



KLASIFIKACIJA STAVB Z GLOBOKIM UČENJEM

CLASSIFICATION OF BUILDINGS WITH DEEP LEARNING

SIMON ŠANCA - WESTERN NORWAY UNIVERSITY OF APPLIED SCIENCES, NORVEŠKA


ALEN MANAFIĆ - GEODETSKI INŠTITUT SLOVENIJE

DR. KRIŠTOF OŠTIR - UNIVERZA V LJUBLJANI, FAKULTETA ZA GRADBENIŠTVO IN GEODEZIJO

1. MOTIVACIJA

- Alternativni pristop pri iskanju neevidentiranih stavb.
- Trenutno uporabljena metoda za klasifikacijo stavb:
 - strojno učenje z objektno klasifikacijo.
- **Namen:** Raziskati primernost/uporabnost globokega učenja za klasifikacijo stavb.

2. GLOBOKO UČENJE




- Globoke, usmerjene in več-nivojske nevronske mreže; umetne nevronske mreže (angl. artificial neural networks).
- Algoritmi globokega učenja so sposobni prepoznati podrobne informacije iz posnetkov.

3. KONVOLUCIJSKE NEVRONSKE MREŽE

- Specifični primer umetnih nevronske mreže za:
 - klasifikacijo in segmentacijo slik (angl. *image classification/segmentation*),
 - procesiranje naravnega jezika (angl. *natural language processing*).
- Računalniški vid:
 - izluščiti uporabne informacije iz slik (Prince, 2012).
- Filtri → pridobivanje značilik → matrika značilik.
- Od splošnih informacij h konkretnim/specifičnim informacijam.

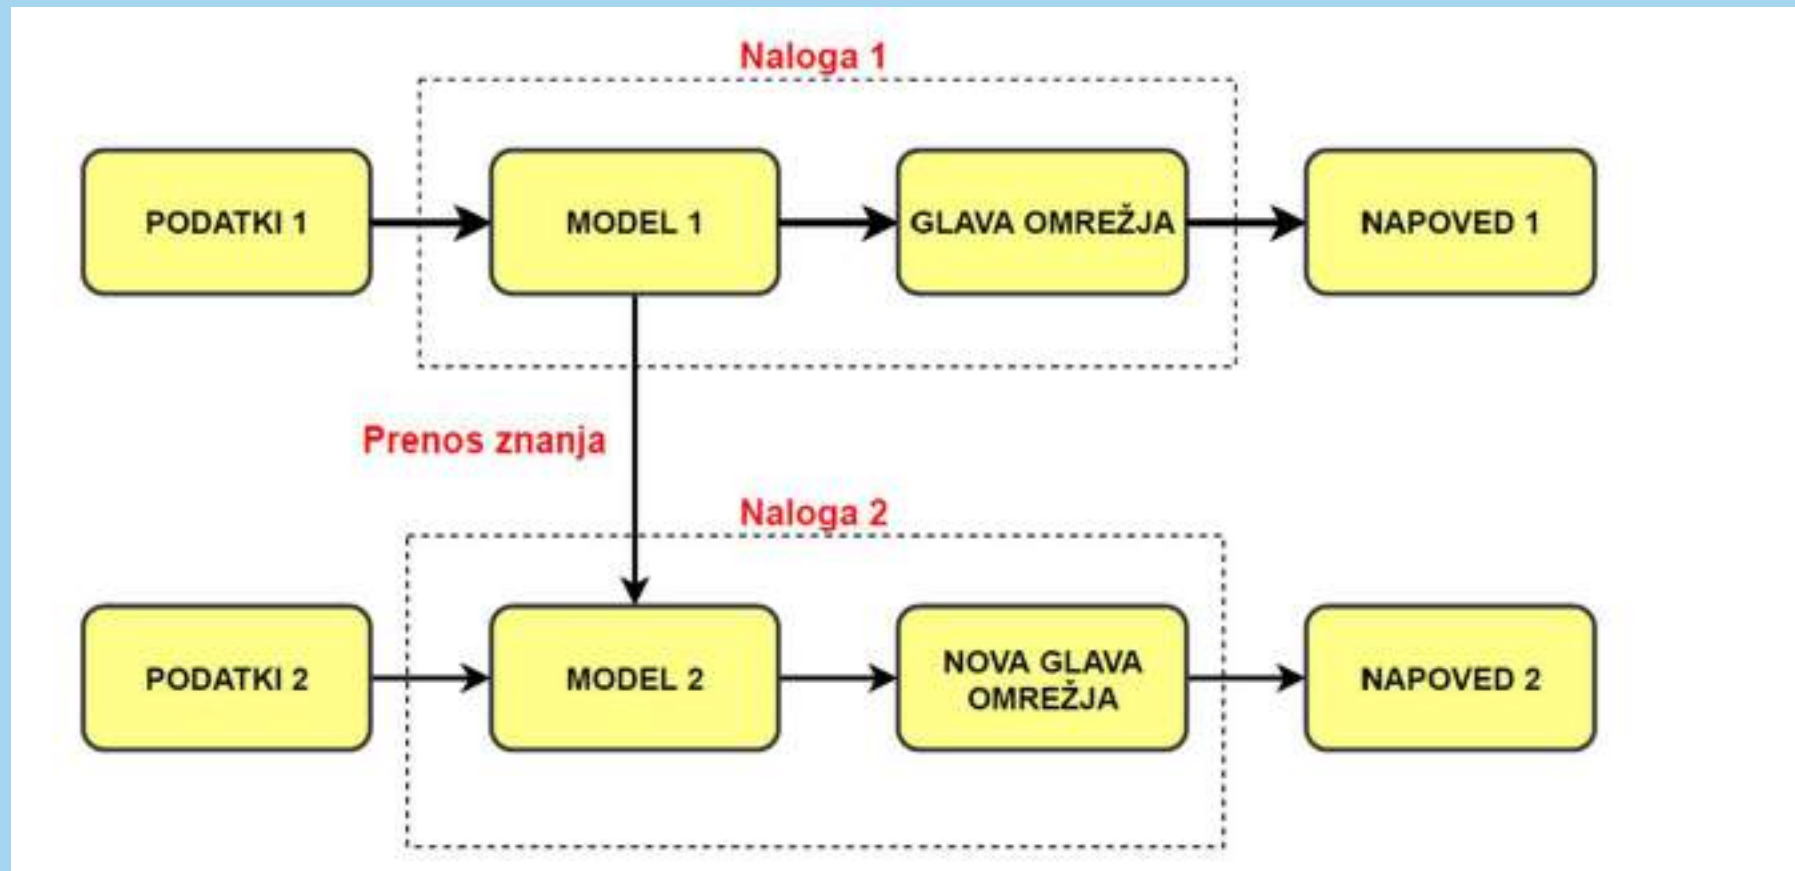
4. TEMELJNE NALOGE RAČUNALNIŠKEGA VIDA



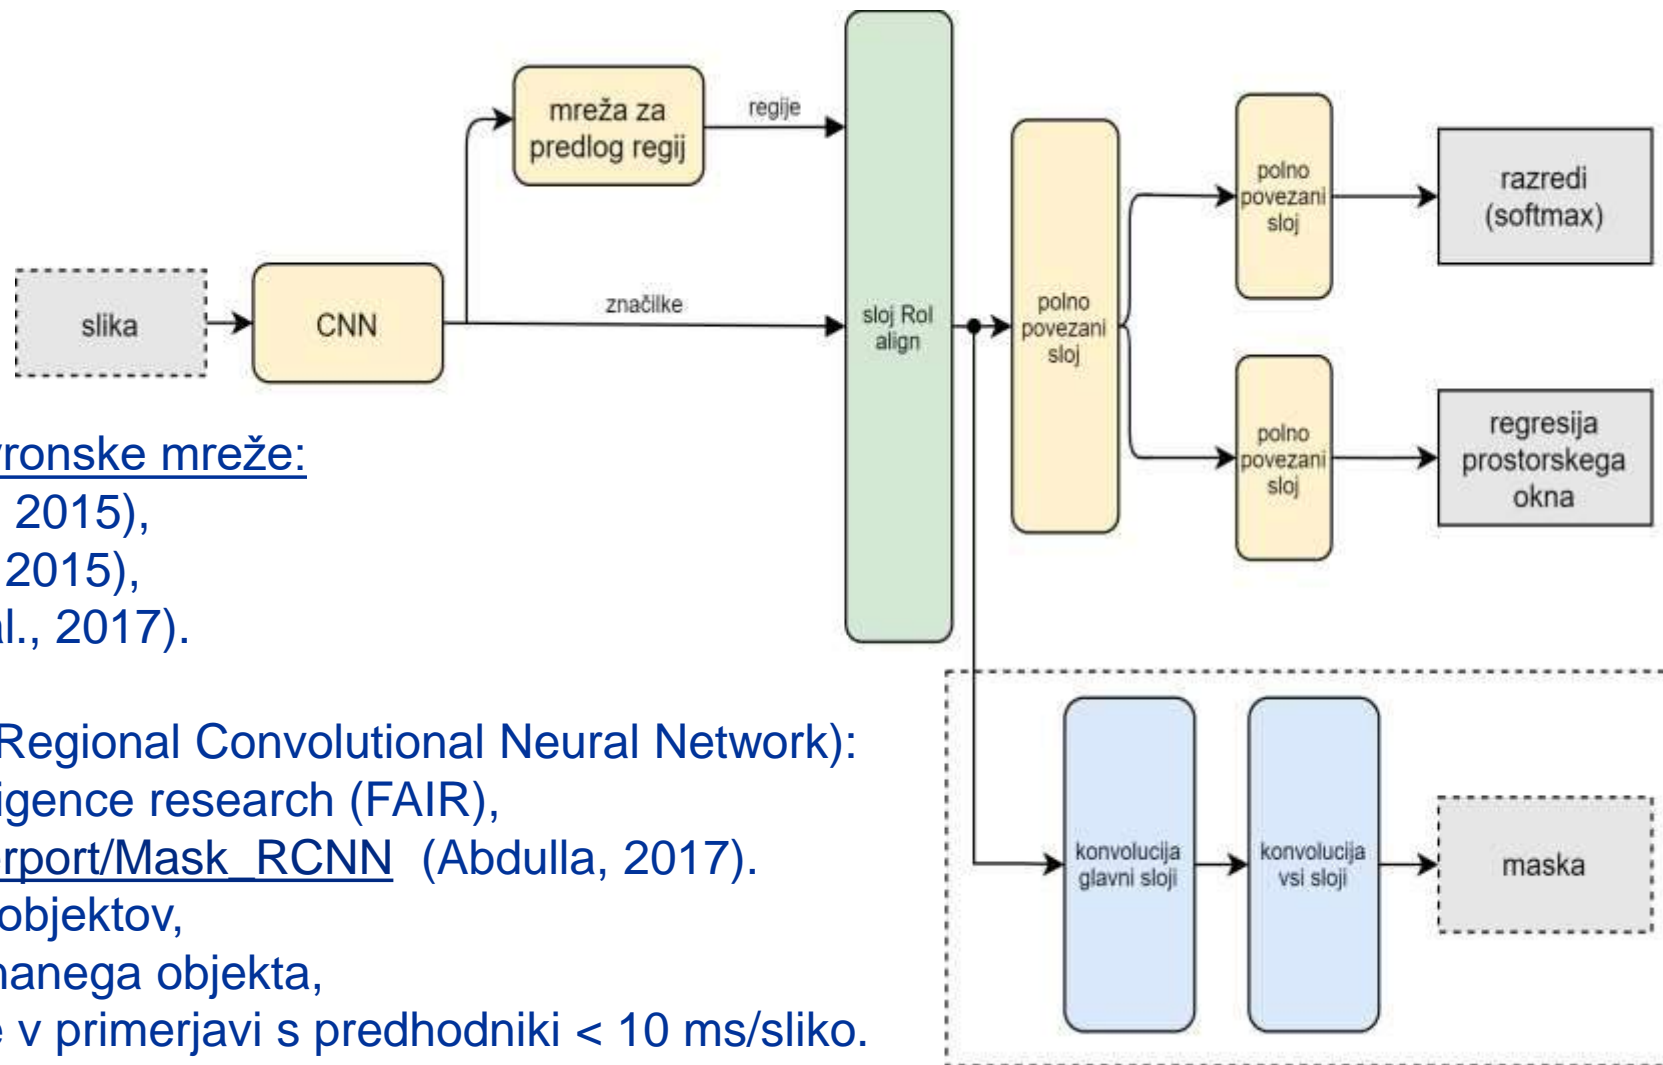
5. UČENJE S PRENOSOM ZNANJA (1)

- Nevronske mreže so za specifične naloge računalniškega vida že izdelane in naučene na velikih podatkovnih zbirkah:
 - MS COCO, ImageNet, Pascal VOC, idr.
- Uporabnik lahko uporabi uteži teh podatkovnih zbirk za učenje novih modelov na lastnih podatkih.
- **Problem:** pridobitev kakovstnih podatkov za konkretno nalogo!

5. UČENJE S PRENOSOM ZNANJA (2)



5. MASK R-CNN



Regijske konvolucijske nevronske mreže:


- R-CNN (Girschick et al., 2015),
- Fast R-CNN (Girschick, 2015),
- Faster R-CNN (Ren et al., 2017).

Mask R-CNN (angl. Mask Regional Convolutional Neural Network):


- Facebook Artificial Intelligence research (FAIR),
- https://github.com/matterport/Mask_RCNN (Abdulla, 2017).
- natančna segmentacija objektov,
- Izdelava maske prepoznanega objekta,
- Izjemna hitrost detekcije v primerjavi s predhodniki < 10 ms/sliko.

6. IZDELAVA PODATKOVNE ZBIRKE STAVB (1)

- Podatki:
 - CAS 2019, DOF BIR-R-G 0,5 m,
 - kataster stavb (28. 3. 2020),
 - generalizirana namenska raba prostora (GNRP).
- Območje:
 - 1389 km²,
 - 98.743 stavb (28. 3. 2020).

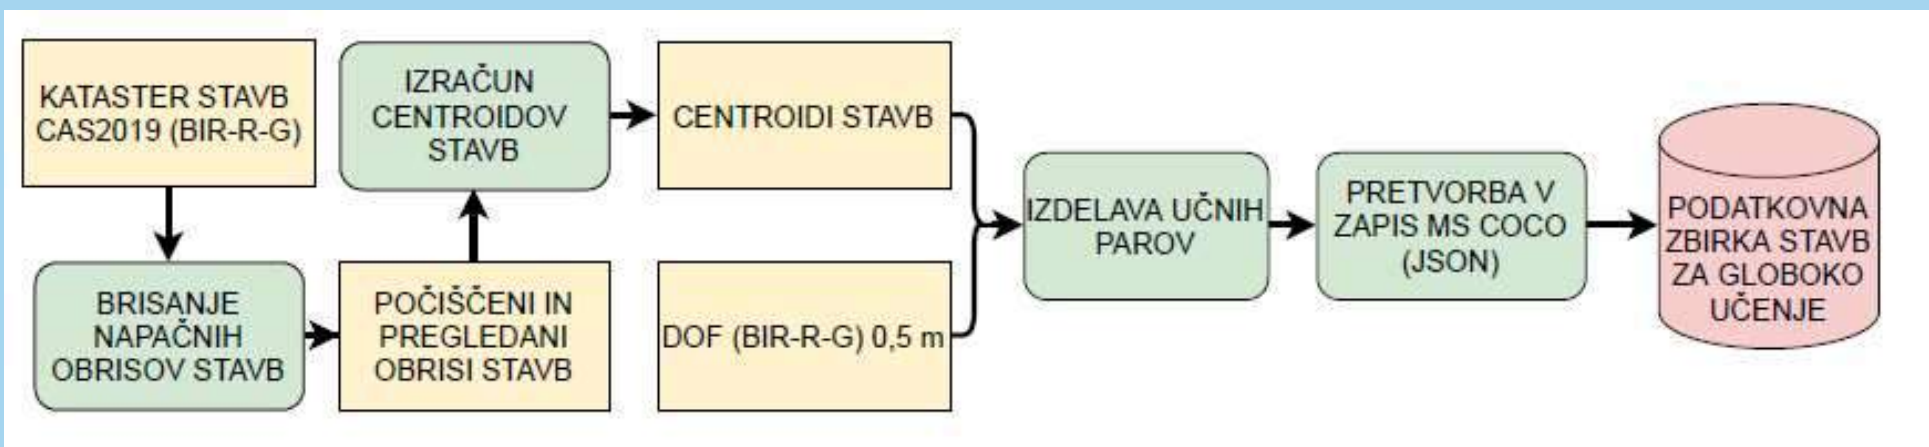


6.1 IZDELAVA UČNIH VZORCEV

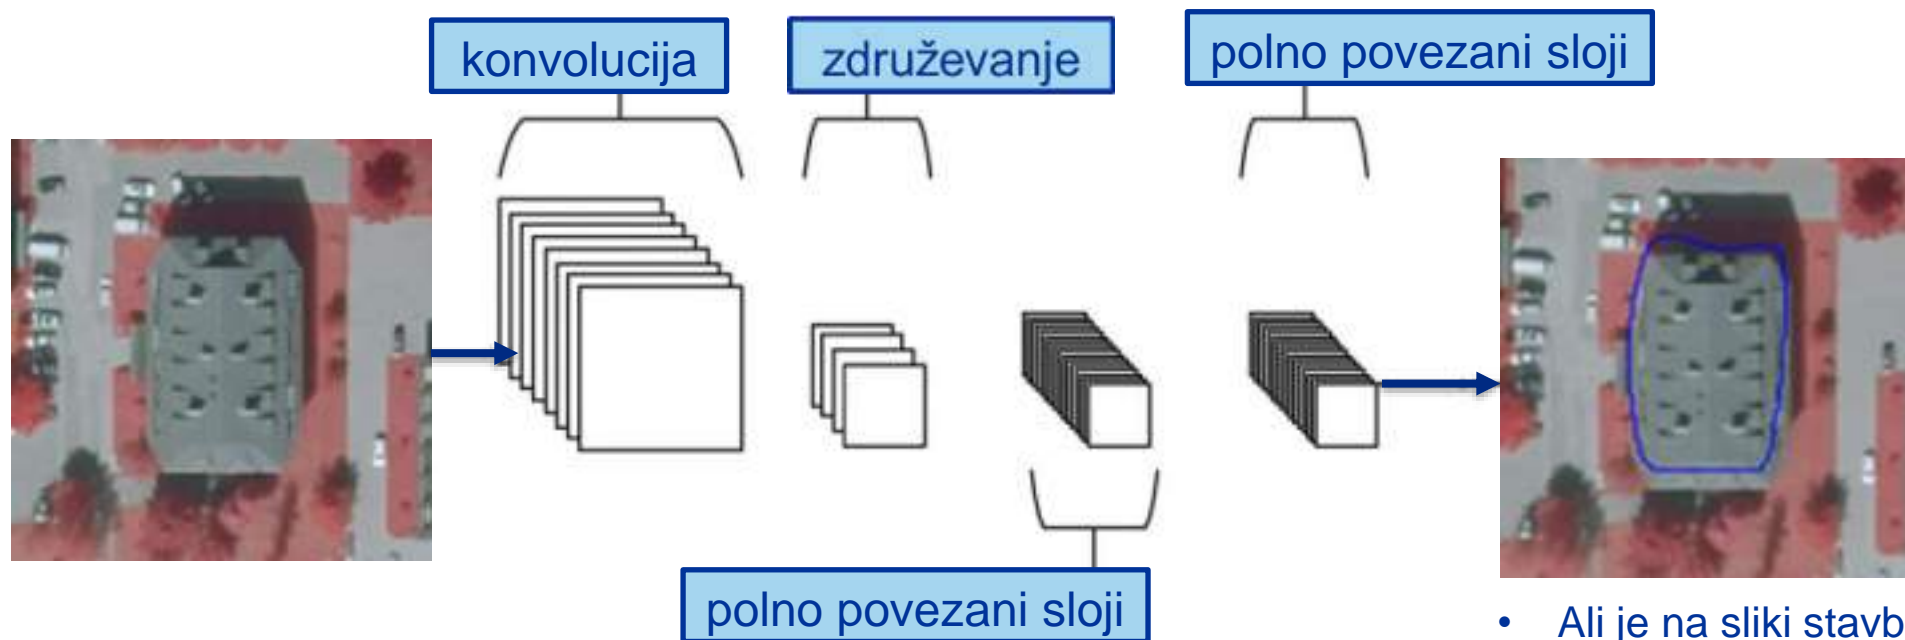


- 58.000 učnih parov: vzorčnih slik in enako število binarnih mask,
- velikost učnih parov: 128×128 px.

6.2 KORAKI IZDELAVE PODATKOVNE ZBIRKE

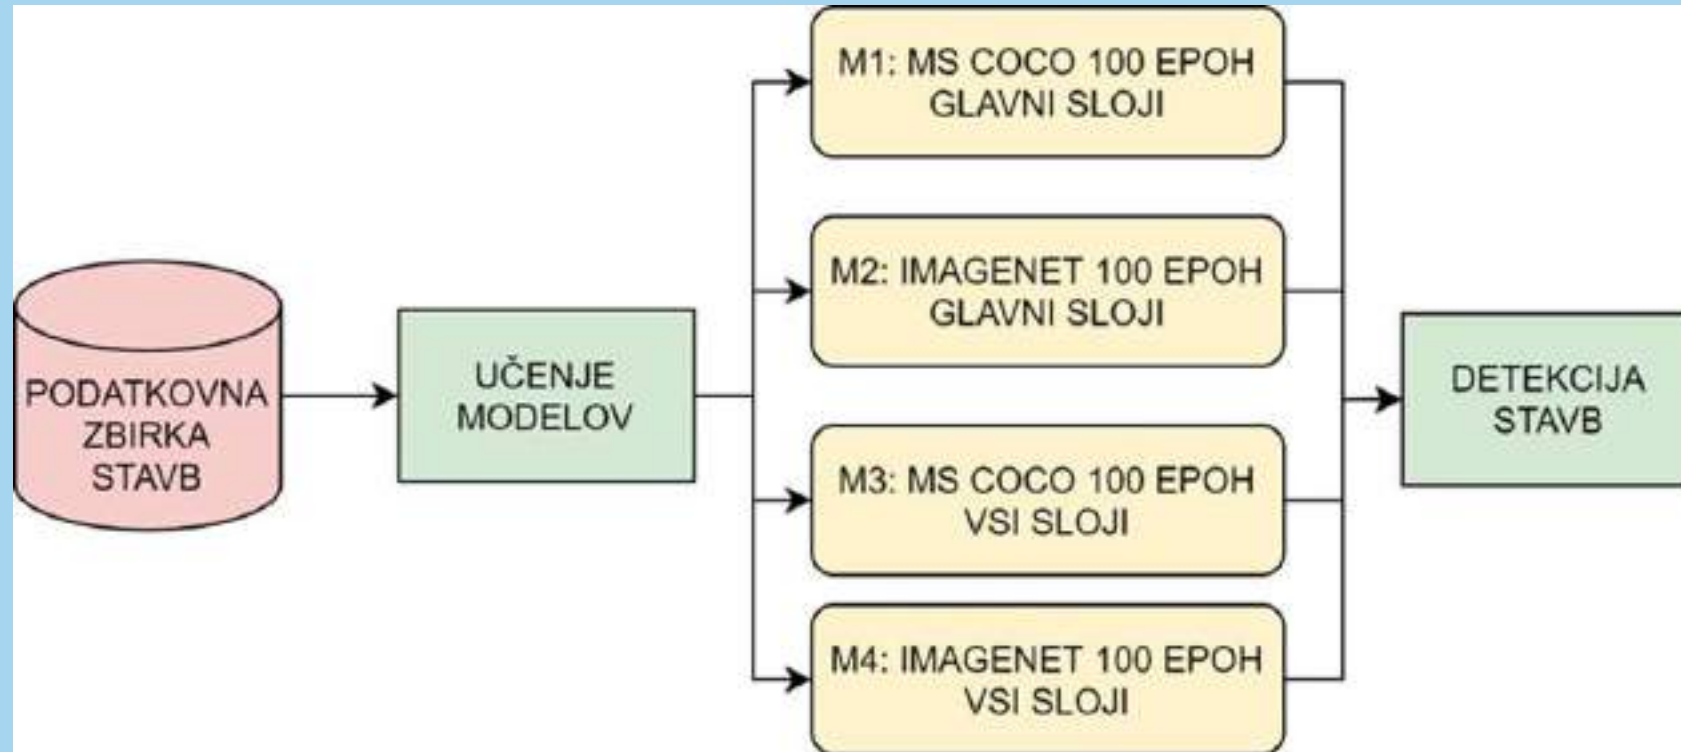


7. KLASIFIKACIJA STAVB Z CNN



- Ali je na sliki stavba?
- Kje točno se ta stavba nahaja?

7. UČENJE MODELOV




8. REZULTATI KLASIFIKACIJE (1)




- Uspešna detekcija oblike in roba stavbe.
- Sence se praviloma ne prepoznajo kot stavba.
- Uspešna detekcija različnih barv streh, brez ločevanja.

8. REZULTATI KLASIFIKACIJE - NAPAKE (2)




- Stavbe, ki so blizu se ne ločujejo in se prepoznajo kot ena stavba,
- neuspešna detekcija na robu slik,
- pravilna geometrija stavbe ni prepoznana.

8. REZULTATI KLASIFIKACIJE – PRIMERJAVA S KATASTROM STAVB (1)



8. REZULTATI KLASIFIKACIJE – PRIMERJAVA S KATASTROM STAVB (2)



8. REZULTATI KLASIFIKACIJE – PRIMERJAVA S KATASTROM STAVB (3)



9. OVREDNOTENJE USPEŠNOSTI KLASIFIKACIJE (1)

- TP – # resnično pozitivnih primerov
 - TN – # resnično negativnih primerov
 - FN – # lažno negativnih primerov
 - FP – # lažno pozitivnih primerov
- izračun evalvacijskih metrik

$$\bullet \text{ natančnost} = \frac{TP+TN}{TP+FP+TN+FP}$$

Matrika zamenjav:

/	Napoved	
Resnica	TP	FN
	FP	TN

$$\bullet \text{ priklic} = \frac{TP}{TP+FN}$$

$$\bullet \text{ mera } F1 = \frac{2 \cdot \text{natančnost} \cdot \text{priklic}}{\text{natančnost} + \text{priklic}}$$

9. OVREDNOTENJE USPEŠNOSTI KLASIFIKACIJE (2)

	TP	TN	FP	FN	Natančnost	Priklic	Mera F1
M1	246	0	38	16	0,82	0,93	0,87
M2	243	0	43	14	0,81	0,94	0,87
M3	296	0	3	1	0,98	0,99	0,98
M4	294	0	4	2	0,98	0,99	0,98

Na vzorcu 300-ih testnih slik znaša:

- natančnost učenih modelov 81 % pri modelih MS COCO in ImageNet, ki smo jih učili 100 epoh.
- natančnost učenih modelov 98 % pri fino nastavljenih modelih MC COCO in ImageNet, ki smo ju po prvem učenju finu nastavljali še za 100 epoh.

ZAKLJUČKI

- Dokazali smo da je globoko učenje primerna metoda za klasifikacijo stavb.
- **Težave:**
 - zaznava pravilne geometrije stavbe,
 - neuspešno ločevanje stavb, ki so si blizu,
 - neuspešno ločevanje med strehami različnih barv.
- **Prednosti:**
 - klasifikacija stavb se izvede samodejno (slika → Mask R-CNN → rezultat),
 - dobri rezultati z uporabo manjše podatkovne zbirke, ki ne zajema stavbe celotne države.
- **Nadaljevanje?**
 - nadgradnja podatkovne zbirke stavb s kombinirano uporabo bližnje infrardečega ortofota in normiranega digitalnega modela površja.
 - razširitev podatkovne zbirke stavb s celotnim katastrom stavb države.
- Več o sami raziskavi v magistrski nalogi (Šanca, 2020).



VPRAŠANJA / QUESTIONS