

Automatska detekcija stanja prostorne baze podataka vertikalne signalizacije koristeći metode strojnog učenja i georeferencirani video

Meštrić, Luka

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Geodesy / Sveučilište u Zagrebu, Geodetski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:256:366938>

Rights / Prava: [Attribution 4.0 International](#) / [Imenovanje 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2025-03-13**



Repository / Repozitorij:

repozitorij.geof.unizg.hr/en





SVEUČILIŠTE U ZAGREBU
GEODETSKI FAKULTET

Luka Meštrić

**AUTOMATSKA DETEKCIJA STANJA
PROSTORNE BAZE PODATAKA VERTIKALNE
SIGNALIZACIJE KORISTEĆI METODE
STROJNOG UČENJA I GEOREFERENCIRANI
VIDEO**

Diplomski rad

Zagreb, 2024

SVEUČILIŠTE U ZAGREBU GEODETSKI FAKULTET



Na temelju članka 19. Etičkog kodeksa Sveučilišta u Zagrebu i Odluke br. 1_349_11 Fakultetskog vijeća Geodetskog fakulteta Sveučilišta u Zagrebu, od 26.10.2017. godine (klasa: 643-03/16-07/03), uređena je obaveza davanja „Izjave o izvornosti“ diplomskog rada koji se vrednuju na diplomskom studiju geodezije i geoinformatike, a u svrhu potvrđivanja da je rad izvorni rezultat rada studenata te da taj rad ne sadržava druge izvore osim onih koji su u njima navedeni.

IZJAVLJUJEM

Ja, **Luka Meštrić**, (JMBAG: 0007182931), rođen dana 02.02.2001. u Zadru, izjavljujem da je moj diplomski rad izvorni rezultat mog rada te da se u izradi tog rada nisam koristio drugim izvorima osim onih koji su u njemu navedeni.

U Zagrebu, dana 6.9.2024.



Potpis studenta / studentice

I. AUTOR	
Ime i prezime:	Luka Meštrić
Datum i mjesto rođenja:	02. veljače 2001. godine, Zadar. Republika Hrvatska
II. DIPLOMSKI RAD	
Naslov:	Automatska detekcija stanja prostorne baze podataka vertikalne signalizacije koristeći metode strojnog učenja i georeferencirani video
Broj stranica:	70
Broj tablica:	15
Broj slika:	30
Broj bibliografskih podataka:	20 + 7 URL-a
Ustanova i mjesto gdje je rad izrađen:	Geodetski fakultet Sveučilišta u Zagrebu
Mentor:	Izv. prof. dr. sc. Mario Miler
Komentor:	dr. sc. Ivan Brkić
Voditelj:	
III. OCJENA I OBRANA	
Datum zadavanja teme:	12.01.2024.
Datum obrane rada:	06.09.2024.
Sastav povjerenstva pred kojim je branjen diplomski rad:	Izv. prof. dr. sc. Mario Miler
	doc. dr. sc. Luka Rumora
	dr. sc. Dino Dobrinić

Zahvala

Ovu priliku bi iskoristio kako bi spomenuo i zahvalio se ljudima koji su na ovaj ili onaj način bili prisutni kroz moj studentski život kojem je evo mogu reći nažalost došao kraj...

Na početku zahvalio bi se svojim mentorima izv. prof. dr. sc. Mariu Mileru i dr. sc. Ivanu Brkiću koji su od odabire teme do samog kraja pisanja ovog diplomskog rada uvijek bili pristupačni i spremni pomoći na koji god problem ja naišao.

Nastavno na zahvalu mentorima s fakulteta, ne izbjegnuto je spomenuti moju ekipu s fakulteta, Mladiće. Hvala Vam na 5 godina ne zaboravnih izlazaka, druženja, kava i čega sve ne. Nadam se da ćemo se nastaviti družiti i u godinama koje dolaze.

Prije zahvale članovima obitelji, nekoliko rečenica ću posvetiti mojoj drugoj obitelji, a to su moji najbolji prijatelji. Josipe, Kristijane, Amadej, Hrvoje, Roko, Maurizio, Bruno i Stipe hvala vam na tome što ste uvijek bili uz mene kad je bilo dobro i kad je bilo loše i što ste uvijek bili sretni i ponosni na moje uspjehe. Za vas se ova zahvala ne odnosi samo na moje akademsko obrazovanje nego cijelo moje obrazovanje s obzirom da se družimo i stvaramo priče i iskustva još od osnovne škole i na tome vam hvala. Velika mi je želja da i ukoliko nas život možda odnese na neke druge strane i kad se možda prestanemo toliko često družiti da ćemo ipak ostati najbolji i da ćemo se s radošću nalaziti i zabavljati na najjače kao i do sad.

Sada slijede ipak najveće zahvale koje se teško mogu sažeti u par rečenica jer ipak idu ljudima koji mi najviše znače u životu, a to je moja obitelj.

Zahvaljujem se mojoj baki Mirjani, ujni Sandri, ujku Antislavu i njihovoj djeci mojim rodicama Antei i Martini. Hvala vam što ste uvijek bili tu spremni pomoći, uvijek pitali za mene i najvažnije od svega vjerovali u mene.

Velike zahvale idu mojoj najdražoj teti Tanji i tetku Alenu koji su četiri godine preuzeli na sebe obvezu da njihova djeca i ja imamo krov nad glavom u Zagrebu. Također vam hvala na svakom savjetu, smjehu i pomoći kroz ovih pet godina, možda to nisam pokazivao ali stvarno mi je puno značilo ali i dalje puno znači. Ema i Hrvoje cimeri moji, hvala vam na tome što ste bili super cimeri koje bi svatko poželio, nadam se da sam i ja vama bio, ako ništa bar imamo puno odličnih i smiješnih priča.

Sada slijedi najteži dio i uopće ne znam s kim i kako početi.

Najveće i najiskrenije hvala mojoj jednoj jedinoj neponovljivoj baki Bubi i najdražem didu Srećku. Hvala vam što ste me se svaki dan sjetili, zvali pitali za mene. Hvala vam na svojoj pomoći kroz cijeli život, ali najviše vam hvala kada govorimo o faksu što ste me gurali kroz ljetni period kada sam imao najteže ispite i tjerali me da učim i da ne ljenčarim.

E sad, što reći za ovu osobu, a da ne napišem knjigu. Vanja moja, zahvaljujući ovom fakultetu upoznao sam najbolju, najdobroćudniju, najpažljiviju i sve naj osobu na ovom svijetu. Hvala ti što si zadnje dvije godine u mom životu i što me guraš naprijed i što si tu uz mene kad je dobro ali meni važnije što si uz mene i kad je loše. Teško mi je išta više i pametnije reći kada sve znaš što mislim i osjećam prema tebi. Hvala na svemu i jako se veselim sljedećoj stranici u mojem životu koji počinje s životom s tobom.

Ipak za kraj ostavljam zahvalu koja je posvećena ljudima koji su i zauvijek će biti duboko u mom srcu. Mama, tata hvala vam na apsolutno svemu, hvala vam što ste mi omogućili da imam sve što mi je potrebno i što želim u životu iako je to možda nekad značilo vaše određeno odricanje i stavljanje vas samih na drugo mjesto. Dok pišem ovo uopće nisam dobre glave s obzirom da pucam od emocija pa ne znam što pametnije od ovoga napisati osim da vam hvala na svemu i da vašu pomoć nikad neću zaboraviti i da se nadam da ću sada ja vama krenut pomagat i potruditi se bar na neki način vratiti vam za sve što ste učinili za mene. Za kraj krajeva ostavljam dvije legende, a to su moj dva mlađa brata. Toni i Dino hvala vam što

postojite i što radi vas pokušavam uvijek biti bolji čovjek i tako vama dati primjer kako trebate ići kroz život. Stvarno vam hvala na svemu na svakom smijehu, dišpetu, svađi i tako dalje... Uvik i zauvik ću vas volit i truditi se da vam bude dobro.

Eto toliko od mene i od zahvala, nadam se da nikog nisam zaboravio i ako jesam moje duboke isprike nije mi bila namjera.

Automatska detekcija stanja prostorne baze podataka vertikalne signalizacije koristeći metode strojnog učenja i georeferencirani video

Sažetak:

Vertikalna signalizacija svakodnevno je prisutna u našim životima, vodeći nas kroz sigurno kretanje po cestama. Ona pruža bitne informacije poput ograničenja brzine, upozorenja na opasnosti i smjerova kretanja, osiguravajući tako sigurnost i red u prometu. Bez vertikalne signalizacije, odnosno prometnih znakova promet bi bio rizičan. Održavanje ažurne prostorne baze vertikalne cestovne signalizacije to jest prometnih znakova je zahtjevan zadatak za bilo kojeg održavatelja cesta.

U ovom diplomskom radu istraživala se mogućnost kreiranja mehanizma koji automatski detektira stanje prostorne baze podataka vertikalne signalizacije čime bi se olakšalo održavanje iste. Drugim riječima cilj je obaviti inventuru određene baze podataka prometnih znakova koristeći suvremene automatizirane metode. Istraživanje se provelo na podacima koji obuhvaćaju područje Brodsko-posavske županije. Podaci se sastoje od prostorne baze podataka vertikalne signalizacije i georeferenciranog videa. Istraživanje je obavljeno s pomoću YOLO algoritma, Python programskog jezika i QGIS-a.

Dodatno je provedena analiza modela za predikciju prometnih znakova koji je dobiven s pomoću YOLOv8 algoritma. Cilj ove analize bio je ocijeniti model, njegovu preciznost i točnost kako vi se vidjelo je li model dovoljno dobar za korištenje u ovom diplomskom radu, ali potencijalno u nekim drugim istraživanjima.

Dobiveni rezultati dokazali su da se korištenjem suvremenih metoda kao što je strojno učenje može olakšati održavanje prostorne baze podataka vertikalne signalizacije. Drugim riječima može se uspješno obaviti automatizirana inventura prometnih znakova za neko odabrano područje. Uz uspješno obavljanje cilja zaključeno je da prostora za napredak u automatskoj detekciji stanja prostorne baze podataka vertikalne signalizacije ima u vidu poboljšanja modela predikcija i korištenja videa koji snima oba smjera ceste.

Ključne riječi: *Vertikalna signalizacija, prometni znakovi, Yolo algoritam, Python*

Automatic detection of the state of the spatial database of vertical signage using machine learning methods and georeferenced video

Abstract:

Vertical signaling is present in our lives every day, guiding us through safe movement on the roads. It provides essential informations such as speed limits, warnings of dangers and directions of movement, thus ensuring safety and order in traffic. Without vertical signaling, in other words traffic signs, traffic would be risky. Maintaining an up-to-date spatial base of vertical road signage, i.e. traffic signs, is a demanding task for any road maintainer.

In this thesis, the possibility of creating a mechanism that automatically detects the state of the spatial database of vertical signage was studied, which would facilitate its maintenance. In other words, the goal is to perform an inventory of a specific traffic sign database using modern automated methods. The research was conducted on data covering the area of Brodsko-posavska županija. The data consists of a spatial database of vertical signage and georeferenced video. The research was carried out using the YOLO algorithm, Python programming language and QGIS.

In addition, an analysis of the traffic sign prediction model obtained using the YOLOv8 algorithm was performed. The goal of this analysis was to evaluate the model, its precision and accuracy as you could see if the model is good enough to be used in this thesis, but potentially in some other research.

The obtained results proved that the maintenance of the spatial database of vertical signaling can be facilitated by using modern methods such as machine learning. In other words, an automated traffic sign inventory can be successfully performed for a selected area. With the successful completion of the goal, it was concluded that there is room for improvement in the automatic detection of the state of the spatial database of vertical signaling in terms of improving the prediction model and the use of video that records both directions of the road.

Keywords: *Vertical signaling, traffic signs, Yolo algorithm, Python*

SADRŽAJ

UVOD	1
1.1 Pregled dosadašnjih radova	2
MATERIJALI I METODE	6
2.1 Općenito o prometnim znakovima.....	6
2.2 Python	10
2.3 YOLO algoritam	11
2.3.1 Princip rada YOLO algoritma	11
2.3.2 Prednosti YOLO algoritma	13
2.3.3 Ograničenja YOLO algoritma	14
2.4 QGIS	14
2.5 Definiranje područja istraživanja i ulaznih podataka	15
2.5.1 Opis metodologije	16
REZULTATI.....	28
3.1 Rezultati YOLOv8 algoritma.....	28
3.2 Rezultati inventure	37
DISKUSIJA.....	39
ZAKLJUČAK	46
LITERATURA.....	48
POPIS TABLICA.....	51
PRILOZI.....	51
Prilog 1.....	51
Prilog 2.....	57
ŽIVOTOPIS	60

UVOD

Vertikalna signalizacija, drugim riječima prometni znakovi, nešto je s čime se u današnje vrijeme svakodnevno svaka osoba susreće. S prometnim znakovima se susrećemo na razne načine, to može biti bilo da smo vozači, pješaci, biciklisti ili pak putnici u vozilima. Vertikalna signalizacija osnovni je element komunikacije unutar cestovnog prometa. Takva signalizacija usmjeruje naše kretanje, upozorava nas na opasnosti te regulira pravila na cesti. Prisutnost prometnih znakova nužna je i krucijalna, jer prometni znakovi omogućuju sigurnost i fluidnost prometa, smanjujući mogućnost nesreća i zastoja. Nedostatak vertikalne signalizacije na određenim mjestima može dovesti do nastanka nepredvidivog i kaotičnog odvijanja prometa koji vrlo lako može prouzročiti kobne i fatalne nesreće, a cilj je naravno to izbjeći. Upravo iz tih razloga potrebno je voditi, te redovito ažurirati bazu podataka prometnih znaka. Održavanje ažurne prostorne baze vertikalne cestovne signalizacije zahtjevan je zadatak za bilo kojeg održavatelja cesta. Često se dešavaju situacije da stanje prostorne baze prometnih znakova ne odgovara stanju na terenu te je inventura podataka vrlo zahtjevan zadatak. Stoga je potrebno pronaći jednostavno rješenje koje će biti moguće univerzalno koristiti s ciljem rješavanja problema održavanja prostorne baze podataka vertikalne signalizacije.

U suvremenom svijetu sve je veća težnja prema automatizaciji i rasterećenju čovjeka od fizičkog rada, što je uvelike potaknuto brzim razvojem tehnologije. Automatizacija ne samo da olakšava svakodnevne zadatke, već i povećava efikasnost te smanjuje i gotovo eliminira mogućnost ljudske pogreške. Kada govorimo o takvoj automatizaciji i napretku, novonastala umjetna inteligencija (*eng. Artificial Intelligence-AI*) i strojno učenje igraju ključnu ulogu, omogućujući razvoj sustava koji mogu preuzeti niz zadataka koji su tradicionalno zahtijevali ljudski rad. Umjetna inteligencija danas se sve češće koristi u različitim područjima, od medicine, preko financija, do prometa. Unutar ovog šireg pojma, strojno učenje, kao specifičan pristup umjetnoj inteligenciji, omogućuje računalima da uče iz podataka i s vremenom postaju sve preciznija u izvršavanju zadataka. Jedan od najistaknutijih primjera primjene strojnog učenja je detekcija objekata, što uključuje prepoznavanje i klasifikaciju raznih elemenata u okolini. Ova tehnologija omogućuje računalima da "vide" i interpretiraju vizualne informacije na sličan način kao što to čini ljudsko oko, ali s puno većom preciznošću i brzinom.

U kontekstu prometne infrastrukture, umjetna inteligencija odnosno strojno učenje može se koristiti za automatsko prepoznavanje vertikalne signalizacije, analize njihovog stanja te detekciju potencijalnih problema, čime se dodatno povećava sigurnost na cestama i olakšava njihovo održavanje. Cilj ovog rada bio bi pronalazak rješenja kada je u pitanju održavanje ažurne prostorne baze podataka prometnih znakova. Povezivat će se prostorne baze podataka vertikalne signalizacije i metode strojnog učenja. Drugim riječima, ovim diplomskim radom će se stvoriti točan i precizan model s pomoću *You Only Look Once* (YOLO) algoritma za detekciju objekata, koji će detektirati objekte vertikalne signalizacije iz georeferenciranog videa čiji će se rezultati koristiti u daljnjoj obradi s pomoću programskog jezika gdje će se stvoriti postupak iz nekoliko koraka koji će vršiti inventuru između prostorne baze podataka prometnih znakova i samog georeferenciranog videa koji daje informacije o stanju na cesti.

Potrebni skup podataka koji će se koristiti za treniranje modela koji će prepoznavati prometne znakove je preuzet s internetskih stranica slovenske tvrtke The Visual Cognitive Systems Laboratory (The Visual Cognitive Systems Laboratory). Model će biti treniran s pomoću YOLO algoritma, te će se nadalje model koristiti na georeferenciranom videu u svrhu prepoznavanja prometnih znakova unutar tog videa. Dobiveni rezultati te detekcije proći će daljnju obradu u kojoj će se koristiti Python programski jezik. Obrada će se sastojati od računanja koordinata i azimuta koji je inače definiran kao kut između linije koja spaja dvije točke i pozitivne x osi, te prijevoda slovenskih oznaka za klase znakova u hrvatske klase. Na kraju takvi, obrađeni podaci, bit će korišteni paralelno s prostornom bazom podataka unutar Python skripte, kako bi se dobio rezultat i ostvario cilj, odnosno to je ažurna prostorna baza podataka prometnih znakova spremljena u .csv formatu.

1.1 Pregled dosadašnjih radova

Tabernik i dr. (2019) svoj rad započinju rečenicom u kojoj kažu da je pravilno upravljanje inventarom prometnih znakova važan zadatak u osiguravanju sigurnosti i učinkovitosti prometnog toka. Ističu kako se taj zadatak najčešće izvodi ručno tako da se prometni znakovi snimaju s pomoću kamere postavljene na vozilo, a ljudski operater obavlja ručnu lokalizaciju i prepoznavanje izvan mreže kako bi provjerio dosljednost s postojećom bazom podataka. Takav ručni rad može biti izuzetno dugotrajan kada se primijeni na tisuće kilometara cesta. Automatizacija ovog zadatka značajno bi smanjila količinu ručnog rada i poboljšala sigurnost

kroz bržu detekciju oštećenih ili nedostajućih prometnih znakova. Ključni korak prema automatizaciji ovog zadatka je zamjena ručne lokalizacije i uvođenje prepoznavanja prometnih znakova automatskom detekcijom. Međutim, detekcija i prepoznavanje velikog broja različitih kategorija prometnih znakova je izazov zbog velikog raspona u izgledu znakova unutar i između kategorija. Postojeći pristupi često zanemaruju složeniji problem detekcije znakova i fokusiraju se na jednostavnije zadatke prepoznavanja. Modificiranje postojećih metoda za pokrivanje širokog spektra kategorija znakova bilo bi zahtjevno, pa je razumniji pristup koristiti duboko učenje. Autori u svom radu predlažu sustav temeljen na dubokom učenju, koristeći konvolucijske neuronske mreže za učenje i detekciju velikog broja kategorija prometnih znakova, što je posebno izazovno zbog potrebe za velikim skupom podataka. Nadalje, predlažu poboljšanja na *Mask Region-based Convolutional Neural Network* (Mask R-CNN) koja su ključna za domenu prometnih znakova. Kao svoj sekundarni doprinos ističu kreiranje skup podataka s 200 kategorija prometnih znakova raspoređenih u 13 000 instanci prometnih znakova i 7000 slika visoke razlučivosti. Takav skup podataka s velikom količinom anotiranih prometnih znakova s najmanje 20 instanci po kategoriji može služiti kao jako dobra osnova za stvaranje modela koji automatski detektira prometne znakove. Kroz rad analizirane su performanse Mask R-CNN modela s prilagodbama na skupu podataka DFG za detekciju prometnih znakova. Kao rezultat dobiven je model koji je pokazao izuzetno visoku preciznost za mnoge kategorije prometnih znakova, posebno za one s niskom varijabilnošću unutar kategorije, kao što su znakovi zabrane i ograničenja brzine. Međutim, znakovi s velikom varijabilnošću unutar kategorije, poput zrcala i digitalnih znakova brzine, pokazali su slabije rezultate. Prikazane su i kategorije znakova s dobrom detekcijom unatoč velikoj varijabilnosti, kao što su smjerokazi s odvojenim trakama. S druge strane, znakovi s lošijom izvedbom, poput spajanja lijeve trake i prijelaza vlakova, uglavnom su imali problema s detekcijom zbog malih dimenzija ili velikih kutova gledanja. Unatoč nekim promašajima, model je općenito pokazao odlične rezultate, čak i u složenim slučajevima s malim znakovima ili znakovima koji su djelomično ili potpuno zaklonjeni. Ovaj diplomski rad bavit će se sličnom problematikom kao i rad spomenutih autora, točnije bavit će se detekcijom prometnih znakova u svrhu njihove inventure te će koristiti set podataka kreiran od strane istih. Vidna razlika dva pristupa bit će korištenje različitog algoritma s pomoću kojeg se vrši detekcija. Tabernik i dr.(2019) u svom radu koriste Mask R-CNN, dok će se u ovom radu koristiti YOLO algoritam.

Du i dr. (2024) u svom istraživačkom radu naglašavaju važnost točne i precizne detekcije vertikalne signalizacije u svrhu poboljšanja autonomne vožnje vozila. Brza i precizna detekcija i prepoznavanje prometnih znakova ključni su aspekti percepcije okoline u autonomnoj vožnji (Du, i dr., 2024.). Tehnologije dubokog učenja i računalnog vida usmjerile su istraživanja u kojima se detektiraju prometni znakovi prema korištenju dubokih konvolucijskih neuronskih mreža, posebno u izazovnim scenarijima autonomne vožnje koji uključuju male znakove i okluzije. Postoje dvije glavne kategorije algoritama za detekciju objekata: jednostupanjski, koji je brži, ali manje precizan, i dvostupanjski, koji je precizniji, ali sporiji. Razvoj YOLO algoritma, posebno njegove najnovije verzije YOLOv8, značajno je poboljšao točnost i brzinu jednostupanjskih metoda. YOLOv8s, manja verzija, nudi veću brzinu detekcije, ali može imati poteškoće s točnošću u složenim prometnim uvjetima. U ovom radu autori koriste YOLOv8s s ciljem da ga poboljšaju općenito kao algoritam, te da ga poboljšaju kada se radi od detekciji prometnih znakova u složenim prometnim scenarijima. Augmentaciju algoritma postigli su korištenjem *Select Kernel (SK)* unutar vratne mreže, što poboljšava fokusiranje i prepoznavanje kritičnih značajki, osobito u slučaju složenih pozadina i okluzija. Također, integriran je modul *Space-to-Depth (SPD)* u okosnicu mreže radi bržeg izdvajanja značajki i proširenja receptivnog polja, čime se poboljšava detekcija prometnih znakova različitih razmjera. Na kraju se koristi funkcija gubitka *WIoUv3* koja se koristi za bolju obradu objekata različitih veličina i učestalosti, posebno za male i rijetke prometne znakove, što povećava točnost prepoznavanja. Kao rezultat istraživanja dobiveno je da su eksperimenti provedeni na različitim skupova podataka otkrili da je implementacija ovih metoda poboljšala performanse modela, posebno na metrici *mAP50*, s poboljšanjima od 3,2 % odnosno 5,1 % u usporedbi s YOLOv8s. Ovi rezultati potvrđuju učinkovitost poboljšanja i ističu sposobnost modela u rukovanju složenim prometnim scenama. Za razliku od spomenutog rada, u ovom diplomskom radu stavlja se naglasak na pronalazak rješenja inventure vertikalne signalizacije, dok su u radu spomenutih autora naglasak stavlja na problematiku detekcije znakova u autonomnoj vožnji. Oba rada koriste YOLO algoritam pri rješavanju zadatka detekcije prometnih znakova.

Dewi i dr. (2021) u svom radu istražuju kako se određuje kvaliteta sintetičkih slika koje stvaraju različiti *Generative Adversarial Networks (GAN)*, kao što su *Deep Convolutional GAN (DCGAN)*, *Least Squares GAN (LSGAN)* i *Wasserstein GAN (WGAN)*. Naime, konvolucijske neuronske mreže (CNN) postižu veoma dobre rezultate u identifikaciji prometnih znakova s

dovoljno označenih podataka za obuku. Sam skup podataka određuje kvalitetu cjelokupnog vizualnog sustava temeljenog na CNN-u. Do problema dolazi jer su baze podataka za prometne znakove iz većine zemalja svijeta su loše i malobrojne. U ovom radu istraživači koriste *Generative Adversarial Network* (GAN) koji služi kako bi se proizvele realističnije i raznovrsnije slike za obuku koje nadopunjuju stvarni raspored slika. Ovaj rad kombinira sintetičke slike s originalnim slikama kako bi se poboljšali skupovi podataka i provjerila učinkovitost sintetičkih skupova podataka. Skup podataka stvarnih i sintetičkih slika treniran je na tada aktualnim iteracijama YOLO algoritma, a to su verzije YOLOv3 i YOLOv4. Rezultati su pokazali da su se performanse prepoznavanja, nakon miješanja stvarne slike sa sintetiziranom slikom koju je proizveo GAN, poboljšale postićući točnost od 84,9 % na YOLOv3 i točnost od 89,33 % na YOLOv4. Rad Dewi i dr. (2021) kao i ovaj diplomski rad prati performanse YOLO algoritma kada je riječ o detekciji prometnih znakova, uz razlike verzija algoritma koje su korištene.

Dewi i dr. (2022) kažu kako prepoznavanje prometnih znakova daje korisne informacije, uključujući upute i upozorenja za napredne sustave pomoći vozaču (ADAS) i kooperativne inteligentne transportne sustave (CITS). Također spominju kako je prometne znakove teško otkriti u praktičnim scenama autonomne vožnje s pomoću iznimno preciznog pristupa u stvarnom vremenu. Ovaj rad analizira metode detekcije objekata kao što su YOLOv4 i YOLOv4-tiny konsolidirane sa *Spatial Pyramid Pooling* (SPP). Rad procjenjuje važnost SPP principa u poboljšanju performansi YOLOv4 i YOLOv4-tiny okosnica mreža u učinkovitijem izdvajanju značajki i značajki objekta učenja. Oba modela se mjere i uspoređuju s ključnim mjernim parametrima, uključujući srednju prosječnu preciznost (mAP), veličinu radnog područja, vrijeme otkrivanja i milijardu brojeva s pomičnim zarezom (BFLOPS). Eksperimenti pokazuju da YOLOv4_1 (sa SPP-om) nadmašuje najsuvremenije sheme, postićući 99,4 % točnosti u ovim istraživanjima, s najboljim ukupnim BFLOPS-om (127,26) i mAP-om (99,32 %). Za razliku od ranijih studija, YOLOv3 SPP proces obuke dobiva samo 98,99 % točnosti za mAP s *Intersection Over Union* (IoU) 90,09. mAP za vježbanje raste za 0,44 % s YOLOv4_1 (mAP 99,32 %) u ovom istraživanju. Može se zaključiti da SPP može poboljšati postignuća svih YOLO modela. Dewi i dr. (2022) u radu bave se statističkim vrijednostima modela dobivenog putem YOLO algoritma poboljšanog sa SPP-om, dok će ovaj diplomski rad također iznijeti statističke vrijednosti svog treniranog modela.

MATERIJALI I METODE

2.1 Općenito o prometnim znakovima

Ceste moraju biti označene odgovarajućim prometnim znakovima kako bi sudionici u prometu, vozači, pješaci, biciklisti i ostali bili upozoreni na opasnosti koje ih čekaju na određenom dijelu ceste. Ti znakovi također informiraju o ograničenjima, zabranama i obvezama koje vozači i ostali sudionici moraju poštovati, te pružaju važne informacije za sigurno i nesmetano odvijanje prometa. Prometnim znakovima moraju biti označene i privremene opasnosti, posebno one koje nastanu zbog iznenadnih oštećenja ili neprohodnosti ceste. Osnovne funkcije prometnih znakova možemo podijeliti na upravljanje, reguliranje, orijentiranje (usmjeravanje) te informiranje (Krištofić, 2022). Uz sve navedeno, privremena ograničenja i zabrane u prometu također moraju biti jasno označena (Petravić, 2017).

Prometni znakovi postavljaju se i održavaju tako da budu lako vidljivi sudionicima u prometu, kako danju tako i noću, kako bi se moglo pravovremeno reagirati u skladu s njihovim značenjem. Ako značenje prometnih znakova više ne odgovara trenutnim uvjetima na cesti ili sigurnosnim zahtjevima, ti znakovi moraju biti uklonjeni, dopunjeni ili zamijenjeni.

Prema značenju, prometni znakovi su podijeljeni na znakove opasnosti, znakove izričitih naredbi, znakove obavijesti, znakove obavijesti za vođenje prometa, dopunske ploče i promjenjivi prometni znakovi (Berišić, 2015). Također obuhvaćaju prometna svjetla, oznake na kolniku i nogostupu, te svjetlosne i druge oznake na cesti. Sudionici u prometu moraju se pridržavati ograničenja, zabrana i obveza prikazanih na prometnim znakovima.

Znakovi opasnosti na kao što su na Slici 2.1 upozoravaju blizinu dijela ceste ili mjesto na kojem sudionicima u prometu prijete opasnost. Oblika su uspravnog jednakostraničnog trokuta bijele podloge s crvenim obrubom.



Slika 2.1 Znakovi opasnosti (Signal Grad, 2020)

Znakovi izričitih naredbi čiji su primjeri prikazani na Slici 2.2 i Slici 2.3 daju do znanja sudionicima u cestovnom prometu zabrane, ograničenja i obaveze. Najčešće su okruglog oblika, te u dvije varijante boja. Prva varijanta je varijanta bijele podloge obrubljene crvenom bojom, a druga je varijanta plave podloge na kojoj su bijelom bojom ispisane oznake. Izuzetak od oblika je znak obveznog zaustavljanja (osmerokut) te znak raskrižja s cestom s prednošću prolaza, koji je oblika naopakog jednakostraničnog.




Slika 2.2 Znakovi izričitih naredbi (prva varijanta i dva izuzetka) (Signal Grad, 2020)



Slika 2.3 Znakovi opasnosti (druga varijanta) (Signal Grad, 2020)

Znakovi obavijesti daju potrebne informacije o cesti kojom se kreću sudionici u prometu, nazivima mjesta, udaljenosti do tih mjesta, prestanku važenja prometnih znakova izričitih naredbi te druge korisne obavijesti. Mogu biti okrugli, pravokutni, kvadratni, oblika strelica, te raznih kombinacija boja podloga i oznaka na njima. Na Slici 2.4 primjer je skupa znakova obavijesti.



Slika 2.4 Znakovi obavijesti (Signal Grad, 2020)

Znakovi obavijesti za vođenje prometa na Slici 2.5 obavješćuju sudionike u prometu o pružanju cestovnih smjerova, rasporedu odredišta te vođenju ili udaljenosti prometa prema njima, ali i o raskrižjima i čvorištima na određenom djelu ceste. Pravokutnog su ili kvadratnog oblika, a boja ovisi o vrsti ceste na kojoj su postavljeni: na autocestama su to znakovi zelene podloge s bijelim oznakama, na brzim cestama plave podloge s oznakama bijele boje, na državnim i ostalim cestama žute podloge s oznakama crne boje, a za dijelove gradova, naselja i značajne objekte odabrana je bijela podloga s oznakama crne boje.



Slika 2.5 Znakovi obavijesti za vođenje prometa (Signal Grad, 2020)

Dopunske ploče poblje označavaju značenje prometnog znaka te mogu biti postavljene uz znakove opasnosti, znakove izričitih naredbi, znakove obavijesti i znakove obavijesti za vođenje prometa. Najčešće su pravokutnog oblika, bijele podloge s crnim oznakama kao što se vidi na Slici 2.6.



Slika 2.6 Dopunske ploče (Signal Grad, 2020) (Dey, 2023)

Da bi prometni znakovi mogli izvršavati svoju funkciju moraju biti tehnički ispravni, pravilno postavljeni i vidljivi u svim uvjetima vožnje (Brkić, 2019). Zabranjeno je stavljati bilo što na prometni znak ili stup na kojem je znak postavljen, osim ako je to povezano sa značenjem samog znaka. Također, nije dopušteno bez ovlaštenja postavljati, uklanjati, zamjenjivati ili oštećivati prometne znakove i cestovnu opremu, niti mijenjati njihovo značenje.

Na cesti se ne smiju postavljati ploče, znakovi, svjetla, stupovi ili drugi predmeti koji zaklanjaju ili smanjuju vidljivost prometnih znakova. Također, ne smiju se postavljati predmeti koji svojim oblikom, bojom, izgledom ili mjestom postavljanja oponašaju ili nalikuju prometnim znakovima, zasljepljuju sudionike u prometu ili odvrćaju njihovu pozornost na način koji može ugroziti sigurnost prometa.

2.2 Python

Python je interpretirani, objektno orijentirani programski jezik visoke razine s dinamičkom semantikom, idealan za brzi razvoj aplikacija i skriptiranje. Njegova jednostavna sintaksa naglašava čitljivost i smanjuje troškove održavanja, dok moduli i paketi potiču modularnost i ponovnu upotrebu koda. Python je moćan, elegantan programski jezik koji se lako čita i razumije (Yuill, i dr., 2006). Dostupan je besplatno za sve glavne platforme, kao što su Windows, macOS, Linux i Unix. Python je razvio Guido van Rossum 1989. godine, a prva verzija objavljena je 1991. godine. Python 1.0 izašao je 1994. godine, dok su verzije 2.0 (2000.) i 3.0 (2008.) donijele važne nove značajke poput podrške za Unicode i bolju obradu pogrešaka. Python je jednostavan za učenje i čitanje, omogućava bržu izradu programa, te ima veliku standardnu knjižnicu koja olakšava razvoj. Također, lako se integrira s drugim jezicima (Java, C, C++) i podržan je od strane velike korisničke zajednice, što olakšava rješavanje problema i učenje. Python je jezik koji za cilj ima kvalitetu, produktivnost, portabilnost, modularnost i ugodnost korištenja (Šantić, 2017). Python se koristi u raznim područjima: web razvoj, automatizacija zadataka, znanost o podacima, strojno učenje, razvoj softvera, te automatizacija testiranja. Njegova svestranost čini ga pogodnim za brojne primjene, od skriptiranja do složenih znanstvenih izračuna.

2.3 YOLO algoritam

YOLO je algoritam za otkrivanje objekata u stvarnom vremenu koji su razvili Joseph Redmon i Ali Farhadi 2015. godine. Ime algoritma objašnjavaju u svom radu sljedećom rečenicom. Koristeći naš sustav, samo jednom pogledate sliku (*You only look once, YOLO*) kako biste predvidjeli koji su objekti prisutni i gdje se nalaze (Redmon, i dr., 2015). YOLO je viralan i široko korišten algoritam koji je poznat po svojim karakteristikama detekcije objekata (Jiang, i dr., 2022). To je jedno stupanjski detektor objekata koji koristi konvolucijsku neuronsku mrežu (CNN) za predviđanje graničnih okvira i vjerojatnosti klasa objekata u ulaznim slikama. YOLO je prvi put implementiran s pomoću okvira Darknet. Darknet je programski okvir otvorenog koda koji sadrži mnoštvo funkcija koje opisuju rad algoritma, a pisan je u C programskoj jeziku (Redmon, 2013).

YOLO algoritam radi na način da dijeli ulaznu sliku u mrežu ćelija, te za svaku ćeliju predviđa vjerojatnost prisutnosti objekta i koordinate graničnog okvira objekta. Također predviđa klasu objekta. Za razliku od dvostupanjskih detektora objekata kao što su R-CNN i njegove varijante, algoritam obrađuje cijelu sliku u jednom prolazu, što ga čini bržim i učinkovitijim. Novi pristup detekciji objekata, odnosno YOLO metoda simbolizira da se na slici može predvidjeti kakvi su objekti i gdje se nalaze u jednome pogledu (Du, 2018).

YOLO je razvijen u nekoliko verzija, kao što su YOLOv1, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, YOLOv7 i YOLOv8. Svaka je verzija izgrađena na temelju prethodne verzije s poboljšanim značajkama kao što su poboljšana točnost, brža obrada i bolje rukovanje malim objektima.


Algoritam se koristi u raznim aplikacijama kao što su samovozeći automobili i sustavi za nadzor. Također se naširoko koristi za zadatke detekcije objekata u stvarnom vremenu kao što je video analitika u stvarnom vremenu i videonadzor u stvarnom vremenu.

2.3.1 Princip rada YOLO algoritma

Kao što je već rečeno YOLO algoritam je vrhunski sustav za otkrivanje objekata u stvarnom vremenu. Toliko je brz da je postao standardni način detekcije objekata u polju računalnog vida. Otkad se pojavio, nadmašio je druge algoritme kao što su detekcija objekata kliznog prozora, R-CNN, Brzi R-CNN, Brži R-CNN, itd. Algoritam funkcionira na temelju sljedeća četiri

pristupa: *Residual blocks*, *Bounding box regression*, *Intersection Over Unions (IOU)*, *Non-Maximum Suppression (Dey, 2023)*.

Prvi korak (*Residual blocks*) počinje dijeljenjem izvorne slike u $N \times N$ ćelija mreže jednakog oblika, gdje je N u slučaju na Slici 2.7 jednak 13. Svaka ćelija u mreži odgovorna je za lokalizaciju i predviđanje klase objekta koji pokriva, s vrijednošću vjerojatnosti/pouzdanosti.



Slika 2.7 Prikaz *Residual blocks* (Dey, 2023)

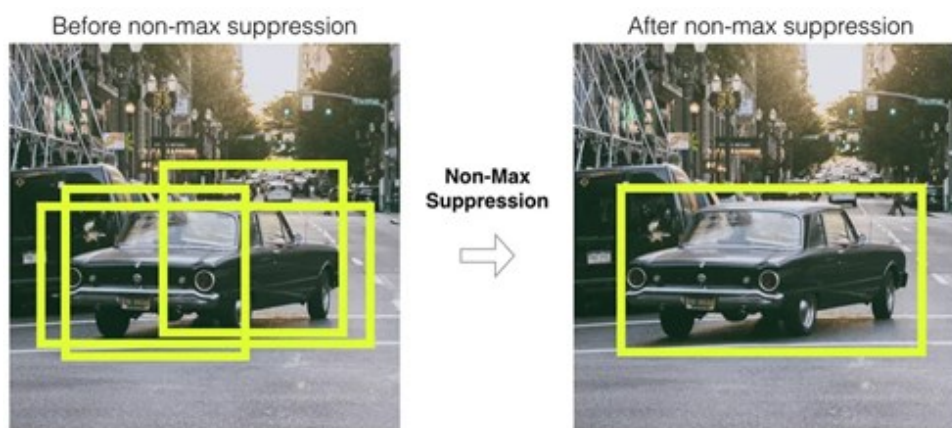
Bounding box regression je tehnika koja se koristi u zadacima otkrivanja objekata za predviđanje koordinata graničnog okvira koji čvrsto zatvara objekt od interesa unutar slike. YOLO određuje attribute ovih graničnih okvira s pomoću jednog regresijskog modula u sljedećem formatu, gdje je Y konačni vektorski prikaz za svaki granični okvir. Vektor Y izgledao bi ovako $Y = [pc, bx, by, bh, bw, c1, c2]$, gdje je pc rezultat vjerojatnosti rešetke koja sadrži objekt, bx, by su koordinate x i y središta graničnog okvira u odnosu na *enveloping grid cell*, bh, bw odgovaraju visini i širini graničnog okvira u odnosu na *enveloping grid celli*, $c1$ i $c2$ odgovaraju dvjema klasama ako ih je toliko na slici. Možemo imati onoliko klasa koliko vaš slučaj upotrebe zahtijeva.

Intersection over Union prikazan na Slici 2.8, koji se obično naziva IOU, metrika je koja se koristi za procjenu preklapanja između dvaju graničnih okvira (*eng. Bounding box*) ili područja interesa. Kvantificira sličnost ili slaganje između predviđenog graničnog okvira i istinitog graničnog okvira. IOU se izračunava kao omjer površine presjeka i površine unije dvaju graničnih okvira. Često se koristi kao kriterij za procjenu izvedbe algoritama za otkrivanje objekata, gdje veći IOU označava bolju točnost otkrivanja.



Slika 2.8 Prikaz Intersection over Union (IOU) (Dey, 2023)

Postavljanje praga za IOU nije uvijek dovoljno jer objekt može imati više okvira s IOU iznad praga, a ostavljanje svih tih okvira može uključivati šum. Ovdje možemo koristiti *Non-Max Suppression* (Slika 2.11) da zadržimo samo okvire s najvećim rezultatom vjerojatnosti otkrivanja.



Slika 2.9 Prikaz Non-Max Suppression (Dey, 2023)

2.3.2 Prednosti YOLO algoritma

YOLO se naširoko koristi u projektima stvarnog svijeta zbog svoje točnosti i brzine. Kada se govori o prednostima vrijedi istaknuti da YOLO algoritam detektira objekte u stvarnom vremenu što ga čini prikladnim za aplikacije kao što su video nadzor ili samovozeći automobili. Kao što je već spomenuto jedna od prednosti je visoka točnost algoritma, koja se postiže korištenjem konvolucijske neuronske mreže (CNN) za predviđanje klase i lokacije objekata na slici. YOLO algoritam je veoma učinkovit, što proizlazi iz spomenute činjenice da YOLO može detektirati objekte na slici sa samo jednim prolazom naprijed kroz mrežu što ga čini učinkovitijim od drugih metoda detekcije objekata koje zahtijevaju više prolaza. Algoritam

također ima dobru izvedbu na malim objektima, odnosno može otkriti male objekte na slici zbog svog pristupa temeljenog na mreži. Nadalje važno je spomenuti učinkovito korištenje GPU-a. YOLO koristi potpuno konvolucijsku mrežnu arhitekturu, koja omogućuje učinkovito korištenje GPU-a tijekom obuke i zaključivanja. Darknet na CPU je brz, ali na GPU je i do 500 puta brži (Wu, i dr., 2013). Na kraju vrijedi istaknuti još sposobnost YOLO algoritma za rukovanje s višestrukim mjerilima. Višestruka mjerila odnose se na sposobnost algoritma da prepozna i detektira objekte različitih veličina unutar iste slike. To je moguće jer algoritam koristi *anchor boxes*, koji omogućuju modelu rukovanje objektima različitih mjerila, osiguravajući tako modelu otkrivanje objekata različitih veličina na istoj slici. *Anchor boxes* su unaprijed određeni pravokutnici različitih veličina koji pomažu algoritmu da prepozna i pronađe objekte različitih veličina i oblika na slici.

2.3.3 Ograničenja YOLO algoritma

Iako je YOLO moćan algoritam za otkrivanje objekata, on također ima neka ograničenja. Neka od tih ograničenja uključuju njegovu usku povezanost s otkrivanjem objekata. Algoritam je prvenstveno dizajniran za otkrivanje. Iako je YOLO precizan, možda neće biti precizan kao dvostupanjske metode, kao što su *RetinaNet* ili *Mask R-CNN*. Iako je među prednostima spomenuto da YOLO algoritam ima dobru izvedbu na malim objektima, algoritam može imati problema s vrlo malim objektima. To proizlazi iz činjenice da se njegov pristup temelji na mreži koja može otežati otkrivanje malih objekata, posebno ako se nalaze blizu drugih objekata.

2.4 QGIS

QGIS (ranije Quantum GIS) je GIS aplikacija otvorenog koda koja omogućuje vizualizaciju, upravljanje, uređivanje i analizu geopodataka. Pokrenut 2002. godine kao projekt Garyja Shermana, QGIS je od 2007. dio Zaklade za geoprostorni softver otvorenog koda, s prvim izdanjem verzije 1.0 u 2009. godini. Program je napisan u C++ jeziku s Qt knjižnicom. Postoji za radne okvire Windows, Mac OS X, Linux, BSD i Android (beta) (Khan, i dr., 2018). Podržava brojne formate (shapefile, dxf, PostGIS) i web usluge (WMS, WFS) te se integrira s drugim GIS alatima otvorenog koda. Njegove funkcionalnosti mogu se proširiti dodacima, a omogućuje i dijeljenje, objavljivanje te izradu tiskanih karata.


2.5 Definiranje područja istraživanja i ulaznih podataka

U ovome radu glavni predmet istraživanja je stvaranje mehanizma koji u nekoliko vrlo jednostavnih koraka vrši automatsku inventuru vertikalne signalizacije. Cilj je kreirati s pomoću YOLO algoritma točan i precizan model na temelju seta podataka koji je kreiran od strane slovenskih stručnjaka. Tabernik i dr.(2019) kreirali su set podataka u kojem se nalazi preko 7000 slika s 13000 instanci prometnih znakova. Drugim riječima postoji 13000 označenih znakova na slikama. Toliko velik broj slika i instanci daje veoma dobru podlogu za stvaranje, odnosno treniranje modela s pomoću YOLO algoritma koji će detektirati kasnije prometne znakove iz georeferenciranog videa.

Kada govorimo o georeferenciranom videu govorimo o videozapisu koji ima pridružene geoprostorne podatke. To znači da je svaka točka unutar videa povezana s određenim geografskim položajem. Geografski položaj se odnosi na koordinate kao što su geografska širina i dužina pa čak i u nekim slučajevima i visina. Ovi podaci omogućuju praćenje i prikazivanje položaja snimke u stvarnom prostoru na karti. Georeferencirani videozapisi se često koriste u kartografiji, nadzoru, praćenju infrastrukture, istraživanju okoliša i sličnim područjima gdje je važno povezati vizualne informacije s točnim lokacijama. Uređaji za snimanje videa kao što su kamere, pametni telefoni i automobilske crne kutije danas su opremljeni GPS senzorima i mogućnošću snimanja videozapisa s prostorno-vremenskim informacijama kao što su vrijeme, lokacija i smjer kamere, a takve videozapise nazivamo georeferenciranim videozapisima (Kim, i dr., 2014). Kroz ovaj diplomski rad obrađivat će se georeferencirani video s područja Brodsko-posavske županije.

Svaki georeferencirani video sastoji se MP4 datoteke, odnosno samog videa, JSON datoteke koja sadrži koordinate videa na temelju vremena videa (konkretno u ovom slučaju koordinate su zapisane za svakih 0.5 sekundi) te GEOJSON datoteku koja nam služi za prikazivanje rute vozila (Slika 2.14), s kojeg je sniman video, u nekom od vizualizacijskih alata. U ovom radu taj alat je QGIS. Također potrebna nam je prostorna baza podataka vertikalne signalizacije za to područje, te su samim time i nabavljeni potrebni podaci, odnosno baze podataka za isto područje. Ubacivanjem baze podataka koja je *.shp* formatu u QGIS, možemo vizualno prikazati prometne znakove i vidjeti gdje se nalaze. Također možemo pristupiti i atributnoj tablici gdje svaki znak ima pridružene određene attribute kao što je šifra znaka, azimut lica znaka, cesta na kojoj se nalazi itd. Lice je prednja strana znaka koju vozač vidi i koja prenosi korisne

informacije (Kunić, 2021). Slika 2.10 prikazuje sve prometne znakove i rute vozila vizualizirane u QGIS-u.



Slika 2.10 Vizualni prikaz prostorne baze podataka i svih ruta vozila

Sada kada se definiralo područje rada s pomoću dobivene baze podataka vertikalne signalizacije i georeferenciranog videa, uz preuzimanje seta podataka može se krenuti u pronalazak rješenja glavnog problema, a to je automatizirana inventura prometnih znakova.

2.5.1 Opis metodologije

Praktični dio ovog diplomskog rada krenuo je s preuzimanjem seta podataka slovenske tvrtke The Visual Cognitive Systems Laboratory. Nakon preuzimanja slika i anotacija, bilo je potrebno razvrstati slike u dvije mape. Prva mapa bila bi mapa za treniranje, dok je druga bila za testiranje. Slike su bile razvrstane na temelju anotacija koje su bile u COCO formatu. COCO (*eng. Common Objects in Context*) format je kompleksniji i sadrži više informacija, a često se koristi u velikim skupovima podataka poput COCO skupa. COCO format koristi JSON datoteku za pohranu podataka o anotacijama. COCO format trebalo se pretvoriti u YOLO format koji je jednostavniji i lakši za implementaciju. Svaka slika ima zasebnu .txt datoteku koja sadrži anotacije za tu sliku. Za razvrstavanje slika i pretvorbu između formata anotacija koristile su se Python skripte.

Sljedeći korak bio je napraviti trening model pomoći YOLO algoritma u svrhu detekcije prometnih znakova. *Model training* (treniranje modela) u kontekstu YOLO algoritma odnosi se na proces učenja modela da prepozna i detektira objekte na slikama. Treniranje modela ključan je korak rješavanja ovog zadatka. Cijeli postupak odvijao se u Conda okruženju, odnosno u condinoj komandnoj liniji (*eng. Command Line Interface*). Prvi korak pokretanju YOLOv8 algoritma na Windows-u je stvaranje virtualnog okruženja u kojem će se raditi. To se postiglo s pomoću `conda create` naredbe, dok se algoritam aktivirao s pomoću `conda activate` naredbe. Sljedeći korak je bio taj da se trebao instalirati PyTorch preko njihove službene stranice (PyTorch), jer se YOLOv8 oslanja na PyTorch kao svoj okvir za duboko učenje. Također je bilo potrebno kreirati `.yaml` datoteku u kojoj se nalaze putanje do *Train* i *Test* foldera i popis svih klasa koje model treba detektirati. Sada je sve spremno za pokretanje trenažnog procesa. U upisanoj liniji koja pokreće trening modela postavljeni su određeni parametri. Parametri koji su bili postavljeni su *mode*, *model*, *data*, *epochs*, *batch*, *imgsz*, te *device*.

Nakon što se pokrenuo i završio trenažni postupak dobiveni su određeni rezultati. Svi rezultati treniranja pohranjeni su u posebnu mapu nazvanu *train*. U mapi *train* pohranjena je mapa nazvana *weights* u kojoj se nalaze dvije datoteke. Datoteke su nazvane *best.pt* i *last.pt*. Datoteka *best.pt* sadrži model s težinama koje su dale najbolje rezultate tijekom treniranja. Takav najbolji rezultat se obično određuje prema metrikama performansi, kao što su najniži gubitak (*eng. loss*) ili najbolja točnost (*eng. accuracy*) na validacijskom skupu. S druge strane datoteka *last.pt* sadrži model s težinama iz posljednje epohe treniranja. To znači da prikazuje stanje modela nakon završetka cijelog procesa treniranja, bez obzira na to je li ta epoha bila najbolja u smislu performansi. Nadalje u mapi *train* dobivena je tekstualna datoteka sa svim parametrima koji su korišteni pri treniranju modela. Većina tih parametara je automatska i nije ih se trebalo upisivati u komandnu liniju prije pokretanja treniranja, no neki su ručno podešeni radi ispunjavanja nekih ciljeva, kao što je na primjer povećanje točnosti modela. Jedan od takvih parametara je *epochs* koji je postavljen na 200. Tijekom treniranja YOLO modela, parametar *epochs* određuje koliko će puta model proći kroz cijeli trening skup podataka. Što bi značilo da ako je *epochs=200*, model će proći kroz cijeli set podataka 200 puta. Od drugih značajnih parametara valja istaknuti još *batch* koji je postavljen na 16, a služi za podjelu podataka na manje skupine ili hrpe kako bi se poboljšala efikasnosti i ubrzao proces treniranja. U Tablici 2.1 prikazani su ručno postavljeni parametri zajedno sa svojim vrijednostima.

Tablica 2.1 Prikaz parametara korištenih pri treniranju modela

<i>task</i>	<i>mode</i>	<i>model</i>	<i>data</i>	<i>epochs</i>	<i>batch</i>	<i>imgsz</i>	<i>save</i>	<i>device</i>
<i>detect</i>	<i>train</i>	yolov8n.pt	data.yaml	200	16	2560	<i>true</i>	0,1

Također u mapi se nalaze vizualno i tablično spremljene određene metrike, odnosno statistički pokazatelji modela temeljeni na performansama treniranja ovisno o epohi treniranja. Pokazatelji su *train/box_loss* koji označava gubitak povezan s regresijom granica okvira (*eng. bounding box*) tijekom treniranja, *train/cls_loss* pokazuje gubitak povezan s klasifikacijom tijekom treniranja. Nadalje *train/dfl_loss* odnosi se na gubitak povezan s finijom procjenom granica okvira, *precision(B)* označava preciznost mjerenja na validacijskom skupu podataka, *recall(B)* u prijevodu znači odaziv te označava koliko dobro model pronalazi sve stvarne objekte. Preciznost se odnosi na broj točnih detekcija metode, dok je *recall* metrika ispravno detektiranih objekata koji stvarno postoje (Atik, i dr., 2022). Metrika *mAP50* mjeri prosječnu preciznost pri IoU pragu od 50 %, dok *mAP50-95* mjeri prosječnu preciznost kroz različite pragove (od 50 % do 95 %). Ovaj prag određuje koliko se predviđeni okvir mora preklapati sa stvarnim okvirom da bi se smatrao ispravnim. *mAP50-95* je rigoroznija metrika koja daje sveobuhvatniji pregled performansi modela. U svrhu mjerenja kvalitete prepoznavanja modela korištena je metrika *mAP* koja se odnosi na raspon vrijednosti od 0 do 1 i određuje prosječnu preciznost rezultata dobivenih u tom rasponu (Činarer, 2024). *Val/box_loss* mjeri koliko su predviđeni okviri blizu stvarnim okvirima tijekom validacije, *val/cls_loss* pokazuje gubitak povezan s klasifikacijom tijekom validacije i *val/dfl_loss* određuje koliko je model precizan u predikciji granica objekata tijekom validacije. Na samome kraju *pg0*, *pg1* i *pg2* se odnose na stopu učenja za različite grupe parametara u modelu tijekom treniranja. Za kraj rezultata treniranja modela valjda istaknuti još jednu stavku koja je spremljena u mapu sa svim ostalim spomenutim rezultatima treniranja, a to su slike koje se odnose na usporedbu treniranih predikcija i istinitih vrijednosti okvira gdje se nalaze prometni znakovi. U mapi su spremljene slike s nazivima *val_batch_pred* (Slika 3.5) i *val_batch_labels* (Slika 3.4). Slike s *val_batch_pred* nazivom označava sliku u kojoj se nalaze predikcije modela za hrpu (*eng. Batch*) podataka iz validacijskog skupa. To su rezultati koje model generira nakon obrade slika ili drugih podataka u toj hrpi. *Val_batch_labels* slike označavaju stvarne oznake (*eng. ground*

truth) za hrpu podataka iz validacijskog skupa. Oznake su podaci koje znamo unaprijed, odnosno to su anotacije kojima su unaprijed označeni objekti od interesa kojima su pridodane klase i koriste se za provjeru točnosti predikcija modela.

Slično kao i kod treninga modela, obavljena je detekcija, odnosno predikcija na MP4 videu. U YOLOv8 algoritmu, zadatak *predict* odnosi se na predikciju odnosno detekciju objekata na slikama ili videozapisima koristeći obučeni model. Obučeni model koji je korišten u ovoj predikciji je već spomenuti *best.pt* model. Za ovaj zadatak predikcije koristila se posebna Python skripta koja je davala rezultate na način koji je bio prikladan za daljnju obradu podataka. Razlog tome leži u činjenici da se htjela postići određena vrsta i izgleda izlaznog podatka. Cilj je bio dobiti tekstualne datoteke za svaki okvir videa u kojem bi se nalazio broj okvira, detekcija te pouzdanost detekcije. Ključno je naglasiti da su se spremale i tekstualne datoteke za okvire koji nisu ništa detektirali. Tablica 2.2 i Tablica 2.3 prikazuju primjer dobivenih izlaznih podataka za okvire s detekcijama i bez detekcija. Uz tekstualne datoteke dobiveni rezultat predikcije je i video na kojem se može pratiti sama detekcija znakova. U Python skripti korišteni su različiti moduli i knjižnice. Uvezen je *os* modul koji omogućuje interakciju s operativnim sustavom, *cv2* uvozi OpenCV knjižnicu koja je popularna za računalni vid koja omogućuje obradu slika i videa, također je uvezen YOLO iz *ultralytics* paketa (Jocher, i dr., 2023), te je na kraju kao i prije spomenuto uveden modul *torch* koji je glavni modul PyTorch knjižnice.

Tablica 2.2 Prikaz tekstualne datoteke koja sadrži detekcije

Okvir	Klasa	Pouzdanost
9911	VI-8	0,958896
9911	III-84	0,928036

Tablica 2.3 Prikaz tekstualne datoteke koja ne sadrži detekcije

Okvir	Klasa
1	<i>no detection</i>

Nakon predikcije izvršene na georeferenciranom videu, točnije rečeno MP4 dijelu georeferenciranog videa, slijedi par nužnih koraka koji će pripremiti podatke dobivene predikcijom kako bi se obavila uspješna inventura vertikalne signalizacije. Bilo je potrebno izračunati koordinate i azimut svakog okvira videa, konvertirati znakove sa slovenske klasifikacije u hrvatsku klasifikaciju, filtrirati okvire koji imaju detekcije te na kraju stvoriti podatkovni okvir sa svim detekcijama. Svaki od ovih zadataka obavljen je s pomoću Python programskog jezika.

Koordinate za svaki okvir videa izračunate su na način da se koristila JSON datoteka dobivena u sklopu georeferenciranog videa sa tekstualnim datotekama dobivenih na predikciji videa. Iz broja tekstualnih datoteka vidio se broj okvira u videu. Taj broj okvira podijeljen je s duljinom trajanja videa u sekundama kako bi se dobio omjer koliko je okvira po jednoj sekundi u videu. Broj okvira po sekundi nam služi kako bi otkrili u kojoj se točno sekundi u videu nalazi pojedini okvir. To se dobije tako da se broj okvira podijeli s brojem okvira po sekundi. U JSON datoteci zapisane su koordinate, tako da je zapisana koordinata prvog videa, te je svaka sljedeća zapisana koordinata vremenski udaljena 0.5 sekundi od prethodne. Kada se izračunalo vrijeme pojedinog okvira, od tog vremena se oduzima vrijeme koje je prvo najbliže manje vrijeme koje ima koordinate zapisano u JSON datoteci. Na primjer, za okvir videa 5474, ukoliko je 10 okvira po sekundi, znači da se taj okvir nalazi na 547,4 sekundi videa. Vremena koja su zapisana u JSON datoteci koja su najbliža tom vremenu bila bi 547 i 547,5. Kao što je spomenuto gore oduzme se vrijeme okvira s prvim nižim zapisanim vremenom u ovom slučaju 547 i dobije se razlika ta dva vremena koja se zatim podijeli s 0,5 jer je to razlika između dva vremena u JSON datoteci. Time smo dobili postotak na kojem se nalazi naš okvir na dionici između vremena 547 i 547,5. U ovom primjeru taj postotak iznosi 80%. Nakon tog potrebno je izračunati koordinatne razlike između X i Y koordinata vremena 547 i 547,5. Te razlike množe se sa postotkom, time se dobije udaljenost X i Y koordinata okvira od X i Y koordinata manjeg vremena. Na kraju koordinate okvira dobiju se zbrajanjem tih udaljenosti s X i Y koordinatama nižeg vremena. Uz već spomenuti os modul uveden je json modul koji omogućuje rad s JSON podacima.

Nakon računanja koordinata bilo je potrebno izračunati azimut svakog okvira videa kako bi dobili putanju po kojoj se kretao auto koji je snimao video. Azimut se računao na temelju koordinata dviju točaka susjednih uzastopnih okvira. Prvo su se izračunale razlike u koordinatama s pomoću formula (1) i (2).

$$\Delta x = x_1 - x_0 \quad (1)$$

gdje je:

Δx - razlika x koordinata dvije točke

x_1 - x koordinata druge točke

x_2 - x koordinata prve točke

$$\Delta y = y_1 - y_0 \quad (2)$$

gdje je:

Δy - razlika y koordinata dvije točke

y_1 - y koordinata druge točke

y_2 - y koordinata prve točke

Nakon toga izračunao se azimut u radijanima s pomoću formule (3), te se pretvorio u stupnjeve s pomoću formule (4).

$$azimut_{rad} = atan2(\Delta y, \Delta x) \quad (3)$$

gdje je:

$azimut_{rad}$ – azimut u radijanima

Δy - razlika y koordinata dvije točke

Δx - razlika x koordinata dvije točke

$$azimut_{stupnjevi} = azimut_{rad} * \frac{180^\circ}{\pi} \quad (4)$$

gdje je:

$azimut_{stupnjevi}$ – azimut u stupnjevima

$azimut_{rad}$ – azimut u radijanima

π – konstanta pi (iznosi 3,14)

Za potrebe rada kut je trebao biti između linije koja spaja dvije točke i sjever, iz tog razloga azimut se računao tako da se referenca pomakla za 90 stupnjeva kako bi se dobio azimut u geografskom smislu s pomoću formule (5).

$$azimut_{konačno} = 90^{\circ} - azimut_{stupnjevi} \quad (5)$$

gdje je:

$azimut_{konačno}$ – konačni azimut

$azimut_{stupnjevi}$ – azimut u stupnjevima

Ukoliko je dobiven azimut manji od 0 dodaje se 360 stupnjeva. Dosad ne spomenuti moduli koji su uvedeni te su korišteni za izračunavanje azimuta s pomoću Python skripte su math modul koji pruža mnoge matematičke funkcije i konstante koje su korisne za znanstvene i inženjerske proračune i modul re (*eng. regular expressions*) koji se koristi se za rad s regularnim izrazima. Regularni izrazi su moćan alat za pretraživanje i manipulaciju tekстом na temelju uzoraka. Izgled izlaznog formata s izračunatim koordinatama i azimutom prikazan je Tablicom 2.4 i 2.5.

Tablica 2.4 Prikaz tekstualne datoteke s detekcijama

Okvir	Klasa	Pouzdanost
9906	II-47	0,878666
9906	III-84	0,822807
9906	VI-8	0,557978

Tablica 2.5 Prikaz koordinata i azimuta u tekstualnoj datoteci

X koordinata:	Y koordinata:	Azimut:
17,865287	45,178476	89,88240

Kako je set podataka s pomoću kojeg je treniran model za detekciju vertikalne signalizacije slovenskog podrijetla samim time i klase, odnosno šifre znakova u anotacijama su vođene slovenskom klasifikacijom znakova. Upravo iz tog razloga sljedeći korak veoma je važan, a on je konverzija slovenske klasifikacije u hrvatsku klasifikaciju. Prijevod znakova odvio se tako da se ručno kreirala tekstualna datoteka koja je imala zapisane slovenske klase i kraj njih hrvatske. Hrvatske klase izvučene su iz kataloga prometnih znakova kreiranog od strane tvrtke Signal Grad (Signal Grad, 2020). U Tablici 2.6 i Tablici 2.8 tablično je prikazan izlazni rezultat za okvir 92 prije i poslije konverzije. Dok su u Tablicama 2.7 i 2.9 prikazane koordinate i azimut za taj okvir.

Tablica 2.6 Prikaz tekstualne datoteke prije prijevoda znakova

Okvir	Klasa	Pouzdanost
92	I-18	0,946219

Tablica 2.7 Prikaz koordinata i azimuta tekstualne datoteke prije prijevoda znakova

X koordinata:	Y koordinata:	Azimut:
17,681697	45,172634	105,999327

Tablica 2.8 Prikaz tekstualne datoteke poslije prijevoda znakova

Okvir	Klasa	Pouzdanost
92	A33	0,946219


Tablica 2.9 Prikaz koordinata i azimuta tekstualne datoteke poslije prijevoda znakova

X koordinata:	Y koordinata:	Azimut:
17,681697	45,172634	105,999327

Radi olakšavanja obrade podataka, nakon računanja koordinata i azimuta gdje su bili potrebni svi okviri videa čak i oni bez detekcija, sljedeći korak bio je filtriranje odnosno spremanje samo onih tekstualnih datoteka okvira koji sadrže detekcije u posebnu mapu. Kada se to odradilo s pomoću Python skripte, napravljena je Python skripta koja kreira podatkovni okvir u formatu .csv, kako bi se lakše pristupilo inventuri. Stupci tog podatkovnog okvira su Frame, class_1, class_2, class_3, class_4, class_5, confidence_1, confidence_2, confidence_3, confidence_4, confidence_5, X, Y i Azimut. Stupac Frame odnosi se broj okvira u videu, stupci class odnosi se na klase detektirane na pojedinom okviru. Moguće je da se više klasa bude detektirano na pojedinom okviru. Stupac confidence odnosi se na pouzdanost detekcije pojedine klase. X i Y su koordinate okvira videa, dok je Azimut azimut okvira. Kreiranjem podatkovnog okvira završena je priprema podataka potrebnih za inventuru prometnih znakova na temelju detekcija iz georeferenciranog videa i prostorne baze podataka. Izgled podatkovnog okvira za prvih 10 okvira videa prikazan je Tablicom 2.10 gdje su stupci class_3, class_4, class_5, confidence_3, confidence_4 i confidence_5 izostavljeni s obzirom da su u izvornom formatu prazni.

Tablica 2.10 Prikaz podatkovnog okvira

Okvir	klasa_1	klasa_2	conf_1	conf_2	X	Y	Azimut
1072	A14		0,412		17,69962	45,16769	102,56
1073	A14		0,412		17,69964	45,16768	102,56
1074	A14		0,892		17,69966	45,16768	102,56
1075	A08		0,683		17,69968	45,16767	102,56
1076	A04-1		0,722		17,69970	45,16767	102,56
1077	A04-1		0,722		17,69972	45,16767	102,56
1078	A04-1		0,722		17,69974	45,16766	102,56
1079	A04-2		0,962		17,69976	45,16766	102,56
1080	A04-2	A04-1	0,890	0,643	17,69977	45,16766	102,56
1081	A04-2	A04-1	0,890	0,643	17,69979	45,16765	102,56



Slika 2.12 Prikaz baze podataka koja se obrađuje

Za kraj, bilo je potrebno kreirati Python skriptu koja radi inventuru prometnih znakova kako bi se ispunio cilj ovog diplomskog rada. Inventura se sastoji od nekoliko postavljenih uvjeta i matematičkih računica. Za početak potrebno je pretvoriti koordinate okvira u isti koordinatni sustav u kojem se nalaze koordinate prometnih znakova u prostornoj bazi podataka. Koordinate okvira videa su u WGS84 koordinatnom sustavu, dok su koordinate znakova u prostornoj bazi podataka u HTRS96 koordinatnom sustavu. Konverzija koordinata provedena je s pomoću biblioteke `pyproj`, koja omogućava rad s različitim projekcijama i transformacijama koordinata. Osim `pyproj` biblioteke, korištene su `shapely` biblioteka za manipulaciju i analizu geometrijskih objekata u Pythonu, `geopandas` knjižnica koja je proširenje također korištene `pandas` knjižnice, koje omogućuju rad s geografski referenciranim podacima, tj. podacima koji imaju prostornu komponentu (koordinate). Sada kada su koordinate u istom koordinatnom sustavu, za svaki prometni znak je izračunata udaljenost do svakog okvira. Udaljenost je izračunata s pomoću formule za računanje udaljenosti (6).

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (6)$$

gdje je:

d – udaljenost koordinata

x_1 – x koordinata prve točke

x_2 – x koordinata druge točke

y_1 – y koordinata prve točke

y_2 – y koordinata druge točke

Nakon računanja udaljenosti postavljen je uvjet da svaki okvir koji je bliži od 15 metara do znaka ostane u daljnjoj obradi. Nakon što je okvir prošao uvjet udaljenosti, mora zadovoljiti uvjet azimuta. Azimut okvira videa mora biti za 180 stupnjeva različit od azimuta znaka uz dopuštenu toleranciju od 60 stupnjeva. Nadalje svaki takav okvir koji je zadovoljio prvo uvjet udaljenosti, pa uvjet azimuta može ući u zadovoljavanje sljedećeg uvjeta. Sljedeći uvjet je taj da se klasa znaka zapisana u bazi podataka prometnih znakova mora poklapati za klasom znaka koji je detektiran u tom okviru koji je zadovoljio prijašnje uvjete. Zadnji uvjet bio bi taj da pouzdanost detekcije mora biti veća od 0,75. Ako je neki okvir zadovoljio svaki od ova 4 uvjeta za neki znak, za potrebe ovoga rada, taj znak se vodi kao da postoji u suprotnom se smatra nepostojećim. Zapis znakova koji postoje i onih koji ne postoje spremljen je u .csv datoteku i time je završena inventura znakova za odabrano područje.

REZULTATI

Ovo poglavlje prikazuje rezultate istraživanja automatske detekcije vertikalne signalizacije koristeći metode strojnog učenja, odnosno u ovom konkretnom slučaju YOLO algoritam i georeferencirani video.

3.1 Rezultati YOLOv8 algoritma

YOLOv8 algoritam koristio se za treniranje modela koji detektira prometne znakove i za predikciju istih na georeferenciranom videu. Dobiveni su statistički podaci za sve epohe, dok su u Tablicama 3.1 i 3.2 prikazani relevantni statistički podaci epohe s najboljim rezultatima, a to je 200. epoha.

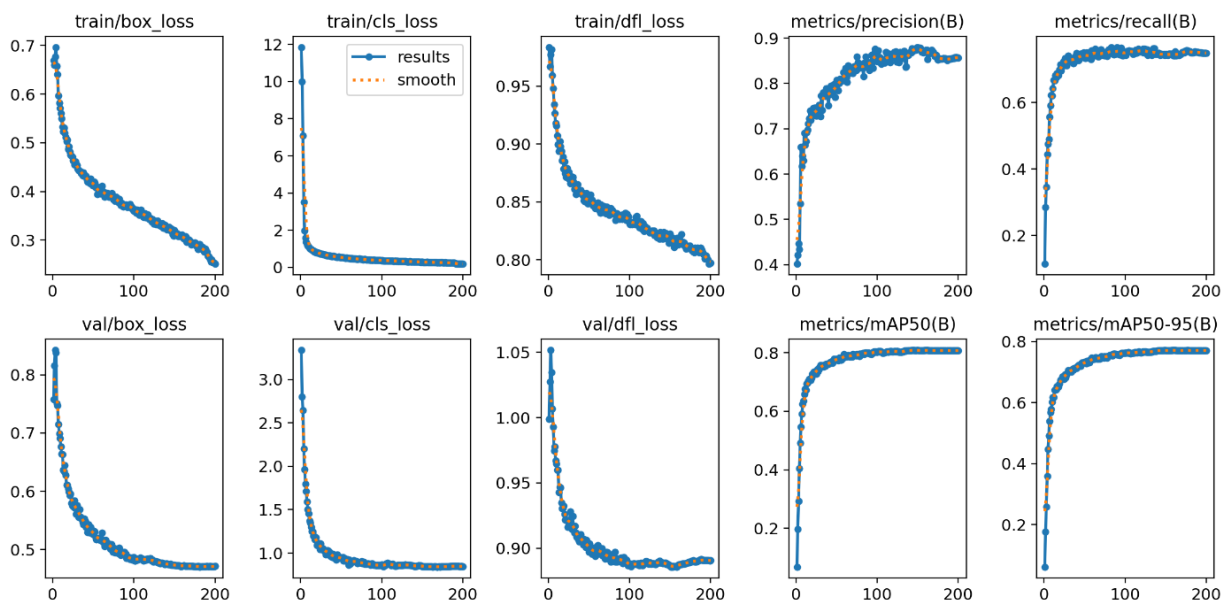
Tablica 3.1 Prikaz statističkih pokazatelja 200. epohe (1)

epoch	precision	recall	mAP50	mAP50-95	val/box_loss
200	0,856	0,749	0,807	0,771	0,471

Tablica 3.2 Prikaz statističkih pokazatelja 200. epohe (2)

val/cls_loss	val/dfl_loss	lr/pg0	lr/pg1	lr/pg2
0,847	0,891	0,00015	0,00015	0,00015

Uz ovaj tablični prikaz još je priložen i vizualni grafički prikaz spomenutih metrika koji se može vidjeti na Slici 3.1.



Slika 3.1 Grafovi statistike modela

Kao što je prije navedeno, nakon treniranja dobivene su i slika određenog *batch*-a koji prikazuje slike sa njihovim stvarnim okvirima i slika koja prikazuje isti taj *batch*, ali s predikcijom okvira koju je model stvorio. Na Slici 3.2 prikazan je batch sa stvarnim okvirima dok je na Slici 3.3 prikazan batch za prediciranim okvirima.



Slika 3.2 Prikaz stvarnih oznaka za batch 0



Slika 3.5 Dio val_batch_pred slike (1)



Slika 3.6 Dio val_batch_labels slike (2)




Slika 3.7 Dio val_batch_pred slike (2)



Slika 3.8 Dio val_batch_labels slike (3)



Slika 3.9 Dio val_batch_pred slike (3)



Slika 3.10 Dio val_batch_labels slike (4)



Slika 3.11 Dio val_batch_pred slike (4)

Nakon provedenog treninga modela, učinjena je predikcija na videu. Dobiveni izlazni rezultat u obliku tekstualne datoteke prikazan je Tablicama 2 i 3. Osim takve tekstualne datoteke dobiven je video koji prikazuje vizualno detekcije. Na Slikama 3.12, 3.13, 3.14, 3.15, 3.16 prikazani su samo neki od okvira videa na kojima su detektirani znakovi.



Slika 3.12 Primjer okvira videa 1



Slika 3.13 Primjer okvira videa 2



Slika 3.14 Primjer okvira videa 3



Slika 3.15 Primjer okvira videa 4



Slika 3.16 Primjer okvira videa 5

3.2 Rezultati inventure

Kao što je već spomenuto za ostvarivanje cilja ovog istraživanja podatke dobivene predikcijom bilo je potrebno izračunati koordinate, azimute te prevesti znakove sa slovenske klasifikacije na hrvatsku klasifikaciju i malo urediti sam izgled podataka radi lakše uporabe pri samoj inventuri. Krajnji izgled tih podataka prikazan je Tablicom 2.10.

Tablični prikaz krajnjeg rezultata predstavljen je u Prilogu 1. Tablica se sastoji od pet stupaca koji prikazuju id znaka, klasu znaka, njegove koordinate i status znaka. Iz tablice konačne inventure može se vidjeti da se prostornoj bazi podataka korištenoj za inventuru nalazi 262 prometna znaka. Od tih 262 prometna znaka 60 znakova je evidentirano kao da postoje, dok ih je 202 evidentirano kao da ne postoje.

Prilog 2. predstavlja tablicu u kojoj se nalaze sve klase vertikalne signalizacije koje se mogu naći u prostornoj bazi podataka, gdje je u stupcima Znak postoji i Znak ne postoji evidentirano koliko je znakove te vrste prepoznato kao da postoji odnosno ne postoji. Iz tablice se može vidjeti da postoji 58 različitih klasa unutar baze podataka. Valja istaknuti da se u bazi podataka najviše puta pojavljuju znakovi klase B30, čak 35 puta. Znakovi ove klase evidentirani su kao da postoje 14 puta, a da ne postoje 21 puta. Postoje klase znakova koje se u bazi podataka samo jednom pojavljuju. Većina takvih znakova je evidentirana kao da ne postoji, osim znaka C83 koji je uspješno evidentiran ako da postoji. Znakovi klase 70, 50, 40, 25, 24, 23, 22 i 14 nijedan put nisu evidentirani kao da postoje dok su ukupno 47 puta evidentirani kao da ne postoje.

Na Slici 3.17 vizualno su prikazani postojeći i ne postojeći znakovi.



Slika 3.17 Vizualni prikaz postojećih i ne postojećih znakova

Na Slici 3.18 prikazan je primjer okvira koji će nam u daljnjoj analizi poslužiti kao primjer dobrog rada skripte koja radi inventuru prometnih znakova.



Slika 3.18 Prikaz okvira s detektiranim A33 prometnim znakom

Tablica 3.3 prikazuje uzastopnu detekciju istog znaka. U tablici je prikazan iznos pouzdanosti za pojedini okvir u kojem je znak B30 detektiran. U prvom okviru koji je detektirao znak pouzdanost iznosi 0,277 dok u zadnjem iznosi 0,973.

Tablica 3.3 Prikaz uzastopnih detekcija

Okvir	klasa 1	klasa 2	klasa 3	klasa 4	klasa 5	conf 1
2290	B30					0,277
2291	B30					0,271
2292	B30					0,851
2293	B30					0,852
2294	B30					0,960
2295	B30					0,972
2296	B30					0,973
2297	B30					0,973

DISKUSIJA

Svrha i cilj ovog istraživanja je stvoriti jednostavan, gotovo automatski postupak s pomoću kojeg će se ručno održavanje prostorne baze podataka vertikalne signalizacije zamijeniti ovim jednostavnijim i modernijim pristupom. Nakon što je u potpunosti provedeno istraživanje i nakon što su dobiveni rezultati, potrebno je napraviti analizu i diskusiju istih. Ovo poglavlje bavit će se upravo time, analizom dobivenih rezultata.

Za početak će se analizirati rezultati dobiveni nakon korištenja YOLOv8 algoritma. Uporabom YOLOv8 algoritma dobiveni su rezultati treninga i predikcije. Rezultati dobiveni nakon završetka treninga modela pohranjeni su u zajedničku mapu gdje su spremljeni određeni statistički pokazatelji i metrike s pomoću kojih možemo ocijeniti naša dva dobivena modela, a to su `best.pt` i `last.pt`. U Tablicama 3.1 i 3.2 mogu se vidjeti gubici, preciznost, odaziv, mAP te brzina učenja za statistički najbolju epohu, dok je na Slici 3.1 grafički prikazano kretanje pojedinih metrika za sve epohe. Stupac `train/box_loss` odnosi se na točnost predikcije okvira objekta tijekom treniranja. Vidljivo je da se smanjuje kako epohe napreduju. U prvih 5 epoha točnost predikcije okvira objekta kreću se oko brojke 0,6 dok od šeste epohe već taj broj pada na 0,5. U zadnjih deset epoha vrijednost ove metrike pala je na vrijednosti koje se kreću između 0,26 do 0,25. Na grafu kretanja `train/box_loss`-a vidljivo je da njegova vrijednost naglo pada u otprilike prvih 25 epoha i da nakon toga vrijednosti kreću padati gotovo jednoliko u skoro ravnoj liniji. Ovakav trend kretanja ove metrike sugerira poboljšanje modela u određivanju položaja objekata kako epohe rastu. Gubitak u stupcu `train/cls_loss` označava točnost klasifikacije objekata tijekom treniranja. Ovdje također pratimo opadanje vrijednosti ove metrike. Točnost klasifikacije objekata u prvoj epohi iznosi 11,848 te ta vrijednost kreće drastično padati u drugoj epohi gdje ova metrika iznosi 10,004, pa u trećoj 7,083, četvrtoj 3,175, petoj 1,979 sve kako bi u zadnjoj 200. epohi ta vrijednost iznosila 0,188. Grafički prikaz jasno prikazuje nagli pad vrijednosti veću prvih 10-ak epoha gdje se poslije toga vrijednosti kreću ispod 1, što ukazuje na to da model postaje bolji u prepoznavanju klase objekta. Sljedeća dva stupca koja će se analizirati odnose se gubitke tijekom validacije, koji bi idealno trebali biti niski i blizu treniranih gubitaka. Ta dva stupca su `val/box_loss` i `val/cls_loss`. U prvih par epoha vrijednosti `val/box_loss` kreću se od 0,7 do 0,8 što je usporedno s prvim vrijednostima "`train/box_loss`" veće za 0,1 no to nije prevelika razlika. S rastom epoha iznos `val/box_loss` pada i u zadnjim epohama iznosi 0,47 dok se u `train/box_loss` stupcu kreće od oko 0,25, što

daje primijetiti razliku no ne preveliku da bi se model odbacio. Usporedimo li dalje val/cls_loss i train/cls_loss, početna vrijednost ovog pokazatelja tijekom validacije iznosi 3,339, dok početna vrijednosti tijekom treniranja 11,848. Vrijednosti ovih pokazatelja iznose 0.847 za validaciju i 0.188 za trening. Iako je na početku velika razlika u vrijednostima, pad obje vrijednosti i smanjenje razlike između njih daje dobar znak da model uči i da se generalizacija poboljšava. Usporedimo li ova dva pokazatelja grafički (Slika 3.1) oni su jako slični što se tiče krivulje. U oba slučaja u prvih nekoliko epoha bilježi se nagli pad i nakon toga ustaljivanje vrijednosti koje se kreću ispod 1. Parametri val/dfloss i train/dfloss odnose se na *Distillation Feature Loss* (DFL), koja je specifična vrsta gubitka korištena u YOLOv8 modelima. Ova vrsta gubitka pomaže modelu da bolje nauči poziciju rubova objekata unutar graničnih okvira, što može poboljšati preciznost modela prilikom lociranja objekata. Parametar train/dfloss se računa na skupu podataka za treniranje, a val/dfloss na validacijskom skupu i predstavlja koliko dobro model uči pozicionirati objekte tijekom treniranja. Oba parametra u prvoj epohi imaju vrijednosti od oko 0,9 i te vrijednosti padaju rastom epoha na konačnih 0,797 odnosno 0,891. Oba gubitka opadaju i razlika između njih je mala, što bi značilo da model dobro generalizira i da je sposoban precizno locirati objekte ne samo na trenirajućem, već i na validacijskom skupu podataka. Stupac precision odnosi se na preciznost modela. Preciznost se definira kao omjer točno predviđenih opažanja prema ukupno predviđenim pozitivnim opažanjima (Guntuboina, i dr., 2021). Preciznost modela raste s povećanjem epoha, što je dobar pokazatelj. Početna vrijednost preciznosti iznosi 0,402 dok preciznost u zadnjoj epohi iznosi 0,856. Iz grafičkog prikaza koji pokazuje rast preciznosti kako raste broj epoha može se iščitati kako postoji nagli rast preciznosti u prvih pedesetak epoha te da nakon toga preciznost i dalje raste ali uz manju stopu rasta. Zaključak da kako epohe rastu, raste i preciznost dokazuju u svom istraživačkom radu Dewi i dr. (2021) koji su čak u 2000 epoha, 10 puta više epoha nego u ovom diplomskom radu, postigli preciznost od 0,99. Odaziv modela označava omjer točno predviđenih pozitivnih uzoraka u odnosu na sve stvarno pozitivne uzorke. Odaziv također raste s povećanjem epoha, kod kojeg vrijednost prve epohe iznosi 0,114, a zadnje epohe 0,749. Grafički prikaz odaziva ukazuje na njegov nagli rast i oko tridesete epohe smirivanje rasta odaziva koji postaje ujednačeniji. Dewi i dr.(2022) u svom modelu koji je poboljššan SPP-om postižu odaziv od 0,99. Autori su svoj model trenirali na 4000 epoha, praćenjem trenda rasta odaziva s povećanjem epoha u ovom diplomskom radu može se zaključiti da kada bi se i u ovom radu broj epoha povećao s 200 na nešto više, metrika odaziva bi se također povećala.

Usporedbom vrijednosti nekoliko prvih i zadnjih epoha modela može se vidjeti stalan porast u mAP50 i mAP50-95 metrikama, što sugerira poboljšanje ukupne performanse modela. Vrijednosti mAP50 i mAP50-95 u prvoj epohi iznose 0,068 odnosno 0,061, dok u zadnjoj epohi te vrijednosti rastu na 0,807 i 0,771. Rast je vidljiv na grafovima, i može se zaključiti da u prvih tridesetak epoha prosječna preciznost pri IoU pragu od 50 % i pragu od 50 % do 95 % naglo raste, te da je poslije tih epoha gdje je zabilježen nagli rast primjetan sporiji ali i dalje vidljiv rast ovih metrika. Du i dr. (2024) u svome radu u kojem su koristili YOLOv8s algoritam i određene alate kako bi isti poboljšali, dobili su mAP50 metrike za dva seta podataka koji su koristili. Na prvom setu dobili su vrijednosti mAP50 od 0,865 i 0,906 za drugi set podataka. Usporede li se ti rezultati s rezultatima dobivenim u ovom diplomskom radu može se primijetiti da su Du i dr. (2024) dobili bolje rezultate, no ne previše bolje te se može zaključiti da bi se vjerojatno slični rezultati postigli i u ovome diplomskom radu da su se koristila određena poboljšanja na modelu. Tabernik i dr. (2019) u svome radu koriste Faster R-CNN i Mask R-CNN kao alat za detekciju znakova i u svojim modelima za metriku mAP50-95 postigli su rezultate 0,80 za Faster R-CNN odnosno 0,84 za Mask R-CNN s određenim poboljšanjima. Uspoređujući sva tri algoritma korištena u radu Tabernika i dr. (2019) i ovom diplomskom radu (Faster R-CNN, Mask R-CNN i YOLOv8) može se zaključiti da su postignute slične vrijednosti mAP50-95 metrike. Brzina učenja (*eng. Learning rate*) nalazi se u stupcima lr/pg0, lr/pg1, lr/pg2 i za nju se može zaključiti proučavanjem Tablice 3.2 da se postupno povećava do treće epohe, a zatim stabilizira. Ovo je normalno kod korištenja određenih strategija za optimizaciju, kao što je korištenje *warmup* faze gdje se brzina učenja povećava na početku treniranja. Kao konačni rezultat treninga modela dobivene su slike koje uspoređuju sliku u kojoj se nalaze predikcije modela za hrpu podataka iz validacijskog skupa i slike koje označavaju stvarne oznake za hrpu podataka iz validacijskog skupa. Na Slici 3.3 nalazi se hrpa sa slikama na kojima se nalaze predikcije modela za hrpu podataka iz validacijskog skupa, dok se na Slici 3.2 nalazi batch slika na kojem se nalaze stvarne oznake za hrpu podataka iz validacijskog skupa. Na sljedećih nekoliko slika izdvojeni su neki od primjera iz val_batch_labels i val_batch_pred koji ukazuju na točnosti i pogreške između predikcija modela i stvarnih oznaka. Gornje slike svakog para odnose se na zadane okvire (stvarne oznake), a donje slike prikazuju predikcije. Na prvom paru na Slici 3.4 može se uočiti da je zadan okvir za znak III-12 i da je taj znak uspješno prepoznat u predikciji na Slici 3.5 i to s pouzdanošću 100 %. Na sljedećem paru na Slikama 3.6 i 3.7 također vidimo uspješnu detekciju oba znaka koja su anotirana uz pouzdanost 100 % i 90

% . Zanimljiv je sljedeći primjer u kojem na Slici 3.8 nije označen donji dio znaka kao dio koji predstavlja određeni znak, kao u gornjem primjeru, ali u predikciji na Slici 3.9 donji dio znaka je detektiran uz pouzdanost 50 % dok je anotirani znak uspješno prepoznat s pouzdanošću 100 %. Na Slici 3.10 je vidljiv primjer u kojem je anotiran znak II-1 kojem je lice znaka okrenuto. Uz taj znak anotirano je još 4 znaka. U predikciji na Slici 3.11 detektiran je samo znak III-86-1 uz pouzdanost 70 %, dok ostali nisu. Dobro za model i ovo istraživanje je to što se znak kojem je lice okrenuto nije detektirao.

Nakon analize modela, slijedi analiza rezultata dobivenih predikcijom. Predikcijom su dobivene tekstualne datoteke i mp4 video. Dobiveno je 9912 tekstualnih datoteka. Svaka od tih datoteka predstavlja jedan okvir georeferenciranog videa nad kojim je izvršena predikcija. Tablicom 2.2 prikazana je struktura dobivenih tekstualnih datoteka. Svaka datoteka sastoji se od bitnih informacija koje su potrebne za daljnji rad. Svaka datoteka u sebi sadrži broj okvira, klasu detektiranog prometnog znaka i shodno tome pouzdanost uz koju je znak detektiran. Okviri na kojima nema detekcija, odnosno prazni okviri također su dobili svoje tekstualne zapise gdje je također evidentiran broj okvira, dok za klasu piše "no detection", kao što se vidi u Tablici 2.3. Važno je napomenuti da ukoliko pojedini okvir ima više detekcija, isto kao i u Tablici 2.2, sve detekcije su spremljene u istu datoteku ali svaka detekcija zapisana je u svoj red s odgovarajućom pouzdanošću gdje je u svakom retku zapisan i broj okvira. Osim ovakvih tekstualnih datoteka sa spremljenim detekcijama dobiven je i video. Video odgovara ulaznom georeferenciranom videu. Razlika je što su u novom videu vidljive predikcije kao što se može vidjeti na Slikama 3.12, 3.13, 3.14, 3.15, 3.16. Svakom prometnom znaku koji detektiran iscertan je granični okvir iznad kojeg je ispisana klasa prometnog znaka i uz koju pouzdanost je detektiran znak. Na Slikama 3.12, 3.13, 3.14 vidimo primjere uspješno detektiranih znakova s velikom pouzdanošću. Na Slici 3.15 vidimo kako prometni znak nije uopće detektiran i svrstan u određenu klasu. Slika 3.16 je izdvojena kao primjer okvira u kojem su detektirana dva znaka iste klase i to sa velikom pouzdanošću.

Dobiveni rezultati predikcijom YOLOv8 algoritma nadopunjeni su i malo modificirani radi praktičnijeg rukovanja i manipulacijom istih u daljnjem radu. Koordinate i azimut koji su se računali za svaki okvir zapisani su u redove ispod onih gdje je zapisan broj okvira, detekcije na tom okviru i pouzdanost tih detekcija. Primjer takvog zapisa može se vidjeti u Tablici 2.5. Važno je istaknuti da su koordinate zapisane u decimalnom zapisu i izračunate za koordinatni

sustav WGS84, također azimut okvira je zapisan u decimalnom obliku. S obzirom na to što je model treniran na setu podataka u kojima su prometni znakovi bili klasificirani slovenskom klasifikacijom, a znakovi unutar prostorne baze podataka hrvatskom klasifikacijom, potrebno je slovensku klasifikaciju prevesti u hrvatsku. U Tablicama 2.6 i 2.8 može se vidjeti kako se detektirani znak I-18 preveo u A33. Struktura datoteke ostala je ista samo je promijenjena klasa znaka. Završni korak pripreme podataka dobivenih predikcijom s pomoću YOLOv8 algoritma bio je kreirati podatkovni okvir koji se sastoji samo do okvira videa na kojima su detektirani znakovi (Tablica 2.10). Razlog tomu leži u činjenici da bi se u kasnijoj inventuri okvira videa u kojima nema detekcija ignorirali, te bi proces inventure bio sporiji radi količine takvih okvira. Podatkovni okvir se sastoji od 14 stupaca gdje je u prvom zapisan broj okvira, u sljedećih 5 zapisane su klase detektiranih znakova, nakon toga slijede stupci s pouzdanošću istih. U zadnja tri stupca zapisane se koordinate i azimut okvira. Kao što je spomenuto zapisani su samo okviri koji imaju detekcije. Takvih okvira je 642 od ukupno 9912 okvira, što znači da 9270 okvira ne sadrži nikakvu detekciju. Navedeno se može zaključiti gledajući video na kojem je jasno vidljivo da ima dosta dijelova ceste po kojoj je sniman video gdje znakova uopće nema tako da se ništa ne može uopće detektirati. Također treba uzeti u obzir broj znakova kojima je lice na zadanoj trajektoriji okrenuto suprotno od smjera vožnje. Nadalje u tablici se može primijetiti kako je uglavnom svaki znak koji je detektiran, detektiran u više uzastopnih okvira otprilike pet do šest uzastopnih okvira videa. Valja primijetiti kako je pouzdanost detekcije u prvim okvirima gdje je neki znak detektiran niža od zadnjeg okvira na kojem je detektiran pojedini znak. Takav trend može se vidjeti na primjeru detekcije znaka B30 koji je prikazan u Tablici 3.3 gdje se vidi da u prvom okviru u kojem je detektiran znak pouzdanost iznosi 28 % dok u zadnjem okviru pouzdanost iznosi 97 %. Navedeno se događa jer kako se vozilo u videu približava znakovima oni su sve veći i čišći te ih je lakše detektirati.

Analizom azimuta svakog okvira može se vidjeti da se vozilo ne kreće pravocrtno, te da postoje određena skretanja u ruti, ali može se zaključiti da se vozilo konstantno kreće u smjeru istoka s obzirom na to da se vrijednost azimuta kreće od 65 do 115 stupnjeva. Ovaj zaključak može se potvrditi uvidom u rutu auta prikazana na Slici 2.11 koja je dobivena u GEOJSON formatu uz georeferencirani video koja je ubačena u QGIS.

Konačni rezultat istraživanja je inventura prikazana kao Prilog 1 obavljena s pomoću Python skripte u kojoj su ulazni podaci bili prostorna baza podataka u kojoj su pohranjeni prometni

znakovi za odabrano područje i prethodno opisani podatkovni okvir. Način na koji je provedena inventura opisan je u rezimeu praktičnog dijela. Kao krajnji rezultat inventure dobivena je .csv datoteka koja ima stupce id, Sifra, X, Y, Status. Stupac id odnosi se na identifikacijski broj koji svaki prometni znak ima unutar prostorne baze podataka, Sifra se odnosi na klasu znaka odnosno šifru pojedinog znaka, X i Y stupci prikazuju koordinate svakog prometnog znaka, a Status odnosi se na status znaka. Dvije su vrijednosti koje se mogu naći u stupcu Status. Prva je "Znak postoji", a druga je "Znak ne postoji". Znak se vodi kao postojeći ukoliko detekcija znaka dobivena YOLOv8 algoritmom ispunjava sva četiri postavljena uvjeta. Prvi uvjet bio bi uvjet udaljenosti, ukoliko je okvir videa udaljen od znaka manje od 15 metara to znači da je okvir zadovoljio prvi uvjet. Drugi uvjet je uvjet azimuta i on se ispunjava ukoliko je azimut okvira onog okvira koji zadovoljio prvi uvjet različit od azimuta lica prometnog znaka za 180 stupnjeva uz toleranciju od 60 stupnjeva. Kada su zadovoljena oba uvjeta slijedi uvjet poklapanja klase i zadovoljavanje određene točnosti. Nakon provjere udaljenosti i azimuta provjerava se nalazi li se ista klasa ili drugim riječima šifra i u prostornoj bazi podataka i u detekciji klase iz videa ukoliko se nalazi ista klasa pouzdanost detekcije mora biti veći od 75 % da bi se znak vodio kao da postoji. Ukoliko sva četiri uvjeta nisu ispunjena bar za jedan okvir prometni znak se u inventurnoj tablici vodi kao da ne postoji. U prostornoj bazi podataka nalazi se 262 prometna znaka, od čega je njih 60 evidentirano kao da postoji. Na Slici 3.18 prikazan je jedan primjer uspješne evidencije znaka. Znak I-18 u prijevodu A33 koji se nalazi u prostornoj bazi podataka po ID-em 2524 znak je koji je evidentiran kao da postoji u tablici inventure. Provjera se može obaviti ručno gdje se u podatkovnom okviru pronašao okvir sa Slike 3.18, odnosno okvir koji je detektirao znak A33 uz pouzdanost 95 %. Odmah na prvu vidimo da su zadovoljena dva uvjeta od četiri. Nadalje računanjem udaljenosti koja je ispala da je 10.87 metara možemo reći da se još jedan uvjet ispunio. Na kraju azimut okvira iznosi 106 stupnjeva, dok azimut lica znaka iznosi 319. Oduzimanjem 319 sa 180 dobije se 139, što bi značilo da je uz toleranciju od 60 stupnjeva i uvjet azimuta zadovoljen te je ovaj znak pravilno evidentiran u tablici inventure.

Kada se vratimo na činjenicu da je od 262 prometna znaka u prostornoj bazi podataka samo 60 znakova evidentirano kao da postoje, mogu se izložiti neki od razloga zašto je to tako. Za početak postoje prometni znakovi kojima je lice znaka okrenuto suprotno od vozila koje vrši snimanje te je evidencija takvih znakova nemoguća. Gledajući Sliku 3.17 na kojoj su prikazani

samo postojeći znakovi može se primijetiti da su skoro svi ti znakovi južno odnosno s desne strane ceste kada se gleda smjer kretanja vozila. Također postoje slučajevi gdje dolazi do određenih razlika u nazivima klasa i nedostatak istih u treniranom modelu. Naime kako je model treniran na slovenskom setu podataka, korištene su slike na kojima su slovenski znakovi koji se naravno u nekim primjerima razlikuju od hrvatskih, te je sama opća klasifikacija znakova drugačija između Hrvatske i Slovenije. Gledajući Prilog 2 znakovi u bazi podataka s klasom 70, 50, 40, 25, 24, 23, 22 i 14 od kojih niti jedan nije detektiran ne postoje u slovenskom setu podataka. Iz tog razloga ti znakovi uopće nisu detektirani. Navedeni znakovi spadaju u turističku signalizaciju koja se razlikuje od države do države. Kada bi se uz pomoć stručnjaka napravio čisti hrvatski set podataka sa svim vrstama znakova ovaj problem bi se riješio. Također uvođenjem određene standardizacije klasificiranja i samog izgleda znakova, na razini Europske unije recimo, riješio bi se ovaj problem. Na najvišem stupnju standardiziranosti nalaze se znakovi izričitih naredaba i znakovi obavijesti, a na nešto nižem stupnju znakovi opasnosti i znakovi obavijesti za vođenje prometa (Milić, 2021). Najveće razlike uočene su u oblicima i bojama podloge prometnih znakova, a nešto manje u bojama simbola i natpisima na prometnim znakovima (Milić, 2021). Promatrajući Prilog 2 mogu se izvući neki zaključci o samoj cesti odnosno ruti po kojoj je sniman video. Postoje određeni prometni znakovi s kojima se često srećemo i od kojih bi očekivali da su se dosta puta pojavili kroz ovu inventuru. Znak klase B02 odnosno znak stop pojavljuje se 7 puta u bazi podataka, no niti jedan put nije detektiran. Nadalje znak B01, znak raskrižja s cestom s prednošću prolaska se niti jedan put nije našao u bazi podataka. Također znak C06 koji označava cestu s prednošću prolaska pojavio se u bazi 4 puta od čega je 3 puta evidentiran kao da postoji. Znak koji se najviše puta pojavio je već spomenuti B30 koji označava ograničenje brzine. Znak se pojavio 35 puta od čega je evidentiran da postoji 14 puta, da ne postoji 21 puta. Uzevši u obzir sve rečeno može se zaključiti da je odabrana ruta cesta koja prolazi kroz manja naselja u kojima nema puno semafora i križanja, što u jednu ruku ima i smisla s obzirom da su slavonska naselja poznata po svom duguljastom obliku koji se pruža u smjeru ceste. S obzirom na sve rečeno dobiveni rezultati inventure su veoma zadovoljavajući i pružaju jake temelje za potencijalno unaprjeđenje.

ZAKLJUČAK

Važnost i utjecaj vertikalne signalizacije istaknut su kroz ovo istraživanje, gdje je nekoliko puta naglašeno kako su prometni znakovi od ključne važnosti za održavanje reda i sigurnosti na cestama. Oni pružaju neophodne informacije i smjernice svim sudionicima u prometu, pomažući u sprječavanju nesreća, smanjenju zastoja i osiguravanju sigurnog i učinkovitog prometa. Samim time važno je su ti prometni znakovi često kontrolirani. Kontrola i evidencija vertikalne prometne signalizacije može biti dugotrajan i težak posao. Cilj ovog istraživanja bio je istražiti rješenje ovog problema koristeći modernu tehnologiju i metodologiju. Područje istraživanja bila je Brodsko-posavska županija unutar Republike Hrvatske unutar koje se odabrala trajektorija na kojoj se obavljalo istraživanje. Uz pomoć modernih alata kao što su Python programski jezik, YOLOv8 algoritam i QGIS kreirani su uvjeti za ispunjenje cilja.

Kroz YOLOv8 algoritam kreiran je općenito uspješan model za detekciju prometnih znakova koji se može primijeniti na raznim formatima ulaznih podataka kao što su na primjer slike i videi. QGIS je poslužio za vizualizaciju baze podataka prometnih znakova i rute vozila koji je snimao georeferencirani video. Python programski jezik pomogao je pri manipulaciji rezultata dobivenih detekcijom i pri izvršavanju glavnog cilja, a to je dobivanje tablice u kojoj su određeni prometni znakovi iz prostorne baze podataka inventirani.

Statistike modela koji je istreniran s pomoću YOLOv8 algoritma daju veoma dobre rezultate i samim time dobre preduvjete za nastavak dobivanja zadovoljavajućih rezultata tijekom istraživanja. Shodno tome dobiveni su veoma dobri rezultati nakon provedene predikcije na georeferenciranom video, gdje uvidom u uređeni podatkovni okvir tih rezultata možemo primijetiti da su detekcije obavljene s velikom preciznošću. Na kraju dobivena je tablica u kojoj se nalaze prometni znakovi iz prostorne baze podataka nad kojima je na temelju detekcija obavljena inventura tih znakova. Rezultati konačne inventure su takvi da je samo 23 % prometnih znakova iz baze podataka evidentirano kao da postoje. No to nije previše zabrinjavajuće s obzirom na to da je dokazano da je skripta koja obavlja inventuru točna.

Na kraju valjda kazati da su rezultati ovog istraživanja zadovoljavajući, ali ne i savršeni. Postizanje savršenijih i boljih rezultata uključivalo bi za početak stvaranje seta podataka koji sačinjen od slika s hrvatskih cesta na kojima su hrvatski znakovi. Samim time anotiranje tih znakova bi se vršilo tako da bi se zapisivale hrvatske klase znakova. Tako bi se uklonile

pogreške nastale radi obavljanja istraživanja na slovenskom setu podataka gdje postoje određene razlike u prometnim znakovima između dvije države. Nadalje bilo bi dobro da se koriste videi koji su snimani u oba smjera ceste tako bi postotak uspješno evidentiranih znakova porastao, jer u ovom istraživanju korišteni video rutu snima samo u jednom smjeru čime automatski eliminira veliki broj znakova. Sve ovo neke su od ideja i prijedloga koji bi se mogli primijeniti u potencijalnim novim istraživanjima na istu ili sličnu tematiku.

Zaključno, prometni znakovi su neizostavan dio sigurnosti na našim cestama i moramo ih doživljavati s ozbiljnošću koju zaslužuju. Njihova uloga u prevenciji nesreća i održavanju reda na cestama ne može se zanemariti. Svako odstupanje ili zanemarivanje tih znakova može dovesti do nesreća i kobnih situacija koje se mogu izbjeći pravovremenim i odgovornim ponašanjem. Stoga, potrebno je kontinuirano ulagati u njihovo održavanje i nadzor, kako bismo osigurali da sigurnost na cestama ostane prioritet koji nitko od nas ne smije uzimati zdravo za gotovo.

LITERATURA

- Atik, Muhammed Enes, Duran, Zaide i Ozgunluk, Roni. 2022.** Comparison of YOLO Versions for Object Detection from Aerial Images. *International Journal of Environment and Geoinformatics*. 2022.
- Berišić, Ante. 2015.** *Prometni znakovi u funkciji povećanja sigurnosti prometa na cestama*. s.l. : Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2015.
- Brkić, Filip. 2019.** *Analiza kvalitete prometnih znakova na državnim cestama Zadarske županije*. Zagreb : an., 2019.
- Çinarer, Gökalp. 2024.** Deep Learning Based Traffic Sign Recognition Using YOLO Algorithm. *Düzce University Journal of Science & Technology*. 2024.
- Dewi, Christine, i dr. 2022.** Deep Convolutional Neural Network for Enhancing Traffic Sign Recognition developed on Yolo V4. 2022.
- Dewi, Christine, i dr. 2021.** Yolo V4 for advanced traffic sign recognition with synthetic training data generated by various GAN. 26. Lipanj 2021.
- Dey, Ishani. 2023.** Medium. *What is YOLO algorithm*. [Mrežno] 12. Srpanj 2023. <https://medium.com/@ishudey11032002/what-is-yolo-algorithm-ef5a3326510b>.
- Du, Juan. 2018.** Understanding of Object Detection Based on CNN Family and YOLO. *Journal of Physics: Conference Series*. 2018.
- Du, Songjie, i dr. 2024.** TSD-YOLO: Small traffic sign detection based on improved YOLOv8. 24. Travanj 2024.
- Guntuboina, Chakradhar, i dr. 2021.** Deep Learning Based Automated Sports Video Summarization using YOLO. *Electronic Letters on Computer Vision and Image Analysis*. 2021.
- Jiang, Peiyuan, i dr. 2022.** *A review of Yolo Algorithm Developments*. 2022.
- Jocher, G, Chaurasia, A i Qiu, J. 2023.** *Ultralytics YOLO (Version 8.0.0)*. [Mrežno] 2023. <https://github.com/ultralytics/ultralytics>.
- Khan, Shafat i Mohiuddin, Khalid. 2018.** *Evaluating the parameters of ArcGIS and QGIS for GIS Applications*. 2018.
- Kim, Youngwoo, Kim, Jinha i Yu, Hwanjo. 2014.** GeoTree: Using spatial information for georeferenced video search. 2014.
- Krištofić, Mario. 2022.** *Prometni znakovi i njihov utjecaj na sigurnost cestovnog prometa*. Zagreb : Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2022.
- Kunić, Tomislav. 2021.** *Utjecaj pozicije prometnih znakova na vrijednost retrorefleksije*. Zagreb : Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2021.
- Milić, Petar. 2021.** *Analiza standardiziranosti prometnih znakova na području Europske unije*. Zagreb : Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2021.
- Petravić, Darko. 2017.** Instruktor vožnje. *Prometni znakovi*. [Mrežno] 2017. https://www.instruktor-voznje.com.hr/prometni_znakovi/.
- PyTorch.** PyTorch. [Mrežno] <https://pytorch.org/>.

Redmon, Joseph. 2013. Darknet: Open Source Neural Networks in C. *Darknet: Open Source Neural Networks in C*. [Mrežno] 2013. https://pjreddie.com/darknet/#google_vignette.

Redmon, Joseph, i dr. 2015. You Only Look Once: Unified, Real-Time Object Detection. 2015.

Signal Grad. 2020. Katalog prometnih znakova, prometne i dodatne opreme. *Katalog prometnih znakova, prometne i dodatne opreme*. [Mrežno] 2020. [Citirano: 29. Kolovoz 2024.] <https://www.signal.hr/wp-content/uploads/2023/04/katalog-prometnih-znakova-2020.pdf>.

Šantić, Tomislav. 2017. *Programski jezik Python*. Osijek : an., 2017.

Tabernik, Domen i Skočaj, Danijel. 2019.. Deep Learning for Large-Scale Traffic-Sign Detection and Recognition. 2019.

The Visual Cognitive Systems Laboratory. ViCoS Lab. *The Visual Cognitive Systems Laboratory*. [Mrežno] <https://www.vicos.si/research/traffic-sign-detection/>.

Wu, Yihui, i dr. 2013. *Traffic Sign Detection based on Convolutional Neural Networks*. Dallas : an., 2013.

Yuill, Simon i Halpin, Harry. 2006. *Python*. Boston : an., 2006.

POPIS SLIKA

Slika 2.1 Znakovi opasnosti (Signal Grad, 2020)	7
Slika 2.2 Znakovi izričitih naredbi (prva varijanta i dva izuzetka) (Signal Grad, 2020)	7
Slika 2.3 Znakovi opasnosti (druga varijanta) (Signal Grad, 2020).....	8
Slika 2.4 Znakovi obavijesti (Signal Grad, 2020).....	8
Slika 2.5 Znakovi obavijesti za vođenje prometa (Signal Grad, 2020).....	9
Slika 2.6 Dopunske ploče (Signal Grad, 2020) (Dey, 2023).....	9
Slika 2.7 Prikaz Residual blocks (Dey, 2023).....	12
Slika 2.8 Prikaz Intersection over Union (IOU) (Dey, 2023)	13
Slika 2.9 Prikaz Non-Max Suppression (Dey, 2023).....	13
Slika 2.10 Vizualni prikaz prostorne baze podataka i svih ruta vozila	16
Slika 2.11 Prikaz odabrane rute.....	25
Slika 2.12 Prikaz baze podataka koja se obrađuje	26
Slika 3.1 Grafovi statistike modela	29
Slika 3.2 Prikaz stvarnih oznaka za batch 0	29
Slika 3.3 Prikaz predikcije modela za batch 0	30
Slika 3.4 Dio val_batch_labels slike (1).....	30
Slika 3.5 Dio val_batch_pred slike (1).....	31
Slika 3.6 Dio val_batch_labels slike (2).....	31
Slika 3.7 Dio val_batch_pred slike (2).....	32
Slika 3.8 Dio val_batch_labels slike (3).....	32
Slika 3.9 Dio val_batch_pred slike (3).....	33
Slika 3.10 Dio val_batch_labels slike (4).....	33
Slika 3.11 Dio val_batch_pred slike (4).....	34
Slika 3.12 Primjer okvira videa 1	34
Slika 3.13 Primjer okvira videa 2.....	35
Slika 3.14 Primjer okvira videa 3	35
Slika 3.15 Primjer okvira videa 4.....	36
Slika 3.16 Primjer okvira videa 5.....	36
Slika 3.17 Vizualni prikaz postojećih i ne postojećih znakova.....	37
Slika 3.18 Prikaz okvira s detektiranim A33 prometnim znakom	38

POPIS TABLICA

Tablica 2.1 Prikaz parametara korištenih pri treniranju modela	18
Tablica 2.2 Prikaz tekstualne datoteke koja sadrži detekcije	19
Tablica 2.3 Prikaz tekstualne datoteke koja ne sadrži detekcije	19
Tablica 2.4 Prikaz tekstualne datoteke s detekcijama	22
Tablica 2.5 Prikaz koordinata i azimuta u tekstualnoj datoteci.....	22
Tablica 2.6 Prikaz tekstualne datoteke prije prijevoda znakova	23
Tablica 2.7 Prikaz koordinata i azimuta tekstualne datoteke prije prijevoda znakova	23
Tablica 2.8 Prikaz tekstualne datoteke poslije prijevoda znakova.....	23
Tablica 2.9 Prikaz koordinata i azimuta tekstualne datoteke poslije prijevoda znakova.....	23
Tablica 2.10 Prikaz podatkovnog okvira.....	24
Tablica 3.1 Prikaz statističkih pokazatelja 200. epohe (1).....	28
Tablica 3.2 Prikaz statističkih pokazatelja 200. epohe (2).....	28
Tablica 3.3 Prikaz uzastopnih detekcija	38
Tablica 8.1 Prikaz konačne tablice inventure.....	51
Tablica 8.2 Prikaz svih klasa baze podataka i kvantitativni status pojedine klase.....	57

PRILOZI

Prilog 1

Tablica 8.1 Prikaz konačne tablice inventure

id	Sifra	X	Y	Status
2518	B47	592856,721	5004329,884	Znak ne postoji
2519	B02	592856,721	5004329,884	Znak ne postoji
2520	C81	592850,180	5004337,354	Znak ne postoji
2521	22	592872,499	5004332,426	Znak ne postoji
2522	D07	592872,499	5004332,426	Znak ne postoji
2523	50	592876,887	5004327,972	Znak ne postoji
2524	A33	592885,571	5004300,094	Znak postoji
2525	C06	592887,579	5004314,205	Znak ne postoji
2526	14	592936,474	5004251,239	Znak ne postoji
2527	D03-1	592995,349	5004219,630	Znak ne postoji
2529	C76	593030,916	5004181,269	Znak postoji
2530	C77	593037,774	5004188,200	Znak ne postoji
2531	A33	593365,963	5004054,618	Znak ne postoji

2532	B30	593625,674	5003968,066	Znak ne postoji
2533	C47	594319,226	5003779,496	Znak ne postoji
2534	A04-2	594319,787	5003770,151	Znak postoji
2537	C47	594342,147	5003762,706	Znak postoji
2538	50	594347,233	5003760,995	Znak ne postoji
2539	24	594347,233	5003760,995	Znak ne postoji
2540	70	594347,233	5003760,995	Znak ne postoji
2541	A05	594374,236	5003753,304	Znak ne postoji
2542	B30	594374,236	5003753,304	Znak postoji
2543	B30	594383,507	5003761,009	Znak ne postoji
2544	A22	594403,156	5003744,381	Znak postoji
2545	C78-1	594429,418	5003736,889	Znak ne postoji
2546	70	594429,418	5003736,889	Znak ne postoji
2648	C78-1	598548,433	5003685,394	Znak ne postoji
2649	C78-1	598548,433	5003685,394	Znak ne postoji
2650	C78-1	598548,433	5003685,394	Znak ne postoji
2651	B02	598550,895	5003666,042	Znak ne postoji
2715	C78-1	595129,994	5003994,576	Znak ne postoji
2716	A21	595237,057	5004034,171	Znak ne postoji
2717	A36	595401,387	5004076,362	Znak ne postoji
2718	A36-5	595398,194	5004085,352	Znak ne postoji
2719	A36-3	595472,479	5004088,780	Znak postoji
2720	A36-8	595471,298	5004097,170	Znak ne postoji
2721	A36-4	595545,353	5004101,857	Znak postoji
2722	A36-9	595543,107	5004110,966	Znak ne postoji
2723	B23	595602,027	5004098,401	Znak ne postoji
2724	G13	595632,694	5004106,429	Znak postoji
2725	G13	595636,514	5004122,355	Znak ne postoji
2726	K10-1	595647,330	5004128,824	Znak ne postoji
2727	A36-4	595729,145	5004143,298	Znak ne postoji
2728	A36-9	595730,466	5004132,599	Znak ne postoji
2729	A36-8	595793,342	5004144,371	Znak ne postoji
2730	A36-3	595791,298	5004154,008	Znak ne postoji
2731	A36	595868,086	5004166,202	Znak ne postoji
2732	A36	595868,645	5004157,067	Znak ne postoji
2733	A05-2	595928,877	5004176,368	Znak ne postoji
2734	B30	595928,877	5004176,368	Znak ne postoji
2735	C47	596129,522	5004211,664	Znak ne postoji
2736	C47	596236,876	5004217,599	Znak postoji
2737	A05-1	596424,078	5004249,233	Znak postoji
2738	B30	596685,222	5004237,336	Znak ne postoji
2739	C76	596712,373	5004226,926	Znak ne postoji
2740	A05	596738,462	5004217,025	Znak ne postoji
2741	C76	596867,854	5004153,737	Znak postoji

2742	25	596874,366	5004151,893	Znak ne postoji
2743	B30	596991,344	5004104,234	Znak postoji
2744	C47	597216,193	5004018,555	Znak postoji
2745	C47	597320,017	5004000,388	Znak ne postoji
2746	B30	597614,849	5003924,308	Znak ne postoji
2747	C76	597644,602	5003916,358	Znak ne postoji
2748	C76	597665,993	5003903,550	Znak postoji
2749	14	597697,982	5003894,163	Znak ne postoji
2750	B30	597731,023	5003885,003	Znak postoji
2751	14	597752,116	5003877,866	Znak ne postoji
2752	C47	598093,860	5003789,706	Znak postoji
2753	24	598107,597	5003787,817	Znak ne postoji
2754	50	598107,597	5003787,817	Znak ne postoji
2755	24	598107,597	5003787,817	Znak ne postoji
2756	24	598107,597	5003787,817	Znak ne postoji
2757	24	598231,172	5003754,415	Znak ne postoji
2758	A05-1	598272,770	5003744,338	Znak ne postoji
2759	24	598284,381	5003750,404	Znak ne postoji
2760	B30	598403,366	5003713,886	Znak ne postoji
2761	70	598403,366	5003713,886	Znak ne postoji
2762	C44	598408,662	5003712,391	Znak ne postoji
2763	C06	598505,748	5003687,307	Znak postoji
2764	A22	598525,278	5003679,097	Znak ne postoji
2765	C44	596018,654	5004183,662	Znak ne postoji
2766	C78-1	595013,491	5003955,052	Znak ne postoji
2767	C76	595049,016	5003955,688	Znak postoji
2768	25	595052,824	5003968,987	Znak ne postoji
2769	C78-1	595070,729	5003963,265	Znak ne postoji
2770	A05	595063,002	5003972,292	Znak ne postoji
2771	C02	595088,037	5003969,304	Znak ne postoji
2772	C02	595097,509	5003984,579	Znak ne postoji
2773	50	594486,201	5003733,320	Znak ne postoji
2774	24	594486,201	5003733,320	Znak ne postoji
2775	C78-1	594501,674	5003728,085	Znak ne postoji
2776	70	594501,674	5003728,085	Znak ne postoji
2777	C02	594519,575	5003715,635	Znak postoji
2778	C02	594552,076	5003728,205	Znak ne postoji
2779	B36	594562,169	5003716,059	Znak ne postoji
2780	E05	594562,169	5003716,059	Znak ne postoji
2781	B36	594562,060	5003737,497	Znak ne postoji
2782	B24	594571,009	5003745,512	Znak ne postoji
2783	A22	594603,809	5003752,201	Znak ne postoji
2784	A05-1	594702,652	5003806,116	Znak ne postoji
2785	B30	594702,652	5003806,116	Znak ne postoji

2786	A21	594926,141	5003908,556	Znak postoji
2787	C76	594916,016	5003915,761	Znak ne postoji
2788	C78-1	595009,586	5003941,226	Znak ne postoji
2789	K28	595015,664	5003943,734	Znak ne postoji
2790	C39	598576,557	5003663,602	Znak postoji
2791	E12	598576,557	5003663,602	Znak ne postoji
2792	B30	598697,921	5003630,279	Znak ne postoji
2793	B45	598697,921	5003630,279	Znak ne postoji
2794	C39	598688,688	5003627,298	Znak ne postoji
2796	B28-1	598745,637	5003572,691	Znak ne postoji
2797	E06-3	598745,637	5003572,691	Znak ne postoji
2798	A05	598869,999	5003489,284	Znak ne postoji
2799	B28	598859,114	5003497,522	Znak ne postoji
2800	E06-3	598859,114	5003497,522	Znak ne postoji
2802	A14	599057,543	5003340,910	Znak postoji
2803	A22	599115,411	5003302,136	Znak postoji
2804	B30	599115,411	5003302,136	Znak postoji
2806	C02	599171,954	5003263,815	Znak postoji
2807	C02	599184,341	5003267,477	Znak ne postoji
2808	B30	599240,797	5003217,908	Znak postoji
2809	A22	599243,378	5003228,248	Znak ne postoji
2810	B30	599243,378	5003228,248	Znak ne postoji
2811	C59	599258,587	5003206,519	Znak ne postoji
2812	A14	599301,570	5003189,112	Znak ne postoji
2813	24	599364,741	5003135,129	Znak ne postoji
2814	C59	599369,011	5003145,286	Znak ne postoji
2815	C47	599376,560	5003141,410	Znak ne postoji
2816	14	599415,555	5003116,059	Znak ne postoji
2817	24	599439,509	5003101,613	Znak ne postoji
2818	A05	599493,193	5003054,209	Znak ne postoji
2819	B30	599539,751	5003037,596	Znak ne postoji
2820	C76	599585,288	5002998,683	Znak postoji
2821	C76	599587,038	5003008,170	Znak postoji
2822	25	599595,025	5003003,250	Znak ne postoji
2823	B30	599625,305	5002975,555	Znak postoji
2824	A05-1	599897,681	5002930,852	Znak ne postoji
2825	C47	600099,252	5002922,253	Znak ne postoji
2826	A05	600144,600	5002908,987	Znak ne postoji
2827	A05-1	600486,745	5002927,845	Znak ne postoji
2828	A05-2	600755,906	5002973,418	Znak postoji
2829	A33	600812,937	5002994,925	Znak postoji
2830	A05-1	601013,911	5003123,410	Znak ne postoji
2831	B30	601032,010	5003139,254	Znak ne postoji
2832	C76	601057,341	5003144,597	Znak postoji

2833	C76	601053,922	5003154,002	Znak ne postoji
2834	C44	601185,478	5003223,892	Znak ne postoji
2835	B30	601191,728	5003228,774	Znak postoji
2836	A33	601216,936	5003255,084	Znak ne postoji
2837	A04-2	601598,464	5003533,504	Znak postoji
2838	24	601830,208	5003681,100	Znak ne postoji
2839	24	601890,166	5003729,883	Znak ne postoji
2840	B04	601992,334	5003776,821	Znak ne postoji
2841	B45	602008,314	5003786,432	Znak ne postoji
2842	B30	602008,314	5003786,432	Znak ne postoji
2843	B30	602057,541	5003826,950	Znak ne postoji
2844	B30	602034,285	5003823,949	Znak postoji
2845	A22	602101,983	5003856,777	Znak postoji
2846	C47	602152,698	5003889,963	Znak postoji
2847	C02	602193,186	5003916,468	Znak postoji
2848	C47	602184,129	5003922,313	Znak ne postoji
2849	A22	602268,894	5003975,700	Znak ne postoji
2850	A05-1	602321,640	5004000,512	Znak postoji
2851	B30	602321,640	5004000,512	Znak ne postoji
2852	B30	602319,371	5004010,460	Znak ne postoji
2853	24	602343,262	5004013,262	Znak ne postoji
2854	50	602371,115	5004031,997	Znak ne postoji
2855	24	602371,115	5004031,997	Znak ne postoji
2856	25	602371,115	5004031,997	Znak ne postoji
2857	C78-1	602397,678	5004045,668	Znak postoji
2858	D07	602423,981	5004055,866	Znak ne postoji
2876	B02	594996,197	5003949,966	Znak ne postoji
2877	B02	595111,594	5003966,399	Znak ne postoji
2878	C02	595111,594	5003966,399	Znak ne postoji
2964	B02	602419,719	5004071,666	Znak ne postoji
2965	B02	603129,062	5004052,250	Znak ne postoji
5046	B30	603254,193	5004041,462	Znak postoji
5047	70	603285,763	5004045,443	Znak ne postoji
5048	D03-1	603389,352	5004030,104	Znak ne postoji
5049	A05	603545,259	5004013,832	Znak ne postoji
5050	A05	603883,425	5004046,575	Znak ne postoji
5051	40	604029,651	5004093,530	Znak ne postoji
5052	B30	604076,873	5004107,546	Znak ne postoji
5053	C76	604107,870	5004107,844	Znak postoji
5054	C76	604104,348	5004116,825	Znak ne postoji
5055	A05-1	604128,689	5004124,370	Znak ne postoji
5056	A05	604150,671	5004121,368	Znak postoji
5057	B30	604150,671	5004121,368	Znak postoji
5058	A05-1	604359,432	5004219,118	Znak ne postoji

5059	C47	604396,180	5004235,171	Znak ne postoji
5060	C47	604524,540	5004278,059	Znak postoji
5061	A05	604681,495	5004338,788	Znak ne postoji
5062	A05-1	604923,238	5004449,788	Znak ne postoji
5063	B36	604923,238	5004449,788	Znak ne postoji
5064	E06	604923,238	5004449,788	Znak ne postoji
5065	A04-2	605241,207	5004592,508	Znak postoji
5066	A04-1	605411,542	5004684,869	Znak ne postoji
5067	B30	605619,398	5004771,500	Znak postoji
5068	B30	605617,466	5004779,874	Znak ne postoji
5069	A22	605663,132	5004791,878	Znak postoji
5070	C02	605783,621	5004844,063	Znak ne postoji
5071	C02	605784,402	5004860,470	Znak ne postoji
5072	C47	605776,008	5004858,018	Znak ne postoji
5073	C47	605868,659	5004891,298	Znak postoji
5074	A22	605914,737	5004922,751	Znak ne postoji
5075	23	605919,215	5004913,421	Znak ne postoji
5076	70	605919,215	5004913,421	Znak ne postoji
5077	23	606068,311	5004994,880	Znak ne postoji
5078	70	606068,311	5004994,880	Znak ne postoji
5079	A05-1	606082,596	5004991,809	Znak postoji
5080	B30	606093,797	5004996,620	Znak postoji
5081	B30	606089,866	5005004,751	Znak ne postoji
5082	70	606109,342	5005012,800	Znak ne postoji
5083	70	606109,342	5005012,800	Znak ne postoji
5084	70	607061,310	5005181,731	Znak ne postoji
5085	24	607061,310	5005181,731	Znak ne postoji
5086	70	607061,310	5005181,731	Znak ne postoji
5087	D03-1	607067,984	5005173,595	Znak ne postoji
5088	A05-3	607108,696	5005185,210	Znak ne postoji
5089	B30	607155,620	5005178,541	Znak postoji
5090	B30	607181,200	5005187,169	Znak ne postoji
5091	C06	607230,452	5005180,015	Znak postoji
5092	C83	607230,452	5005180,015	Znak postoji
5093	14	607237,231	5005190,638	Znak ne postoji
5094	B47	607321,464	5005197,315	Znak ne postoji
5095	K05	607321,464	5005197,315	Znak ne postoji
5096	B02	605342,968	5004629,978	Znak ne postoji
5097	a,C120	605335,738	5004633,641	Znak ne postoji
5102	C78-1	602451,649	5004072,917	Znak ne postoji
5103	A05	602480,603	5004082,212	Znak ne postoji
5104	24	602517,735	5004094,372	Znak ne postoji
5105	K10-1	602554,654	5004106,634	Znak ne postoji
5106	K10-1	602608,969	5004112,556	Znak ne postoji

5107	D03-1	602862,538	5004094,852	Znak ne postoji
5108	C47	603031,944	5004091,240	Znak ne postoji
5109	70	603041,820	5004080,470	Znak ne postoji
5110	70	603041,820	5004080,470	Znak ne postoji
5111	B30	603074,235	5004084,360	Znak ne postoji
5112	C06	603087,954	5004070,710	Znak postoji
5113	C78-1	603105,297	5004067,628	Znak postoji
5114	C78-1	603105,297	5004067,628	Znak postoji
5115	C78-1	603105,297	5004067,628	Znak ne postoji
5635	70	598504,010	5003697,369	Znak ne postoji
5649	A05-1	603774,738	5004038,282	Znak ne postoji
5650	B04	598648,272	5003649,477	Znak ne postoji
5651	D03-1	598774,397	5003567,778	Znak ne postoji
5652	C47	598793,885	5003548,743	Znak ne postoji
6203	C47	598458,504	5003709,925	Znak ne postoji
6204	C42	598996,644	5003393,557	Znak ne postoji
6205	C02	602197,824	5003930,067	Znak postoji
6267	B24	607280,110	5005192,571	Znak ne postoji
6268	B24	592871,664	5004313,814	Znak ne postoji
6269	B24	598529,623	5003691,303	Znak ne postoji
6270	B24	598562,664	5003668,694	Znak ne postoji
6271	B24	603102,664	5004080,460	Znak ne postoji
6272	B24	603144,758	5004059,704	Znak ne postoji
6297	B30	595932,143	5004167,773	Znak postoji
6298	B30	603261,367	5004050,984	Znak ne postoji
6782	C122	602319,371	5004010,460	Znak ne postoji
6783	C122	602057,541	5003826,950	Znak ne postoji
6789	C122	605619,398	5004771,500	Znak ne postoji
6790	C122	606089,866	5005004,751	Znak ne postoji

Prilog 2

Tablica 8.2 Prikaz svih klasa baze podataka i kvantitativni status pojedine klase

Sifra	Znak postoji	Znak ne postoji
K28	0	1
K10-1	0	3
K05	0	1
G13	1	1
E12	0	1
E06-3	0	2
E06	0	1
E05	0	1
D07	0	2

D03-1	0	5
C83	1	0
C81	0	1
C78-1	3	11
C77	0	1
C76	8	5
C59	0	2
C47	7	11
C44	0	3
C42	0	1
C39	1	1
C122	0	4
C06	3	1
C02	4	7
B47	0	2
B45	0	2
B36	0	3
B30	14	21
B28-1	0	1
B28	0	1
B24	0	7
B23	0	1
B04	0	2
B02	0	7
A36-9	0	2
A36-8	0	2
A36-5	0	1
A36-4	1	1
A36-3	1	1
A36	0	3
A33	2	2
A22	4	5
A21	1	1
A14	1	1
A05-3	0	1
A05-2	1	1
A05-1	3	9
A05	1	10
A04-2	3	0
A04-1	0	1
a.C120	0	1
70	0	14
50	0	5
40	0	1

25	0	4
24	0	15
23	0	2
22	0	1
14	0	5

ŽIVOTOPIS





Luka Meštrić

Datum rođenja: 02/02/2001 | **Državljanstvo:** hrvatsko | **Spol:** Muško]

Telefonski broj: [REDACTED] | **E-adresa:** [REDACTED]

Ime i prezime: lmestric0202@gmail.com | **Facebook:** [REDACTED]

LinkedIn: <https://www.linkedin.com/in/luka-meštrić-0350252ba/>]

WhatsApp: [REDACTED]

Adresa: [REDACTED]

● O MENI

Ambiciozan sam i spreman unaprijediti i upotrijebiti sva svoja znanja i vještine koje sam stekao do sada. Marljiv sam i predan bilo čemu što radim te sam posebno zainteresiran za rad u struci s naglaskom na prostorne podatke i njihovu svrhu u širokom spektru industrija. Volim učiti nove stvari i svaki zadani zadatak rješavam u zadanome roku. Dobro funkcioniram u timu, odnosno dobar sam timski radnik. Volim rad sa ljudima, ali isto tako i nemam ništa protiv odrađivanja određenog posla samostalno. Kroz sezonski rad, studentski posao i poluprofesionalno bavljenje sportom (košarka) steko sam red, rad i disciplinu, a trenutno sam u potrazi za znanjem iz struke i za novim izazovima i iskustvima.

● RADNO ISKUSTVO

2015 – 2022 Zadar, Hrvatska

RAD U TURIZMU APARTMENT TONI, APARTMENT SREČKO

Rad u ugostiteljskom sektoru za vrijeme turističke sezone. Čišćenje apartmana, doček gostiju, rad s gostima. Komunikacija na različitim jezicima.

2015 – 2022 Kukljica, Hrvatska

RAD NA TURISTIČKOM BRODU ANTEA TOURS

Prodaja karata za izlet, rad s gostima, obilazak PP Telašćica i NP Kornati s gostima u sklopu turističkoga izleta.

03/2023 – 01/2024 Zagreb, Hrvatska

STUDENTSKI POSAO ERICSSON NIKOLA TESLA

Zaposlen na projektu modernizacije radijske pristupne mreže (RAN) HT-a. Bio sam glavni odgovorni za izradu i isporuku "Marking set-a", a radio sam i crteže promjene dokumenata tehničkih rješenja tzv. REDPEN u ZWCAD-u.

● OBRAZOVANJE I OSPOSOBLJAVANJE

TRENTAČNO Zagreb, Hrvatska

SVEUČILIŠNI PRVOSTUPNIK INŽENJER GEODEZIJE I GEOINFORMATIKE (UNIV. BACC. ING. GEOD. ET GEOINF.) Geodetski fakultet

Adresa Kačićeva ulica 26, 10000, Zagreb, Hrvatska | **Internetske stranice** <https://www.geof.unizg.hr/>]

Područje studija Inženjerstvo, proizvodnja i graditeljstvo | **Konačna ocjena** 3.4 | **Vrsta bodova** ECTS]

Broj bodova 183

2015 – 2019 Zadar, Hrvatska

JEZIČNA GIMNAZIJA VLADIMIRA NAZORA

Uz obavezni strani jezik, engleski jezik, jezična gimnazija zahtjeva još jedan obavezni strani jezik koji je bio njemački jezik.

Adresa: Perivoj Vladimira Nazora, 23000, Zadar, Hrvatska | Internetske stranice: <http://gimnazija-vnazora-zd.skole.hr/>

● JEZIČNE VJEŠTINE

Materinski jezik/jezici: **HRVATSKI**

Drugi jezici:

	RAZUMIJEVANJE		GOVOR		PISANJE
	Slušanje	Čitanje	Govorna produkcija	Govorna interakcija	
ENGLESKI	C2	C2	C2	C2	C2

Razine: A1 i A2: temeljni korisnik; B1 i B2: samostalni korisnik; C1 i C2: iskusni korisnik

● DIGITALNE VJEŠTINE

Digitalne vještine

Poznavanje AutoCad | Dobro poznavanje MS Office paketa | Internet | Poznavanje rada u ArcGIS i QGIS programima | Poznavanje programa SketchUp | Poznavanje Pythona | Rad u programu PostgreSQL | Osnovno poznavanje RStudio | Osnovno poznavanje BlueJ | komunikacijski programi (Skype, Team Viewer, Log me in) | Poznavanje rada u ZWCad-u | Poznavanje OCAD programa

Komunikacijske i međuljudske vještine

Timski rad | Sposobna raditi u timu | S lakocom prihvacam i rjesavam nove izazove kroz koje napredujem | Uporan, pedantan i marljiv | Prilagodljivost | Timski duh stečen obrazovanjem i bavljenjem sportom (košarka). | Sposobnost prilagodavanja promjenama

Hobiji i interesi

Košarka | putovanja | čitanje