

Aktivno učenje z mešanimi oznakami za detekcijo površinskih napak z globokimi nevronskimi mrežami

Domen Tabernik, Danijel Skočaj

Fakulteta za računalništvo in informatiko, Univerza v Ljubljani

E-pošta: {domen.tabernik,danijel.skocaj}@fri.uni-lj.si

Active learning with mixed supervision for surface defect detection using deep neural networks

This paper investigates active learning strategies for mixed supervision in surface defect detection, where we search for a minimal set of samples selected for more accurate manual segmentation. We explore several approaches for sample selection based on entropy, margin sampling, and least confidence and apply them to a mixed supervision method, SegDecNet. We additionally explore extending active learning with probability calibration and equal sampling by categories to improve the robustness. Active learning approaches are evaluated on the KSDD2 dataset and compared against random sampling and a related purpose-built method for active learning in surface defect detection. We demonstrate that the least confidence method with the proposed extensions can outperform random sampling and other methods, achieving the same result as fully annotated dataset while requiring only a third of the fully annotated samples.

1 Uvod

Učinkovita detekcija površinskih napak je ključna za zagotavljanje kakovosti izdelkov v proizvodnih procesih. Uporaba globokih nevronskih modelov za detekcijo napak pogosto zahteva obsežne učne množice podatkov z natančnimi oznakami, kar pa pogosto predstavlja izziv zaradi zamudnosti in zahtevnosti pri pridobivanju natančnih oznak. Zamudnost in zahtevnost sta pogosto odvisna od same natančnosti oznake. Medtem ko so oznake na ravni pikslov (t.j. segmentacija) zelo zahtevne, je pogosto enostavneje pridobiti oznake na ravni celotne slike (t.j. prisotnost napake). Kljub temu je segmentacija ključna za visokokakovostno delovanje. Nekatere obstoječe metode, kot je SegDecNet [4], zato uporabljajo mešano učenje z manj natančnimi oz. šibkimi oznakami skupaj z nekaj natančno segmentiranimi primeri. Vendar pri tem ne raziščejo katere primere bi bilo najbolj optimalno izbrati za segmentacijo, kar lahko vodi v ne-optimalno učenje.

V tem članku se osredotočamo na nadgradnjo obstoječega modela mešanega učenja SegDecNet z metodami aktivnega učenja, kjer primere za ročno segmentacijo izbiramo glede na negotovost napovedi. S tem želimo izboljšati delovanje modela z minimalnim številom dodatnih natančnih oznak (t.j. segmentacij). V članku razi-

ščemo pristope za dodatno segmentacijo primerov na podlagi njihove uspešnosti detektiranja napak z začetnimi šibkimi oznakami, s čimer zagotovimo dodaten učni signal za najtežje primere. Pri tem preučujemo tri klasične pristope aktivnega učenja: i) izbiro na podlagi entropije, ii) mejno vzorčenje in iii) najmanjše zaupanje. Pri izboru primerov dodatno izvedemo kalibracijo verjetnosti ter zagotovimo enakomerno zastopanost vseh kategorij površinskih napak. Različne pristope izbire primerov ovrednotimo na podatkovni množici KSDD2 [4] ter jih primerjamo z naključnim pristopom in sorodnim namensko razvitim pristopom aktivnega učenja za detekcijo površinskih napak [8].

2 Sorodna dela

Izbiranje učnih primerov za dodatno oznako je dobro raziskan problem v aktivnem učenju. Aktivno učenje predpostavlja velik nabor neoznačenih slik, iz katerih se izbere manjši nabor za ročno označevanje in učenje novega modela. Pristope delimo na tri skupine: a) izbiranje z negotovostjo, b) izbiranje z raznovrstnostjo in c) hibridni pristopi.

Pristopi na podlagi negotovosti poskušajo identificirati težke primere, kjer model deluje najslabše. Ker v običajnem aktivnem učenju ni na voljo pravih oznak, kar onemogoča natančno preverjanje pravilnosti napovedi modela, metode uporabljajo različne nadomestne funkcije, kot so entropija, mejno vzorčenje, najmanjše zaupanje [10] in norma gradienta [11]. Pri stohastičnih modelih se uporablja maksimizacija skupne informacije med napovedjo modela in parametri [5, 7]. Pristopi z raznovrstnostjo se namesto na težke primere osredotočajo na izbor primerov, ki pokrijejo celotno učno množico. To dosežejo s primerjavo razdalj med globokimi značilkami na podlagi metod CoreSet [9] ali K-means [6]. Hibridni pristopi nato združujejo negotovost in raznovrstnost [7], kar nekateri dosežejo z uporabo vložitev gradienta [1] (ang. *gradient embedding*).

Za razliko od splošnega aktivnega učenja, kjer slike nimajo oznak, ima predlagano aktivno učenje z mešanim nadzorom za detekcijo površinskih napak na voljo tudi informacije o prisotnosti napake. Oznake slik lahko smatramo kot šibke označbe, medtem ko za dobro delovanje dodatno potrebujemo na piksel natančne oznake (t.j., segmentacija). Aktivno učenje za šibke oznake je raziskano

v nekaj sodobnih delih. V [3] je bila predlagana nadgradnja stohastičnega modela za šibko učenje z dodatnim aktivnim učenjem, kjer je bila izbira primerov izvedena z divergenco maxKL. Za detekcijo objektov z očitanim okvirjem je bil predlagan model, ki uporablja nestrinjanje modelov učenec-učitelj za ugotavljanje negotovosti primerov [12]. Pri segmentaciji pa je bil raziskan model, ki temelji na dodatni psevdo-segmentaciji, kjer se manj natančne napovedi segmentacije iz obstoječega modela uporabijo za učenje naslednjega modela [2].

V literaturi je bilo raziskano tudi aktivno učenje za detekcijo površinskih napak [8]. Avtorji uporabijo metodo izbiranja z negotovostjo, kjer predlagajo še dodatno normalizacijo skale s povprečnim mejnim vzorčenjem za vsako kategorijo napake. Metodo primerjajo s pristopi na podlagi entropije ter mejnim vzorčenjem na podatkovni množici NEU-DET.

3 Aktivno učenje z mešanim nadzorom

Pri učenju z mešanim nadzorom uporabljamo dve množici slik: i) slike s šibko oznako $x_s \in \mathcal{S}$, t.j., indikacijo prisotnosti napake na sliki, ter ii) slike s polno oznako $x_f \in \mathcal{F}$, t.j., slike s segmentacijo. Pri tem imamo šibke oznake x_s za vse učne slike, medtem ko imamo polne oznake x_f le za podmnožico vseh slik. Polnih oznak tudi ne potrebujemo za slike brez napak, saj je v tem primeru natančna oznaka znana, ker so vsi piksli brez napak, torej potrebujemo polne oznake le za podmnožico slik s prisotnimi napakami.

Aktivno učenje z mešanim nadzorom definiramo kot izbor N slik iz množice učnih slik z napakami, ki bodo nato uporabljeni za dodatno ročno segmentacijo. Pri tem želimo maksimizirati uspešnost modela pri čim manjšem N , zato je cilj izbrati take primere, kjer bo označevanje pikslov najbolj pripomoglo k izboljšavi modela. V ta namen vsako učno sliko z napakami rangiramo po primerosti za ročno oznako pikslov ter izberemo N najboljših.

3.1 Funkcije rangiranja

Za funkcijo rangiranja definiramo tri različne pristope: i) izbiranje na podlagi entropije, ii) mejno vzorčenje, ter iii) najmanjše zaupanje.

Entropija. Negotovost napovedi modela ocenimo z entropijo napovedi. Pri tem izbiramo primere z visoko negotovostjo, torej z visoko entropijo, kjer je napoved enakomerno porazdeljena med različnimi možnostmi:

$$H(y|x) = - \sum_c P(y = c|x) \log P(y = c|x), \quad (1)$$

kjer je $P(y = c|x)$ verjetnost napovedi y za kategorijo c pri vhodni sliki x . V primeru binarnega problema se enačba poenostavi v:

$$H(y|x) = -P \log P - (1 - P) \log(1 - P). \quad (2)$$

Za rangiranje primerov po entropiji se uporabi $H(y|x)$ z največjimi vrednostmi.

Mejno vzorčenje. Pri mejnem vzorčenju negotovost ocenjujemo na podlagi razlike verjetnosti med najboljšo in drugo najboljšo napovedjo:

$$Q(y|x) = P(y = c_1|x) - P(y = c_2|x), \quad (3)$$

kjer je c_1 kategorija prve in c_2 kategorija druge najboljše napovedi. Manjša razlika med obema predstavlja večjo negotovost modela. V primeru binarnega problema se enačba poenostavi v:

$$Q(y|x) = \begin{cases} 2P(y|x) - 1; & P(y|x) > 1 - P(y|x) \\ 1 - 2P(y|x); & \text{sicer} \end{cases} \quad (4)$$

Za rangiranje primerov po mejnem vzorčenju se uporabi $Q(y|x)$ z najmanjšimi vrednostmi.

Najmanjše zaupanje. Izbiranje primerov se lahko izvede tudi na podlagi verjetnosti za najboljše napovedi modela $P(y|x)$, pri čemer se izbere primere z najmanjšo verjetnost. Na ta način se izbere težke primere, kjer ima trenutni model najslabšo napoved. Za rangiranje primerov po najmanjšem zaupanju se torej uporabi primere z najmanjšim $P(y|x)$.

3.2 Ocenjevanje negotovosti za mešan nadzor

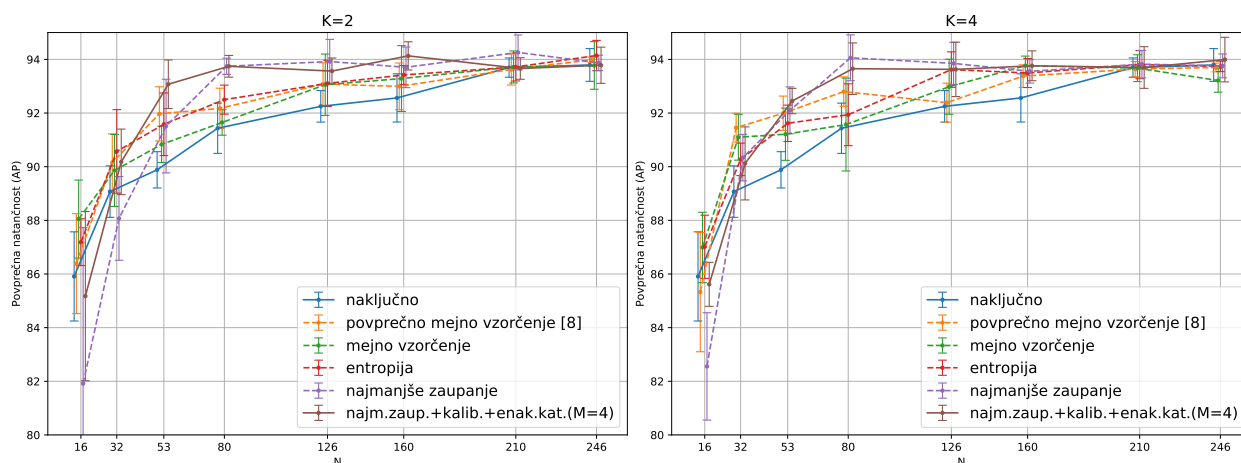
Za ocenjevanje negotovosti učnih primerov pri uporabi mešanega nadzora lahko izkoristimo obstoječo šibko oznako ter naučimo model za oceno negotovosti na podlagi oznak o prisotnosti napake na sliki. Za vsak učni primer nato pridobimo napoved modela $P(y|x)$, ki je nato uporabljena v funkciji rangiranja. Pri tem se za oceno negotovosti učnega primera izognemo uporabi istega modela na katerem je bil model naučen, saj bi to vodilo v preveč optimistične napovedi. Namesto tega učno množico naključno razdelimo na K podmnožic ter učimo K različnih modelov. Za vsako k -to podmnožico učimo model na slikah, ki niso del k -te podmnožice, podobno kot pri k -kratnem prečnem preverjanju, ter nato s tem modelom izračunamo napovedano verjetnost $P(y|x)$ za primere v k -ti podmnožici.

3.3 Kalibracija verjetnosti

Dodatno raziščemo tudi možnost kalibracije napovedane verjetnosti modela $P(y|x)$ glede na zanesljivost delovanja k -tega modela, saj so napovedi različnih modelov lahko pristranske. Kalibracijo izvedemo z uporabo praga, pri katerem model doseže najboljši rezultat na k -ti podmnožici. Pri tem se zanašamo le na znano šibko oznako primerov z indikacijo prisotnosti napake na sliki. Vrednosti kalibriramo z delno linearno preslikavo, pri čemer se vrednosti praga preslikajo na 0.5, medtem ko se najmanjše in največje verjetnosti obdržijo med 0 in 1.

3.4 Izbiranje z upoštevanjem kategorij

Pri primerih, kjer je znana kategorija napake, dodatno raziščemo metodo izbire primerov z enakomernim upoštevanjem kategorij. V situacijah, ko je določena kategorija napake pogostejše označena za težaven primer, lahko pri izbiri primerov z majhnim številom N opazimo slabo



Slika 1: Rezultati različnih tipov funkcij izbiranja pri razdelitvi učne množice na 2 oz. 4 podmnožice.

zastopnost preostalih kategorij. V izogib temu izvajamo ločeno rangiranje za vsako kategorijo ter zagotavljamo, da izberemo vsaj prvih M primerov iz vsake kategorije z enakomernim vzorčenjem.

4 Eksperimentalni rezultati

Pristope aktivnega učenja z mešanim nadzorom ovrednotimo na modelu SegDecNet [4] s primerjavo z učenjem na naključno izbranih primerih ter z obstoječim pristopom aktivnega učenja za detekcijo površinskih napak [8].

4.1 Podatkovna množica slik

Vrednotenje izvedemo na podatkovni množici KSDD2 [4], ki vsebuje 3335 slik velikosti 230×630 pikselov, od tega 2979 slik brez napak ter 356 slik z napakami. Slike z napakami vsebujejo 10 različnih vrst napak, kot so praske, pike ali površinske deformacije. Vsaka slika vsebuje oznako napake na piksel natančno vključno z informacijo o tipu napake. V našem primeru uporabimo tip napake le pri izbiranju z upoštevanjem kategorij, medtem ko je model SegDecNet učen izključno na binarnem problemu, t.j., prisotnost ali odsotnost napake na sliki.

4.2 Rezultati

Pristope smo ovrednotili z različno velikim razbitjem učne množice ($K = 2$ in $K = 4$). Vsak eksperiment ponovimo vsaj 5-krat z različnimi razdelitvami primerov na K podmnožic ter poročamo povprečje in standardni odklon *povprečne natančnosti* (ang. *average precision*). Za osnovno primerjavo vzamemo naključno izbrane primere z vsaj 5 ponovitvami in poročanim povprečnim rezultatom. Aktivno učenje ponovimo z različnim številom izbranih učnih primerov N .

Rezultati različnih tipov funkcij izbiranja so prikazani na Sliki 1. Pri vsakem N so rezultati delno zamaknjeni po x-osi zaradi boljše berljivosti. Pri zelo majhnem N se različne funkcije izbiranja ne odrežejo bolje od naključnega izbiranja, medtem ko se pri $N > 50$ izkažejo veliko bolje. Izboljšano delovanje je še posebej opazno pri metodi najmanjšega zaupanja, kjer v povprečju negativno odstopa pri $N < 50$, medtem ko doseže najboljši

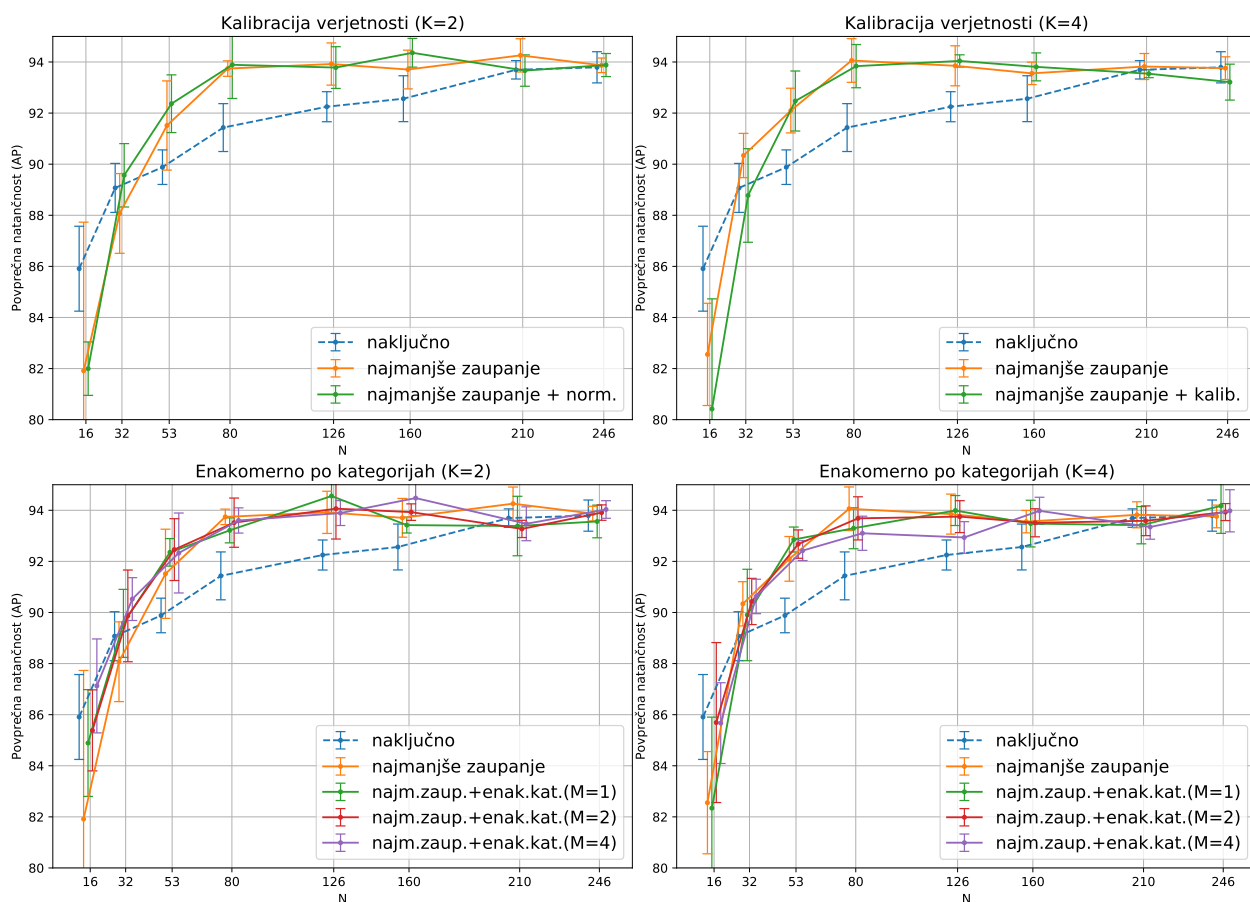
rezultat že pri $N = 80$ oz. pri $1/3$ učnih podatkov, kar je za 2 odstotni točki bolje od preostalih metod in naključja. S predlaganimi izboljšavami pa lahko nato izničimo negativno odstopanje pri majhnem N . Preostale metode sicer v povprečju dosežejo boljši rezultat od naključja, vendar po standardnem odklonu le-tega ne presežejo. V to skupino sodi tudi sorodni pristop aktivnega učenja za detekcijo površinskih napak s povprečnim mejnim vzorčenjem [8].

Kalibracija verjetnosti. Pri metodi najmanjšega zaupanja dodatno preverimo delovanje s kalibracijo verjetnosti, kar poročamo v zgornji vrstici na Sliki 2. Kalibracija ima minimalen pozitiven vpliv. V večini primerov bistveno ne izboljša rezultatov, navkljub temu pa v dveh primerih ($N = 32$ in 53 , pri $K = 2$) doseže boljši povprečen rezultat.

Izbiranje z upoštevanjem kategorij. Preizkusili smo tudi metodo najmanjšega zaupanja, nadgrajeno z enakomernim izbiranjem po kategorijah, pri čemer smo zagotovili vsaj M primerov iz vsake kategorije. Preizkusili smo različne vrednosti $M = [1, 2, 4]$, kar je skupaj rezultiralo v 10, 20 in 40 primerih izbranih enakomerno po kategorijah napak. Rezultati so prikazani v spodnji vrstici Slike 2. Pri $N > 50$ izbira z upoštevanjem kategorij bistveno ne vpliva na delovanje metode, zato pa se pri $N = 16$ in $N = 32$ delno izboljša povprečni rezultat v primerjavi z metodo brez upoštevanja kategorij, vendar predvsem pri $M \geq 2$. Pri $N = 32$ je rezultat z $M = 4$ tudi boljši od naključne izbire za povprečno 1 odstotno točko.

5 Zaključek

V tem članku smo preučili različne pristope aktivnega učenja za detekcijo površinskih napak v kontekstu učenja z mešanim nadzorom. Raziskali smo tri klasične funkcije izbiranja: a) entropija, b) mejno vzorčenje, in c) najmanjše zaupanje, ter jih primerjali z naključnim izbiranjem in namensko razvitim pristopom aktivnega učenja za detekcijo površinskih napak [8]. Na podatkovni zbirki



Slika 2: Kalibracija (zgoraj) in enakomerno izbiranje po kategorijah (spodaj) za metodo najmanjšega zaupanja.

KSDD2 lahko metoda najmanjšega zaupanja že pri tretjini izbranih učnih primerov ($N > 50$) bistveno izboljša natančnost detekcije napak v primerjavi z naključnim izborom ter doseže rezultat primerljiv z natančno označeno celotno učno množico, medtem ko preostale metode sicer dosežejo malenkost boljše povprečne rezultate vendar pogosto ne presežejo standardnega odklona naključnega izbiranja. Dodatno smo raziskali še kalibracijo verjetnosti ter izbiro po kategorijah, ki imata pozitiven vpliv na rezultat predvsem pri majhnem številu izbranih primerov.

Literatura

- [1] Jordan T. Ash, Chicheng Zhang, Akshay Krishnamurthy, John Langford, and Alekh Agarwal. Deep Batch Active Learning By Diverse, Uncertain Gradient Lower Bounds. *8th International Conference on Learning Representations, ICLR 2020*, 2020.
- [2] Soufiane Belharbi, Ismail Ben Ayed, Luke McCaffrey, and Eric Granger. Deep active learning for joint classification & segmentation with weak annotator. In *Proceedings - 2021 IEEE Winter Conference on Applications of Computer Vision, WACV 2021*, pages 3337–3346, 2021.
- [3] Samantha Biegel, Rafah El-Khatib, Luiz Otavio Vilas Boas Oliveira, Max Baak, and Nanne Aben. Active WeaSuL: Improving Weak Supervision with Active Learning. In *ICLR*, pages 1–13, 2021.
- [4] Jakob Božič, Domen Tabernik, and Danijel Škočaj. Mixed supervision for surface-defect detection: from weakly to fully supervised learning. *Computers in Industry*, 129, 2021.
- [5] Yarin Gal, Riashat Islam, and Zoubin Ghahramani. Deep Bayesian active learning with image data. *34th International Conference on Machine Learning, ICML 2017*, 3:1923–1932, 2017.
- [6] Guy Hacohen, Avihu Dekel, and Daphna Weinshall. Active Learning on a Budget: Opposite Strategies Suit High and Low Budgets. *Proceedings of Machine Learning Research*, 162:8175–8195, 2022.
- [7] Andreas Kirsch, Joost van Amersfoort, and Yarin Gal. BatchBALD: Efficient and diverse batch acquisition for deep Bayesian active learning. *Advances in Neural Information Processing Systems*, 32(NeurIPS), 2019.
- [8] Xiaoming Lv, Fajie Duan, Jia Jia Jiang, Xiao Fu, and Lin Gan. Deep active learning for surface defect detection. *Sensors (Switzerland)*, 20(6), 2020.
- [9] Ozan Sener and Silvio Savarese. Active learning for convolutional neural networks: A core-set approach. *6th International Conference on Learning Representations, ICLR 2018 - Conference Track Proceedings*, pages 1–13, 2018.
- [10] Dan Wang and Yi Shang. A new active labeling method for deep learning. In *Proceedings of the International Joint Conference on Neural Networks*, pages 112–119. IEEE, 2014.
- [11] Tianyang Wang, Xingjian Li, Pengkun Yang, Guosheng Hu, Xiangrui Zeng, Siyu Huang, Cheng Zhong Xu, and Min Xu. Boosting Active Learning via Improving Test Performance. *Proceedings of the 36th AAAI Conference on Artificial Intelligence, AAAI 2022*, 36:8566–8574, 2022.
- [12] Yuting Wang, Velibor Ilic, Jiatong Li, Branislav Kisačanin, and Vladimir Pavlovic. ALWOD: Active Learning for Weakly-Supervised Object Detection. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 6436–6446, 2023.

Zahvala: To delo je bilo delno podprto s strani projektov ARIS J2-3169 (MV4.0) in J2-4457 (RTFM) ter raziskovalnega programa Računalniški vid (P2-0214) in z uporabo Slovenskega superračunalniškega omrežja SLING.