

Ocena modelov globokega učenja za razvrščanje gozdnih lesnih sortimentov po tržni vrednosti na podlagi slik

Matevž Triplat¹, Žiga Lukancič¹, Vasja Kavčič¹

¹ Gozdarski inštitut Slovenije, Večna pot 2, 1000 Ljubljana

E-naslov: matevz.triplat@gozdis.si (M.T.); ziga.lukancic@gmail.com (Ž.L.); vasja.kavcic@gozdis.si (VK)

POUDARKI:

- Prepoznavanje drevesnih vrst, gozdnih lesnih sortimentov in ocena njihove kakovosti ter vrednosti na terenu s pomočjo slik ponuja velik potencial za uporabo v gozdarstvu.
- Študija obravnava temo razvrščanja gozdnih lesnih sortimentov po tržni vrednosti z uporabo programske opreme za rudarjenje podatkov Orange iz niza podatkov slik, zbranih na dražbi lesa v Slovenij Gradcu.
- Rezultati kažejo natančnost pri razvrščanju tržne vrednosti (40 %–55 %). Ti izsledki poudarjajo obetavnost globokega učenja za identifikacijo vrst, hkrati pa kažejo na potrebo po nadaljnjih metodoloških izboljšavah za povečanje zanesljivosti razvrščanja vrednosti, kar ima praktičen vpliv na operativno gozdarstvo in vrednostne verige bioekonomije.

IZVLEČEK:

Prispevek obravnava uporabo modelov globokega učenja oziroma slikovnih vgraditev za razvrščanje gozdnih lesnih sortimentov (v nadaljevanju sortimentov) glede na tržno vrednost. Analiza temelji na slikah sortimentov, posnetih na 17. licitaciji vrednejših sortimentov lesa v Slovenij Gradcu, ter na pripadajočih podatkih o drevesni vrsti, dimenzijah, prostornini in doseženi prodajni ceni. Sortimenti štirih bolje zastopanih drevesnih vrst (evropski macesen, navadna smreka, hrast graden in gorski javor) so bile vrednosti preračunane na m³ in razvrščene v tri vrednostne razrede: nižji kvartil, srednji razred ter zgornji kvartil. Za analizo je bilo uporabljeno programsko okolje Orange. Slike so bile najprej pretvorjene v vektorje značilnosti z vnaprej naučenim modelom Inception v3, nato pa je bila klasifikacija izvedena z logistično regresijo in 10-kratno stratificirano navzkrižno validacijo. Rezultati kažejo zmerno uspešnost razvrščanja. Najvišja natančnost je bila dosežena pri evropskem macesnu in hrastu gradnu, približno 55 %, najnižja pa pri navadni smreki, približno 40 %. Rezultati potrjujejo, da analiza slik lahko prispeva k avtomatiziranemu vrednotenju sortimentov, vendar trenutna metodologija še ne omogoča zanesljive operativne uporabe brez dodatnih podatkov, izboljšav modelov in vključitve drugih informacij o sortimentih. Študija je pomembna, ker odpira vprašanje, ali je mogoče tržno vrednost lesa vsaj deloma napovedovati iz slikovnih podatkov. Hkrati jasno pokaže, da je vrednost sortimentov odvisna od številnih dejavnikov, ki jih sama slika pogosto ne zajame dovolj dobro, na primer notranjih napak, porekla, dimenzij, kakovostnega razreda, ponudbe in povpraševanja ter posebnosti licitacijskega trga.

UVOD:

Analiza slik se vsakodnevno uporablja na številnih področjih in ima velik potencial tudi v gozdarstvu. Od nizkocenovnega ocenjevanja prostornine dreves na podlagi posameznih slik [1], do digitalizacije operativnih procesov s podatki o posameznih drevesih [2] ter natančnim merjenjem premera in oblike debla [3]. Uporaba tehnik globokega učenja nudi možnost avtomatizirane,

prilagodljive in natančnejše klasifikacije drevesnih vrst in napak [4,5]. Poleg tega analiza slik, zlasti z uporabo modelov globokega učenja, odpira nove možnosti za sledljivost lesa, saj omogoča identifikacijo sortimentov na podlagi slik čel v različnih pogojih po sečnji, osvetlitvi in kotih [6,7].

V več študijah so računalniški vid in globoko učenje uspešno uporabili za prepoznavanje lesa in dreves. Grondin

in sod. [9] so na primer uporabili nadzorovano globoko učenje od začetka do konca za zaznavanje dreves in oceno premera v gozdovih, pri čemer so dosegli 90,4-odstotno natančnost zaznavanja dreves, 87,2-odstotno natančnost segmentacije ter centimetrovsko natančnost pri ocenjevanju ključnih točk.

Globoko učenje je uporabno pri sledljivosti sortimentov in določanju drevesnih vrst. Metode globokega učenja so bile uporabljene tudi pri ocenjevanju kakovosti površine žaganega lesa [8]. Podobno so bile tehnike globokega učenja uporabljene za analizo CT-slik sortimentov [4]. Holmström et al. [10] so prikazali ponovno identifikacijo sortimentov na podlagi slik čel, posnetih v različnih časovnih obdobjih po sečnji ter pri različnih svetlobnih pogojih in pod različnimi koti. Vihlman et al. [7] pa so ocenjevali modele globokega učenja za identifikacijo sortimentov smreke in bora na podlagi slik.

Medtem ko so prejšnje študije tehnike globokega učenja uporabljale predvsem za prepoznavanje drevesnih vrst, pa uporaba globokega učenja za razvrščanje sortimentov po tržni vrednosti s pomočjo analize slik zahteva nadaljnje raziskave [8]. Študija zapolnjuje to vrzel s preučevanjem, ali lahko orodje za analizo podatkov Orange oceni vrednost sortimentov na podlagi slik s terena. Cilj raziskave je napredek pri praktičnih uporabah orodij za prepoznavanje slik v gozdarstvu, zlasti za razvrščanje po vrednosti.

METODA:

Opis vzorca

V študiji smo uporabili slike sortimentov, posnete leta 2023 na 17. licitaciji vrednejših sortimentov lesa v Slovenji Gradcu [11]. Organizatorji licitacije so zagotovili bazo podatkov, ki zajema ključne lastnosti sortimentov, vključno s premerom, dolžino, prostornino, drevesno vrsto, številom ponudb in zmagovalno ponudbo. Podatki o sortimentih so bili pridobljeni iz kataloga sortimentov [12].

Slike so bile posnete z različnimi fotoaparati (Nikon D7000, iPhone 11 Pro in Canon PowerShot G3X), kar je omogočilo ločljivosti 4928 × 3264, 3024 × 4032 in 3648 × 5472 pikselov. V programu Adobe Lightroom so bile slike obdelane le v smislu organizacije datotek in obrezovanja do robov sortimentov, tako je vsaka fotografija vsebovala celoten sortiment, ki je bil na sredini slike in na njej v celoti zajet.

Sortimenti štirih drevesnih vrst so bili razvrščeni po tržni vrednosti: navadna smreka, hrast graden, evropski macesen in gorski javor. V analizo razvrščanja po vrednosti

so bile vključene le številčno zadostno zastopane vrste, da je bila mogoča zanesljiva razdelitev v kvartile na podlagi vrednosti in zagotovljena zanesljiva zmogljivost modela. Znotraj vsakega niza posameznih drevesnih vrst so bile slike razdeljene v kvartile na podlagi vrednosti na m³, nato pa so bili sortimenti po drevesnih vrstah razvrščeni v mape po kvartilih: 1. kvartil (najnižjih 25 %), združena 2. in 3. kvartila (25 %–75 %) ter 4. kvartil (najvišjih 25 %).

Statistika in metoda

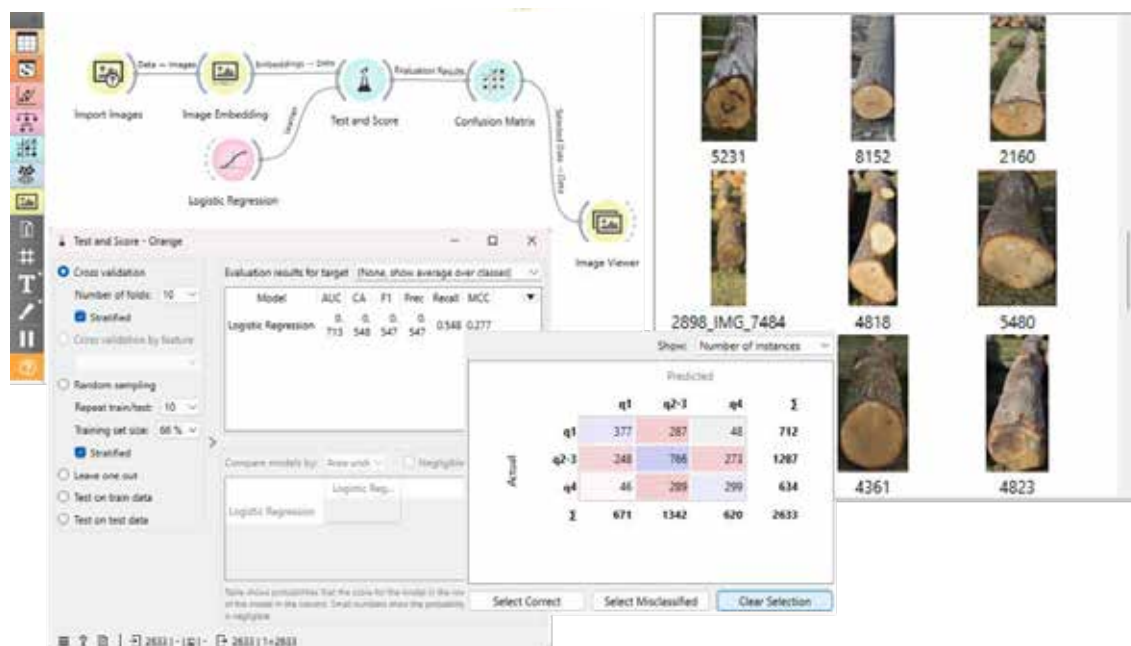
V študiji smo uporabili programsko orodje Orange (različica 3.38.1) [13], ki je brezplačno odprtokodno vizualno programsko orodje [14].

Slika 1 prikazuje potek dela pri razvrščanju slik. Z uporabo pripomočka »Import Images« smo uvozili slike, nato pa jih s pripomočkom »Image Embedding« pretvorili v vektorje, s čimer je nastala podatkovna tabela. Pripomoček »Image Embedding« uporablja aktivacije iz predzadnje plasti vnaprej usposobljene nevronske mreže, da slike predstavlja kot vektorje značilnosti za poteke nadzorovanega strojnega učenja [14]. Ta pristop izkorišča robustno ekstrakcijo značilnosti nevronske mreže za pretvorbo kompleksnih vizualnih podatkov v format, primeren za klasifikacijo in regresijo [15]. Pripomoček »Image Embedding« ponuja različne vnaprej usposobljene vgrajevalce (npr. SqueezeNet, Inception v3, VGG-16, VGG-19, Painters, DeepLoc) in omogoča obdelavo lokalno ali na oddaljenem strežniku. Uporabili smo Inception v3 [14]. Nevronske mreže niso bile usposobljene na tem nizu podatkov, ampak so bile uporabljene kot fiksni izvlečevalci značilnosti, kar je omogočilo učinkovito uporabo tudi z relativno omejenimi podatki. Ni bilo opravljeno nobeno spreminjanje ali natančno prilagajanje uteži mreže.

Postopek analize podatkov se začne z uvozom slik iz lokalne mape. Slike se posredujejo v program Image Embedder, ki je bil nastavljen na model globoke nevronske mreže Inception V3. Vektorsko vgrajevanje posreduje matriko podatkov v navzkrižno validacijo in pošlje rezultate ocenjevanja v widget Confusion Matrix. Widget Confusion Matrix zagotavlja informacije o napačni klasifikaciji. Izbor določene celice v Confusion Matrix sproži pošiljanje teh slik in njihovih deskriptorjev naprej v Image Viewer.

Pripomoček »Test and Score« je nato na vgrajene podatke uporabil logistično regresijo in zagotovil kazalnike uspešnosti, kot so natančnost razvrščanja, površina pod ROC krivuljo, F1-score, natančnost, pokritost in Matthewsov korelacijski koeficient. Te je mogoče nadalje analizirati s pomočjo ROC krivulje ali matrike zamenljivosti. AUC količinsko opredeljuje sposobnost

Slika 1: Potek dela za razvrščanje slik.



modela za razlikovanje med razredi (lestvica 0–1; $\geq 0,8$ kaže na visoko uspešnost). Natančnost klasifikacije (CA) meri delež pravilno klasificiranih primerov, kar odraža, kako tesno se niz napovedi ujema z njihovimi resničnimi vrednostmi. F1-score je harmonična sredina natančnosti in ponovljivosti [16]. Natančnost (Precision) se nanaša na razmerje resničnih pozitivnih primerov med vsemi primeri, napovedanimi kot pozitivni. Ponovljivost (Recall) označuje delež resničnih pozitivnih primerov med vsemi dejanskimi pozitivnimi primeri v nizu podatkov. Matthewsov korelacijski koeficient (MCC) upošteva resnične in lažne pozitivne ter negativne primere in je splošno priznan kot uravnotežena metrika, primerna tudi takrat, ko so porazdelitve razredov zelo neenakomerne.

Za oceno zanesljivosti klasifikacije smo uporabili stratificirano 10-kratno navzkrižno validacijo: nabor podatkov je bil razdeljen na 10 delov. Vsak del je bil enkrat

uporabljen za testiranje, preostali deli pa za usposabljanje. Za testiranje je bila uporabljena logistična regresija z L2-regularizacijo ($C = 1$).

Navedene vrednosti (npr. natančnost razvrščanja, AUC, F1-score predstavljajo povprečno učinkovitost v vseh delih. V zadnjem koraku je bil za vizualizacijo učinkovitosti razvrstitvenih modelov uporabljen widget »Confusion Matrix«, ki prikazuje število pravih pozitivnih, pravih negativnih, napačnih pozitivnih in napačnih negativnih napovedi. Navedene vrednosti temeljijo na združenih napovedih iz postopka navzkrižne validacije.

REZULTATI:

Preglednica 1 prikazuje rezultate razvrščanja sortimentov po vrednosti. Najbolj natančno razvrščanje je bilo doseženo pri evropskem macesnu (55,3 %), sledil pa mu je hrast graden, pri katerem je bilo pravilno razvrščenih

Preglednica 1: rezultati razvrščanja sortimentov po vrednosti.

Podatkovna zbirka	Embedder	Površina pod krivuljo	Natančnost razvrščanja	F1	Natančnost	Prepoznavnost	Matthewsov korelacijski koeficient
Evropski macesen	Inception v3	0.694	0.553	0.553	0.554	0.553	0.319
Navadna smreka	Inception v3	0.568	0.404	0.401	0.400	0.404	0.076
Hrast graden	Inception v3	0.713	0.548	0.547	0.547	0.548	0.277
Gorski javor	Inception v3	0.608	0.452	0.450	0.450	0.452	0.124

1442 od 2634 sortimentov (54,8 %). Najmanj natančno razvrščanje je bilo pri navadni smreki, pri kateri je bilo pravilno razvrščenih 338 od 837 sortimentov (40,4 %).

DISKUSIJA:

V študiji smo preučili izvedljivost strojnega učenja na podlagi slik za ocenjevanje vrednosti sortimentov. Glavni cilj je bil ugotoviti, ali lahko okolje za analizo slik Orange zagotovi natančne in uporabne rezultate za gozdarske naloge, kot je ocenjevanje vrednosti sortimentov. Ta metodologija je temeljila na modelu Inception v3, ki mu je sledila logistična regresija z L2-regularizacijo in 10-kratno navzkrižno validacijo.

Naša študija je presegla okvire preproste klasifikacije, saj je razvrščala zbirko sortimentov na podlagi tržne vrednosti. To je zapletena naloga, ki zahteva natančno razumevanje lastnosti lesa in dinamike trga. Rezultati kažejo, da slikovne značilnosti, pridobljene z vnaprej naučenim modelom globokega učenja, vsebujejo določeno informacijo, povezano s tržno vrednostjo sortimentov. Vendar dosežena natančnost kaže, da sama slikovna informacija v uporabljeni obliki še ne zadostuje za zanesljivo razvrščanje sortimentov po vrednosti.

Podobno so študije, ki uporabljajo prenos znanja za razvrščanje rastlinskih bolezni [17] in prepoznavanje rastlinskih vrst na podlagi vzorcev listnih žil, pokazale zanesljive rezultate, kar potrjuje uporabnost takšnih metod v botaničnem kontekstu [18].

Omejitev te študije je, da temelji na enem samem nizu podatkov, pridobljenem iz licitacije lesa in na vgrajenem modelu, ki je na voljo v okviru programa Orange. Razširitev teh metod na ocenjevanje vrednosti sortimentov ostaja precejšen izziv. Da bi to izboljšali, bi bilo treba v prihodnjih raziskavah preučiti multimodalne pristope, ki združujejo analizo slik z drugimi viri podatkov, kot so 3D-skeniranje, podatki o poreklu ali ročno ocenjevanje napak, s čimer bi izboljšali učinkovitost napovedovanja vrednosti [15]. Poleg tega bo potrebno testiranje na bolj raznolikih in terenskih zbirkah slik, da se potrdi robustnost modela v realnih operativnih pogojih. Poleg uporabe vnaprej usposobljenega modela, kot je Inception v3, ki je bil prvotno usposobljen na splošnih zbirkah podatkov, kot je ImageNet, bi bila obetavna smer razvoja domensko specifičnega modela globokega učenja, usposobljenega neposredno na gozdarskih podatkih, opremljenih z znanimi vrednostmi sortimentov. Tak model bi se lahko naučil podrobnih značilnosti kakovosti lesa in lastnosti sortimentov, ki niso prisotne v splošnih zbirkah podatkov slik, kar bi potencialno omogočilo natančnejšo klasifikacijo na podlagi vrednosti. Čeprav bi ta pristop zahteval sestavo

obsežne, reprezentativne zbirke podatkov o sortimentih z natančno opredeljenimi oznakami vrednosti, bi to predstavljalo pomemben korak k praktični in prilagodljivi rešitvi za avtomatizirano vrednotenje sortimentov.

LITERATURA IN VIRI:

Yu, Z.; Zhang, B.; Ma, T.; Zhang, M.; Wang, S.; He, M.; Ji, W.; Li, H.; Feng, Z.; Wang, Z. Single-image estimation of tree volume via pixel-mapped 3D reconstruction: A low-cost solution using deep learning and curvature segmentation. *Sci. Total Environ.* 2025, 1002, 180420. <https://doi.org/10.1016/j.scitotenv.2025.180420>.

Keefe, R.F.; Zimbelman, E.G.; Picchi, G. Use of Individual Tree and Product Level Data to Improve Operational Forestry. *Curr. For. Rep.* 2022, 8, 148–165. <https://doi.org/10.1007/s40725-022-00160-3>.

Tran, H.; Woeste, K.; Li, B.; Verma, A.; Shao, G. Measuring tree stem diameters and straightness with depth-image computer vision. *J. For. Res.* 2023, 34, 1395–1405. <https://doi.org/10.1007/s11676-023-01600-x>.

Vacek, O.; Gergel, T.; Bucha, T.; Gracovský, R.; Gejdoš, M. Automatic Wood Species Classification and Pith Detection in Log CT Images. *Forests* 2024, 15, 2207. <https://doi.org/10.3390/f15122207>.

Fard, F.H.; Fard, S.H.; Jonoobi, M. A Low-Cost Machine Learning Approach for Timber Diameter Estimation. *arXiv* 2025, arXiv:2507.17219. <https://doi.org/10.48550/arXiv.2507.17219>.

Wimmer, G.; Schraml, R.; Hofbauer, H.; Uhl, A. Two-Stage CNN-Based Wood Log Recognition; University of Applied Sciences Salzburg: Salzburg, Austria, 2021; 4p.

Vihlman, M.; Kulovesi, J.; Visala, A. Tree Log Identity Matching using Convolutional Correlation Networks. In *Proceedings of the 2019 Digital Image Computing: Techniques and Applications (DICTA)*, Perth, Australia, 2–4 December 2019; pp. 1–8.

Wang, Y.; Zhang, W.; Gao, R.; Jin, Z.; Wang, X. Recent advances in the application of deep learning methods to forestry. *Wood Sci. Technol.* 2021, 55, 1171–1202. <https://doi.org/10.1007/s00226-021-01309-2>.

Grondin, V.; Fortin, J.-M.; Pomerleau, F.; Giguère, P.; Fassnacht, F. Tree detection and diameter estimation based on deep learning. *For. Int. J. For. Res.* 2023, 96, 264–276. <https://doi.org/10.1093/forestry/cpac043>.

Holmström, E.; Raatevaara, A.; Pohjankukka, J.; Korpunen, H.; Uusitalo, J. Tree log identification using convolutional neural networks. *Smart Agric. Technol.* 2023, 4, 100201. <https://doi.org/10.1016/j.atech.2023.100201>.

Triplat, M.; Kavčič, V.; Jež, M. Forest Log Assortments Photo Dataset from the 2023 Slovenj Gradec Timber Auction; Slovenian Forestry Institute: Ljubljana, Slovenia, 2025. <https://doi.org/10.20315/Data.0006>.

Katalog Sortimentov, 17. Licitacija Vrednejših Sortimentov Lesa—Wertholzsubmission; Društvo Lastnikov Gozdov Mislinjske Doline, Zveze Lastnikov Gozdov Slovenije: Slovenj Gradec, Slovenia, 2023; 435p.

Demšar, J.; Curk, T.; Erjavec, A.; Gorup, Č.; Hočevar, T.; Možina, M.; Polajnar, M.; Toplak, M.; Starič, A.; Štajdohar, M.; et al. Orange: Data Mining Toolbox in Python. *J. Mach. Learn. Res.* 2013, 14, 2349–2353.

Godec, P.; Pancur, M.; Ilenic, N.; Copar, A.; Strazar, M.; Erjavec, A.; Pretnar, A.; Demšar, J.; Starič, A.; Toplak, M.; et al. Democratized image analytics by visual programming through integration of deep models and small-scale machine learning. *Nat. Commun.* 2019, 10, 4551. <https://doi.org/10.1038/s41467-019-12397-x>.

Achatz, J.; Lukovic, M.; Hilt, S.; Lädach, T.; Schubert, M. Convolutional neural networks for quality and species sorting of roundwood with image and numerical data. *Expert. Syst. Appl.* 2024, 246, 123117. <https://doi.org/10.1016/j.eswa.2023.123117>.

Shin, S.J.; Kim, H.; Han, S.-T. Comparison of the Performance Evaluations in Classification. *Ijarccce* 2016, 5, 441–444. <https://doi.org/10.17148/ijarccce.2016.5890>.

Sai, N.R.; Rao, T.S.; Kumari, G.L.A. Comparative Study on Reliability of Transfer Learning to Classify Plant-Based Diseases. *Int. J. Eng. Adv. Technol.* 2021, 10, 154–160. <https://doi.org/10.35940/ijeat.F3080.0810621>.

Bharadwaj, B.; Mishra, A.; Bharadwaj, S. Transfer Learning-Based CNN Models for Plant Species Identification Using Leaf Venation Patterns. *arXiv* 2025, arXiv:2509.03729. <https://doi.org/10.48550/ARXIV.2509.03729>.

KLJUČNE BESEDE:

Razvrščanje slik; kakovost lesa; strojno učenje v gozdarstvu.

ZAHVALE:

Zbiranje podatkov za to študijo sta sofinancirala MKGP ter ARIS v okviru projekta V4-2013. Študijo je podprla tudi raziskovalna skupina (P4-0107), ki jo financira ARIS.