

ŠOLSKI CENTER VELENJE
ELEKTRO IN RAČUNALNIŠKA ŠOLA
TRG MLADOSTI 3, 3320 VELENJE

MLADI RAZISKOVALCI ZA RAZVOJ ŠALEŠKE DOLINE

RAZISKOVALNA NALOGA

PRIMERJAVA PROGRAMOV ZA PREPOZNAVANJE PREDMETOV

Tematsko področje: APLIKATIVNI INOVACIJSKI PREDLOGI IN PROJEKTI

Avtorja:
Tim Povše, 3. TRA
Anže Goršek, 3. TRA

Mentorja:
Uroš Remenih, inž.
Samo Železnik, inž.

Velenje, 2020

Raziskovalna naloga je bila opravljena na Elektro in računalniški šoli Velenje.

Mentorja: Uroš Remenih, inž.
Samo Železnik, inž.

Datum predstavitve: marec 2020

KLJUČNA DOKUMENTACIJSKA INFORMACIJA

- ŠD ŠC Velenje, Elektro in računalniška šola, 2019/2020
- KG detekcija / algoritem / primerjava / predmeti / slike / YOLO / Mask R-CNN
- AV POVŠE, Tim / GORŠEK, Anže
- SA REMENIH, Uroš / ŽELEZNIK, Samo
- KZ 3320 Velenje, SLO, Trg mladosti 3
- ZA ŠC Velenje, Elektro in računalniška šola
- LI 2020
- IN **PRIMERJAVA PROGRAMOV ZA PREPOZNAVANJE PREDMETOV**
- TD Raziskovalna naloga
- OP IX, 33 s., 3 tab., 14 sl., 5 graf., 57 ref.
- IJ SL
- JI sl / en
- AI Algoritme za prepoznavanje predmetov lahko koristno uporabimo na različnih področjih življenja. Glede na različne potrebe morajo imeti ti algoritmi primerne karakteristike. V raziskavi so primerjali dva algoritma za prepoznavanje predmetov, in sicer YOLO in Mask R-CNN. Primerjali so njuno natančnost, hitrost obdelave podatkov ter druge lastnosti. Ugotovljeno je bilo, da algoritem YOLO bistveno hitreje prepozna predmete na slikah, saj jih lahko prepozna v realnem času. Hitrost prepoznavanja se z večjim številom objektov na sliki pri obeh algoritmih povečuje. Na slikah, kjer je bilo 5-11 objektov, jih je algoritem Mask R-CNN zaznal več. Na slikah z manj ali več objekti pa med algoritmoma ni bilo večje razlike. Prav tako ni bilo razlik pri obdelavi slik večje ali manjše kakovosti. Raziskava je pokazala, da je za uporabo v pametnih hladilnikih bolj priporočljiv program, ki bi deloval na principu algoritma Mask R-CNN, le da bi mu bilo potrebno izboljšati hitrost delovanja.

KEY WORDS DOCUMENTATION

- ND ŠC Velenje, Elektro in računalniška šola, 2019/2020
- CX detection / algorithm / object / pictures / comparison / YOLO / Mask R-CNN
- AU POVŠE, Tim / GORŠEK, Anže
- AA REMENIH, Uroš / ŽELEZNIK, Samo
- PP 3320 Velenje, SLO, Trg mladosti 3
- PB ŠC Velenje, Elektro in računalniška šola
- PY 2020
- TI **COMPARISON OF OBJECT RECOGNITION PROGRAMS**
- DT RESEARCH WORK
- NO IX, 33 p., 3 tab., 5 graf, 14 fig., 57 app.
- LA SL
- AL sl / en
- AB Object recognition algorithms can be useful in various areas of life. Depending on the different needs, these algorithms must have appropriate characteristics. The study compared two algorithms for object recognition, namely YOLO and Mask R-CNN. Their accuracy, data processing speed and other features were compared. It has been found that the YOLO algorithm recognizes objects in images much faster and can also recognize them in real time. The recognition speed increases with the number of objects in the image for both algorithms. In the pictures where there were 5-11 objects, the Mask R-CNN algorithm detected more of them. However, there were no major differences between the algorithms in images with more or fewer objects. There were also no differences in object detection between higher or lower quality images. Research has shown that a program that works on the principle of the Mask R-CNN algorithm is better for use in smart refrigerators, if the operating speed could be improved.

KAZALO VSEBINE

KLJUČNA DOKUMENTACIJSKA INFORMACIJA	III
KEY WORDS DOCUMENTATION	IV
KAZALO VSEBINE	V
KAZALO TABEL	VI
KAZALO GRAFOV	VII
KAZALO PRILOG	VII
SEZNAM OKRAJŠAV	IX
1 UVOD	1
1.1 HIPOTEZE	1
2 PREGLED OBJAV	2
2.1 PROGRAMI ZA PREPOZNAVANJE PREDMETOV NA SLIKAH	2
2.2 NAČINI OZNAČEVANJA PREPOZNANIH PREDMETOV	3
2.3 R-CNN	3
2.4 YOLO	4
3 METODE DELA	6
3.1 IZBIRA ALGORITMOV ZA PREPOZNAVANJE PREDMETOV	6
3.2 IZDELAVA SPLETNE STRANI	7
3.3 IZBIRA IN PRIMERJAVA SLIK	9
4 REZULTATI	10
4.1 TESTIRANJE GLEDE NA ŠTEVILO OBJEKTOV	10
4.1.1 REZULTATI TESTIRANJA SLIK Z MALO OBJEKTI	10
4.1.2 REZULTATI TESTIRANJA SLIK S SREDNJE VELIKO OBJEKTI	11
4.1.3 REZULTATI TESTIRANJA SLIK Z VELIKO OBJEKTI	11
4.1.4 POVPREČNA NATANČNOST IN ČAS	12
4.2 TESTIRANJE GLEDE NA KAKOVOST SLIKE	13
4.3 UGOTOVITVE	14
5 DISKUSIJA	17
6 ZAKLJUČEK	21
7 POVZETEK	22
8 A SUMMARY	23
9 ZAHVALA	24
10 LITERATURA IN VIRI	25
11 PRILOGE	29

KAZALO TABEL

TABELA 1: PRIKAZ POVPREČNE NATANČNOSTI IN ŠTEVILA ZAZNANIH OBJEKTOV PRI TESTIRANJU ALGORITMOV YOLO IN MASK R-CNN Z MALO OBJEKTI	10
TABELA 2: PRIKAZ POVPREČNE NATANČNOSTI IN ŠTEVILA ZAZNANIH OBJEKTOV PRI TESTIRANJU ALGORITMOV YOLO IN MASK R-CNN S SREDNJE VELIKO OBJEKTI.....	11
TABELA 3: PRIKAZ POVPREČNE NATANČNOSTI IN ŠTEVILA ZAZNANIH OBJEKTOV PRI TESTIRANJU ALGORITMOV YOLO IN MASK R-CNN Z VELIKO OBJEKTI.....	11

KAZALO SLIK

SLIKA 1: NA LEVI SLIKI JE RISANJE KVADRATOV OKOLI PREDMETA, DESNA SLIKA PA PRIKAZUJE SEGMENTIRANJE PREDMETOV (OUAKNINE, 2018).	3
SLIKA 2: PRIKAZ DELOVANJA R-CNN MODELA (REMANAN, 2019)	4
SLIKA 3: PRIKAZ DELOVANJA YOLO-ALGORITMA (REMANAN, 2019).....	5
SLIKA 4: SPLETNA STRAN ALGORITMA YOLO (YOLO, 2019).....	6
SLIKA 5: IZPIS PO ZAGONU ALGORITMA YOLO.....	7
SLIKA 6: DEL JAVASCRIPTA NA NAJINI SPLETNI STRANI	8
SLIKA 7: UVODNA STRAN NAJINE SPLETNE STRANI	8
SLIKA 8: PRIMER PREPOZNAVE Z ALGORITMOM YOLO (LEVO) IN MASK R-CNN (DESNO).....	9
SLIKA 9: PRIMER, KO MASK R-CNN ZAZNA NEKAJ OBJEKTOV IZ OZADJA.....	15
SLIKA 10: NAPAKA PRI ZAZNAVU OBJEKTA Z ALGORITMOM MASK R-CNN.....	15
SLIKA 11: PRIMER NAPAKE ALGORITMA YOLO	16
SLIKA 12: NAPAKA ALGORITMA MASK R-CNN	16
SLIKA 13: TESTIRANO SLIKO 46 OBA ALGORITMA ZMOTNO ZAZNATA.	17
SLIKA 14: OZNAČENI PREDMETI V OZADJU Z ALGORITMOM MASK R-CNN (LEVO) IN YOLO (DESNO).....	18

KAZALO GRAFOV

GRAF 1: PRIMERJAVA POVPREČNE NATANČNOSTI ZAZNAVE ALGORITMOV YOLO IN MASK R-CNN	12
GRAF 2: PRIMERJAVA ČASA ZAZNAVE ALGORITMOV YOLO IN MASK R-CNN.....	13
GRAF 3: PRIKAZ POVPREČNE NATANČNOSTI ZAZNAVE BOLJŠE IN SLABŠE KAKOVOSTNIH SLIK..	13
GRAF 4: PRIKAZ ČASA ZAZNAVE SLABE IN VISOKE KAKOVOSTI SLIKE	14
GRAF 5: PRIMERJAVA HITROSTI ALGORITMOV YOLO IN MASK R-CNN PRI OBDELAVI PRVIH 10. TESTNIH SLIK.	18

KAZALO PRILOG

PRILOGA 1: 1. TESTNA SLIKA	29
PRILOGA 2: 2. TESTNA SLIKA	29
PRILOGA 3: 3. TESTNA SLIKA	29
PRILOGA 4: 4. TESTNA SLIKA	29
PRILOGA 5: 5. TESTNA SLIKA	29
PRILOGA 6: 6. TESTNA SLIKA	29
PRILOGA 7: 7. TESTNA SLIKA	29
PRILOGA 8: 8. TESTNA SLIKA	30
PRILOGA 9: 9. TESTNA SLIKA	30
PRILOGA 10: 10. TESTNA SLIKA	30
PRILOGA 11: 11. TESTNA SLIKA	30
PRILOGA 12: 12. TESTNA SLIKA	30
PRILOGA 13: 13. TESTNA SLIKA	30
PRILOGA 14: 14. TESTNA SLIKA	30
PRILOGA 15: 15. TESTNA SLIKA	31
PRILOGA 16: 16. TESTNA SLIKA	31
PRILOGA 17: 17. TESTNA SLIKA	31
PRILOGA 18: 18. TESTNA SLIKA	31
PRILOGA 19: 19. TESTNA SLIKA	31
PRILOGA 20: 20. TESTNA SLIKA	31
PRILOGA 21: 21. TESTNA SLIKA	31
PRILOGA 22: 22. TESTNA SLIKA	31
PRILOGA 23: 23. TESTNA SLIKA	32

PRILOGA 24: 24. TESTNA SLIKA	32
PRILOGA 25: 25. TESTNA SLIKA	32
PRILOGA 26: 26. TESTNA SLIKA	32
PRILOGA 27: 27. TESTNA SLIKA	32
PRILOGA 28: 28. TESTNA SLIKA	32
PRILOGA 29: 29. TESTNA SLIKA	32
PRILOGA 30: 30. TESTNA SLIKA	32
PRILOGA 31: 31. TESTNA SLIKA	33
PRILOGA 32: 32. TESTNA SLIKA	33
PRILOGA 33: 33. TESTNA SLIKA	33
PRILOGA 34: 34. TESTNA SLIKA	33
PRILOGA 35: 35. TESTNA SLIKA	33
PRILOGA 36: 36. TESTNA SLIKA	33
PRILOGA 37: 37. TESTNA SLIKA	33
PRILOGA 38: 38. TESTNA SLIKA	34
PRILOGA 39: 39. TESTNA SLIKA	34
PRILOGA 40: 40. TESTNA SLIKA	34
PRILOGA 41: 41. TESTNA SLIKA	34
PRILOGA 42: 42. TESTNA SLIKA	34
PRILOGA 43: 43. TESTNA SLIKA	34
PRILOGA 44: 44. TESTNA SLIKA	34
PRILOGA 45: 45. TESTNA SLIKA	34
PRILOGA 46: 46. TESTNA SLIKA	35
PRILOGA 47: 47. TESTNA SLIKA	35
PRILOGA 48: 48. TESTNA SLIKA	35
PRILOGA 49: 49. TESTNA SLIKA	35
PRILOGA 50: 50. TESTNA SLIKA	35

SEZNAM OKRAJŠAV

ŠC Šolski center

in sod. in sodelavci

npr. na primer

ipd. in podobno

MB megabajt

YOLO you only look once

R-CNN region based convultional neural networks

oz. oziroma

št. število

1 UVOD

Programi za prepoznavanje objektov lahko imajo zelo širok krog uporabe. Uporabljajo se za prepoznavanje črk v različnih zapisih, v kriminalistiki so zelo uporabni programi za prepoznavanje obrazov in prstnih odtisov, v avtomobilski industriji so še posebno v zadnjem času postali aktualni programi za prepoznavanje prometnih znakov ipd. Vsem tem programom pa je skupno to, da morajo zagotavljati izredno veliko zanesljivost pri prepoznavanju posameznih objektov.

V sodelovanju s podjetjem Gorenje, d. o. o., ki razvija med drugim tudi pametne hladilnike, sva se lotila raziskave zanesljivosti programov za prepoznavanje predmetov. V ta namen sva najprej izdelala spletno stran, ki nam omogoča zagon izbranega programa. Primerjala sva dva programa in njuno zanesljivost določala na podlagi testiranja s 50 slikami. Pri tem sva preverjala, koliko objektov je program pravilno zaznal, koliko jih je bilo napačno določenih in koliko jih je zgrešil. Primerjala sva tudi hitrosti v obdelavi slik. Testirala sva dva algoritma, YOLO (You Only Look Once) ter Mask R-CNN. Pri primerjanju obeh sva prišla do nekaterih zanimivih ter nepričakovanih ugotovitev.

Najina raziskava je lahko podlaga za razvoj aplikacije, s katero bi lahko uporabniki pametnih hladilnikov dostopali do podatka o tem, katera živila imajo v hladilniku in kakšen je njihov rok uporabe.

1.1 HIPOTEZE

1. Več objektov, kot je na sliki, več časa bo algoritem potreboval za njihovo prepoznavanje.
2. Algoritem YOLO bo hitrejši kot algoritem Mask R-CNN.
3. Algoritem Mask R-CNN bo natančnejši kot YOLO.
4. Uspelo nama bo izdelati spletno stran za zagon in detekcijo preko kamere.

2 PREGLED OBJAV

2.1 PROGRAMI ZA PREPOZNAVANJE PREDMETOV NA SLIKAH

Prepoznavanje predmetov je v današnjem času vse bolj zanimivo in uporabno na različnih področjih vsakdanjega življenja. Na ta način se računalniške tehnike zelo približajo praktični uporabi posameznikov, čeprav le-ti ne poznajo ozadja delovanja posameznih programov. Prepoznavanje predmetov uporabljamo v avtomobilski industriji za prepoznavanje prometnih znakov in avtonomno vožnjo, na novejših telefonih nam glede na zaznan predmet pomagajo optimizirati sliko ipd.

Vsi algoritmi za prepoznavanje predmetov na slikah delujejo na podlagi predhodno vnesenih ali shranjenih podatkov o raznih predmetih. Algoritem primerja zaznane predmete na sliki s podatki v bazi na podlagi njihove barve, oblike, robov, posebnih značilnosti in se s pomočjo nevronske mreže odloči, kateri predmet v njegovi bazi se najbolj ujema z zaznanim predmetom na sliki. Celoten sistem deluje na podlagi statistične obdelave, zato vsi programi za prepoznavanje predmetov na slikah ob prepoznavi podajo tudi podatek o verjetnosti ujemanja. Uporabniki algoritmov se lahko večinoma sami odločijo, kakšna je spodnja meja verjetnosti.

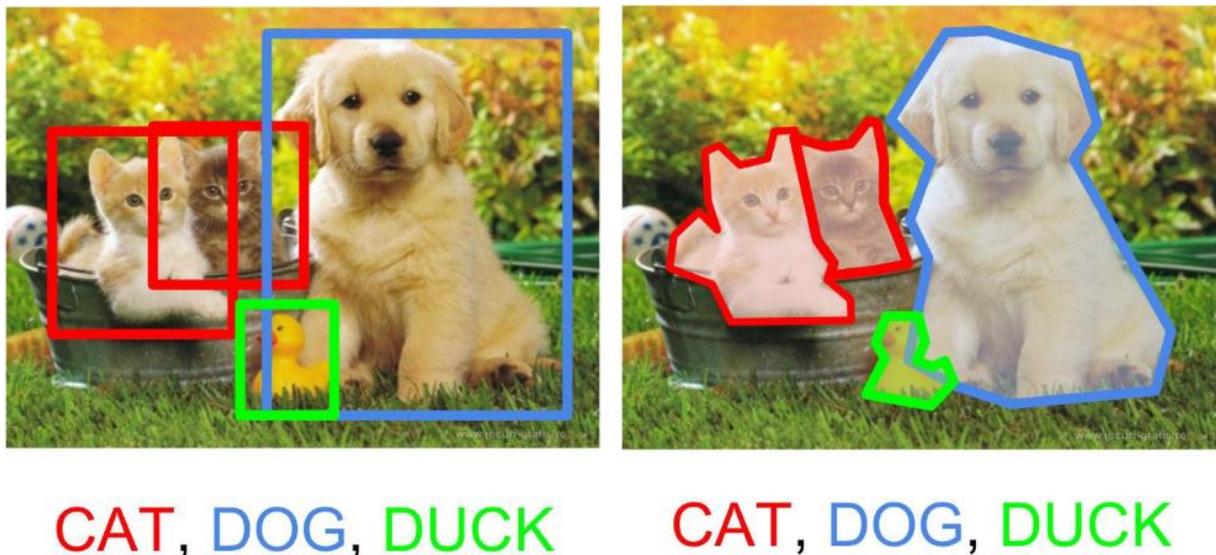
Strojno učenje se uporablja v vseh najpomembnejših področjih za analiziranje podatkov, generiranje novih algoritmov in podatkovnih baz ter tudi za učenje prepoznavanja in napovedi. Deluje na principu algoritmov, ki se učijo glede na že pridobljeno znanje. Osnovni namen je modeliranje pojavov iz podatkov, to pomeni, da se lahko odločajo glede podatkov in ne programiranja. Računalnik se tako uči in razvija, ne da bi bil programiran za vsako posamezno funkcijo, saj uporablja že prej shranjeno znanje, ki ga razvija in uporablja za pridobivanje novih podatkov. Strojno učenje je tesno povezano z umetno inteligenco, prepoznavanjem vzorcev in računalniško statistiko (Dalbelo Bašič, Šnajder, 2019).

Algoritmi za prepoznavanje objektov uporabljajo predvsem nadziran način strojnega učenja, pri katerem računalniku podamo slike z že vnaprej označenimi predmeti. Pri tem je pomembno, da je za en predmet podanih čim več slik iz različnih zornih kotov in v različnih svetlobnih pogojih, saj na ta način povečamo možnost pravilnega zaznavanja in odstranimo neželene detekcije.

Druga možnost je nenadziran način učenja, ki pa je malce bolj zahteven in nepredvidljiv, ampak ima zato tudi skupno večji potencial. Računalnik za učenje uporablja vse vhodne informacije, ki niso predhodno pregledane in predelane, zato mora računalnik sam najti vzorec med njimi (Fuks, Ravnak, 2018).

2.2 NAČINI OZNAČEVANJA PREPOZNANIH PREDMETOV

Prepoznavanje predmetov je pogost problem strojnega vida, ki se ukvarja z identificiranjem in lociranjem objektov v sliki. Interpretacija objekta se lahko naredi na več načinov. Eden izmed teh je risanje kvadrata okoli prepoznanega predmeta, drugi pa je označevanje vsakega piksla, ki je del predmeta. Slednji deluje na principu segmentiranja (Ganesh, 2019).



Slika 1: Na levi sliki je risanje kvadratov okoli predmeta, desna slika pa prikazuje segmentiranje predmetov (Ouaknine, 2018).

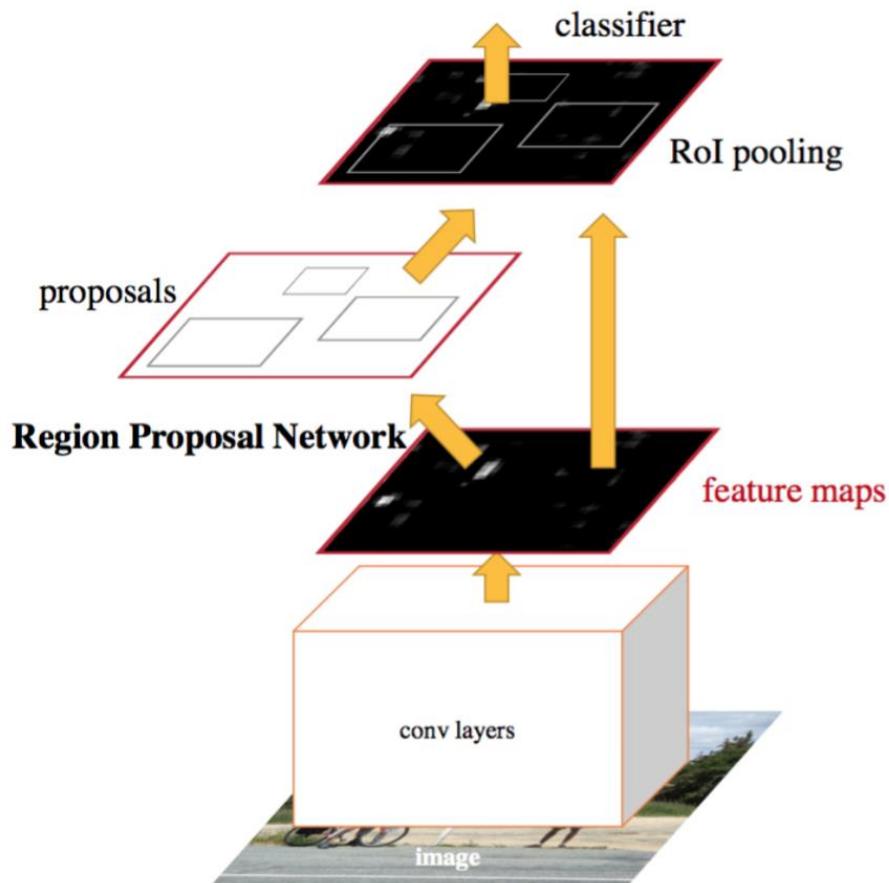
2.3 R-CNN

Mask R-CNN je eden od algoritmov za detekcijo objektov, ki sva se jih odločila podrobneje proučiti. Osnova njegovega delovanja izhaja iz algoritma Faster R-CNN, ta pa za detekcijo uporablja model R-CNN. R-CNN je kratica za regionalno zasnovane konvolucijske nevronske mreže (Region based Convolutional Neural Networks).

Namesto da bi algoritem šel čez vsak piksel, ali da bi procesiral veliko število regij, algoritem R-CNN oblikuje veliko število okvirjev in znotraj teh okvirjev pregleduje, ali vsebuje kateri od njih kakšen objekt. Nato prikaže tiste okvirje, ki vsebujejo objekte iz naše zbirke (Sharma, 2019).

Slabost prvotnega algoritma R-CNN je v njegovi počasni obdelavi slik. Ravno zaradi tega so razvili sodobnejše različice, kot sta Fast R-CNN in Faster R-CNN, ki procesiranje slik opravljata bistveno hitreje (Sharma, 2019).

Mask R-CNN se od ostalih razlikuje po tem, da za prikazovanje zaznanih objektov uporablja segmentacijo.

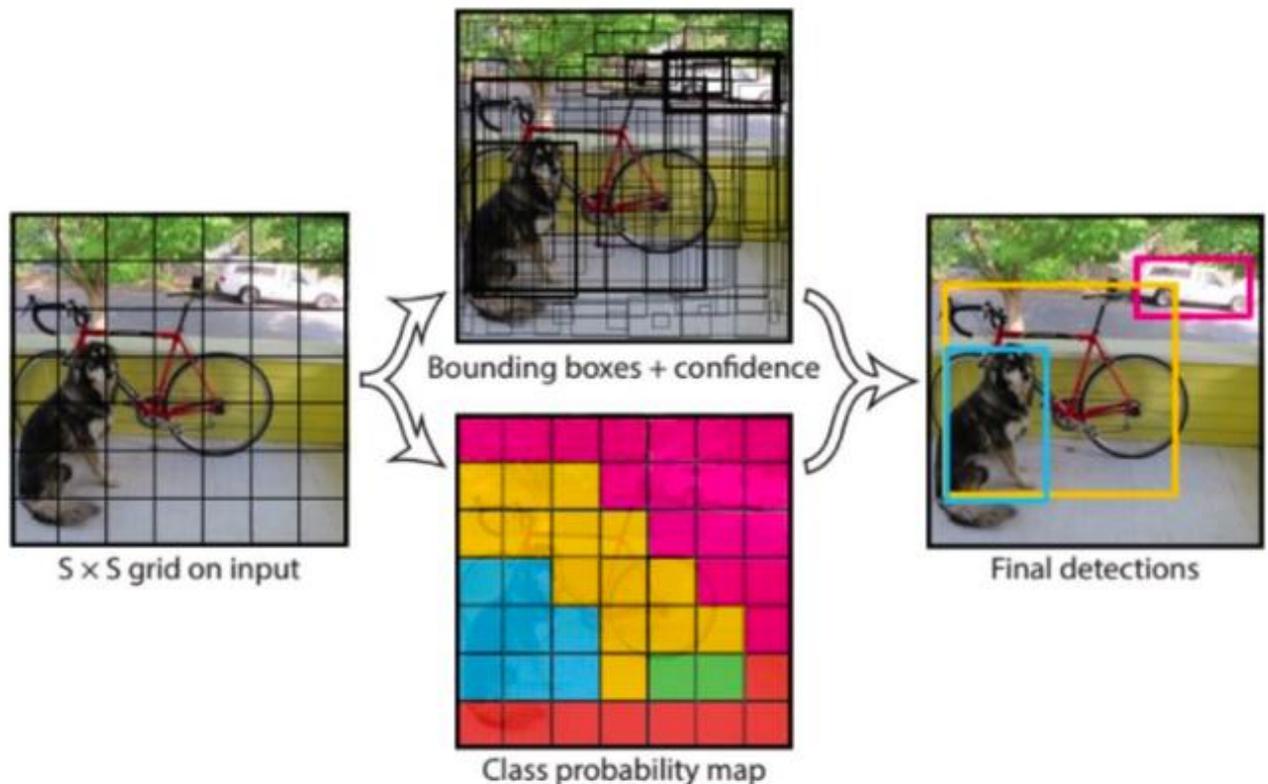


Slika 2: Prikaz delovanja R-CNN modela (Remanan, 2019)

2.4 YOLO

Večina algoritmov slike najprej pregleda in ugiba, kje na sliki je največja verjetnost, da se nahajajo objekti, ter kje se objekti zagotovo ne bodo nahajali, in jo razdeli v regije. Za razliko od ostalih algoritmov za zaznavanje objektov YOLO (You Only Look Once) slike predhodno ne razdeli na regije, vendar deluje algoritem zaznavanja na celotni sliki. Najprej na sliko nariše mrežo dimenzij $S \times S$. Znotraj te mreže oblikuje okvirje z večjo verjetnostjo nahajanja predmetov, predmete detektira in jih prikaže v okvirjih. Glede na predhodno naučene

informacije o objektih, YOLO prikaže tudi, kakšna je verjetnost, da se v danem okvirju nahaja predmet, ki ga je zaznal (Remanan, 2019).



Slika 3: Prikaz delovanja YOLO-algoritma (Remanan, 2019)

Prednost algoritma YOLO je v tem, da je zelo hiter. Zaradi svoje hitrosti omogoča tudi zaznavanje objektov v realnem času, kot na primer video. Zato je zelo uporaben v različnih življenjskih situacijah, kot na primer nadzor prometa, gibanje ljudi na ulicah in v prostoru ipd. Hitrost algoritma je odvisna od zmogljivosti računalnika, ki ga poganja. Če algoritem deluje s pomočjo grafičnega procesorja in ne samo glavnega procesorja, je lahko tudi več kot 10 x hitrejši.

Slabost algoritma YOLO pa je njegova omejenost pri zaznavanju manjših objektov, kot so na primer jata ptic. Težava se pojavi zaradi prostorske omejenosti algoritma, saj je mreža, ki jo nariše, lahko večja, kot objekt sam (Remanan, 2019).

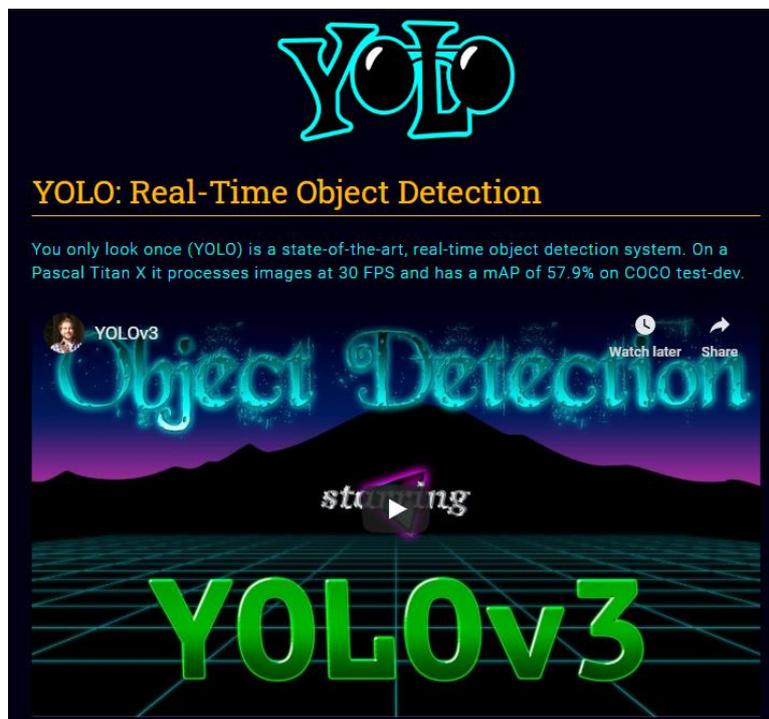
3 METODE DELA

3.1 IZBIRA ALGORITMOV ZA PREPOZNAVANJE PREDMETOV

Ker sva se želela seznaniti s tem, kakšne lastnosti bi moral imeti program za prepoznavanje objektov v hladilnikih, sva se odločila najprej primerjati lastnosti algoritmov, ki jih že lahko najdemo na spletu. Pregledala sva več odprtokodnih algoritmov in se nato odločila za uporabo ter primerjavo dveh, ki delujeta po različnih principih.

Ta dva algoritma sta YOLO in Mask R-CNN. Oba algoritma imata določene posebnosti, ki so pritegnile najino pozornost. Ker se tako razlikujeta med sabo, sva ju želela podrobneje preučiti.

Za YOLO sva se odločila, ker naj bi bil po avtorjevih testih najhitrejši in je narejen po čisto drugačnem principu, kot večina ostalih. Deluje tako, da sliko pregleda le enkrat, iz česar izhaja tudi njegovo ime – You Only Look Once. Sliko razdeli na mrežo in v vsakem predelu mreže pregleda, ali se v njem nahaja predmet. Nato ta predmet primerja s predmeti, ki jih ima v knjižnici. Če se s katerim ujema, ga označi tako, da okoli njega nariše kvadrat ter zapiše ime predmeta. Ravno to, da sliko pregleduje le enkrat, je njegova največja prednost, saj se s tem poveča hitrost zaznavanja. Slabost je le v tem, da ne prepozna majhnih predmetov.



Slika 4: Spletna stran algoritma YOLO (YOLO, 2019)

Mask R-CNN sva izbrala, ker je tudi ta malce drugačen od ostalih, saj zaznane predmete prikaže s pomočjo segmentacije. Pričakovala sva, da naj bi bila pravilnost zaznavanja predmetov zelo visoka, hitrost pa manjša, kot pri YOLO.

Algoritem YOLO sva našla z lahkoto, saj ima svojo spletno stran, kjer je predstavljen in kjer so navodila za nalaganje ter uporabo. Naložila sva ga s spletne strani GitHub, kjer razvijalci večkrat objavijo izvirne kode za algoritme ali programe. Algoritem Mask R-CNN sva prav tako našla na spletni strani GitHub. Ker je odprtokodni, sva ga lahko brez težav naložila. Preden pa sva ju lahko začela uporabljati, sva morala na računalnik naložiti še nekaj dodatne programske opreme. Najprej sva naložila Oracle VM VirtualBox, preko katere sva lahko naredila virtualni računalnik, ki ga je poganjal operacijski sistem Ubuntu Linux. Za Linux sva se odločila, ker sta algoritma napisana tako, da zahtevata nekatere od Linuxovih ukazov. Naložiti sva morala še Python ter nekaj dodatnih knjižnic zanj.

```
95 route 91 -> 26 x 26 x 256
96 conv 128 1 x 1/ 1 26 x 26 x 256 -> 26 x 26 x 128 0.044 BF
97 upsample 2x 26 x 26 x 128 -> 52 x 52 x 128
98 route 97 36 -> 52 x 52 x 384
99 conv 128 1 x 1/ 1 52 x 52 x 384 -> 52 x 52 x 128 0.266 BF
100 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
101 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
102 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
103 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
104 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
105 conv 255 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 255 0.353 BF
106 yolo
[yolo] params: iou loss: mse (2), iou_norm: 0.75, cls_norm: 1.00, scale_x_y: 1.00
Total BFLOPS 65.864
Loading weights from yolov3.weights...
seen 64
Done! Loaded 107 layers from weights-file
data/horses.jpg: Predicted in 6664.380000 milli-seconds.
horse: 88%
horse: 99%
horse: 96%
horse: 99%
Not compiled with OpenCV, saving to predictions.png instead
```

Slika 5: Izpis po zagonu algoritma YOLO

3.2 IZDELAVA SPLETNE STRANI

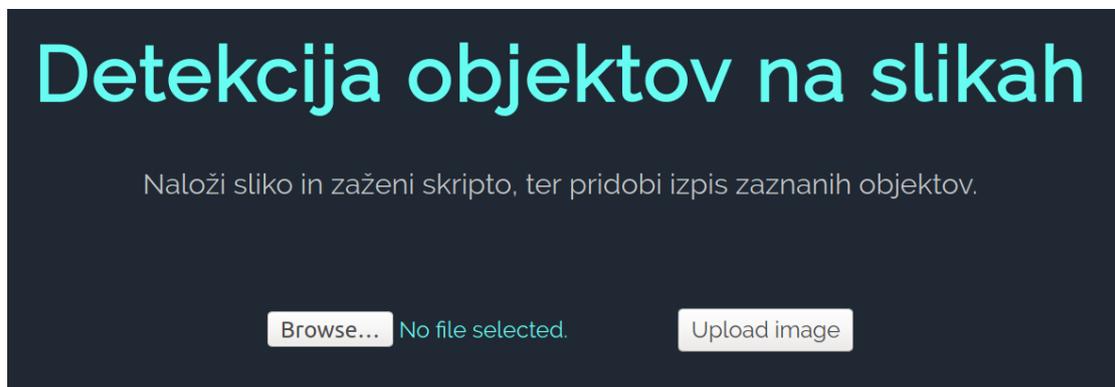
Ko sva začela pregledovati slike, sva ugotovila, kako zamudno je lahko to delo in koliko predpriprav rabiš, preden lahko detekcijo sploh zaženeš. Ker sva želela drugim uporabnikom omogočiti čim enostavnejše pregledovanje slik, sva se odločila za izdelavo spletne strani. Ta spletna stran je dobra podlaga za izdelavo aplikacije, ki bi jo lahko uporabljali tudi za pregledovanje predmetov oziroma izdelkov v hladilnikih, kar je bil tudi osnovni namen najine naloge.

Spletna stran je oblikovana z uporabo HTML in CSS, funkcionalnost pa dobi z jezikom PHP ter malo Javascripta. Stran uporablja za detekcijo objektov algoritem YOLO, ki ga sama zažene ter oblikuje izpis tako, da nam izpiše sigurnost zaznanega predmeta in kje na sliki se le-ta nahaja. Spletna stran deluje tako, da sliko naložimo in najprej preveri, če je datoteka res slika. Nato preveri, če je slika manjša od 5 MB. Če ustreza vsem kriterijem, se slika naloži in algoritem se zažene. Ko algoritem zaključi z delom, nam izpiše vse podatke o zaznanih objektih ter nam pokaže sliko z označenimi predmeti.

```
var x = `<?php echo $izpis; ?>`;
var razdeljeno = x.split("seconds.")[1].split("\n").filter(x => x != "");
console.log(razdeljeno);
for (var i = 0; i < razdeljeno.length; i+=1) {
  document.write(razdeljeno[i]);
  document.write("<br>");
}

function moveForward() {
  var link = `kopiraj.php?data=${JSON.stringify(razdeljeno)}`;
  window.location = link;
}
```

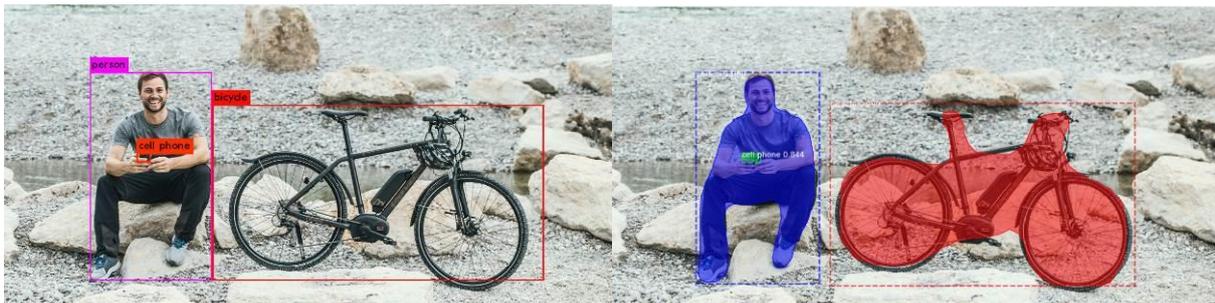
Slika 6: Del Javascripta na najini spletni strani



Slika 7: Uvodna stran najine spletne strani

3.3 IZBIRA IN PRIMERJAVA SLIK

Za primerjavo učinkovitosti in natančnosti obeh algoritmov sva izbrala 50 različnih slik. Slike sva dobila na spletu. Edini pogoj za izbiro slik je bil, da vsebujejo različne objekte. Pozorna sva bila tudi na to, da imajo slike različno število objektov. Tako sva lahko primerjala tudi hitrost in natančnost z manj oziroma več objekti na eni sliki ter tudi preverjala, kako se hitrost in pa natančnost spreminjata glede na kakovost slike. Vse izbrane slike sva dodala kot prilogo raziskovalne naloge (glej Priloga 1).



Slika 8: Primer prepoznave z algoritmom YOLO (levo) in Mask R-CNN (desno)

Testiranja sva se lotila tako, da sva na vsaki od 50 slik izvedla prepoznavo objektov z algoritmom YOLO in Mask R-CNN, ob tem pa sva si zabeležila še čas, ki ga je algoritem potreboval za izvedbo, natančnost prepoznave posameznega objekta in pa povprečno natančnost vseh objektov na sliki. Spremljala pa sva tudi razne napake in posebnosti ter razlike med algoritmoma.

4 REZULTATI

Algoritma YOLO in Mask R-CNN sva testirala na podlagi 50 slik. Opazovala sva število zaznanih objektov, čas, ki je bil potreben za zaznavo in natančnost. Testiranje sva razdelila na 2 dela, v prvem sva bila pozorna, kako se rezultati spreminjajo glede na število objektov na sliki, v drugem delu pa glede na kakovost (resolucijo) slike.

4.1 TESTIRANJE GLEDE NA ŠTEVILO OBJEKTOV

Testiranje glede na število objektov sva izvedla v treh korakih. Najprej sva testirala 10 slik z malo objekti (2–4 objektov na sliko), nato 10 slik s srednje veliko objekti (5–11 objektov na sliko) in na koncu še 10 slik z veliko objekti (8–29 objektov na sliko).

4.1.1 REZULTATI TESTIRANJA SLIK Z MALO OBJEKTI

Tabela 1: Prikaz povprečne natančnosti in števila zaznanih objektov pri testiranju algoritmov YOLO in Mask R-CNN z malo objekti

Slika	Št. objektov YOLO	Št. objektov Mask R-CNN	Povprečna natančnost YOLO	Povprečna natančnost Mask R-CNN
Slika 1	3	3	99,33 %	94,77 %
Slika 2	4	4	99,75 %	99,68 %
Slika 3	3	4	90,67 %	99,83 %
Slika 4	2	2	74,67 %	98,33 %
Slika 5	2	1	90 %	99,9 %
Slika 6	4	4	100 %	100 %
Slika 7	3	4	100 %	98,25 %
Slika 8	3	2	82,75 %	99,9 %
Slika 9	2	2	99,5 %	100 %
Slika 10	3	3	99,33 %	99,93 %
SKUPAJ	29	28	93 %	99,06 %

S tabele je razvidno, da sta oba algoritma zaznala skoraj enako število objektov in ne prihaja do večjih razlik o številu objektov na posamezni fotografiji, največ za 1 objekt. Pri preučevanju natančnosti opazimo, da je algoritem Mask R-CNN natančnejši s povprečno natančnostjo 99,06 % in predvsem bolj konstanten. Kljub še vedno visoki natančnosti algoritma YOLO (93 %), je ta še vedno manj natančen od algoritma Mask R-CNN. To se še posebej kaže na četrti in osmi sliki.

4.1.2 REZULTATI TESTIRANJA SLIK S SREDNJE VELIKO OBJEKTI

Tabela 2: Prikaz povprečne natančnosti in števila zaznanih objektov pri testiranju algoritmov YOLO in Mask R-CNN s srednje veliko objekti

Slika	Št. objektov YOLO	Št. objektov Mask R-CNN	Povprečna natančnost YOLO	Povprečna natančnost Mask R-CNN
Slika 11	3	5	88 %	97,80 %
Slika 12	6	8	80,83 %	93,21 %
Slika 13	6	8	97,67 %	96,49 %
Slika 14	6	7	98,67 %	97,73 %
Slika 15	8	7	93,75 %	99,23 %
Slika 16	9	11	73 %	93,17 %
Slika 17	6	7	100 %	98,97 %
Slika 18	8	9	95,88 %	94,66 %
Slika 19	11	11	90,09 %	94,05 %
Slika 20	5	9	94,8 %	94,03 %
SKUPAJ	67	82	91,27 %	95,93 %

Pri testiranju slik s srednje veliko objekti pa se že kažejo večje razlike pri številu zaznanih objektov in tukaj je zmagovalec algoritem Mask R-CNN, saj je prepoznal kar 15 objektov več. Ko primerjamo natančnost, je zgodba enaka kot pri testiranju slik z malo objekti, saj se je algoritem Mask R-CNN spet bolje odrezal od algoritma YOLO, se pa je pri obeh natančnost zmanjšala, ampak je vseeno visoka, saj je pri obeh povprečna natančnost višja od 90 %.

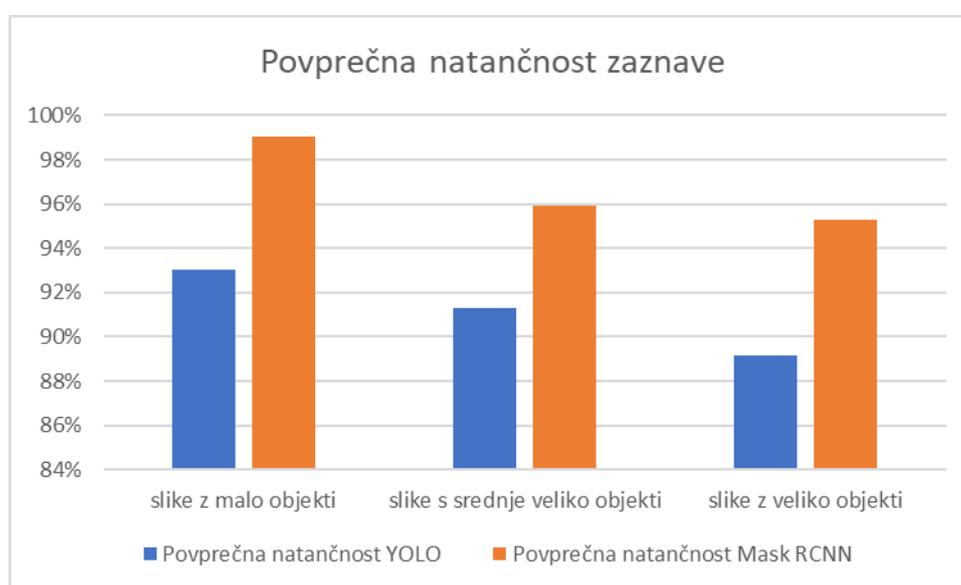
4.1.3 REZULTATI TESTIRANJA SLIK Z VELIKO OBJEKTI

Tabela 3: Prikaz povprečne natančnosti in števila zaznanih objektov pri testiranju algoritmov YOLO in Mask R-CNN z veliko objekti

Slika	Št. objektov YOLO	Št. objektov Mask R-CNN	Natančnost YOLO	Natančnost Mask R-CNN
Slika 21	14	14	91,71 %	99,45 %
Slika 22	15	16	95,4 %	94,77 %
Slika 23	18	21	89,67 %	94,6 %
Slika 24	29	20	82,03 %	91,26 %
Slika 25	11	13	94,64 %	94,63 %
Slika 26	16	16	86,5 %	94,48 %
Slika 27	8	9	77,38 %	92,66 %
Slika 28	11	11	97,82 %	99,5 %
Slika 29	11	9	92,45 %	98,78 %
Slika 30	5	8	84 %	92,48 %
SKUPAJ	138	137	89,16 %	95,26 %

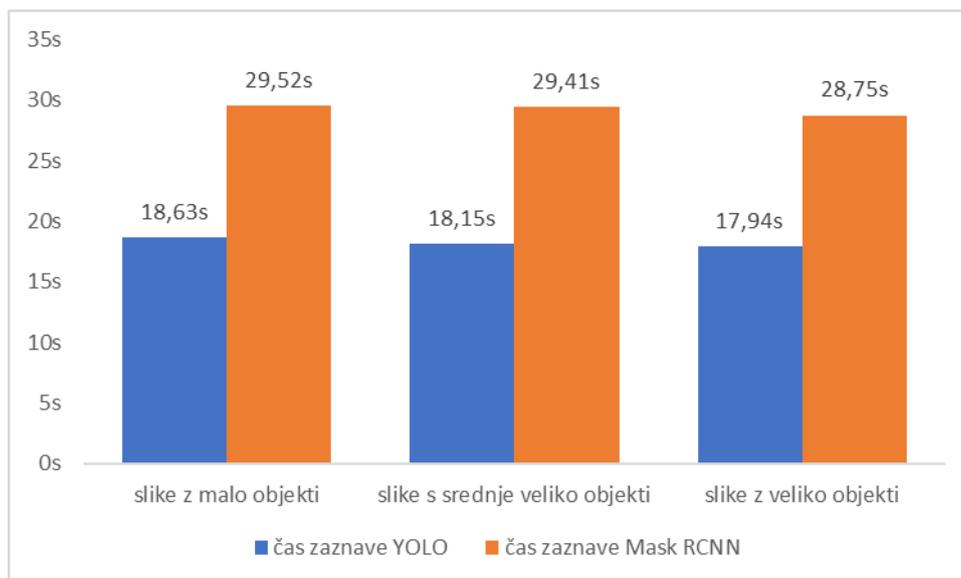
Ko opazujemo skupno število zaznanih objektov, ne opazimo več takšne razlike, kot pri testiranju slik s srednje veliko objekti, a ko pogledamo posamezne slike, opazimo večja nihanja tudi za 9 objektov na sliki 24. Večjo povprečno natančnost je spet pokazal algoritem Mask R-CNN, ki je še zmeraj višja od 95 %, medtem ko je pri algoritmu YOLO malo pod 90%, kar pa je še vseeno veliko. Kljub velikemu številu objektov je algoritem Mask R-CNN zelo konstanten, saj so posamezne povprečne natančnosti znotraj 10 %, medtem ko se pri algoritmu YOLO razlikujejo tudi za več kot 20 %, ampak podobno je bilo pri testiranju slik z malo in srednje veliko objekti.

4.1.4 POVPREČNA NATANČNOST IN ČAS



Graf 1: Primerjava povprečne natančnosti zaznave algoritmov YOLO in Mask R-CNN

Na grafu se lepo vidi, da natančnost pada s številom objektov, le da je pri algoritmu YOLO padec malo bolj očiten, medtem ko začne pri Mask R-CNN natančnost padati, saj je razlika v natančnosti med slikami s srednje veliko objekti in slikami z veliko objekti manjša od 1 %.

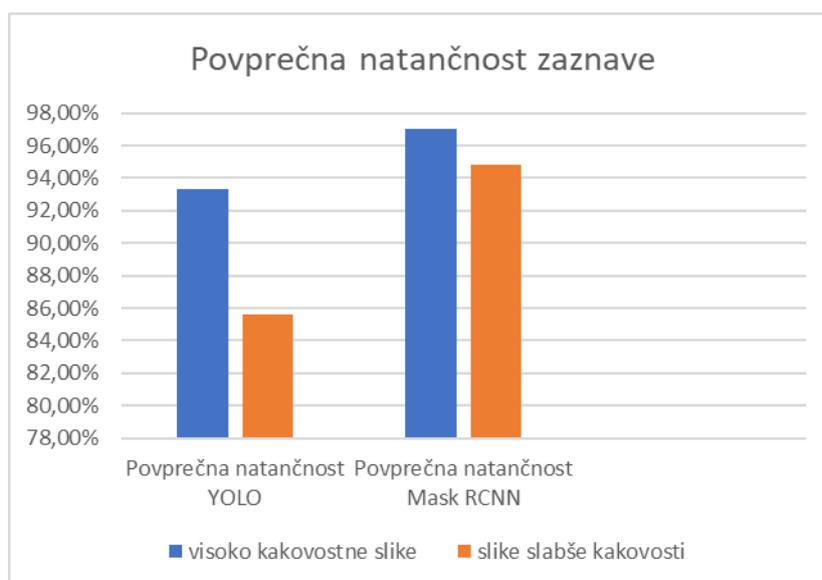


Graf 2: Primerjava časa zaznave algoritmov YOLO in Mask R-CNN

Na grafu je lepo razvidno, da je algoritem YOLO za več kot 10 sekund hitrejši od algoritma Mask R-CNN, kar pa je logično, saj je algoritem Mask R-CNN natančnejši in za izvedbo potrebuje več časa. Malo manj logičen pa je rezultat, da se čas, ki je potreben za izvedbo algoritmov, ne veča s številom objektov, ki so na sliki, ampak celo malo pada.

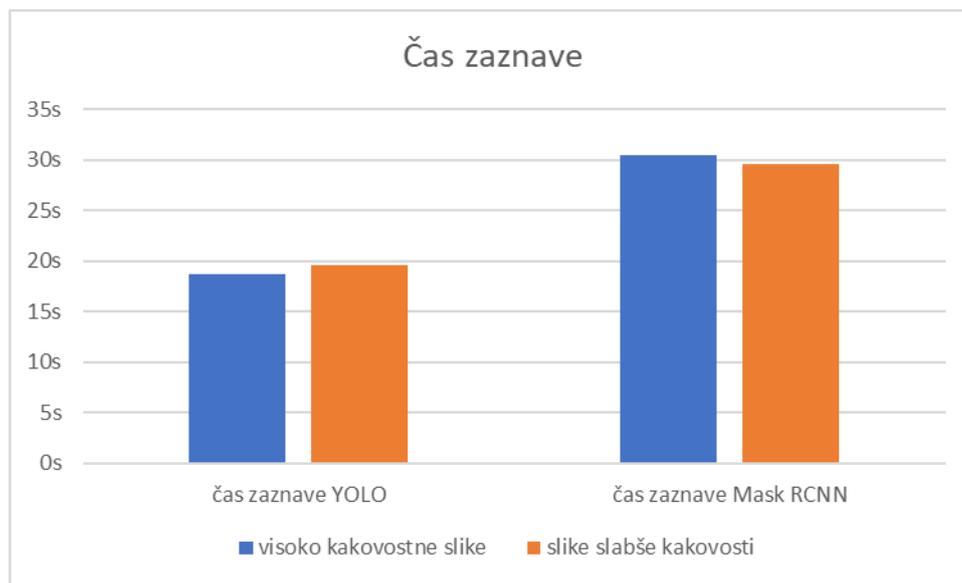
4.2 TESTIRANJE GLEDE NA KAKOVOST SLIKE

Drugi del testiranja pa sva izvedla tako, da sva vzela 10 slik s slabšo kakovostjo, vse do 720 x 480 slikovnih pik, in pa 10 slik z boljšo kakovostjo, 2160 x 3840 slikovnih pik in več.



Graf 3: Prikaz povprečne natančnosti zaznave boljše in slabše kakovostnih slik

Na grafu se lepo vidi, da je algoritem Mask R-CNN spet dosegel višjo povprečno natančnost kot algoritem YOLO, vidi pa se tudi razlika v natančnosti med slabše in boljše kakovostnimi slikami, ki pa ni pretirana. Čeprav se kaže slabša natančnost obeh algoritmov pri slabši kakovosti slik, je jasno, da to ni edini niti glavni razlog za natančnost zaznave, kar se kaže pri posameznih primerih. Največja natančnost slabše kakovostne slike je enaka 99,90 %, najslabša natančnost visoko kakovostne slike pa je enaka 67,36 %, kar potrjuje, da kakovost slike nima bistvenega pomena pri natančnosti. Če pa bi želeli natančnejše rezultate, bi morali uporabiti 10 enakih slik v različni kakovosti.



Graf 4: Prikaz časa zaznave slabe in visoke kakovosti slike

Na grafu lahko opazimo, da je algoritem YOLO bistveno hitrejši, kar pa je še bolj zanimivo, je to, da algoritem Mask R-CNN potrebuje manj časa za slike slabše kakovosti, medtem ko pa YOLO potrebuje manj časa za zaznavo visoko kakovostnih slik.

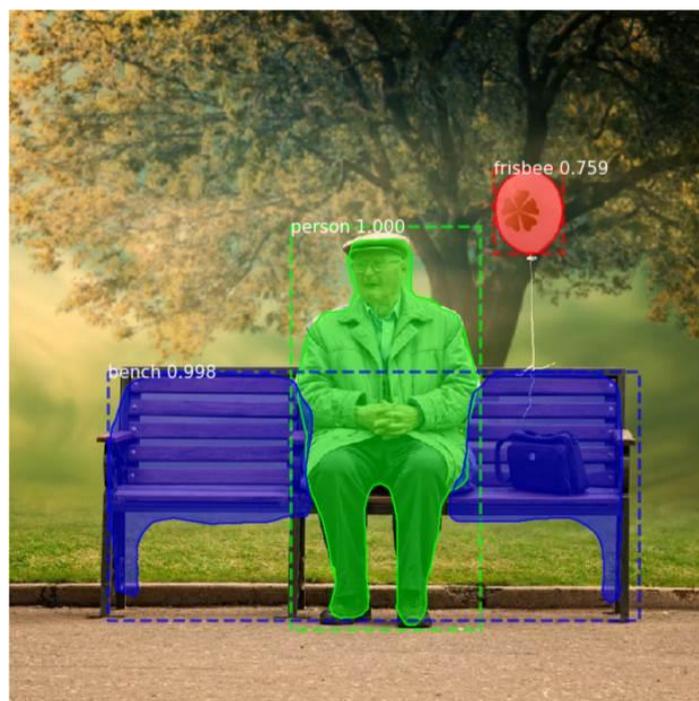
4.3 UGOTOVITVE

Med testiranjem sva zasledila tudi nekaj nepričakovanih pozitivnih in negativnih rezultatov.



Slika 9: Primer, ko Mask R-CNN zazna nekaj objektov iz ozadja.

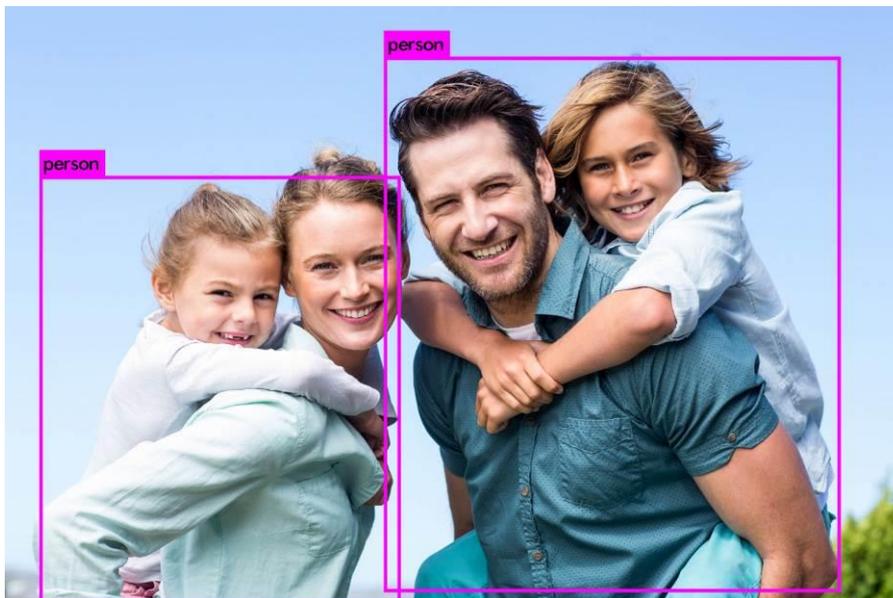
Pri algoritmu Mask R-CNN sva opazila, da velikokrat zazna nekaj objektov iz ozadja, ki so zelo slabo vidni.



Slika 10: Napaka pri zaznavi objekta z algoritmom Mask R-CNN

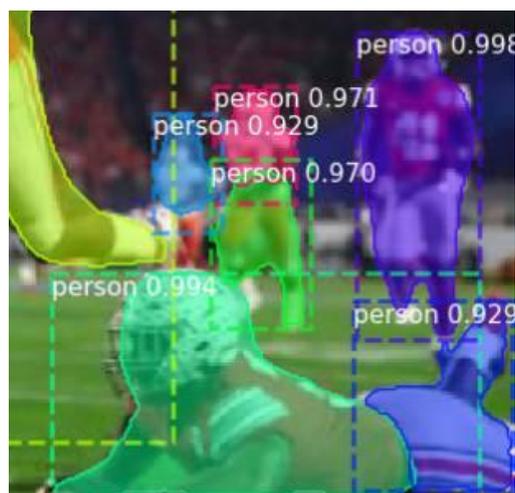
Večkrat sva opazila, da je algoritem Mask R-CNN zaznal kakšen predmet narobe, kar se je zgodilo tudi na zgornji sliki, ko je balon zaznal kot frizbi, kar pa je še bolj zanimivo, je to, da je do teh napak prihajalo predvsem na slikah z manjšim številom objektov. Na zgornji sliki je še ena pomanjkljivost, in sicer algoritem ni zaznal torbe, je pa to redka napaka. Tudi

algoritem YOLO je zaznal nekaj predmetov narobe, ampak je bila ta napaka bolj izrazita pri Mask R-CNN.



Slika 11: Primer napake algoritma YOLO

Ena od pogostejših napak je bila tudi, da sta algoritma YOLO in Mask R-CNN zaznala dva človeka kot enega. Zanimivo je to, da sta se skoraj zmeraj oba zmotila na isti sliki. Ni jima bila tuja niti napaka, da enega človeka zaznata kot 2, ampak je bila manj pogosta in se je kazala predvsem pri algoritmu Mask R-CNN.

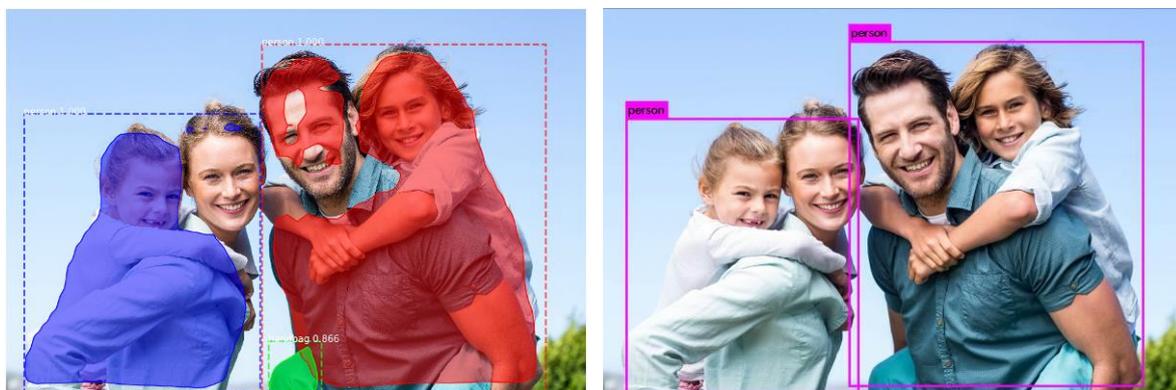


Slika 12: Napaka algoritma Mask R-CNN

5 DISKUSIJA

Algoritmi za prepoznavanje predmetov se med seboj razlikujejo po različnih lastnostih. Delujejo lahko na različnih principih in zato so lahko rezultati zadetkov med posameznimi algoritmi različni, čeprav obdelujemo isto sliko. Če hočemo ugotoviti, kateri algoritem je bolj primeren za naše potrebe, v našem primeru za uporabo v pametnem hladilniku, je najboljše predhodno testirati čim več različnih algoritmov in različnih parametrov znotraj teh algoritmov.

Pri testiranju dveh algoritmov, YOLO in Mask R-CNN, sva ugotovila, da je bistvena razlika med njima predvsem v hitrosti obdelave slike, vendar pa se razlikujeta tudi v pravilnosti označenih zaznanih predmetov. Določanje natančnosti je lahko zavajajoče, če upoštevamo zgolj verjetnost, ki jo program izpiše ob vsakem najdenem predmetu. Čeprav program izpiše visoko stopnjo natančnosti, še vedno ne pomeni, da je vse predmete na sliki pravilno zaznal. Lahko se zgodi, da kakšnega predmeta ne prepozna, ali pa celo, da je prepoznal predmet, ki ga tam ni in je del nekega drugega objekta.

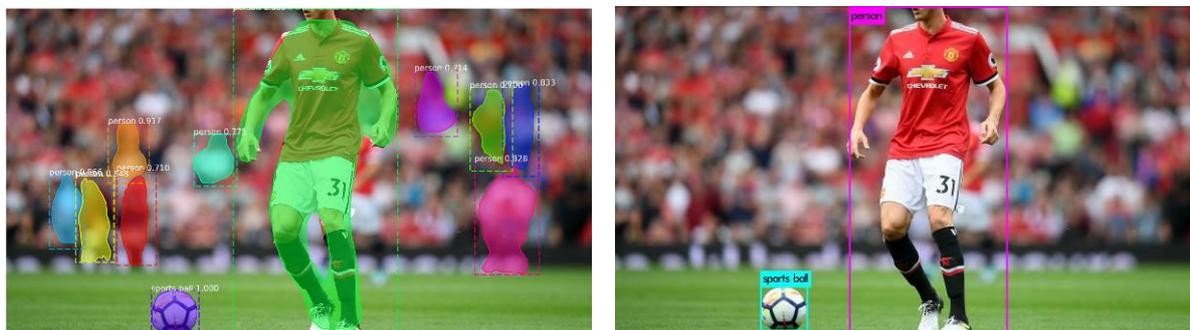


Slika 13: Testirano sliko 46 oba algoritma zmotno zaznata.

Na zgornjih dveh slikah lahko vidimo, da je algoritem Mask R-CNN (levo) zaznal kot dve osebi, pri čemer je dve osebi izpustil. Na sliki je označil tudi torbico, čeprav je to del noge otroka. Prav tako je algoritem YOLO (desno) na sliki zaznal dve osebi, čeprav so na sliki štiri, vendar pa nobene osebe ni izpustil pri označevanju. Pri obeh algoritmih je zapisana 100 % verjetnost prepoznavanja objektov.

Pri obdelavi slik z več predmeti algoritem Mask R-CNN najde in pravilno označi veliko več predmetov, kot algoritem YOLO, ki označi le tistega, ki najbolj izstopa. Mask R-CNN

prepozna tudi predmete v ozadju in tudi zamegljene predmete, ki niso v ospredju slike. To lahko vidimo na spodnji sliki, kjer imamo primerjavo med tema dvema algoritmoma.

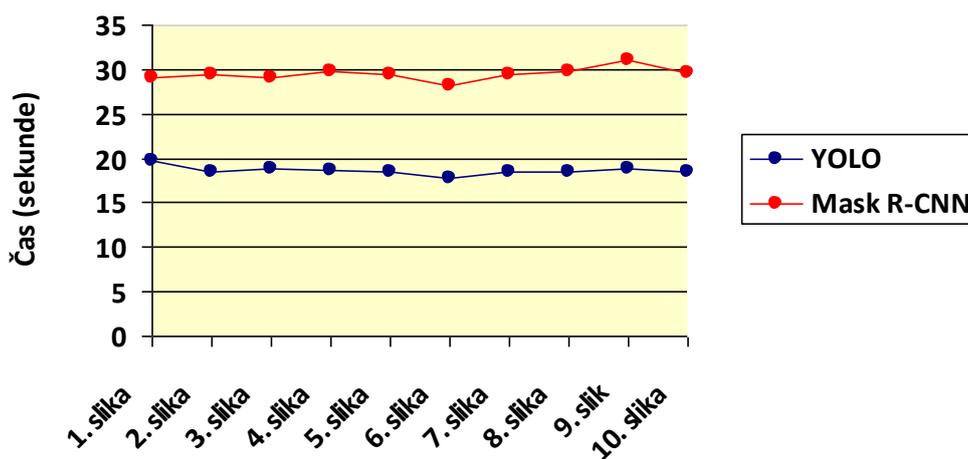


Slika 14: Označeni predmeti v ozadju z algoritmom Mask R-CNN (levo) in YOLO (desno)

Iz zgornje slike je razvidno tudi, da jasnost oziroma ostrina slike pri algoritmu Mask R-CNN ne igra pomembne vloge, medtem ko YOLO zamegljenih osebkov v ozadju ni zaznal.

Zaradi načina obdelave slike je algoritem YOLO hitrejši, kot algoritem Mask R-CNN. Zaradi svoje hitrosti lahko obdeluje tudi videoposnetke. Zanimivo je, da sta oba algoritma hitrejša pri obdelavi slik z več predmeti, kar ravno ni bilo v najinih pričakovanjih.

V prvi hipotezi sva predvidevala, da bo algoritem potreboval več časa, če bo slika vsebovala več objektov. Izkazalo se je ravno nasprotno, saj sta oba algoritma potrebovala malo več časa pri zaznavi slik z manj objekti.



Graf 5: Primerjava hitrosti algoritmov YOLO in Mask R-CNN pri obdelavi prvih 10. testnih slik.

Druga hipoteza, v kateri sva predvidela, da bo algoritem YOLO hitrejši od algoritma Mask R-CNN, se je izkazala za pravilno. V grafu 5 lahko vidimo primerjavo hitrosti med obema algoritmoma pri obdelavi prvih desetih testnih slik. Algoritem YOLO je bil pri obdelavi vseh testiranih slik hitrejši za približno 10 sekund.

Tretja hipoteza se je glasila: »Algoritem Mask R-CNN bo natančnejši, kot YOLO.« Pri slikah s srednje veliko objekti je algoritem Mask R-CNN res natančnejši. Pri slikah z malo objekti pa algoritem Mask R-CNN včasih zazna predmete, ki jih na sliki dejansko ni. Pri slikah z malo in veliko objekti je število zaznanih predmetov pri obeh algoritmih skoraj enako. Torej lahko hipotezo potrdiva le za slike s srednje veliko objekti, pri ostalih pa hipoteza ne drži.

Za četrto hipotezo sva si zadala cilj izdelati spletno stran, preko katere bomo lahko zagnali detekcijo objektov in detekcijo izvajali tudi nad video posnetkih oziroma v živo. Prvi del naloge nama je uspel, saj lahko na spletno stran naložimo sliko in zaženemo detekcijo ter dobimo izpisano sliko ter predmete, ki so na njej. Drugi del naloge, torej detekcija nad videi in v živo preko kamere, pa nama ni uspel, saj bi za takšno spletno stran potrebovali zelo zmogljiv računalnik in internet visoke hitrosti. Tako lahko tudi četrto hipotezo le delno potrdiva.

Če povzameva vse rezultate, lahko ugotovitve uporabiva v povezavi z izdelavo algoritmov za pametne hladilnike. Algoritem, ki bi ga lahko uporabili v pametnih hladilnikih, bi moral delovati po principu algoritma Mask R-CNN, saj je le-ta bolj natančen. V hladilniku namreč ne potrebujemo velikih hitrosti obdelave slike, saj se vsebina hladilnika ne spreminja tako hitro. Osveževanje detekcije vsake nekaj minut bi bilo tako čisto dovolj. Prav tako v hladilniku ne bi potrebovali zelo natančne kamere, saj sva ugotovila, da resolucija slike nima bistvenega vpliva na natančnost prepoznavanja predmetov. Največjo težavo vidiva v zelo velikem številu izdelkov, ki so lahko različno pakirani, prav tako pa lahko imajo različni izdelki zelo podobne embalaže (npr. mleko v tetrapaku in sok v tetrapaku, jogurt in kislá smetana). Za dovolj veliko natančnost prepoznavanja izdelkov bi bilo potrebno izdelati izredno obsežno knjižnico. Prav tako bi bilo potrebno redno osveževati knjižnico, saj proizvajalci neprestano spreminjajo embalaže. Algoritem v večji meri deluje po principu prepoznavanja oblik, barv in kakršnihkoli posebnih značilnosti. Če bi lahko prepoznaval še napise, bi to bistveno povečalo zanesljivost prepoznavanja.

Vsak algoritem pa ima svoje prednosti in slabosti. Največja prednost algoritma YOLO je, da je hitrejši od ostalih algoritmov na marketu. Če za detekcijo uporabljamo še grafično kartico in ne le procesorja, lahko detekcijo izvajamo tudi v realnem času. Prednost algoritma Mask R-CNN je, da je pri slikah s srednje veliko objekti bolj natančen, kot je YOLO, vendar se pri slikah z manj objekti večkrat zmoti, kar je poleg počasnega delovanja njegova slabost.

Oba algoritma bi bila primerna za uporabo v pametnem hladilniku, izbira algoritma pa je odvisna od naših potreb in želja.

Najbolj napredni pametni hladilniki bi lahko imeli vgrajene algoritme, ki bi delovali v sodelovanju z umetno inteligenco in bi se prilagajali potrebam vsakega posameznega uporabnika. Možnosti za razvoj v tej smeri je ogromno, vendar to zahteva veliko časa in sodelovanja različnih strokovnjakov.

6 ZAKLJUČEK

Programi za detekcijo predmetov se lahko uporabljajo v zelo različne namene. Eden od zanimivih načinov uporabe bi bil lahko tudi prepoznavanje živil in izdelkov v naših hladilnikih, pri čemer bi nam program lahko posredoval informacije tako o izdelku kot tudi o roku njegove uporabe. Samo zaznavanje izdelkov se nama ne zdi tako zahtevno, zato lahko v bližnji prihodnosti pričakujemo, da se bo slej kot prej takšna detekcija začela bolj razširjeno uporabljati. Malo večje težave vidiva v branju podatkov o roku uporabe, saj je na različnih artiklih napisan na drugačnih lokacijah in v drugačni pisavi. Vendar tudi te težave niso nepremostljive.

Vsekakor je poleg detekcije izdelkov zelo pomemben tudi način integracije takšne detekcije in komunikacija z uporabniki. Torej bi bila lahko nadgradnja grobega zaznavanja predmetov izdelava aplikacije, ki bi uporabniku sporočila, da bo nekemu izdelku kmalu potekel rok uporabe, ali da nekega izdelka v hladilniku nima več. Na tem mestu pride zelo prav tudi umetna inteligenca. Če bi se program lahko naučil uporabnikove rutine in se sproti učil, kaj pogosto uporablja, bi se algoritem še bolj približal potrebam vsakega posameznika.

Z nekaj idejami in potrpljenja je možno izdelati veliko različnih uporabnih aplikacij, ki nam še bolj približajo uporabo takšnih algoritmov v vsakdanjem življenju, in se s tem še bolj približamo nečemu, kar smo nekoč gledali v znanstveno-fantastičnih filmih.

Oblikovanje takšnega programa, ki bo dovolj zanesljiv in zato uporaben v pametnih hladilnikih, zahteva sodelovanje večjega števila ljudi – programerjev. Verjameva, da predstavlja najina raziskovalna naloga pomemben korak k doseganju cilja podjetja Gorenje, d. o. o., ki razvija tudi pametne hladilnike.

7 POVZETEK

Algoritmi za prepoznavanje objektov lahko imajo zelo širok krog uporabe. Uporabljajo se za prepoznavanje črk v različnih zapisih, v kriminalistiki so zelo uporabni algoritmi za prepoznavanje obrazov, v avtomobilski industriji so, še posebno v zadnjem času, postali aktualni algoritmi za prepoznavanje prometnih znakov ipd. Vsem tem algoritmom pa je skupno to, da morajo zagotavljati izredno veliko zanesljivost pri prepoznavanju posameznih objektov.

V sodelovanju s podjetjem Gorenje, d. o. o., ki razvija med drugim tudi pametne hladilnike, sva se lotila raziskave zanesljivosti algoritmov za prepoznavanje predmetov. V ta namen sva najprej izdelala spletno stran, ki nam omogoča zagon izbranega programa. Primerjala sva dva algoritma, in sicer YOLO in Mask R-CNN, in njuno zanesljivost določala na podlagi testiranja s 50 slikami. Pri tem sva preverjala, koliko objektov je algoritem pravilno zaznal, koliko jih je bilo napačno določenih in koliko jih je zgrešil. Primerjala sva tudi hitrosti v obdelavi slik. Natančno sva preučila prednosti in slabosti vsakega algoritma.

Oba primerjana algoritma imata podobne funkcije, ampak čisto drugačen pristop. YOLO je hitrejši pri obdelavi slik. Pri slikah s 5-11 objekti je Mask R-CNN na slikah zaznal bistveno več objektov, kot YOLO, pri slikah z manj ali več objekti pa med njima ni bilo razlik v številu zaznanih objektov. Na samo zaznavanje objektov resolucija slike ni imela vpliva.

Program, ki bi deloval po principu Mask R-CNN, bi bil primernejši za uporabo v pametnih hladilnikih, če pa bi potrebovali detekcijo v realnem času, pa bi bil algoritem YOLO bolj primeren.

8 SUMMARY

Object recognition algorithms can have a very wide range of uses. They are used for recognizing letters in various records, in criminalistics algorithms for face recognition, in the automotive industry, especially in recent times, algorithms for recognizing traffic signs have become widely used. All these algorithms must provide extremely high reliability in identifying individual objects.

In cooperation with Gorenje d.o.o., which develops, among other things, smart refrigerators, we have undertaken research into the reliability of object recognition algorithms. For research purposes, we first created a website that allows us to run the selected program. We compared two algorithms, YOLO and Mask R-CNN, and determined their reliability based on 50-image testing. In doing so, we checked how many objects the algorithm correctly detected, how many were incorrectly defined, and how many were missing. We also compared speeds in image processing. We carefully examined the pros and cons of each algorithm.

The two algorithms compared have similar functions, but a completely different approach. YOLO is faster at image processing. For images with 5-11 objects, Mask R-CNN detected significantly more objects in the images than YOLO, and for images with fewer or more objects, there were no differences in the number of detected objects. Object detection was not affected by image resolution alone.

A program based off of Mask R-CNN would be better suited for use in smart refrigerators. If real-time object detection would be required, YOLO would be the better choice.

9 ZAHVALA

Najprej gre zahvala najinima mentorjema za potrpežljivost in strokovno pomoč pri delu. Zahvalila bi se gospodu Gregorju Koporcu iz podjetja Gorenje, d. o. o., za odlično idejo in spodbudo pri raziskovanju.

Profesorici Lidiji Šuster se zahvaljujeva za lektoriranje raziskovalne naloge, profesorici Vlasti Leban pa za lektoriranje angleškega dela.

Hvala tudi najinim staršem za moralno podporo.

10 LITERATURA IN VIRI

- ~ Dalbello Bašić, B., Šnajder, J. Strojno učenje. Fakultet elektronike i računarstva, Zagreb.
<https://www.fer.unizg.hr/predmet/su#> (21. 12. 2019)
- ~ Fuks, A., Ravnak, P. 2018. Uporaba video kamere v hladilniku. ŠCV, Elektro in računalniška šola, Velenje.
- ~ Ganesh, P. 2019. Object Detection: Simplified
<https://towardsdatascience.com/object-detection-simplified-e07aa3830954> (28. 12. 2019)
- ~ Ouaknine, A. 2018. Review of Deep Learning Algorithms for Object Detection
<https://medium.com/zylapp/review-of-deep-learning-algorithms-for-object-detection-c1f3d437b852> (8. 1. 2020)
- ~ Remanan, S. 2019. Beginner's Guide to Object Detection Algorithms.
<https://medium.com/@ksuryaremanan/beginners-guide-to-object-detection-algorithms-6620fb31c375> (8. 1. 2020)
- ~ Sharma, A. 2019. Introduction to basic object detection algorithms.
<https://heartbeat.fritz.ai/introduction-to-basic-object-detection-algorithms-b77295a95a63> (10. 1. 2020)
- ~ YOLO
<https://pjreddie.com/darknet/yolo/> (19. 11. 2019)

VIRI TESTNIH SLIK:

1. testna slika : <https://www.univega.com/fileadmin/Startseite/Cross-E-Bike-Start.jpg>
2. testna slika : https://dravabike.si/imager/assets/images/1015/dravabike-uvodna_e85d19d4cf7411199b5428131f3adfa.jpg
3. testna slika : <https://thenypost.files.wordpress.com/2019/05/wild-horses.jpg?quality=80&strip=all&w=618&h=410&crop=1>
4. testna slika : <https://hips.hearstapps.com/hmg-prod.s3.amazonaws.com/images/work-from-home-jobs-airbnb-host-1560283295.jpg>
5. testna slika : <https://dailycaring.com/wp-content/uploads/2019/08/what-it-means-when-a-person-with-dementia-says-i-want-to-go-home.jpg>

6. testna slika :

https://www.aljazeera.com/mritems/imagecache/mbdxxlarge/mritems/Images/2019/10/17/513a8668938041ab87aa4270d8fb5212_18.jpg

7. testna slika : https://image.freepik.com/free-photo/happy-people-relaxing-bench-talking_23-2148219065.jpg

8. testna slika : http://carasdesign.com/wp-content/uploads/2016/08/FineArt_Bench_077_Some_Old_People_Are_Like_Lost_Children.jpg

9. testna slika : https://www.runtastic.com/blog/wp-content/uploads/2018/04/thumbnail_8-tips-beginner_1200x800-1024x683.jpg

10. testna slika : <https://cdn2.momjunction.com/wp-content/uploads/2016/01/Steps-To-Fly-A-Kite-With-Your-Kid.jpg>

11. testna slika : <https://siol.net/media/img/86/93/42b37e1164a1ad7b8604-google-street-view.jpeg>

12. testna slika : https://cdn6.dissolve.com/p/D929_44_798/D929_44_798_1200.jpg

13. testna slika :

<https://www.athens2020.org/sites/default/files/styles/fullhd/public/disciplines-handball.jpg?itok=bkuZGxPr>

14. testna slika :

<http://challengercup.volleyball.world/2019/api/images/download/201934349/LefttorightCanadaTripleblockDanielleSmithJenniferCrossandAlexaGraystopsMichaelaMlejnkovaofCzechRepublic>

15. testna slika : https://gmhslancerledger.com/wp-content/uploads/2017/10/IMG_0477-900x600.jpg

16. testna slika : <https://education.cu-portland.edu/wp-content/uploads/sites/33/2013/01/teacher-hands-raised-min.jpg>

17. testna slika : <https://tfctournament.com/wp-content/uploads/2018/08/Football.jpg>

18. testna slika : <https://cdn.images.express.co.uk/img/dynamic/67/590x/Heung-min-Son-925466.jpg>

19. testna slika : <https://metroquest.com/wp-content/uploads/People-on-bench-over-road-blog.jpg>

20. testna slika :

<https://nationalpostcom.files.wordpress.com/2015/02/imitation.jpg?quality=60&strip=all&w=640>

21. testna slika :

<https://www.vmcnd.ca/f/files/rmotoday/import/18/2018/09/VgirlsSerious1.jpg;w=960>

22. testna slika : https://media.phillyvoice.com/media/images/HD1_9194.2e16d0ba.fill-735x490.jpg

23. testna slika : <https://upload.wikimedia.org/wikipedia/sl/d/df/Abbeyroad.jpg>

24. testna slika : https://img.rtvsl.si/_up/upload/2012/08/25/64907193_pred-ravbarkomando-ob-16_fp-xl.jpg

25. testna slika : <https://www.milton.ca/en/town-hall/resources/meeting-room.2.jpg>

26. testna slika : <https://jtf.org/wp-content/uploads/2015/05/White-College-Students.jpg>

27. testna slika : [https://arc-anglerfish-washpost-prod-](https://arc-anglerfish-washpost-prod-washpost.s3.amazonaws.com/public/PZ325BUIKII6TJEREXPWDR4NYQ.jpg)

[washpost.s3.amazonaws.com/public/PZ325BUIKII6TJEREXPWDR4NYQ.jpg](https://arc-anglerfish-washpost-prod-washpost.s3.amazonaws.com/public/PZ325BUIKII6TJEREXPWDR4NYQ.jpg)

28. testna slika : https://c.ndtvimg.com/2019-10/2qi8djho_indian-football-team-twitter_625x300_13_October_19.jpg

29. testna slika : <https://techcrunch.com/wp-content/uploads/2019/11/GettyImages-1183267196.jpg?w=730&crop=1>

30. testna slika : <https://icdn4.digitaltrends.com/image/digitaltrends/samsung-un40mu6300-tv-510x0.jpg>

31. testna slika : https://ageru-unki.com/wp/wp-content/uploads/2019/09/shutterstock_1390240415.jpg

32. testna slika : <https://i.guim.co.uk/img/static/sys-images/Guardian/Pix/pictures/2014/1/7/1389098263209/People-running-in-park-011.jpg?width=300&quality=85&auto=format&fit=max&s=e31ca8930c0a534af61b3abcbcd0d104>

33. testna slika : https://lh3.googleusercontent.com/proxy/CAchvmYFjTVD-SjpJdkM9RZPb1c562JNzTRAesdG5qbYv4yMbEFKXYqngKk_foaJyqd1K_FlqJ2G-NMROn8HWvcLjVew7sqAvb1HORMWdPrV_T3CEg

34. testna slika : <https://www.rd.com/wp-content/uploads/2013/09/04-couple-park-happy-sl.jpg>

35. testna slika : https://blog.heartmanity.com/hs-fs/hubfs/Young-man-very-depressed-893401086_1416x2124.jpeg?width=244&name=Young-man-very-depressed-893401086_1416x2124.jpeg

36. testna slika :

https://www.newcastle.gov.uk/sites/default/files/Our%20city/19110A6_005.JPG

37. testna slika : <https://sportshub.cbsistatic.com/i/r/2019/12/29/286e2c63-2e01-476c-a0c3-b6e54525febb/thumbnail/640x360/ecb1974c789246faa561160aad0bd84d/usatsi-13846797-1.jpg>

38. testna slika : https://cdn.videvo.net/videvo_files/video/free/2012-08/thumbnails/motorcycle%20racing-H264%2075_small.jpg

39. testna slika : <https://thumbs.dreamstime.com/t/young-man-riding-vintage-bicycle-city-road-sporty-guy-cycling-urban-environment-healthy-active-lifestyle-close-up-slow-105376268.jpg>

40. testna slika :

<https://us.123rf.com/450wm/famveldman/famveldman1804/famveldman180400163/100214897-child-riding-a-bike-in-summer-park-little-girl-learning-to-ride-a-bicycle-without-training-wheels-ki.jpg?ver=6>

41. testna slika : <https://free4kwallpapers.com/uploads/originals/2016/02/04/bike-rider-wallpaper.jpg>

42. testna slika : <https://i.imgur.com/1D7ydFS.jpg>

43. testna slika : https://images.wallpapersden.com/image/download/nemanja-matic-manchester-united-football-player_59083_3840x2160.jpg

44. testna slika : https://adwallpapers.xyz/uploads/posts/72959-bicycle-man-4k-ultra-hd-wallpaper__sport.jpg

45. testna slika : <https://images6.alphacoders.com/549/549198.jpg>

46. testna slika : <https://diolli.com/wp-content/uploads/2017/10/start-a-family.jpg>

47. testna slika : https://adwallpapers.xyz/uploads/posts/72375-family-relax-4k-ultra-hd-wallpaper__other.jpg

48. testna slika : <https://wallpaperaccess.com/full/13652.jpg>

49. testna slika : <https://media.gizmodo.co.uk/wp-content/uploads/2014/06/footballers.jpg>

50. testna slika : <https://wallpercave.com/wp/wp1891207.jpg>

11 PRILOGE



Priloga 1: 1. testna slika



Priloga 2: 2. testna slika



Priloga 3: 3. testna slika



Priloga 4: 4. testna slika



Priloga 5: 5. testna slika



Priloga 6: 6. testna slika



Priloga 7: 7. testna slika



Priloga 8: 8. testna slika



Priloga 9: 9. testna slika



Priloga 10: 10. testna slika



Priloga 11: 11. testna slika



Priloga 12: 12. testna slika



Priloga 13: 13. testna slika



Priloga 14: 14. testna slika



Priloga 15: 15. testna slika



Priloga 20: 20. testna slika



Priloga 16: 16. testna slika



Priloga 21: 21. testna slika



Priloga 17: 17. testna slika



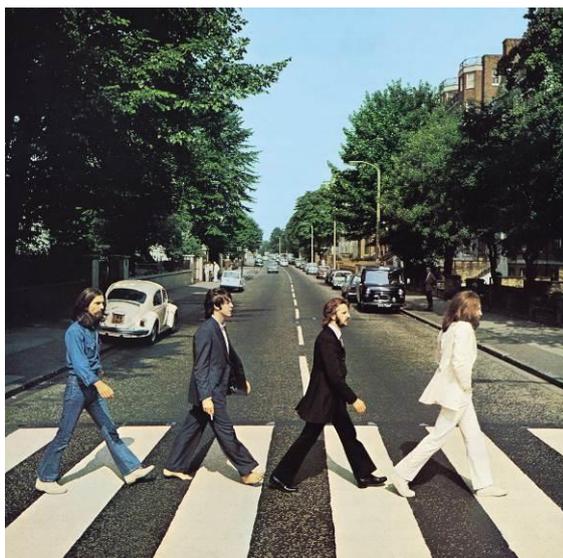
Priloga 22: 22. testna slika



Priloga 18: 18. testna slika



Priloga 19: 19. testna slika



Priloga 23: 23. testna slika



Priloga 24: 24. testna slika



Priloga 25: 25. testna slika



Priloga 26: 26. testna slika



Priloga 27: 27. testna slika



Priloga 28: 28. testna slika



Priloga 29: 29. testna slika



Priloga 30: 30. testna slika



Priloga 31: 31. testna slika



Priloga 32: 32. testna slika



Priloga 33: 33. testna slika



Priloga 34: 34. testna slika



Priloga 35: 35. testna slika



Priloga 36: 36. testna slika



Priloga 37: 37. testna slika



Priloga 38: 38. testna slika



Priloga 42: 42. testna slika



Priloga 39: 39. testna slika



Priloga 43: 43. testna slika



Priloga 40: 40. testna slika



Priloga 44: 44. testna slika



Priloga 41: 41. testna slika



Priloga 45: 45. testna slika



Priloga 46: 46. testna slika



Priloga 49: 49. testna slika



Priloga 47: 47. testna slika



Priloga 50: 50. testna slika



Priloga 48: 48. testna slika