanja slikovno podprtega spremljanja bolnikov in omogoči, da postane pristop "brez

zdravljenja" smiselna alternativa kirurškemu posegu pri bolnikih z manjšim tveganjem prihodnje rasti anevrizme.

LITERATURA

- [1] M. H. Vlak, A. Algra, R. Brandenburg, and G. J. Rinkel, 'Prevalence of unruptured intracranial aneurysms, with emphasis on sex, age, comorbidity, country, and time period: a systematic review and meta-analysis', *Lancet Neurol.*, vol. 10, no. 7, pp. 626–636, Jul. 2011, doi: 10.1016/S1474-4422(11)70109-0.
- [2] H. L. Hodes, L. Steinfeld, and S. Blumenthal, 'Congenital cerebral aneurysms and coarctation of the aorta', *Arch. Pediatr.*, vol. 76, no. 1, pp. 28–43, Jan. 1959.
- [3] Sedat J. *et al.*, 'Endovascular Treatment of Ruptured Intracranial Aneurysms in Patients Aged 65 Years and Older', *Stroke*, vol. 33, no. 11, pp. 2620–2625, Nov. 2002, doi: 10.1161/01.STR.0000034788.70971.14.
- [4] W. Brinjikji, G. Lanzino, A. A. Rabinstein, D. F. Kallmes, and H. J. Cloft, 'Age-Related Trends in the Treatment and Outcomes of Ruptured Cerebral Aneurysms: A Study of the Nationwide Inpatient Sample 2001–2009', *Am. J. Neuroradiol.*, vol. 34, no. 5, pp. 1022–1027, May 2013, doi: 10.3174/ajnr.A3321.
- [5] D. Backes *et al.*, 'ELAPSS score for prediction of risk of growth of unruptured intracranial aneurysms.', *Neurology*, vol. 88, no. 17, pp. 1600–1606, Apr. 2017, doi: 10.1212/WNL.0000000000003865.
- [6] M. Clarke, 'Systematic review of reviews of risk factors for intracranial aneurysms', *Neuroradiology*, vol. 50, no. 8, p. 653, Jun. 2008, doi: 10.1007/s00234-008-0411-9.
- [7] Sonobe Makoto, Yamazaki Tomosato, Yonekura Masahiro, and Kikuchi Haruhiko, 'Small Unruptured Intracranial Aneurysm Verification Study', *Stroke*, vol. 41, no. 9, pp. 1969–1977, Sep. 2010, doi: 10.1161/STROKEAHA.110.585059.
- [8] B. Neyazi *et al.*, 'Rupture risk assessment for multiple intracranial aneurysms: why there is no need for dozens of clinical, morphological and hemodynamic parameters', *Ther. Adv. Neurol. Disord.*, vol. 13, p. 1756286420966159, Jan. 2020, doi: 10.1177/1756286420966159.
- [9] C. G. Ludwig, A. Lauric, J. A. Malek, R. Mulligan, and A. M. Malek, 'Performance of Radiomics derived morphological features for prediction of aneurysm rupture status', *J. NeuroInterventional Surg.*, Nov. 2020, doi: 10.1136/neurintsurg-2020-016808.
- [10] A. Chien *et al.*, 'Unruptured intracranial aneurysm growth trajectory: occurrence and rate of enlargement in 520 longitudinally followed cases', *J. Neurosurg.*, vol. 1, no. aop, pp. 1–11, Mar. 2019, doi: 10.3171/2018.11.JNS181814.
- [11] A. Chien, M. Xu, H. Yokota, F. Scalzo, E. Morimoto, and N. Salamon, 'Nonsphericity Index and Size Ratio Identify Morphologic Differences between Growing and Stable Aneurysms in a Longitudinal Study of 93 Cases', *Am. J. Neuroradiol.*, vol. 39, no. 3, pp. 500–506, Mar. 2018, doi: 10.3174/ajnr.A5531.
- [12] R. Q. Charles, H. Su, M. Kaichun, and L. J. Guibas, 'PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation', in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, Jul. 2017, pp. 77–85, doi: 10.1109/CVPR.2017.16.
- [13] A. R. Podgorsak *et al.*, 'Automatic radiomic feature extraction using deep learning for angiographic parametric imaging of intracranial aneurysms', *J. NeuroInterventional Surg.*, vol. 12, no. 4, pp. 417–421, Apr. 2020, doi: 10.1136/neurintsurg-2019-015214.
- [14] L. Breiman, 'Random Forests', *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [15] F. Rosenblatt, 'The perceptron: A probabilistic model for information storage and organization in the brain', *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958, doi: 10.1037/h0042519.
- [16] O. Kramer, 'Scikit-Learn', in *Machine Learning for Evolution Strategies*, O. Kramer, Ed. Cham: Springer International Publishing, 2016, pp. 45–53.
- [17] S. Dhar *et al.*, 'MORPHOLOGY PARAMETERS FOR INTRACRANIAL ANEURYSM RUPTURE RISK ASSESSMENT', *Neurosurgery*, vol. 63, no. 2, pp. 185–197, Aug. 2008, doi: 10.1227/01.NEU.0000316847.64140.81.

Žiga Bizjak je leta 2016 diplomiral, leta 2019 pa magistriral na Fakulteti za elektrotehniko Univerze v Ljubljani, kjer je zaposlen kot asistent in raziskovalec in je vpisan na doktorski študij. Njegovo raziskovalno področje je trenutno osredotočeno na detekcijo, izolacijo in kvantifikacijo možganskih anevrizem.

Žiga Špiclin je leta 2006 diplomiral, leta 2011 pa doktoriral na Fakulteti za elektrotehniko Univerze v Ljubljani, kjer je trenutno zaposlen kot predavatelj in raziskovalec. Leta 2020 je bil izvoljen za izrednega profesorja na Fakulteti za elektrotehniko Univerze v Ljubljani. Njegovo raziskovalno delo v Laboratoriju za slikovne tehnologije se osredotoča na razvoj in vrednotenje avtomatskih postopkov za obdelavo in analizo digitalnih slik na področju biomedicine in v aplikacijah računalniškega vida.