

Analiza i vrednovanje metoda za prepoznavanje linija vozne trake zasnovanih na strojnom učenju na različitim skupovima podataka

Jukić, Grgur

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:200:781486>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-03-20**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU FAKULTET
ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH
TEHNOLOGIJA**

Sveučilišni studij

**ANALIZA I VREDNOVANJE METODA ZA
PREPOZNAVANJE LINIJA VOZNE TRAKE
ZASNOVANIH NA STROJNOM UČENJU NA
RAZLIČITIM SKUPOVIMA PODATAKA**

Diplomski rad

Grgur Jukić

Osijek, 2022.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za imenovanje Povjerenstva za diplomski ispit****Osijek, 11.09.2022.****Odboru za završne i diplomske ispite****Imenovanje Povjerenstva za diplomski ispit**

| | |
|---|--|
| Ime i prezime Pristupnika: | Grgur Jukić |
| Studij, smjer: | Diplomski sveučilišni studij Automobilsko računarstvo i komunikacije |
| Mat. br. Pristupnika, godina upisa: | D-48ARK, 11.10.2020. |
| OIB studenta: | 10983666859 |
| Mentor: | Izv. prof. dr. sc. Mario Vranješ |
| Sumentor: | Denis Vajak, mag. ing. comp. |
| Sumentor iz tvrtke: | Zvonimir Kaprocki |
| Predsjednik Povjerenstva: | Izv.prof.dr.sc. Ratko Grbić |
| Član Povjerenstva 1: | Izv. prof. dr. sc. Mario Vranješ |
| Član Povjerenstva 2: | Prof. dr. sc. Marijan Herceg |
| Naslov diplomskog rada: | Analiza i vrednovanje metoda za prepoznavanje linija vozne trake zasnovanih na strojnom učenju na različitim skupovima podataka |
| Znanstvena grana diplomskog rada: | Umetna inteligencija (zn. polje računarstvo) |
| Zadatak diplomskog rada: | Jedan od najčešće korištenih sustava za pomoću vozaču u vožnji je onaj namijenjen za prepoznavanje linija vozne trake. Takav sustav omogućava automobilu određenu razinu samostalnosti u vožnji, a može i upozoravati vozača u slučaju napuštanja vozne trake. Suvremene metode prepoznavanja linija vozne trake na cesti zasnivaju se na različitim algoritmima zasnovanim na tehnikama tradicionalnog računalnog vida i dubokog učenja, koristeći neuronske mreže. Kako bi se različite metode detekcije linija vozne trake uspješno testirale, koriste se veliki podatkovni skupovi. Ovakvi skupovi su od iznimne važnosti za metode zasnovane na |
| Prijedlog ocjene pismenog dijela ispita (diplomskog rada): | Izvrstan (5) |
| Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova: | Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina |
| Datum prijedloga ocjene od strane mentora: | 11.09.2022. |
| Potvrda mentora o predaji konačne verzije rada: | <i>Mentor elektronički potpisao predaju konačne verzije.</i> |
| | Datum: |

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 20.09.2022.

Ime i prezime studenta:

Grgur Jukić

Studij:

Diplomski sveučilišni studij Automobilsko računarstvo i komunikacije

Mat. br. studenta, godina upisa:

D-48ARK, 11.10.2020.

Turnitin podudaranje [%]:

2

Ovom izjavom izjavljujem da je rad pod nazivom: **Analiza i vrednovanje metoda za prepoznavanje linija vozne trake zasnovanih na strojnom učenju na različitim skupovima podataka**

izrađen pod vodstvom mentora Izv. prof. dr. sc. Mario Vranješ

i sumentora Denis Vajak, mag. ing. comp.

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.

Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

IZJAVA

o odobrenju za pohranu i objavu ocjenskog rada

kojom ja Grgur Jukić, OIB: 10983666859, student/ica Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek na studiju Diplomski sveučilišni studij Automobilsko računarstvo i komunikacije, kao autor/ica ocjenskog rada pod naslovom: Analiza i vrednovanje metoda za prepoznavanje linija vozne trake zasnovanih na strojnom učenju na različitim skupovima podataka,

dajem odobrenje da se, bez naknade, trajno pohrani moj ocjenski rad u javno dostupnom digitalnom repozitoriju ustanove Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek i Sveučilišta te u javnoj internetskoj bazi radova Nacionalne i sveučilišne knjižnice u Zagrebu, sukladno obvezi iz odredbe članka 83. stavka 11. *Zakona o znanstvenoj djelatnosti i visokom obrazovanju* (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).

Potvrđujem da je za pohranu dostavljena završna verzija obranjenog i dovršenog ocjenskog rada. Ovom izjavom, kao autor/ica ocjenskog rada dajem odobrenje i da se moj ocjenski rad, bez naknade, trajno javno objavi i besplatno učini dostupnim:

- a) široj javnosti
- b) studentima/icama i djelatnicima/ama ustanove
- c) široj javnosti, ali nakon proteka 6 / 12 / 24 mjeseci (zaokružite odgovarajući broj mjeseci).

**U slučaju potrebe dodatnog ograničavanja pristupa Vašem ocjenskom radu, podnosi se obrazloženi zahtjev nadležnom tijelu Ustanove.*

Osijek, 20.09.2022.

(mjesto i datum)

(vlastoručni potpis studenta/ice)

SADRŽAJ

| | |
|--|----|
| 1. UVOD | 1 |
| 2. PREGLED BAZA PODATAKA SLIKA S OZNAČENIM LINIJAMA VOZNE TRAKE | 3 |
| 2.1. TuSimple baza podataka | 3 |
| 2.2. CULane baza podataka | 5 |
| 2.3. LLAMAS baza podataka..... | 7 |
| 2.4. KITTI baza podataka..... | 8 |
| 2.5. BDD100K baza podataka..... | 9 |
| 2.6. Jiqing Expressway baza podataka | 10 |
| 2.7. Osvrt na predstavljene baze podataka za analizu i vrednovanje metoda za prepoznavanje linija vozne trake..... | 12 |
| 3. PREGLED POSTOJEĆIH RJEŠENJA ZA DETEKCIJU LINIJA VOZNE TRAKE | 14 |
| 3.1. Rješenja za detekciju linija vozne trake zasnovana na tehnikama tradicionalnog računalnog vida | 14 |
| 3.2. Rješenja za detekciju linija vozne trake zasnovana na dubokom učenju | 15 |
| 4. ANALIZA PERFORMANSI METODA ZA DETEKCIJU LINIJA VOZNE TRAKE ZASNOVANIH NA DUBOKOM UČENJU NA RAZLIČITIM SKUPOVIMA PODATAKA | 19 |
| 4.1. Opis korištenih alata i biblioteka..... | 20 |
| 4.1.1. Virtualno radno okruženje..... | 20 |
| 4.1.2. PyTorch okvir za strojno učenje..... | 21 |
| 4.1.3. PyTorchAutoDrive..... | 22 |
| 4.2. Provjera ispravnosti vlastite implementacije odabranih modela za detekciju linija vozne trake zasnovanih na dubokom učenju | 24 |
| 4.3. Pretvarači formata oznaka zapisa voznih linija | 26 |
| 4.3.1. Pretvarač zapisa oznaka linija voznih traka iz TuSimple u CULane format | 26 |
| 4.3.2. Pretvarač zapisa oznaka linija vozne trake iz CULane u TuSimple format | 28 |
| 4.4. Evaluacija performansi modela za detekciju linija voznih traka zasnovanih na dubokom učenju korištenjem triju podatkovnih skupova | 30 |
| 4.4.1. Analiza rezultata modela testiranih na testnom skupu CULane podatkovnog skupa..... | 31 |
| 4.4.2. Analiza rezultata modela testiranih na testnom skupu TuSimple podatkovnog skupa..... | 42 |
| 4.4.3. Analiza rezultata modela testiranih na validacijskom skupu LLAMAS podatkovnog skupa | 52 |

| | |
|---|----|
| 4.5. Završni osvrt na rezultate dobivene testiranjem i evaluacijom različitih metoda za detekciju linija vozne trake na različitim skupovima podataka | 60 |
| 4. ZAKLJUČAK | 62 |
| LITERATURA | 63 |
| SAŽETAK | 65 |
| ABSTRACT | 66 |
| ŽIVOTOPIS | 67 |
| PRILOZI | 68 |

1. UVOD

Razvoj novih tehnologija, uvođenje strogih emisijskih standarda kao i zahtjevi potrošača, zahtijevali su promjene u automobilskoj industriji. Kako bi se zadovoljile potrebe, automobilska industrija ulaže velike količine resursa u moderne trendove poput digitalizacije, električnih vozila, autonomne vožnje i mobilnosti. Autonomna vožnja se odnosi na transportne sustave koji se kreću ili obavljaju radnje bez potrebe za ljudskom pomoći. SAE International (engl. *Society of Automotive Engineers*) definirao je različite razine autonomije u rasponu od razine 0 koja podrazumijeva nepostojanost automatizacije, do razine 5 koja se odnosi na vozila u kojima uopće nije potrebna ljudska interakcija, tj. pomoć. Da bi se omogućila autonomna vožnja, potrebno je prikupiti podatke iz okoline vozila, obraditi ih odgovarajućim softverskim rješenjem te izdati naredbu aktuatorima koju radnju u vožnji poduzeti. ADAS (engl. *Advanced Driver Assistance System*) je elektronički sustav u vozilu koji koristi različite tehnologije i metode za povećanje sigurnosti vozača i prometa općenito. ADAS koristi različite senzore i kamere koji postoje u automobilu kako bi prikupio informacije o vozilu i okolini. Jedan od najčešće korištenih sustava za pomoć vozaču u vožnji je onaj namijenjen za prepoznavanje linija vozne trake. Prometna traka je dio kolnika koji je namijenjen za promet u jednom redu vozila, radi kontrole i usmjeravanja vozača te smanjenja broja prometnih nesreća. Iako ADAS uključuje RADAR (engl. *Radio Detection And Ranging*) i LIDAR (engl. *Light Detection and Ranging*), uređaji zasnovani na vidu obično se primjenjuju za prepoznavanje voznih traka. Takav sustav omogućava automobilu određenu razinu samostalnosti u vožnji, a može i upozoravati vozača u slučaju napuštanja vozne trake. Detekcija vozne trake, koja je zasnovana na računalnom vidu (budući da se zasniva na obradi slike s kamere), igra ključnu ulogu u pomoći vozaču u vožnji. Dok postojeći algoritmi za prepoznavanje linija voznih traka uspješno detektiraju voznu traku u preko 90.00% slučajeva, testiranje i evaluacija obično se provode u ograničenom broju scenarija u realnom okruženju, budući da zahtijevaju mnoštvo vremena. S druge strane, postoji problem sigurnosti i pouzdanosti takvih rješenja i želi se postići da ona jednog dana rade bez greške, kako bi se u potpunosti mogao izostaviti vozač u procesu vožnje. Trenutno postoje značajni problemi kada se postojeća rješenja primjenjuju u različitim uvjetima u autonomnoj vožnji u stvarnom životu i zbog toga je ovo područje već dulji niz godina u fokusu mnoštva istraživača diljem svijeta. Suvremene metode prepoznavanja linija vozne trake na cesti zasnivaju se na različitim algoritmima zasnovanim na tehnikama tradicionalnog računalnog vida ili na tehnikama dubokog učenja, koristeći neuronske mreže. Podaci prikupljeni sa sustava kamera koriste se za lokalizaciju ceste, određivanje relativnog

položaja vozila te analizu smjera kretanja. Zadatak ovog diplomskog rada je istražiti različite postojeće metode za detekciju linija voznih traka na cesti i izabrati tri najprivlačnije metode, pri čemu barem dvije moraju biti zasnovane na dubokom učenju. Uz ove tri metode, potrebno je izabrati i barem tri različita postojeća podatkovna skupa s označenim linijama voznih traka. Odabrane metode koje zahtijevaju treniranje potrebno je trenirati na jednom od skupova, a testiranje metoda potrebno je provesti na svim trima skupovima. Cilj rada je analizirati performanse odabranih metoda i razlike među njima, te provjeriti koliko su različite metode prilagodljive promjeni podatkovnog skupa. Rezultate je potrebno protumačiti i detaljno analizirati.

U drugom poglavlju dan je pregled baza podataka slika s označenim linijama vozne trake. U trećem poglavlju dan je pregled postojećih rješenja za detekciju linija vozne trake zasnovanih na dubokom učenju. U četvrtom poglavlju provedene su evaluacija i analiza rada metoda za prepoznavanje vozne trake na trima različitim podatkovnim skupovima. U petom poglavlju dan je zaključak cjelokupnog rada.

2. PREGLED BAZA PODATAKA SLIKA S OZNAČENIM LINIJAMA VOZNE TRAKE

U ovom poglavlju dan je pregled postojećih baza podataka slika s označenim linijama vozne trake. Za analizu i vrednovanje metoda za prepoznavanje linije vozne trake potrebni su veliki podatkovni skupovi koji sadrže podatke o postojanosti i lokaciji linija voznih traka na slici. Objekti prisutni u bazama podataka dijele se na statične i dinamične. Oznake voznih traka predstavljaju statične objekte koji usmjeravaju vozilo.


U nastavku ovog poglavlja opisane su neke od najpoznatijih baza podataka slika s označenim linijama vozne trake. U potpoglavlju 2.7 dan je osvrt na predstavljene baze podataka za analizu performansi metoda za detekciju linija voznih traka zasnovanih na dubokom učenju.

2.1. TuSimple baza podataka

TuSimple baza podataka objavljena je 2017. godine povodom TuSimple izazova detekcije linija voznih traka (engl. *TuSimple Lane Detection Challenge*) [1]. Skup podataka sastoji se od slika cesta s američkih brzih cesta i autocesta. Rezolucija slike je 1280×720 elemenata slike. Skup podataka sastoji se od ukupno 6408 slika, od kojih 3626 pripada trening skupu, 358 validacijskom skupu i 2782 testnom skupu. Videozapisi iz kojih su izdvojene slike, snimljeni su kamerom koja je postavljena na kontrolnoj ploči vozila. Skup prikazuje različite vremenske uvjete. Za zapis linija voznih traka koristi se format polilinija. Polilinija je objekt građen od linija i lukova na temelju točaka. Točke su predstavljene koordinatama elemenata slike. Uređeni par elemenata listi *lanes* i *h_samples* određuje položaj točke koja predstavlja oznaku linije na slici. Maksimalan broj označenih linija voznih traka na pojedinoj slici je četiri.

TuSimple baza podataka predstavlja jednostavnu i homogenu bazu podataka. Slike sadržavaju jasno vidljive linije voznih traka. Vremenski uvjeti zastupljeni na slikama su uglavnom sunčani, oblačni ili kišoviti. Podaci su precizno označeni u formatu polilinija.

Glavni nedostatak podatkovnog skupa su mala količina slika i jednolikost scenarija prikazanih na slikama. Ovaj skup odlikuje i nedostatak prometnih scenarija koje uključuju noćnu vožnju pod ekstremnim uvjetima (kiša, snijeg). Primjeri slika iz TuSimple baze podataka snimljenih u različitim scenarijima prikazani su na slici 2.1.



(a)



(b)



(c)



(d)

Sl. 2.1. Prikaz slika iz TuSimple baze podataka snimljenih u različitim scenarijima: (a) brza cesta, ravna cesta, tri različita tipa linija voznih traka (b) brza cesta, zakrivljena cesta, tri različita tipa linija voznih traka (c) autocesta, zakrivljena cesta, dva različita tipa linija voznih traka (d) autocesta, ravna cesta, sjena, slaba vidljivost, isprekidane linije vozne trake

Naziv i opis struktura koje opisuju slike iz TuSimple podatkovnog skupa prikazan je tablicom 2.1.

Tab. 2.1. Naziv, tip i opis struktura koje opisuju sliku TuSimple podatkovnog skupa

| Naziv strukture | Tip podatka | Opis strukture |
|------------------|-------------|--|
| <i>lanes</i> | Lista | Lista linija voznih traka. Za svaku liniju vozne trake postoji lista koja sadrži brojeve koji predstavljaju vrijednost širine u x koordinati. Cjelobrojna vrijednost -2 označava da ne postoji oznaka linije vozne trake na određenoj lokaciji y koordinate. |
| <i>h_samples</i> | Lista | Predefinirani cjeli brojevi koji predstavljaju vrijednost visine u y koordinati. |
| <i>raw_file</i> | Niz | Relativna putanja do slike |

34680 slika te je podijeljen u 9 kategorija, kategoriziranih na temelju vremenskih uvjeta, cestovnih uvjeta te oblika linija voznih traka na slici. Validacijski skup sastoji se od 9675 slika. Količina podataka, velika varijacija u vremenskim uvjetima, vidljivosti i tipu oznaka voznih linija čini CULane bazu podataka vrlo prikladnom za testiranje i evaluaciju metoda za detekciju linija voznih traka. Glavni nedostatak CULane podatkovnog skupa su često nejasne i loše označene linije voznih traka. Također, postoji velik broj krivo označenih linija temeljne istine (engl. *ground truth* - GT) unutar podatkovnog skupa. Postoji velik broj javno dostupnih znanstvenih radova koji se bave problemom detekcije linija voznih traka metodama zasnovanim na dubokom učenju, koji koriste CULane bazu podataka kako bi testirali i analizirali različite metode za detekciju linija voznih traka. Podaci o oznakama linija voznih traka dostupni su za trening skup, testni skup i validacijski skup. Dostupna je službena evaluacijska skripta koja se koristi za testiranje i evaluaciju modela koji se koriste za detekciju linija voznih traka. Prikaz slika iz CULane baze podataka snimljenih u različitim scenarijima može se vidjeti na slici 2.3.



(a)



(b)



(c)



(d)

Sl. 2.3. Prikaz slika iz CULane baze podataka snimljenih u različitim scenarijima: (a) gradska cesta, ravna cesta, dva različita tipa linija voznih traka, sunčano, vedro (b) gradska cesta, ravna cesta, slaba vidljivost linija voznih traka, noćna vožnja, odsjaj (c) gradska cesta, ravna cesta, slaba vidljivost linija voznih traka, noćna vožnja, odsjaj, ravna cesta, sjena, slaba vidljivost, isprekidane linije vozne trake (d) gradska cesta, ravna cesta, slaba vidljivost linija voznih traka, noćna vožnja, odsjaj, ravna cesta, sjena, slaba vidljivost, isprekidane linije vozne trake

Za svaki okvir je označena linija koristeći kubične splajнове (engl. *cubic spline*). Označene su najviše četiri linije. Za svaku sliku postoji odgovarajuća TXT (engl. *plain text file*) datoteka koja sadrži oznake linija voznih traka. Svaki redak u datoteci daje informaciju o jednoj liniji vozne trake. Točku čini uređeni par koji se sastoji od decimalnog broja koji predstavlja x koordinatu i cjelobrojne vrijednosti koja y koordinatu elementa slike. Na slici 2.4. prikazan je sadržaj TXT datoteke za jednu sliku iz CULane baze podataka koja sadrži 4 linije voznih traka.

```

0 430 45.9607 420 92.0637 410 139.002 400 185.942 390 232.88 380 279.819 370 326.758 360 372.719 350 419.8
340 466.738 330 513.677 320 560.615 310 606.576 300 653.515 290 700.454 280

117.027 590 137.239 580 156.944 570 177.544 560 197.248 550 217.701 540 238.301 530 258.005 520 277.933 510
298.533 500 318.237 490 338.837 480 358.765 470 378.469 460 399.069 450 418.773 440 439.597 430 459.301 420
479.753 410 499.457 400 520.057 390 539.762 380 559.689 370 580.289 360 599.993 350 620.593 340 640.521 330
661.121 320 680.825 310 701.425 300 721.353 290 741.057 280

985.558 590 978.893 580 972.312 570 965.732 560 959.151 550 952.985 540 946.404 530 939.823 520 932.836 510
926.804 500 920.223 490 913.642 480 906.655 470 900.074 460 893.493 450 886.912 440 880.474 430 873.893 420
867.728 410 861.147 400 854.566 390 847.985 380 841.546 370 834.965 360 828.384 350 821.803 340 814.816 330
808.236 320 802.203 310 795.217 300 788.636 290 782.055 280

1656.33 520 1622.22 510 1587.65 500 1553.07 490 1518.84 480 1484.26 470 1449.69 460 1414.81 450 1380.24 440
1345.66 430 1311.58 420 1277 410 1242.14 400 1207.56 390 1173.95 380 1139.48 370 1104.91 360 1070.04 350
1035.46 340 1000.88 330 966.978 320 932.403 310 897.827 300 862.959 290 828.383 280

```

Sl. 2.4. Prikaz TXT datoteke za jednu sliku iz CULANE baze podataka

2.3. LLAMAS baza podataka

LLAMAS (engl. *Labeled Lane Markers*) baza podataka za otkrivanje i segmentaciju voznih traka objavljena je 2019. godine od strane Bosch-a [3]. Oznake linija voznih traka označene su pomoću automatiziranog algoritma za označavanje, koristeći precizne mape napravljene pomoću LIDAR-a. Baza podataka sadrži 100042 slika s američkih autocesta, od kojih 58269 pripada trening skupu, 20844 testnom skupu te 20929 validacijskom. Oznake linija vozne trake koje predstavljaju GT za testni skup nisu javno dostupne, stoga se za testiranje i evaluaciju modela za detekciju linija vozne trake koristi validacijski skup. Slika je formata PNG (engl. *Portable Network Graphic*), rezolucije 1276 x 717 elemenata slike. Skup podataka LLAMAS koristi JSON datoteke za spremanje oznaka linije voznih traka. Za svaku sliku postoji jedna JSON datoteka.

LLAMAS podatkovni skup sadrži veliku količinu precizno označenih linija voznih traka. Vremenski uvjeti na slikama su uglavnom sunčani ili oblačni. Podaci su precizno označeni na razini elemenata slike. Maksimalni broj označenih linija voznih traka na slikama je četiri. Glavni nedostatak


podatkovnog skupa su homogenost scenarija prikazanih na slikama, tj. nedostatak noćne vožnje ili vožnje po ekstremnim vremenskim uvjetima. Primjeri slika iz LLAMAS baze podataka snimljenih u različitim scenarijima dani su na slici 2.5.



(a)



(b)



(c)



(d)

Sl. 2.5. Prikaz slika iz LLAMAS baze podataka snimljenih u različitim scenarijima: (a) ruralno okruženje, ravna cesta, dva različita tipa linija voznih traka, oblačno (b) brza cesta, zakrivljena cesta, dobra vidljivost linija voznih traka, oblačno (c) brza cesta, ravna cesta, dobra vidljivost linija voznih traka, sjena, slaba vidljivost, isprekidane linije vozne trake (d) brza cesta, ravna cesta, dobra vidljivost linija voznih traka, isprekidane linije vozne trake, sjena

2.4. KITTI baza podataka

KITTI (engl. *Karlsruhe Institute of Technology and Toyota Technological Institute*) baza podataka za detekciju linija voznih traka objavljena je 2013. godine [4]. Podatkovni skup se sastoji od ukupno 579 slika, od kojih 289 pripada trening skupu, a 290 testnom skupu. Rezolucija slika je 1242x375 elemenata slike, te sadrže tri različite kategorije scena s ceste (urbano neoznačeno, urbano označeno, i urbano višestruko obilježene trake). Podatkovni skupovi snimljeni su vožnjom po

područjima grada Karlsruhe-a i njegove okolice. Po slici je vidljivo do 15 automobila i 30 pješaka. GT je generiran ručnim označavanjem slika. Oznake linija voznih traka doradene su u dvodimenzionalnom BEV (engl. *Bird's Eye View*) prostoru, što omogućava veću preciznost označavanja. Maksimalni broj linija voznih trake na slikama je pet.

Vremenski uvjeti na slikama su sunčani ili oblačni. Linije voznih traka označene su punim ili isprekidanim linijama. Glavni nedostatak KITTI baze podataka je mala varijacija u vremenskim uvjetima prikazanim na slikama te nedostatak noćne vožnje ili vožnje pod ekstremnim uvjetima, poput kiše ili snijega. Baza podataka sadrži malu količinu podataka. Prikaz slika iz KITTI baze podataka snimljenih u različitim scenarijima dan je na slici 2.6.




Sl. 2.6. Prikaz slika iz KITTI baze podataka snimljenih u različitim scenarijima: (a) gradska, ravna cesta, isprekidane linije vozne trake, sjena (b) gradska, ravna cesta, dobra vidljivost linija voznih traka (c) urbano područje, ravna cesta, slaba vidljivost linija voznih traka, sjena (d) gradska, ravna cesta, ne postoje linije vozne trake, sjena

2.5. BDD100K baza podataka

BDD100K baza podataka objavljena je 2020. godine [5]. Sadrži ukupno 100000 slika, od kojih 70000 pripada trening skupu, 20000 testnom skupu i 10000 validacijskom skupu. Rezolucija slike je 1280x720 elemenata slike. Skup podataka sadrži različite vrste scena kao što su gradske ulice, stambena naselja i autoceste. Videozapisi su snimljeni u različitim vremenskim uvjetima u različito

doba dana. Skup podataka sadrži podjednak broj video zapisa snimljenih po danu i noći. Oznake linija voznih traka grupirane su u 8 glavnih kategorija: rubnjak ceste, pješački prijelaz, dvostruka bijela linija, dvostruka žuta linija, dvostruke linije ostalih boja, jednostruka bijela linija, jednostruka žuta linija, jednostruka linija ostalih boja (engl. *road curb, crosswalk, double white, double yellow, double other color, single white, single yellow, single other color*). Maksimalan broj linija voznih traka je 5.

BDD100K sadrži veliku količinu podataka s označenim linijama vozne trake. Linije voznih traka označene su punim ili isprekidanim linijama različitih boja. Manji broj slika prikazuje prometne scenarije na kojima nema označenih linija vozne trake. Uključuje scenarije noćne vožnje i vožnje po ekstremnim uvjetima (kiša i snijeg). Prikaz slika iz BDD100K baze podataka snimljenih u različitim scenarijima dan je na slici 2.7.



Sl. 2.7. Prikaz slika iz BDD100K baze podataka snimljenih u različitim scenarijima: (a) autocesta, ravna cesta, isprekidane linije vozne trake, sunčano, oblačno (b) gradska, ravna cesta, loša vidljivost linija voznih trak, noćna vožnja, odsjaj (c) gradska, ravna cesta, slaba vidljivost linija voznih traka, sjena (d) gradska, ravna cesta, dobra vidljivost linija voznih traka

2.6. Jiqing Expressway baza podataka

Jiqing Expressway baza podataka objavljena je 2019. godine [6]. Videozapisi su prikupljeni uređajem za snimanje prometa okrenutim prema cesti. Prometne scene su snimljene na području grada Jiqing,

Kina. Baza podataka se sastoji od 40 videozapisa od kojih svaki traje 3 minute i ima brzinu izmjene okvira (engl. *framerate*) od 30 okvira po sekundi. Rezolucija videa je 1920×1080 elemenata slike. Uključeno je ukupno 210610 slika cesta s različitim intenzitetom osvjetljenja i različitim uvjetima na cesti (ceste uzbrdo, ceste nizbrdo, tuneli, rampe). Linije voznih traka se označavaju za svaki okvir te se spremaju u TXT datoteku. Koordinate točaka ključnih obilježja (x , y) različitih linija voznih traka odvojene su novim redovima, a linija *id* koristi se za predstavljanje serijskog broja linije. Prikaz slika iz Jiqing Expressway baze podataka snimljenih u različitim scenarijima dan je na slici 2.8. Maksimalan broj linija voznih traka je 4.

Slike iz Jiqing Expressway baze podatak prikazuju jednostavne prometne scenarije. Linije voznih traka označene su punim ili isprekidanim bijelim linijama. Glavni nedostatak Jiqing Expressway baze podataka je manjak prometnih scenarija koji prikazuju scene iz urbanih područja te nedostatak scenarija noćne vožnje.



(a)



(b)



(c)



(d)

Sl. 2.8. Prikaz slika iz Jiqing Expressway baze podataka snimljenih u različitim scenarijima: (a) tunel, ravna cesta, odlična vidljivost linija voznih traka, odsjaj (b) brza cesta, ravna cesta, dva tipa oznaka voznih traka, dnevna vožnja, sunčano, dobra vidljivost linija voznih traka (c) ravna cesta, odlična vidljivost linija voznih traka, oblačno (d) brza cesta, ravna cesta, dva tipa oznaka linija voznih traka, dobra vidljivost linija voznih traka, oblačno

2.7. Osvrt na predstavljene baze podataka za analizu i vrednovanje metoda za prepoznavanje linija vozne trake

Na koncu ovog poglavlja još je jednom dan zbirni pregled najvažnijih karakteristika predstavljenih skupova podataka u Tablici 2.2. Također, pojašnjeni su razlozi odabira triju baza podataka koji će se dalje koristiti u sklopu ovog diplomskog rada.

Tab. 2.2. Zbirni pregled glavnih karakteristika baza podataka za analizu i vrednovanje metoda za prepoznavanje linija vozne trake (CULane, KITTI, BDD100K, Jiqing Expressway, TuSimple, LLAMAS)

| BAZA PODATAKA | CULane [2] | KITTI [4] | BDD100K [5] | Jiqing Expressway [6] | TuSimple [1] | LLAMAS [3] |
|---|---|---|---------------------------------------|---|---------------------------|---|
| REZOLUCIJA SLIKE [elemenata slike] | 1640 x 590 | 1242 x 375 | 1280 x 720 | 1920 X 1080 | 1280 x 720 | 1276 x 717 |
| FORMAT VIDEA | MP4 | / | MP4 | MOV | / | / |
| FORMAT SLIKE | JPG | PNG | JPG | JPG | JPG | PNG |
| VELIČINA CIJELOG SKUPA PODATAKA | 20.3 GB | 460 MB | 6.89 GB | 43.3 GB | 22.7 GB | 34.1 GB |
| FORMAT OZNAKA LINIJA | Kubični splajnovi | Ego Lane Area(BEV) | Klase,2D Poligoni s vrhovima | Koordinate | Polilinije (JSON) | Oznake na razini piksela, 2D isprekidane linije |
| MAKSIMALNI BROJ OZNAČENIH LINIJA VOZNIH TRAKA | 4 | 5 | 5 | 4 | 4 | 4 |
| BROJ KAMERA | 1 | 4 | 1 | 1 | 1 | 1 |
| BROJ VOZILA | 6 | 1 | 50000 | 1 | 1 | / |
| LOKACIJA | Peking, Kina | Karlsruhe, Njemačka | Berkeley, SAD | Jiqing, Kina | SAD | SAD |
| VREMENSKI UVJETI | Sunčano, oblačno, noćna vožnja, odsjaj, sjena | Sunčano, oblačno | Sunčano, oblačno, kiša, snijeg, magla | Sunčano, oblačno | Sunčano, oblačno, sjena, | Sunčano, oblačno |
| DOBANA DANA | Dan, noć | Dan | Dan | Dan | Dan | Dan |
| TIPOVI CESTA | Ruralna područja, autoceste, tuneli | Ruralna područja, autoceste, oštećene ceste | Ruralna i gradska područja | Autoceste, tuneli, ceste uzbrdo i ceste nizbrdo | Autoceste, oštećene ceste | Autoceste |
| UKUPAN BROJ SLIKA | 133235 | 579 | 100000 | 210610 | 6408 | 100042 |
| BROJ SLIKA U TRENING SKUPU | 88880 | 289 | 70000 | / | 3626 | 58269 |
| BROJ SLIKA U VALIDACIJSKOM SKUPU | 9675 | / | 10000 | / | 358 | 20844 |
| BROJ SLIKA U TESTNOM SKUPU | 34680 | 290 | 20000 | / | 2782 | 20929 |

Za vrednovanje metoda za detekciju linija voznih traka u sklopu ovog diplomskog rada odabrane su TuSimple, CULane i LLAMAS baze podataka. Razlog tome je što su te baze korištene u velikom broju radova s javno dostupnim programskim kodom i dokumentacijom. Pri odabiru baza uzeta je u

obzir jednostavnost zapisa i mogućnost pretvorbe zapisa linija voznih traka u drugačiji tip zapisa. Oznake linija voznih traka precizno su označene za sve tri odabrane baze podataka. Raznolikost i kompleksnost CULane podatkovnog skupa služi kao kontrast jednostavnim i homogenim skupovima poput TuSimple i LLAMAS baza podataka. CULane podatkovni skup sadrži slike koje prikazuju realne prometne scenarije iz urbanih i ruralnih područja. Vrste i oblik oznaka voznih linija bitno se razlikuju od TuSimple i LLAMAS baze podataka. Uključuje scene noćne vožnje i vožnje pod ekstremnim uvjetima poput kiše. TuSimple i LLAMAS prikazuju slične prometne scenarije koji uključuju promet na autocestama i brzim cestama. Vrste i oblik oznaka linija voznih traka su slične za TuSimple i LLAMAS skup.

3. PREGLED POSTOJEĆIH RJEŠENJA ZA DETEKCIJU LINIJA VOZNE TRAKE

Detekcija linija vozne trake je zadatak koji se sastoji od detektiranja instanci objekata i označavanja njihovih granica. Metode detekcije linija vozne trake mogu se podijeliti na metode zasnovane na tehnikama tradicionalnog računalnog vida i metode zasnovane na dubokom učenju. Metode detekcije linija vozne trake zasnovane na tehnikama tradicionalnog računalnog vida s visokom preciznošću detektiraju linije pojedinih tipova cesta. Raznolikost prometnih scenarija, tipova prometnih oznaka i vremenskih uvjeta, predstavlja prepreku algoritmima koji koriste metode zasnovane na tehnikama tradicionalnog računalnog vida. Razvoj tehnologija, eksponencijalni rast procesorske moći računala i sve veća dostupnost velikih baza podataka omogućava korištenje metoda za detekciju linija vozne trake zasnovanih na dubokom učenju. Korištenje velikih podatkovnih skupova za treniranje i testiranje mreže omogućava veću preciznost u različitim prometnim scenarijima. U potpoglavlju 3.1. predstavljeni su neki od radova koji koriste pristup detekcije linija vozne trake zasnovanih na tehnikama tradicionalnog računalnog vida. U potpoglavlju 3.2. predstavljeni su radovi koji koriste pristup detekcije linija vozne trake zasnovan na dubokom učenju.

3.1. Rješenja za detekciju linija vozne trake zasnovana na tehnikama tradicionalnog računalnog vida

Metode detekcije linija vozne trake zasnovane na tehnikama tradicionalnog računalnog vida koriste algoritme koji se sastoje od predobrade, naknadne obrade i prepoznavanja linija. U [7] autori opisuju rad jednostavnog sustava za detekciju linija voznih traka koji koristi linearni model. Korištenjem Canny operatora detekcije rubova u fazi predobrade (engl. *pre processing*) i Houghove transformacije kako bi se pronašle relevantne linije u fazi naknadne obrade (engl. *post processing*), omogućava se određivanje parametara geometrijskog modela. Model zahtjeva jasno vidljive linije konzistentnog oblika te je širina ceste morala biti konstantna ili uz relativno mala odstupanja. Model ne uspijeva detektirati linije na slikama koje uključuju zakrivljene linije ili ekstremne vremenske uvjete.

U radu [8] autori predlažu algoritam za detekciju linija voznih traka zasnovan na RANSAC (engl. *Random Sample Consensus*) metodu. Algoritam uzima slike ceste iz ptičje perspektive te ih

filtrira koristeći Gaussovog filtra. Algoritam zatim koristi pojednostavljenu Houghovu transformaciju kako bi prebrojao koliko linija vozne trake ima na slici. Koristi se RANSAC metoda za uklapanje linija (engl. *line fitting*). Za provođenje eksperimenta, prikupljeno je niz videozapisa s urbanih ulica, koje su označene ravnim ili zakrivljenim linijama voznih traka. Linije su ručno označene. Za testiranje modela korištena su četiri videozapisa. Algoritam uspješno detektira linije različitih oblika s preciznošću od oko 90,00%. Visoku preciznost postiže i u detekciji linija na slikama koje uključuju sjene, vozila i krivine. RANSAC algoritam zahtjeva veliku računalnu snagu što ga ne čini privlačnim za primjenu u sustavima koji rade u stvarnom vremenu.

3.2. Rješenja za detekciju linija vozne trake zasnovana na dubokom učenju

Razvoj tehnologija, eksponencijalni rast procesorske moći računala i sve veća dostupnost velikih baza podataka omogućava korištenje metoda za detekciju linija vozne trake zasnovanih na dubokom učenju. Kao što je spomenuto u prethodnom odlomku, metode zasnovane na tehnikama tradicionalnog računalnog vida sklonije su pogreškama zbog varijacije cestovnih i vremenskih uvjeta. U radu [9] autori opisuju metodu za detekciju linija voznih traka koja se zasniva na arhitekturi LaneNet (engl. *Real-Time Lane Detection Networks for Autonomous Driving*) duboke neuronske mreže. S obzirom na ulaznu sliku, LaneNet daje mapu instanci, označavajući svaki element slike koji pripada liniji vozne trake identifikacijskom oznakom linije. Elementi slike se zatim transformiraju pomoću matrice transformacije. Na izlazu konvolucijske neuronske mreže (engl. *Convolutional Neural Network – CNN*) dobije se binarna slika koja označava linije voznih traka na slici. Korištenje LaneNet arhitekture kao osnove modela za detekciju linija voznih traka omogućilo je detekciju uz visoku preciznost u različitim prometnim scenarijima i vremenskim uvjetima.


U radu [10] autori predstavljaju novi model za detekciju linija voznih traka naziva RESA (engl. *Recurrent Feature-Shift Aggregator*), za obogaćivanje značajki linija nakon početnog izdvajanja značajki koristeći arhitekture CNN-a. RESA iskorištava karakteristike oblika linija voznih traka te bilježi prostorne odnose elemenata slika u redove i stupce prostorne matrice. Poboljšava prostornu propagaciju informacija i rješava problem loših performansi kod slika gdje postoji zaklonjenost (engl. *occlusion*) linija. Autori u radu koriste ResNet50 kao osnovu modela. Model postiže kompetitivne rezultate na TuSimple podatkovnom skupu, postignuvši preciznost veću 96.00%. Model je potvrdio

svoju sposobnost generalizacije postignuvši visoke performanse i na svih devet kategorija CULane testnog skupa.


SCNN je vrsta konvolucijske neuronske mreže objavljena 2017. godine kao dio rada *Spatial As Deep: Spatial CNN for Traffic Scene Understanding* [2]. U CNN, konvolucijski sloj prima ulazne podatke od prethodnog sloja, primjenjujući potom operaciju konvolucije. Takva vrsta propagacije informacija u konvolucijskim neuronskim mrežama naziva se sloj po sloj propagacija. Nakon konvolucije, primjenjuje se nelinearna aktivacijska funkcija te se rezultat šalje sljedećem sloju. Za razliku od sloj po sloj konvolucije koja se koristi u klasičnim CNN, SCNN koristi „isječak po isječak“ (engl. *slice by slice*) metodu konvolucije.

U SCNN-u, redovi i stupci mapi značajki predstavljaju slojeve nad kojima se izvodi operacije konvolucije, nelinearne aktivacije i operacije zbrajanja. Korištenjem isječak po isječak metode, omogućava se prenošenje informacija između neurona u istom sloju. Detekcija linija voznih traka zahtijeva precizno predviđanje krivine (engl. *curve*). Izlaz modela su mape vjerojatnosti (engl. *probability maps*), stoga se generiraju ciljevi na razini elemenata slike za treniranje mreže kao u zadacima semantičke segmentacije. Cilj je razlikovati različite oznake linija voznih traka umjesto klasificiranja svih linija voznih traka jednom klasom. Tijekom testiranja, potrebno je prijeći iz formata mapi vjerojatnosti u format krivulja. Za svaku oznaku linije čija je vrijednost postojanja veća od 0.5, traži se odgovarajuća mapa vjerojatnosti svakih 20 redaka za poziciju s najvećim odgovorom. Ti položaji su onda povezani kubičnim splajnovima, koji su konačna predviđanja. Oznake linija se uzimaju kao linije širine 30 elemenata slike. Računa se presjek preko unije (engl. *Intersect over Union* - IoU) između predviđanja modela i GT podataka. Ukoliko je IoU veći od postavljenog praga, predviđanje se smatra točnim pozitivnim primjerom (engl. *True Positive* - TP).

VGG16 i ResNet101 arhitekture mreže korištene su kao osnove rada. SCNN-VGG16 i SCNN-ResNet101 modeli trenirani su i testirani na CityScapes i CULane podatkovnim skupovima. SCNN modeli ocjenjuju se za dva zadatka u razumijevanju prometne scene (otkrivanje trake i semantička segmentacija). SCNN modeli postižu bolje rezultate od dotad postojećih modela koji koriste suvremene metode. Rezultati pokazuju da SCNN učinkovito čuva kontinuitet dugačkih tankih struktura poput linija koje predstavljaju linije voznih traka. Usporedba arhitekture i propagacije informacija između klasične konvolucijske neuronske mreže i SCNN prikazana je na slici 3.1.



(a)




(b)

Sl. 3.1. (a) Metoda zasnovana na Markovljevim slučajnim poljima (engl. *Markov Random Fields – MRF*) ili uvjetno slučajnim poljima (engl. *Conditional Random Fields - CRF*) (b) Implementacija *Spatial CNN*-a [2]


Kao što je prikazano u modulu 'SCNN D' na slici 3.1. (b), uzimajući u obzir SCNN primijenjen na tenzor veličine $C \times H \times W$, gdje C , H i W označavaju broj kanala, redova i stupaca, tenzor se dijeli na H isječaka (engl. *slices*), gdje se prvi isječak zatim šalje u konvolucijski sloj sa C jezgri (engl. *kernel*) veličine $C \times w$, gdje je w širina jezgre. U klasičnim CNN, izlaz konvolucijskog sloja je ulaz u sljedeći sloj, dok se u SCNN-u izlaz dodaje u sljedeći isječak, kako bi se dobio novi isječak. Proces se ponavlja dok se zadnji isječak ne ažurira.

Postojeće metode koje su prethodile SCNN-u, modeliraju prostorne odnose zasnovane na MRF ili CRF. U procesu prosljeđivanja informacija tradicionalnih metoda, svaki element slike prima informacije svih ostalih elemenata slike, što je računski skupo i neiskoristivo u automobilske industriji, posebice za zadatke koji se moraju izvršiti u stvarnom vremenu, poput detekcije linije vozne trake. Usporedba smjera propagacije poruka u SCNN modelu i modelu zasnovanom na MRF prikazana je na slici 3.2.



Sl. 3.2. Smjer propagacije poruka u (a) dubokoj MRF/CRF (zbog jasnoće prikazano prenošenje informacije u unutrašnja četiri elementa slike) (b) Propagacija informacije u SCNN s lijeva na desno [2]

Posebna struktura SCNN mreže omogućava modelu bolje shvaćanje prostornih odnosa, što omogućava zadržavanje kontinuiranih struktura poput linija voznih traka, koje mogu biti djelomično skrivene vozilima u prometu. Usporedba između predviđanja linija voznih traka između modela zasnovanog na CNN i modela zasnovanog na SCNN prikazana je na slici 3.3.



Sl. 3.3. (a) slika iz CULane podatkovnog skupa koja prikazuje okluziju linija vozne trake (b) predviđanje linija vozne trake za sliku (a) modela zasnovanog na CNN-u, (c) predviđanje linija vozne trake za sliku (a) modela zasnovanog na SCNN-u (d) slika iz CULane podatkovnog skupa koja prikazuje okluziju linija vozne trake (e) predviđanje linija vozne trake za sliku (d) modela zasnovanog na CNN-u (f) predviđanje linija vozne trake za sliku (d) modela zasnovanog na SCNN-u [2]

Osim predstavljenih rješenja zasnovanih na tehnikama tradicionalnog računalnog vida i dubokom učenju, postoji mnoštvo postojećih rješenja, a više detalja o njima može se naći u [11].

4. ANALIZA PERFORMANSI METODA ZA DETEKCIJU LINIJA VOZNE TRAKE ZASNOVANIH NA DUBOKOM UČENJU NA RAZLIČITIM SKUPOVIMA PODATAKA

Zadatak ovog diplomskog rada bio je izabrati tri različite metode detekcije linija voznih traka zasnovanih na dubokom učenju te ih testirati i evaluirati na trima različitim podatkovnim skupovima. Za testiranje i evaluaciju rada metoda za detekciju linija vozne trake, odabrani su CULane, TuSimple i LLAMAS podatkovni skupovi. Odabrane su tri metode koje se zasnivaju na trima različitim CNN. VGG16 (engl. *Visual Geometry Group*) je model CNN [12]. VGG16 sadrži 13 konvolucijskih slojeva, 5 slojeva združivanja po maksimalnoj vrijednosti, tri potpuno povezana sloja i jedan *softmax* sloj. ResNet34 je model CNN koja koristi rezidualne blokove kako bi olakšala treniranje i testiranje dubljih neuronskih mreža [13]. ERFNet (engl. *Efficient Residual Factorized Network*) je model CNN za semantičku segmentaciju u stvarnom vremenu [14]. ERFNet je dizajniran uzastopnim slaganjem predloženih (engl. *non bottleneck-ID*) slojeva na način koji najbolje iskorištava njihovu izvedbu učenja i učinkovitosti. Modeli zasnovani na trima spomenutim CNN-ovima modificirani su *state-of-the-art* SCNN metodom prostorne konvolucije.

U sklopu ovog rada izrađena su i dva pretvarača (engl. *converter*) formata zapisa voznih linija. Pretvarači omogućavaju testiranje modela koji su prethodno trenirani na skupu podataka koji koristi nekakav drugačiji format zapisa voznih linija, kako bi se njihov rad mogao verificirati uz dva različita tipa zapisa linija. U potpoglavlju 4.1. opisani su korišteni alati i biblioteke za izradu ovog rada. U djelu 4.1.1. opisano je *Conda* virtualno radno okruženje. U djelu 4.1.2. opisan je *PyTorch*, *Python* okvir za strojno učenje. U djelu 4.1.3. detaljno je opisan *PytorchAutoDrive* okvir kao i konfiguracijske datoteke potrebne za testiranje i evaluaciju. U potpoglavlju 4.2. napravljena je provjera ispravnosti vlastite implementacije odabranih modela za detekciju linija vozne trake. U potpoglavlju 4.3. opisuju se pretvarači formata zapisa voznih linija za CULane i TuSimple format zapisa oznaka linija vozne trake. U potpoglavlju 4.4. napravljena je evaluacija performansi modela za detekciju linija voznih traka. U djelu 4.4.1. napravljena je analiza rezultata modela za detekciju linija vozne trake na testnom skupu CULane podatkovnog skupa. U djelu 4.4.2. napravljena je analiza rezultata modela za detekciju linija vozne trake na testnom skupu TuSimple podatkovnog skupa. U djelu 4.4.3. napravljena je analiza rezultata modela za detekciju linija vozne trake na testnom skupu LLAMAS podatkovnog skupa. Cilj je prilagoditi istrenirane modele različitim podatkovnim skupovima, kako bi se uspješno testirali, evaluirali i vrednovali.

4.1. Opis korištenih alata i biblioteka

U ovom potpoglavlju opisani su alati i biblioteke korišteni za izradu zadatka diplomskog rada. U djelu 4.1.1 opisano je virtualno radno okruženje potrebno za izradu diplomskog rada. U djelu 4.1.2 opisan je *PyTorch*, ubrzani tenzorski računalni okvir za duboko učenje pomoću GPU-a (engl. *Graphics processing unit*). U djelu 4.1.3 opisan je *PyTorchAutoDrive*, kao *Python* okvir koji uključuje modele za semantičku segmentaciju i detekciju voznih traka temeljenih na *PyTorch-u*.

4.1.1. Virtualno radno okruženje

Virtualno okruženje (engl. *Virtual environment*) je alat koji pomaže u održavanju odvojenih ovisnosti (engl. *dependencies*) koje zahtijevaju različiti projekti, stvaranjem *Python* okruženja za njih. *Conda* je sustav za upravljanje paketima otvorenog koda i sustav za upravljanje okruženjem koji radi na *Windows*, *macOS* i *Linux* platformama [15]. *Conda* instalira, pokreće i ažurira pakete i njihove ovisnosti. Omogućava jednostavno spremanje, učitavanje i prebacivanje između okruženja. Popis potrebnih ovisnosti za rad s *PyTorchAutoDrive* okvirom dan je tablicom 4.1.

Tab. 4.1. *Popis potrebnih ovisnosti za rad s PyTorchAutoDrive okvirom*

| Softverske ovisnosti | Verzija | Softverske ovisnosti | Verzija |
|----------------------|--------------|----------------------|--------------|
| <i>Python</i> | ≥ 3.6 | <i>MMCV</i> | $\geq 1.3.5$ |
| <i>CUDA</i> | ≥ 9.2 | <i>openCV</i> | $= 4.5.4.58$ |
| <i>PyTorch</i> | ≥ 1.6 | <i>sciPy</i> | $= 1.5.4$ |
| <i>TorchVision</i> | $\geq 0.7.0$ | <i>tqdm</i> | $= 4.62.3$ |
| <i>MMCV</i> | $\geq 1.3.5$ | <i>ujson</i> | $= 4.2.0$ |
| <i>openCV</i> | $= 4.5.4.58$ | <i>tensorboard</i> | $= 2.7.0$ |
| <i>sciPy</i> | $= 1.5.4$ | <i>Shapely</i> | 1.8.0 |


Za izradu diplomskog rada stvoreno je virtualno okruženje pomoću naredbe:

```
conda create --name pytorchautodrive python=3.8
```

koja se unosi u *Linux* terminal, unutar prethodno stvorenog virtualnog okruženja.

4.1.2. PyTorch okvir za strojno učenje

PyTorch je ubrzani tenzorski računalni okvir za duboko učenje pomoću *GPU*-a [16]. Temelji se na *Torch-u* te je dizajniran za pružanje veće fleksibilnosti i brzine implementacije dubokih neuronskih mreža. *Torch* je biblioteka za strojno učenje otvorenog koda. *Torch* paket unutar biblioteke sadrži podatkovne strukture za višedimenzionalne tenzore i definira matematičke operacije nad tenzorima. Pruža fleksibilno *N*-dimenzionalno polje ili tenzor, koji podržava osnovne operacije za indeksiranje, rezanje, transponiranje, upisivanje tipa, promjenu veličine, dijeljenje pohrane i kloniranje. Ovaj objekt koristi većina drugih paketa i stoga čini osnovni objekt biblioteke. Ima *CUDA* (engl. *Compute Unified Device Architecture*) podršku koja omogućava pokretanje tenzorskih izračuna na *NVIDIA GPU-u* s računalnim mogućnostima (engl. *compute capability*) veće ili jednako verziji 3.0. Automatska diferencijacija provodi se sustavom zasnovanim na vrpci i na funkcionalnoj razini i na razini sloja neuronske mreže. Ova funkcionalnost donosi visoku razinu fleksibilnosti i brzine ovom okviru dubokog učenja i pruža ubranu funkcionalnost sličnu *NumPy-u*. Vizualizacija različitih oblika tenzora prikazana je na pet podslika na slici 4.2.



Sl. 4.2. Prikaz slika koje prikazuju (a) tenzor 1. reda (b) tenzor 2. reda (c) tenzor 3. reda (d) tenzor 4. reda (e) tenzor 5. reda [17]

Skalar je tenzor nultog reda ili tenzor nultog ranga. Vektor je jednodimenzionalan ili tenzor prvog reda, a matrica je dvodimenzionalan ili tenzor drugog reda. Kocka je tenzor trećeg reda. Tenzori četvrtog i petog reda strukturirani su kao vektor kocki, odnosno matrica kubova.

4.1.3. PyTorchAutoDrive

PytorchAutoDrive je *Python* okvir koji uključuje modele za semantičku segmentaciju i detekciju voznihih traka temeljenih na *PyTorch-u* [18]. Sadrži širok raspon metoda i modela neuronskih mreža implementiranih pomoću konfiguracijskih datoteka. Omogućava treniranje mješovitom preciznošću (engl. *Mixed precision training*), vizualizaciju podataka i *tensorboard* bilježenje.

U direktoriju *utils* nalaze se direktoriji koji sadrže prikladne klase ili funkcije za modele, skupove podataka, optimizatore i datoteke za korištenje pomoćnih programa. *PyTorchAutoDrive* direktorij koji sadrži skripte potrebne za rad okvira dan je kao elektronički prilog P.4.1. ovom radu.

Konfiguracijske datoteke služe za definiranje procesa treniranja, testiranja modela kao i samog definiranja modela. Unutar *PytorchAutoDrive* okvira konfiguracijske datoteke definirane su s 9 imenika (engl. *dictionary*).

Cjevovod podataka (engl. *Data pipeline*):

1. Skup podataka: klasa skupa podataka;
2. Trening augmentacija: pretvorbe za treniranje;
3. Test augmentacija: pretvorbe za testiranje.

Cjevovod optimizacije (engl. *Optimization pipeline*):

3. Gubitak (engl. *loss*): funkcija gubitka (npr. *CrossEntropy*);
4. Optimizator: npr. SGD (engl. *Stochastic Gradient Descent*);
5. *LR_scheduler*: planer brzine učenja (engl. *the learning rate scheduler*) (npr. korak LR).

Opcije modela:

7. Trening: opcije za trening (npr. epohe, veličina serije);
8. Test: opcije za evaluaciju, profiliranje i vizualizaciju (npr. put kontrolne točke, veličina slike);
9. Model: opcije za definiranje svog modela [18].

Konfiguracijske datoteke napisane su za svih 27 različitih kombinacija testiranja modela za detekciju linija vozne trake i podatkovnih skupova koje će se pojaviti u nastavku rada. Direktorij koji sadrži konfiguracijske datoteke potrebne za testiranje modela dan je kao elektronički prilog P.4.1. ovom radu. Programski kod konfiguracijske datoteke za testiranje SCNN-RESNET34 modela treniranog i testiranog na CULane podatkovnom skupu prikazan je na slici 4.3.

```

# Data pipeline
from configs.lane_detection.common.datasets.culane_seg import dataset
from configs.lane_detection.common.datasets.train_level0_288 import
train_augmentation
from configs.lane_detection.common.datasets.test_288 import test_augmentation

# Optimization pipeline
from configs.lane_detection.common.optims.segloss_5class import loss
from configs.lane_detection.common.optims.sgd02 import optimizer
from configs.lane_detection.common.optims.ep12_poly_warmup200 import
lr_scheduler

train = dict(
    exp_name='resnet34_scnn_culane',
    workers=10,
    batch_size=20,
    checkpoint=None,
    # Device args
    world_size=0,
    dist_url='env://',
    device='cuda',

    val_num_steps=0,
    save_dir='./checkpoints',

    input_size=(288, 800),
    original_size=(590, 1640),
    num_classes=5,
    num_epochs=12,
    collate_fn=None,
    seg=True
)

test = dict(
    exp_name='resnet34_scnn_culane',
    workers=10,
    batch_size=80,
    checkpoint='./checkpoints/resnet34_scnn_culane/model.pt',
    device='cuda',
    save_dir='./checkpoints',
    seg=True,
    gap=20,
    ppl=18,
    thresh=0.3,
    collate_fn=None,
    input_size=(288, 800),
    original_size=(590, 1640),
    max_lane=4,
    dataset_name='culane'
)

```

```

model = dict(
    name='standard_segmentation_model',
    backbone_cfg=dict(
        name='predefined_resnet_backbone',
        backbone_name='resnet34',
        return_layer='layer4',
        pretrained=True,
        replace_stride_with_dilation=[False, True, True]
    ),
    reducer_cfg=dict(
        name='RESAReducer',
        in_channels=512,
        reduce=128
    ),
    spatial_conv_cfg=dict(
        name='SpatialConv',
        num_channels=128
    ),
    classifier_cfg=dict(
        name='DeepLabV1Head',
        in_channels=128,
        num_classes=5,
        dilation=1
    ),
    lane_classifier_cfg=dict(
        name='SimpleLaneExist',
        num_output=5 - 1,
        flattened_size=4500
    )
)

```

Sl. 4.3. *Prikaz programskog koda konfiguracijske datoteke za SCNN_RESNET34_Culane model*

4.2. Provjera ispravnosti vlastite implementacije odabranih modela za detekciju linija vozne trake zasnovanih na dubokom učenju

PyTorchAutoDrive okvir sadrži kolekciju istreniranih modela za detekciju linija vozne trake i semantičku segmentaciju. Za izradu diplomskog rada korištena su tri različita istrenirana modela CNN: ResNet34, VGG16 i ERFNet, sva tri prilagođena SCNN metodom. SCNN formulira detekciju trake kao višeklasnu semantičku segmentaciju i osnova je suvremenih rješenja koje su u vrhu natjecanja na TuSimple izazovu detekcije linija voznih traka. Direktorij koji sadrži sve istrenirane modele za detekciju linija vozne trake dan je kao elektronički prilog P.4.2. ovom radu.

PyTorchAutoDrive okvir sadrži repozitorij istreniranih modela dostupnih za preuzimanje, čiji su rezultati evaluirani koristeći službene evaluacijske metrike pojedinog podatkovnog skupa. Autori TuSimple, CULane i LLAMAS podatkovnih skupova koriste različite evaluacijske metrike za evaluaciju metoda za detekciju linija vozne trake. Metode se na CULane i LLAMAS podatkovnim skupovima rangiraju prema F1 metrici. TuSimple koristi preciznost kao glavnu izlaznu metriku.

Kako bi bilo sigurno da su modeli implementirani u sklopu ovog diplomskog rada ispravno implementirani, sva su tri modela (SCNN-ResNet34, SCNN-VGG16 i SCNN-ERFNet) nakon vlastite implementacije testirana i evaluirana na odgovarajućim skupovima te su rezultati uspoređeni sa službenim rezultatima dostupnim unutar *PyTorchAutoDrive* okvira. Metoda, model mreže, podatkovni skup korišten za treniranje, glavna izlazna metrika, prosječni rezultat, najbolji rezultat i vrijeme treniranja svih korištenih modela prikazani su tablicom 4.2. Prosječni rezultat postignut od strane autora u izvornom znanstvenom radu dobije se kao prosječna točnost ili F1- mjera (ovisno o korištenom podatkovnom skupu) modela kroz više treniranja. Najbolji rezultat postignut od strane autora u izvornom radu odnosi se najbolji rezultat postignut kroz više provedenih treniranja.

Tab. 4.2. *Usporedba performansi modela implementiranih u sklopu ovog rada i performansi istih modela na istim skupovima podataka objavljenih u izvornom radu [18]*

| METODA | MODEL CNN | PODATKOVNI SKUP KORIŠTEN ZA TRENIRANJEE | GLAVNA IZLAZNA METRIKA | PROSJEČNI REZULTATI POSTIGNUTI OD STRANE AUTORA U IZVORNOM RADU [18] | NAJBOLJI REZULTATI POSTIGNUTI OD STRANE AUTORA U IZVORNOM RADU [18] | VRIJEME TRENIRANJA OD STRANE AUTORA (NVIDIA RTX 2080TI) [18] |
|--------|-----------|---|------------------------|--|---|--|
| SCNN | RESNET34 | TUSIMPLE | Točnost | 95.19% | 95.25% | 1h i 40 min |
| SCNN | VGG16 | TUSIMPLE | Točnost | 95.01% | 91.17% | 2 h |
| SCNN | ERFNET | TUSIMPLE | Točnost | 96.18% | 96.29% | 1h i 40 min |
| SCNN | RESNET34 | CULANE | F1 | 72.44% | 72.70% | 10h i 45 min |
| SCNN | VGG16 | CULANE | F1 | 74.02% | 74.29% | 12h i 50 min |
| SCNN | ERFNET | CULANE | F1 | 73.85% | 74.03% | 11h i 20 min |
| SCNN | RESNET34 | LLAMAS | F1 | 96.17% | 96.19% | 10h i 3min |
| SCNN | VGG16 | LLAMAS | F1 | 96.39% | 96.42% | 12h i 30min |
| SCNN | ERFNET | LLAMAS | F1 | 95.89% | 95.94% | 14h i 15 min * |

* trenirana na NVIDIA GTX 1080 TI

Istrenirani SCNN modeli za detekciju linija vozne trake trenirani su od strane autora koristeći NVIDIA RTX 2080 TI grafičku karticu. Prosječno vrijeme treniranja modela treniranih na TuSimple podatkovnom skupu je 1 sat i 45 minuta. Najbolje rezultate od modela treniranih na TuSimple podatkovnom skupu, postignute od strane autora, postigao je SCNN-ERFNet model, s točnošću detekcije linija voznih traka od 96.29%. Od istreniranih SCNN modela treniranih na CULane

podatkovnom skupu, najbolju F1 mjeru postiže SCNN-VGG16 model s rezultatom od 74.03%. Treniranje modela na CULane podatkovnom skupu traje u prosjeku 11 sati, što je šest puta duže od potrebnog vremena treniranja modela na TuSimple podatkovnom skupu. Od istreniranih SCNN modela treniranih na LLAMAS podatkovnom skupu, najbolju F1 mjeru postiže SCNN-VGG16 model s rezultatom od 96.42%. Rezultati evaluacije modela postignuti od strane autora su uspoređeni s vlastitim rezultatima kako bi se potvrdila točnost implementacije *PyTorchAutoDrive* okvira. Nakon potvrde točnosti implementacije modela unutar *PyTorchAutoDrive* okvira (mogu se vidjeti minimalne razlike u postignutim rezultatima za svih devet redaka u tablici 4.2), prelazi se na glavni dio diplomskog rada, a to je testiranje i evaluacija modela na trima različitim podatkovnim skupovima, uz različite kombinacije trening skupova i test skupova.

4.3. Pretvarači formata oznaka zapisa voznih linija

Kako bi se izvršila evaluacija testiranja modela na različitim podatkovnim skupovima, bilo je potrebno napraviti pretvarače formata zapisa linija voznih traka za CULane i TuSimple podatkovne skupove. Unutar *PyTorchAutoDrive* okvira, postoji pretvarač iz LLAMAS formata označavanja linija voznih traka u CULane format. Modeli koji su trenirani na određenom podatkovnom skupu daju izlazne rezultate u formatu tog podatkovnog skupa. Kako bi evaluirali modele koji su testirani na drugačijem podatkovnom skupu, bilo je potrebno napisati pretvarače formata. Pretvoreni izlazi se uspoređuju s GT, te se izračunavaju izlazne metrike. Pretvarači su pisani u *Python* programskom jeziku. U dijelu 4.3.1. opisan je pretvarač CULane formata zapisa u TuSimple format zapisa. U dijelu 4.3.2. opisan je pretvarač TuSimple formata u CULane format.

4.3.1. Pretvarač zapisa oznaka linija voznih traka iz TuSimple u CULane format

Modeli trenirani na TuSimple podatkovnom skupu kao rezultat daju jedinstvenu JSON datoteku formata opisanog u potpoglavlju 2.1. Službena evaluacijska skripta za CULane koja je dio *PyTorchAutoDrive* okvira, traži specifičnu hijerarhijsku strukturu direktorija i tekstualnih datoteka, koje predstavljaju rezultate testiranja za pojedinu sliku. Kako bi evaluirali modele koji su trenirani na TuSimple skupu podataka a testirani na CULane skupu, bilo je potrebno napisati pretvarač formata zapisa iz TuSimple u CULane format. Pretvarač omogućava korištenje jedinstvene CULane evaluacijske skripte za sve modele koji su testirani na CULane skupu podataka, neovisno o skupu na kojem su trenirani. Pretvarač je pisan u *Python* programskom jeziku, koristeći *Python* modul *OS*

(engl. *Miscellaneous operating system interfaces*) i JSON format zapisa za rad s direktorijima odnosno, JSON strukturom podataka. Pomoću funkcije *open()* otvara se JSON datoteka koja sadrži informacije o predviđenim linija vozne. Datoteka je potrebna samo za čitanje podataka, stoga se kao argument funkcije daje „r“ . JSON datoteka sadrži predviđanja za sve slike CULane testnog skupa u TuSimple formatu. Metoda *json.loads()* unutar *for* petlje omogućava sekvencijalno raščlanjivanje važećeg JSON niza i njegovo pretvaranje u rječnik (engl. *dictionary*). Druga *for* petlja omogućava prolazak kroz svaki rječnik unutar liste. Ukoliko je dužina liste koja sadržava vrijednosti koje predstavljaju *x* koordinatu elementa slike točke koja pripada liniji vozne trake zvana *lanes* veća od nule, kreira se nova tekstualna datoteka koja predstavlja predviđene točke pojedinih linija za pojedinu sliku.

Ime tekstualne datoteke se uzima iz niza (engl. *string*) pod ključnom riječju *raw file*. *Raw file* je ime niza koji sadrži podatke o slici. Pomoću funkcije *replace()*, uzima se dio niza koji se odnosi na ime datoteke, dok se ekstenzija koja predstavlja JPG format mijenja u *lines.txt* ekstenziju, koja odgovara formatu imenovanja tekstualnih datoteka koje sadržavaju koordinate predviđenih točaka CULane modela za pojedinu sliku. Linije i njihove pripadajuće točke strukturirane su kao liste nizova koje sadržavaju cjelobrojne vrijednosti. Koristeći ugniježdene *for* petlje omogućava se direktan pristup, prolazak i rad s elementima niza koji predstavljaju točke.

Prolazi se kroz sve elemente svake liste te se uspoređuju vrijednosti elementa s -2. Ukoliko je različit od -2, upisuje se u datoteku te se zatim upisuje razmak i odgovarajući element iz liste s ključnom riječju *h_samples*. *x* i *y* točke se zadržavaju u paru pomoću pamćenja indeksa elementa. Programski kod pretvarača zapisa oznaka linija voznih traka iz TuSimple u CULane format prikazan je na slici 4.4. Direktorij koji sadrži *Python* skriptu pretvarača zapisa oznaka linija vozne trake iz TuSimple u CULane format dan je kao elektronički prilog P.4.2. ovom radu.

```
import json
import os

new_list = []

for line in open('test_label.json', 'r'):
    data = json.loads(line)
    new_list.append(data)
```

```

for line in open('test_label.json', 'r'):
    data = json.loads(line)
    new_list.append(data)

for index in range(len(new_list)):
    if len(new_list[index]['lanes']) == 0:
        print(new_list[index]['raw_file'])
        directory = os.path.dirname(new_list[index]['raw_file'])
        if not os.path.exists(directory):
            os.makedirs(directory)
        with open(new_list[index]['raw_file'], "w"):
            pass
    else:
        directory = os.path.dirname(new_list[index]['raw_file'])
        if not os.path.exists(directory):
            os.makedirs(directory)

        file = new_list[index]['raw_file']
        file_path = file.replace(".jpg", ".lines.txt")
        with open(file_path, "w") as f:
            for element1 in range(len(new_list[index]['lanes'])):
                for element2 in range(len(new_list[index]['lanes'][element1])):
                    if new_list[index]['lanes'][element1][element2] != -2:
                        f.write(str(new_list[index]['lanes'][element1][element2]))
                        f.write(' ')
                        f.write(str(new_list[index]['h_samples'][element2]))
                        f.write(' ')
            f.write('\n')

```

Sl. 4.4. *Prikaz programskog koda pretvarača zapisa oznaka linija voznih traka iz TuSimple u CULane format*

4.3.2. Pretvarač zapisa oznaka linija vozne trake iz CULane u TuSimple format

Unutar *PyTorchAutoDrive* okvira, modeli trenirani na CULane ili LLAMAS podatkovnom skupu kao izlaz daju skup direktorija koji sadrže datoteke TXT formata koje predstavljaju predviđanja modela za pojedinu sliku. Kako bi testirali modele na TuSimple podatkovnom skupu, potrebno je pretvoriti predviđanja modela iz CULane formata u TuSimple format. Evaluacijska skripta za TuSimple podatkovni skup zahtjeva jedinstvenu JSON datoteku koja sadrži sva predviđanja za svaku sliku unutar testnog skupa.

Format zapisa za pojedinu sliku objašnjen je u potpoglavlju 2.2. Skripta je pisana u *Python* programskom jeziku, koristeći JSON i GLOB (engl. *global*) module. Modul GLOB je dio Python standardne biblioteke te se koristi za vraćanje svih putanja datoteka koje odgovaraju određenom

uvjetu. Omogućava pretraživanje datoteke čiji naziv datoteke odgovara određenom uzorku korištenjem zamjenskih znakova.

Pomoću funkcije *open()* otvara se datoteka JSON formata u koju se planiraju zapisati pretvorena predviđanja modela. Korištenje *for* petlje i funkcije *iglob()* omogućava obradu svih datoteka koja završavaju s ekstenzijom TXT. Kreira se rječnik *dict1* koji sadrži strukturu TuSimple zapisa kao i rječnik *dict2* koji će predstavljati formatiran zapis linija vozne trake. Funkcija *rstrip()* omogućava uklanjanje zaostajućeg razmaka (engl. *trailing whitespace*) koji sprječava rastavljanje niza znakova koji predstavljaju brojeve u niz decimalnih brojeva. Funkcija *split()* rastavlja niz u polje znakova, u ovom slučaju polje brojeva. Korištenjem ugniježđenih *for* petlji prolazi se kroz svaku listu i svaki pojedini element pojedine liste te se pomoću funkcije *float()*, elementi niza pretvaraju u realne brojeve.

Trostruka ugniježđena petlja omogućava pristup, iteriranje i provjeravanje uvjetovanjem svakog pojedinog elementa niza koji predstavlja *x* vrijednost. Ukoliko je element niza različit od -2, provjerava se indeks njegovog para koji predstavlja *y* vrijednost. Ukoliko se vrijednosti podudaraju, *x* vrijednost se zapisuje u rječnik *dict2*.

Rječnik se pomoću funkcije *json.loads()* sprema u JSON datoteku. Na slici 4.5. nalazi se prikaz programskog koda pretvarača zapisa oznaka linija voznih traka iz CULane u TuSimple format. Direktorij koji sadrži *Python* skriptu pretvarača zapisa oznaka linija vozne trake iz CULane u TuSimple format dan je kao elektronički prilog P.4.3. ovom radu.

```
import json
import glob

out_file = open("test1.json", "w")
root_dir = "clipsss/"
run_time = 0

for filename in glob.iglob(root_dir + '**/*.txt', recursive=True):
    dict1 = {"lanes": [],
            "h_samples": [160, 170, 180, 190, 200, 210, 220, 230, 240, 250, 260, 270, 280, 290,
                          300, 310, 320, 330,
                          340,
                          350, 360,
                          370, 380, 390, 400, 410, 420, 430, 440, 450, 460, 470, 480, 490, 500,
                          510, 520, 530, 540,
                          550,
                          560, 570,
                          580, 590, 600, 610, 620, 630, 640, 650, 660, 670, 680, 690, 700, 710],
            "raw_file": "",
            "run_time": run_time}
```

```

dict2 = {
    "lanes": [
        [-2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2,
        -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2,
        -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2, -2,
        -2, -2, -2, -2]],
    "h_samples": [160, 170, 180, 190, 200, 210, 220, 230, 240, 250, 260, 270, 280, 290, 300,
310, 320, 330, 340,
                350, 360,
                370, 380, 390, 400, 410, 420, 430, 440, 450, 460, 470, 480, 490, 500, 510,
520, 530, 540, 550,
                560, 570,
                580, 590, 600, 610, 620, 630, 640, 650, 660, 670, 680, 690, 700, 710],
    "raw_file": "",
    "run_time": run_time}

with open(filename) as file:
    dict1["lanes"] = [line.rstrip() for line in file]
    dict1["lanes"] = [line.split() for line in dict1["lanes"]]
    dict2["raw_file"] = filename.replace("txt", "jpg").replace("\\", "/")
    print(dict2["raw_file"])
    for element1 in range(len(dict1["lanes"])):
        for element2 in range(len(dict1["lanes"][element1])):
            dict1["lanes"][element1][element2] = float((dict1["lanes"][element1][element2]))

    for element3 in range(len(dict1["lanes"]) - 1):
        dict2["lanes"].append([])
        dict2["lanes"][element3 + 1] = [-2] * 56

    for element1 in range(len(dict1["lanes"])):
        for element2 in range(len(dict1["lanes"][element1])):
            for element3 in range(len(dict1["h_samples"])):
                if element2 % 2 != 0:
                    if dict1["h_samples"][element3] == dict1["lanes"][element1][element2]:
                        dict2["lanes"][element1][element3] = dict1["lanes"][element1][element2] -
1]

    json.dump(dict2, out_file, sort_keys=False)
    out_file.write('\n')
out_file.close()

```

Sl. 4.5. *Prikaz programskog koda pretvarača zapisa oznaka linija vozni traka iz CULane u TuSimple format*

4.4. Evaluacija performansi modela za detekciju linija vozni traka zasnovanih na dubokom učenju korištenjem triju podatkovnih skupova

U ovom potpoglavlju opisan je način evaluacije i analize triju različitih modela na trima različitim podatkovnim skupovima. Modeli su kategorizirani ovisno o podatkovnom skupu na kojem su testirani. Sveukupno postoji 27 različitih kombinacija korištenog modela, trening skupa i testnog skupa (3 modela, 3 trening skupa i 3 testna skupa $\rightarrow 3 \times 3 \times 3 = 27$). U dijelu 4.4.1. analizirani su rezultati evaluacije svih modela koji su testirani na testnom skupu CULane podatkovnog skupa, a trenirani na trima različitim trening skupovima. U dijelu 4.4.2. prikazani su rezultati testiranja na testnom skupu TuSimple podatkovnog skupa, kada su modeli trenirani na trima različitim trening skupovima. U dijelu 4.4.3. analizirani su rezultati testiranja na validacijskom skupu LLAMAS podatkovnog skupa (za

LLAMAS ne postoji GT za testni skup), također kada su modeli trenirani na trima različitim trening skupovima. Za svako je testiranje napravljena vizualizacija IoU između predviđenih linija i GT. Testiranja i evaluacija su izvršene na NVIDIA RTX 3080 12GB grafičkoj kartici. Direktorij koji sadrži rezultate vizualizacije predviđanja modela za detekciju linija vozne trake dan je kao elektronički prilog P.4.4. ovom radu.

4.4.1. Analiza rezultata modela testiranih na testnom skupu CULane podatkovnog skupa

Prije evaluacije rezultata testiranja svih kombinacija modela i trening skupova na CULane podatkovnom skupu, potrebno je postaviti parametre evaluacije. Širina linije predstavlja debljinu linije izraženu u elementima slike, dok zadani prag veličine IoU predstavlja minimalnu granicu IoU da bi se detekcija linije smatrala točnom. Kako bi se procijenilo je li oznaka linije uspješno otkrivena, oznake linija gledaju se kao pravci širine 30 elemenata slike te se izračunava IoU između GT linija vozne trake i linija koje predviđa model. Predviđanja gdje je IoU veći od postavljenog praga smatraju se točnim (engl. *true positive* - *TP*). Rezultati evaluacije modela na testnom skupu CULane baze podataka prikazani su tablicom 4.3. Preciznost se izračunava kao omjer između broja točno pozitivnih primjera i ukupnog broja primjera koji su klasificirani kao pozitivni:

$$Preciznost = \frac{TP}{TP+FP} * 100\% \quad (4-1)$$

gdje je TP broj točno pozitivnih primjera, FP broj lažno pozitivnih primjera.

Odziv se izračunava kao omjer između broja točno pozitivnih primjera te sume točno pozitivnih i lažno negativnih primjera (engl. *false negative* - *FN*):

$$Odziv = \frac{TP}{TP+FN} * 100\% \quad (4-2)$$

gdje je TP broj točno pozitivnih primjera, FN broj lažno negativnih primjera.

Odziv mjeri sposobnost modela da otkrije pozitivne uzorke. Kao glavna evaluacijska metrika točnosti modela za detekciju linija vozne trake koristi se F1 mjera. Predstavlja evaluacijski indeks koji

kombinira preciznost i odziv modela, a definiran je kao harmonijska sredina preciznosti i odziva modela [19]:

$$F1 = 2 * \frac{Odziv * Preciznost}{Odziv + Preciznost} * 100\% \quad (4-3)$$

Prag IoU da bi se detekcija smatrala točno pozitivnom postavljen je na 0.5, što se smatra strožim pragom detekcije linija vozne trake.

Tab. 4.3. Rezultati evaluacije modela (F1 mjera) na testnom skupu CULane baze podataka za svaki podskup (Normal, Crowded, Night, No line, Shadow, Dazzle light, Curve, Crossroad) i ukupna F1 mjera za cijeli testni skup

| Mreža | Trening skup | Testni skup | Normal [%] | Crowded [%] | Night [%] | No line [%] | Shadow [%] | Arrow [%] | dazzle light [%] | Curve [%] | Crossroad [broj FP primjera] | ukupna F1 mjera [%] |
|---------------|--------------|-------------|------------|-------------|-----------|-------------|------------|-----------|------------------|-----------|------------------------------|---------------------|
| SCNN-ResNet34 | CULane | CULane | 91.07 | 70.04 | 67.80 | 44.63 | 68.86 | 86.49 | 61.46 | 65.83 | 2019 | 72.70 |
| SCNN-ResNet34 | LLAMAS | CULane | 37.18 | 14.59 | 5.33 | 9.72 | 3.83 | 16.75 | 10.84 | 25.30 | 6564 | 19.14 |
| SCNN-ResNet34 | TuSimple | CULane | 10.30 | 3.30 | 2.04 | 3.45 | 0.07 | 5.11 | 6.24 | 9.72 | 3325 | 5.54 |
| SCNN-VGG16 | CULane | CULane | 92.04 | 72.29 | 69.15 | 45.87 | 76.22 | 87.65 | 64.55 | 69.06 | 1921 | 74.27 |
| SCNN-VGG16 | LLAMAS | CULane | 41.19 | 17.12 | 10.57 | 11.40 | 6.53 | 19.19 | 16.34 | 29.17 | 4932 | 28.39 |
| SCNN-VGG16 | TuSimple | CULane | 11.59 | 5.32 | 1.40 | 1.95 | 0.93 | 6.89 | 4.17 | 7.13 | 1173 | 6.28 |
| SCNN-ERFNet | CULane | CULane | 91.79 | 72.15 | 69.43 | 46.63 | 70.73 | 87.27 | 65.67 | 68.05 | 2226 | 74.01 |
| SCNN-ERFNet | LLAMAS | CULane | 21.87 | 4.70 | 2.50 | 1.70 | 1.35 | 8.10 | 5.15 | 9.80 | 6759 | 9.35 |
| SCNN-ERFNet | TuSimple | CULane | 11.03 | 4.36 | 3.24 | 3.15 | 0.91 | 7.90 | 3.78 | 9.31 | 2935 | 6.17 |

CULane testni podatkovni skup sastoji se od 9 kategorija. Podatkovni skup je kategoriziran prema cestovnim i vremenskim uvjetima, gustoći prometa kao i prema tipu cestovnih oznaka. CULane predstavlja najkompleksniji podatkovni skup, gdje posljednja dostignuća tehnike modeli postižu ukupnu F1 mjeru oko 80.00%. Linije označene crvenom bojom predstavljaju liniju temeljne istine, zelene linije predstavljaju predviđanje modela dok je žutom označen presjek predviđanja i temeljne istine.

Na slici 4.6. prikazana je vizualizacija triju okvira iz testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima. Prvi okvir predstavlja vožnju pod dnevnim svjetlom, s jasno vidljivim bijelim isprekidanim oznakama linija. Odsjaj sunčeve svjetlosti i velika površina sjena predstavljaju izazov za ispravnu detekciju linija voznih traka. Prvi okvir pripada *normal*, *shadow*, *dazzle light* kategorijama. Postoje 3 označene linije kao GT. Drugi i treći okvir predstavljaju noćnu vožnju sa slabom vidljivošću linija. Jak odsjaj i slaba vidljivost predstavljaju veliki izazov za ispravnu detekciju linija.


SCNN-ResNet34 model treniran i testiran na CULane podatkovnom skupu je za okvir sa slike 4.6. (a) uspješno i precizno predvidio sve tri linije vozne trake. Odsjaj i sjene ne predstavljaju problem u točnom predviđanju linija voznih traka. Velik broj konzistentnih predviđanja uzrokuje dugačke, ravne linije koje se pružaju cijelom dužinom linije vozne trake koja predstavlja temeljnu istinu. Postoje manja odstojanja u predviđanjima koja se zanemaruju s obzirom na postavljeni prag.

Model je s obzirom na kompleksnost okvira prikazanog na slici 4.6.(b), uspješno predvidio sve četiri linije vozne trake. Linije vlastite vozne trake predviđene su s visokom preciznošću. Gustoća i preciznost predviđenih točaka daju unutarnjim linijama ravni oblik. Uzrok lošijeg predviđanja vanjskih linija voznih traka, posebice krajnje desne, je iznimno loša vidljivost linija voznih traka, uzrokovana lošom osvjetljenošću ceste. Unatoč vozilima koja zaklanjaju vidljivost linija voznih traka, model uspješno predviđa njihovu postojanost i oblik.


Za okvir (c) sa slike 4.6. model neuspješno predviđa jednu liniju unutarnje vozne trake. Nepostojanost jasnih voznih oznaka za unutarnju prometnu traku uzrokuje krivo predviđanje modela. Vanjske linije voznih traka predviđene su s visokom preciznošću. Linije koje predstavljaju predviđanja za vanjske trake su ravne, za razliku od predviđenih unutarnjih linija koje nisu označene.



(a)



(b)




(c)

Sl. 4.6. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na CULane trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije (GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta))

SCNN-ResNet34 model treniran na LLAMAS trening skupu daje vrlo loše rezultate na testnom skupu CULane podatkovnom skupu za okvire prikazane na slici 4.7. Model uspješno predviđa krajnju lijevu liniju vozne trake. Uzorak ograde zamjenjuje se za oznake voznih linija, zajedno s kontrastom kolnika uzrokovanim sjenama i odsjajem sunca. F1 mjera predviđanja za cijeli *normal* skup iznosi 37.18%.

Model za okvir (b) sa slike 4.7. ne predviđa nijednu liniju vozne trake. Slaba vidljivost linija vozni traka te odsjaj na cesti uzrokuje velik broj FN primjera. Model je za okvir (c) sa slike 4.7. točno predvidio samo dio krajnje lijeve linije vozne trake. Komplexnost CULane testnog skupa prevelik problem za model koji je treniran na homogenom i jednostavnom trening skupu poput LLAMAS trening skupa.



Sl. 4.7. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na LLAMAS trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

SCNN-ResNet34 model treniran na trening skupu TuSimple podatkovnog skupa daje lošije rezultate u usporedbi s istim modelom treniranim na trening skupu CULane ili LLAMAS skupa. Na slici 4.8. prikazana je vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na TuSimple trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima.

Za okvir (a) sa slike 4.8. model uspješno detektira samo dio lijeve unutarnje linije vozne trake. Tanke, slabo vidljive i isprekidane linije voznih traka predstavljaju prepreku za model koji je treniran na jednostavnom trening skupu poput TuSimple skupa. Model za okvir (b) sa slike 4.8. nema uspješnih predviđanja linija vozne trake. Oznaka strelice koja u prometu pokazuje smjer prometa, pod lošim osvjetljenjem je zamijenjena za liniju vozne trake. Za okvir (c) sa slike 4.8. model uspješno predviđa dio krajnje lijeve trake. Presjek je za prvi dio predviđanja polovičan, što upućuje na razliku od 15-ak elemenata slike ili više (širina linija je 30 elemenata slike).



(a)



(b)



(c)

Sl. 4.8. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na TuSimple trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

SCNN-VGG16 model treniran i testiran na CULane podatkovnom skupu, za sliku 4.9. precizno je predvidio sve tri linije vozne trake. Model treniran na CULane podatkovnom skupu nema problema s predviđanjem linija vozni traka na okvirima na kojima je cesta osvijetljena dnevnim svjetlošću. Postignuta je F1 mjera od 92.04% za *normal* kategoriju CULane testnog skupa.

Model precizno detektira tri od četiri linije vozne trake za okvir (a) slike 4.9. koja prikazuje vizualizaciju predviđenih linija SCNN-VGG16 modela treniranog na CULane trening skupu za 3 okvira iz CULane podatkovnog testnog skupa. Krajnje desna linija detektirana je s polovičnom preciznošću zbog loše vidljivosti linije. Linije vozne trake predviđene od strane modela imaju valovit oblik zbog manjih odstupanja u predviđanju točaka za koje se smatra da pripadaju linijama vozne trake.

Model neuspješno predviđa jednu unutarnju liniju vozne trake za okvir (b) slike 4.9. Nepostojanost jasnih voznih oznaka za unutarnju liniju uzrokuje krivo predviđanje. Manje odstupanje je uzrokovano zaklanjanjem linija voznih traka vozilom u prometu.



(a)



(b)




(c)

Sl. 4.9. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na CULane trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-VGG16 model treniran na LLAMAS trening skupu za okvir (a) slike 4.10. neuspješno predviđa unutarnje linije vozne trake. Krajnja lijeva linija vozne trake je većinom svoje dužine uspješno detektirana. Postoji neravnina kod predviđene linije, što upućuje na devijacije kod predviđanja točaka. Kontrast odsjaja sunčeve svjetlosti i sjene na kolniku uzrokuju velik broj krivo predviđenih točaka. Kontrast svjetline ograde koja odvaja kolnik od pločnika koji je u sjeni uzrokuje krivu detekciju linije vozne trake.

Za okvir (b) slike 4.10. nema točnih predviđanja modela. Loše osvjetljenje ceste uzrokuje slabu vidljivost linija voznih traka. Model je za okvir (c) slike 4.10. točno predvidio dio krajnje lijeve linije

vozne trake. Predviđeni dio linije vozne trake je ujedno i najbolje vidljiv dio linije vozne trake na slici. Nepostojanost oznaka unutarnje linije kao i općenita loša vidljivost uzrokuju nedostatak točnih predviđanja.



(a)



(b)



(c)

Sl. 4.10. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded ,no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)


SCNN-VGG16 model treniran na TuSimple trening skupu daje rezultate ukupne F1 mjere ispod 7.00%. Na slici 4.11. prikazana je vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz CULane podatkovnog testnog skupa. Nedostatak predviđenih točaka na sve tri slike, uzrokuje velik broj FN linija. U usporedbi sa SCNN-VGG16 modelom treniranim na LLAMAS podatkovnom skupu, SCNN-VGG16 model treniran na TuSimpleu nije točno predvidio ni jednu liniju vozne trake.

Za okvir (a) slike 4.11. model uspješno predviđa mali dio lijeve unutarnje linije vozne trake. Za razliku od istog modela treniranog na LLAMAS trening skupu, postoji veliki nedostatak predviđenih točaka.

Za okvire (b) i (c) slike 4.11. nema uspješnih predviđanja linija vozne trake. Urbani i ruralni scenariji cestovnog prometa zastupljeni u CULane podatkovnom skupu previše su kompleksni za model treniran na slikama s američkih cesta s jasno vidljivim voznim oznakama linija voznih traka.



(a)



(b)



(c)

Sl. 4.11. *Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na TuSimple trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)*


SCNN-ERFNet model treniran i testiran na CULane podatkovnom skupu daje rezultate ukupne F1 mjere od 74.02%. Na slici 4.12. prikazana je vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na CULane trening skupu za 3 okvira iz CULane podatkovnog testnog skupa.

Za okvir (a) slike 4.12. uspješno su predviđene sve tri linije vozne trake. Odsjaj sunčeve svjetlosti i sjene ne predstavljaju smetnju pri predviđanju točki. Predviđene linije su ravne i preklapaju se odlično s linijama koje predstavljaju temeljnu istinu.

Za razliku od VGG16 i ResNet34 modela, SCNN-ERFNet nema problema sa slabom vidljivošću oznake krajnje desne linije vozne trake kod okvira (b) slike 4.12. Nepostojanost oznaka za unutarnju liniju vozne trake kod okvira (c) slike 4.12. uzrokuje krivo predviđanje unutarnje linije vozne trake, kao što je slučaj i kod SCNN-VGG16 i SCNN-ResNet34 modela, koji su trenirani i testirani na CULane podatkovnom skupu.



(a)



(b)



(c)

Sl. 4.12. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na CULane trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)


SCNN-ERFNET model treniran na LLAMAS trening skupu daje velik broj lažno pozitivnih točaka (zelena boja). Na slici 4.9. prikazana je vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz CULane podatkovnog testnog skupa.

Za okvir (a) slike 4.13. velik broj krivih predviđanja dolazi od linija vozila na koje je kamera montirana. Iako postoji IoU linija temeljne istine i predviđenih linija modela (žuta boja), broj lažno pozitivnih i lažno negativnih točaka uzrokuje nisku preciznost na relativno jednostavnom okviru iz CULane podatkovnog skupa.

Za okvire (b) i (c) slike 4.13. postoji velik broj lažno pozitivnih točaka koje su spojene u oblike koji ne mogu predstavljati linije voznih traka. Slaba vidljivost oznaka, kao i jak odsjaj noćne rasvjete i prometnih sudionika, uzrokuju predviđanja niske preciznosti.



(a)



(b)




(c)

Sl. 4.13. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ERFNET model treniran na TuSimple trening skupu daje najlošije rezultate od svih kombinacija modela i trening skupova. Model nije uspješno predvidio niti jednu liniju vozne trake za svim trima okvirima. Prometni scenariji, oznake linija vozne trake kao i vremenski uvjeti na slikama iz TuSimple trening skupa, različiti su naspram scenarija u CULane testnom skupu, što uzrokuje neuspješno predviđanje linija voznih traka.



(a)



(b)



(c)

Sl. 4.14. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na TuSimple trening skupu za 3 okvira iz CULane podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) Okvir iz normal, dazzle light kategorije (b) Okvir iz night, crowded, dazzle light kategorije (c) Okvir iz night, crowded, no line, dazzle light kategorije GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

4.4.2. Analiza rezultata modela testiranih na testnom skupu TuSimple podatkovnog skupa

Iz TuSimple testnog skupa također su odabrana tri okvira za vizualizaciju IoU predviđenih linija i linija koje predstavljaju GT. Okviri sadržavaju po tri označene linije vozne trake. Kao glavnu evaluacijsku metriku točnosti modela za detekciju linija vozne trake na testnom skupu TuSimple podatkovnog skupa koristi se točnost (engl. *accuracy*) (4-4) [1]. Točnost se računa na temelju predviđenih točaka koje čine linije vozne trake i točaka koje čine GT linije. Ukoliko je razlika u udaljenosti predviđene točke i točke koja pripada GT liniji manja od postavljenog praga (30 elemenata slike), točka se smatra TP točkom. Omjer krivo predviđenih linija i ukupnog broja predviđenih linija zove se omjer lažno pozitivnih primjera (engl. *False Positive Rate* – FPR) (4-5) [1]. Omjer neprepoznatih GT linija i ukupnog broja GT linija zove se omjer lažno negativnih primjera (engl.

False Negative Rate – FNR) (4-6) [1]. Prag IoU je postavljen na 0.5, što se smatra strožim pragom detekcije linija vozne trake.

$$Točnost = \frac{\sum_{clip} c_{clip}}{\sum_{clip} s_{clip}} \quad (4-4)$$

gdje c_{clip} predstavlja broj TP točaka u okviru isječka, s_{clip} ukupan broj točaka u okviru isječka. Ako je razlika između širine GT i predviđanja manja od praga, predviđena točka smatra se TP primjerom.

$$FPR = \frac{F_{pred}}{N_{pred}} \quad (4-5)$$

gdje je F_{pred} broj krivo predviđenih linija, N_{pred} ukupan broj svih predviđenih linija.


$$FNR = \frac{M_{pred}}{N_{gt}} \quad (4-6)$$

gdje je M_{pred} je broj neprepoznatih stvarnih linija u predikcijama, N_{gt} je broj svih stvarnih linija. Rezultati evaluacije modela na testnom skupu TuSimple baze podataka prikazani su tablicom 4.4.

Tab. 4.4. Rezultati evaluacije modela (*FPR*, *FNR* i ukupna točnost) na testnom skupu TuSimple baze podataka

| Mreža | Trening skup | Testni skup | FPR | FNR | Točnost [%] |
|---------------|--------------|-------------|------|------|-------------|
| SCNN-ResNet34 | CULane | TuSimple | 0.90 | 0.97 | 43.13 |
| SCNN-ResNet34 | LLAMAS | TuSimple | 0.24 | 0.48 | 67.38 |
| SCNN-ResNet34 | TuSimple | TuSimple | 0.06 | 0.06 | 95.24 |
| SCNN-VGG16 | CULane | TuSimple | 0.90 | 0.97 | 42.96 |
| SCNN-VGG16 | LLAMAS | TuSimple | 0.17 | 0.37 | 75.30 |
| SCNN-VGG16 | TuSimple | TuSimple | 0.06 | 0.06 | 95.15 |
| SCNN-ERFNet | CULane | TuSimple | 0.90 | 0.97 | 41.24 |
| SCNN-ERFNet | LLAMAS | TuSimple | 0.24 | 0.38 | 76.78 |
| SCNN-ERFNet | TuSimple | TuSimple | 0.04 | 0.03 | 96.29 |

SCNN-ResNet34 model treniran i testiran na TuSimple podatkovnom skupu uspješno detektira sve linije voznih traka na primjerima okvira danim na slici 4.15. Vozila na cesti ne ometaju uspješno predviđanje oblika linija voznih traka. Model detektira zakrivljene i ravne linije s visokom preciznošću. Isprekidane bijele linije pod određenim kutem ne predstavljaju problem predviđanju modela.




Sl. 4.15. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na TuSimple trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b)zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ResNet34 model treniran na trening skupu LLAMAS podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa djelomično uspješno detektira linije vozne trake za primjere dane na slici 4.16.

Za sliku 4.16. (a), predviđanja su manje precizna od SCNN-ResNet34 modela treniranog na TuSimple podatkovnom skupu. Okluzija nastala pojavom vozila na cesti stvara prepreku pri detekciji krajnje lijeve linije vozne trake.

Za sliku 4.16. (b), model uspješno predviđa zakrivljene linije trake u kojoj se vozilo nalazi. Model ne detektira krajnju lijevu traku zbog slabe vidljivosti tankih oznaka linija vozne trake. Za sliku 4.16. (c) model uspješno detektira linije vozne trake koje opisuju traku u kojoj se vozilo nalazi. Nema predviđanja za krajnju desnu traku iako je vidljivost linije dobra. Zakrivljene isprekidane linije uzrokuju problem pri detekciji.




Sl. 4.16. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na LLAMAS trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ResNet34 model treniran na trening skupu CULane podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa ne detektira ispravno linije vozne trake za slike prikazane na slici 4.17.

Za sliku 4.17. (a), predviđanja modela su neprecizna te imaju vrlo visok FPR (0.90) i FNR (0.97). Nijedna linija vozne trake nije uspješno detektirana. CULane trening skup je znatno drukčiji

od TuSimple trening skupa, što uzrokuje slabe rezultate predviđanja linija vozne trake na testnom TuSimple skupu.




Sl. 4.17. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na CULane trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-VGG16 model treniran na trening skupu TuSimple podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa uspješno detektira linije voznih traka za primjere dane na slici 4.18. Kroz cijeli TuSimple testni skup podatkovnog skupa, zabilježena je visoka preciznost predviđanja linija voznih traka, uz vrlo mali FPR i FNR.

Za sliku 4.18. (a) model uspješno detektira sve tri linije vozne trake. Vozilo locirano u krajnjoj lijevoj traci, ne ometa model u točnom predviđanju oblika i putanje linije vozne trake Za sliku 4.18. (b), model uspješno detektira sve tri zakrivljene linije vozne trake. Krajnja desna linija zbog svoje slabije vidljivosti uzrokuje manje probleme koji se manifestiraju u obliku neravne linije predviđanja.

Za sliku 4.18. (c) model je uspješno detektirao sve tri linije. Smanjena vidljivost linija voznih traka u daljini te vozila u prometu ne predstavljaju problem modelu u ispravnoj detekciji linija vozne trake.



(a)



(b)



(c)

Sl. 4.18. *Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na TuSimple trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b)zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)*

S ukupnom točnošću od 75.00%, SCNN-VGG16 model treniran na LLAMAS trening skupu te testiran na TuSimple testnom skupu, bolje detektira linije vozne trake od SCNN-ResNet34 modela.

Za sliku 4.19. (a) model uspješno detektira sve tri linije. Okluzija i smanjena vidljivost linija voznih traka u daljini uzrokuju lažno negativna predviđanja.

Za sliku 4.19. (b) model ne detektira ispravno krajnju desnu liniju vozne trake. Zakrivljenost i isprekidani oblik oznake linije vozne trake predstavlja problem pri detekciji. Linije krajnje desne trake su znatno tanje od unutarnjih traka u kojim se vozilo nalazi. Za sliku 4.19. (c) model uspješno detektira unutarnje linije vozne trake. Model ne detektira krajnju desnu liniju, iako je vidljivost linije dobra.



(a)




(b)



(c)

Sl. 4.19. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

SCNN-VGG16 model treniran na trening skupu CULane podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa ni na jednoj slici prikazanoj na 4.20. nije uspješno detektirao linije vozne trake. Za sliku 4.20. (a), predviđanja modela su neprecizna te imaju vrlo visok FPR i FNR.



(a)



(b)




(c)

Sl. 4.20. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na CULane trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ERFNet model treniran na trening skupu te testiran na testnom skupu TuSimple podatkovnog skupa uspješno detektira linije voznih traka na slikama prikazanih na slici 4.21. Od modela koji su i trenirani i testirani na TuSimple podatkovnom skupu, SCNN-ERFNet postiže najbolje rezultate s točnošću $>96.00\%$. Za sliku 4.21. (a) model uspješno detektira sve tri linije vozne trake. Vozila uključena u promet ne ometaju model u uspješnom predviđanju linija vozne trake. Za sliku 4.21. (b), model uspješno detektira sve tri linije.

Krajnja desna linija vozne trake smatra se lažno pozitivnim primjerom jer je zabilježena kao postojeća traka, iako ne postoji njezin zapis u datoteci koja sadrži podatke o linijama vozne trake temeljne istine za tu sliku. Za sliku 4.21. (c), model uspješno detektira sve tri linije te ih pritom ne skraćuje kao SCNN-VGG16 i SCNN-ResNet34 modeli.



(a)



(b)




(c)

Sl. 4.21. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na TuSimple trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ERFNet model treniran na trening skupu LLAMAS podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa, djelomično uspješno detektira linije vozne trake za primjere dane slikom 4.22. Za sliku 4.22. (a), okluzija uzrokovana vozilom u prometu predstavlja prepreku modelu u predviđanju linija voznih traka.

Za sliku 4.22. (b), model uspješno detektira sve tri zakrivljene linije vozne trake. Krajnja desna traka ima odstojanja u rasporedu točaka, uzrokovana slabom vidljivošću linije vozne trake, što uzrokuje neravninu predviđene linije.



(a)



(b)




(c)

Sl. 4.22. *Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)*

SCNN-ERFNet model treniran na trening skupu CULane podatkovnog skupa te testiran na testnom skupu TuSimple podatkovnog skupa, ne detektira uspješno linije voznih traka za primjere dane na slici 4.23. Za sva tri okvira, predviđanja modela su neprecizna.

Uspoređujući sa SCNN-VGG16 i SCNN-ResNet34 modelima koji su trenirani na CULane podatkovnom skupu te testirani na TuSimple podatkovnom skupu, rezultati su smisleniji i točniji, ali i dalje prilično loši.

Predviđene linije se djelomično poklapaju s linijama temeljne istine na okvirima (a) i (c) slike 4.23. Smanjena vidljivost linija voznih traka u daljini uzrokuje velik broj FN primjera. Zakrivljenost isprekidanih bijelih linija predstavlja veliki problem pri detekciji linija na okviru (b) slike 4.23.



(a)



(b)



(c)

Sl. 4.23. *Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na CULane trening skupu za 3 okvira iz TuSimple podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ravna cesta, sunčano, isprekidane linije vozne trake (b) zakrivljena cesta, autocesta, bijele, isprekidane linije, pune linije (c) ruralno područje, oblačno, isprekidane linije, pune linije GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)*


4.4.3. Analiza rezultata modela testiranih na validacijskom skupu LLAMAS podatkovnog skupa

Iz LLAMAS validacijskog skupa također su odabrana tri okvira za vizualizaciju IoU. Okviri prikazuju prometne scenarije s brzih cesta. Postoje isprekidane i pune oznake voznih linija na tim okvirima. Rezultati evaluacije modela na validacijskom skupu LLAMAS baze podataka prikazani su tablicom 4.5. Kao glavnu evaluacijsku metriku točnosti modela za detekciju linija vozne trake koristi se F1 mjera, računata prema izrazu (4-3).

Tab. 4.5. *Rezultati evaluacije modela (TP, FP, FN, preciznost, odziv i F1- mjera) na testnom skupu LLAMAS baze podataka*

| Mreža | Trening skup | Testni skup | Broj TP | Broj FP | Broj FN | Preciznost [%] | Odziv [%] | F1 [%] |
|---------------|--------------|-------------|---------|---------|---------|----------------|-----------|--------|
| SCNN-ResNet34 | CULane | LLAMAS | 30108 | 18804 | 43927 | 61.56 | 40.67 | 48.98 |
| SCNN-ResNet34 | LLAMAS | LLAMAS | 71112 | 2701 | 2923 | 96.34 | 96.05 | 96.20 |
| SCNN-ResNet34 | TuSimple | LLAMAS | 34699 | 8340 | 39336 | 80.06 | 46.87 | 59.28 |
| SCNN-VGG16 | CULane | LLAMAS | 33772 | 14610 | 40263 | 69.80 | 45.62 | 55.18 |
| SCNN-VGG16 | LLAMAS | LLAMAS | 71274 | 2526 | 2761 | 96.58 | 96.27 | 96.42 |
| SCNN-VGG16 | TuSimple | LLAMAS | 32825 | 7881 | 41210 | 80.64 | 44.34 | 57.22 |
| SCNN-ERFNet | CULane | LLAMAS | 38011 | 17148 | 36024 | 68.91 | 51.34 | 58.84 |
| SCNN-ERFNet | LLAMAS | LLAMAS | 71037 | 3019 | 2998 | 95.92 | 95.95 | 95.93 |
| SCNN-ERFNet | TuSimple | LLAMAS | 55529 | 12270 | 18506 | 81.90 | 75.00 | 78.30 |


SCNN-ResNet34 model treniran na trening skupu te testiran na testnom skupu LLAMAS podatkovnog skupa djelomično uspješno detektira linije voznih traka za primjere dane na slici 4.24. Za okvir (a) slike 4.24. model djelomično detektira krajnju lijevu liniju vozne trake. Vozila u prometu te smanjena vidljivosti linija u daljini uzrokuju velik broj lažno negativnih primjera za sva tri okvira. Postoje devijacije od nekoliko elemenata slike koja su zanemariva s obzirom na postavljen IoU točne detekcije linija vozne trake.



Sl. 4.24. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ResNet34 model treniran na trening skupu TuSimple podatkovnog skupa te testiran na testnom skupu LLAMAS podatkovnog skupa, za okvir (a) slike 4.25, koja prikazuje vizualizaciju predviđenih linija SCNN-ResNet34 modela, neuspješno detektira krajnju lijevu liniju vozne trake zbog slabije vidljivosti vozne oznake. Model uspješno detektira linije vozne trake u kojoj se vozilo nalazi. Za okvir (b) sa slike 4.25. model uspješno detektira unutarnje linije voznih traka, dok krajnja desna linija, koja je ujedno i najmanje vidljiva, nije uspješno detektirana. Za okvir (c) sa slike 4.25.


model uspješno detektira unutarnje linije vozne trake. Krajnje linije voznih traka nisu detektirane zbog slabe vidljivosti oznaka.



Sl. 4.25. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

SCNN-ResNet34 model treniran na trening skupu CULane podatkovnog skupa te testiran na testnom skupu LLAMAS podatkovnog skupa ima znatno veći broj lažno pozitivnih primjera od SCNN-ResNet34 modela koji je treniran na TuSimple trening skupu. Na slici 4.26. prikazana je vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. Trening skupovi LLAMAS i TuSimple podatkovnih skupova su sličniji po prometnim scenarijima nego LLAMAS i CULane, što uzrokuje bolje rezultate na svim modelima koji su trenirani na TuSimple-u nego na CULane-u, neovisno o arhitekturi mreže. Za okvir (a) slike 4.26. model zamjenjuje oštar kontrast kolnika i zemlje pored ceste za liniju vozne trake. Model neuspješno detektira krajnju lijevu traku za sva tri okvira sa slike 4.26. Za okvir (b) sa slike 4.26. SCNN-ResNet34 model uspješno detektira unutarnje linije vozne trake. Smanjena vidljivost oznaka linija voznih traka u daljini ne predstavlja problem modelu pri detekciji linija. Model

ne detektira krajnju lijevu liniju vozne trake. Za okvir (c) sa slike 4.26. SCNN-ResNet34 model djelomično uspješno detektira unutarnje linije vozne trake. Postoje nezanemariva odstojanja u predikciji točaka koje čine unutarnje linije vozne trake. Vozilo u prometu ometa predviđanje lijeve unutarnje linije vozne trake. Model ne detektira vanjske linije vozne trake.




Sl. 4.26. Vizualizacija predviđenih linija SCNN-ResNet34 modela treniranog na CULane trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

Model koji koristi arhitekturu mreže VGG16 kao osnovu daje najbolje rezultate uspoređujući ga s modelima koji koriste ResNet34 ili ERFNet. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa Na slici 4.27. prikazana je vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa.

Za okvir (a) sa slike 4.27. model djelomično uspješno detektira krajnju lijevu liniju. Vozila u prometu te smanjena vidljivost linija u daljini uzrokuje manji broj FP primjera nego kod SCNN-ResNet34 modela za sva tri okvira. Postoje odstojanja od nekoliko elemenata slike koja su zanemariva


s obzirom na postavljen IoU prag točne detekcije linije vozne trake. Za okvir (b) i (c) sa slike 4.27. model uspješno detektira sve linije vozne trake. Vozila u prometu ne predstavljaju problem pri predviđanju linija voznih traka u daljini.




Sl. 4.27. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

Na slici 4.28. prikazana je vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. Za okvir (a) sa slike 4.28. model neuspješno detektira krajnju lijevu liniju zbog slabije vidljivosti oznake voznih linija. Model djelomično uspješno detektira unutarnje linije u kojoj se vozilo nalazi.

Za okvir (b) sa slike 4.28. uspješno su detektirane unutarnje linije voznih traka, dok krajnja desna linija, koja je ujedno i najmanje vidljiva, nije uspješno detektirana. Za okvir (c) sa slike 4.28. vozilo u prometu uzrokuje FN predviđanja. Krajnje linije vozne trake nisu detektirane zbog slabe vidljivosti oznaka.



(a)



(b)




(c)

Sl. 4.28. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

Na slici 4.29. prikazana je vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. Za okvir (a) sa slike 4.29. model mijenja oštar kontrast kolnika i travnate površine pored ceste za liniju vozne trake.

Model ne detektira ispravno krajnju lijevu liniju vozne trake. Isprekidane linije u daljini uzrokuju lažno negativna predviđanja.



(a)



(b)




(c)

Sl. 4.29. Vizualizacija predviđenih linija SCNN-VGG16 modela treniranog na CULane trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno, bijele isprekidane linije, (b) ruralno područje, bijele isprekidane linije, (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)

Na slici 4.30. prikazana je vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. Model uspješno detektira sve linije vozne trake za okvir (a) sa slike 4.30. Za razliku od SCNN-ResNet34 modela, slaba vidljivost linija voznih traka u daljini za okvire (b) i (c) slike 4.30. ne predstavlja problem pri detekciji.



(a)




(b)



(c)

Sl. 4.30. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno, bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno, isprekidane linije, žuta puna linija (c) brza cesta, isprekidane linije, bijele pune linije, GT-linije (crvena), predviđene linije modela (zelena), IoU predviđenih linija i GT linija (žuta)


Na slici 4.31. prikazana je vizualizacija linija SCNN-ERFNet modela treniranog na LLAMAS trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. SCNN-ERFNet model za okvir (a) sa slike 4.31. neuspješno detektira krajnju lijevu liniju vozne trake zbog slabije vidljivosti vozne oznake. Djelomično uspješno detektira linije vozne trake u kojoj se vozilo nalazi. Za okvir (b) sa slike 4.31. model uspješno detektira unutarnje linije vozne trake, dok krajnja lijeva linija, koja je ujedno i najmanje vidljiva nije uspješno detektirana. Za okvir (c) sa slike 4.31. model nema predikciju za krajnju lijevu liniju vozne trake. Krajnja desna linija, uz unutarnje linije, je uspješno detektirana.



Sl. 4.31. *Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)*

Na slici 4.32. prikazana je vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na TuSimple trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa. SCNN-ERFNet model ima znatno veći broj FP i FN primjera od SCNN-ERFNet modela koji je treniran na trening skupu TuSimple podatkovnog skupa. Za okvir (a) sa slike 4.32. model mijenja oštar kontrast kolnika i travnate površine za liniju vozne trake. Model neuspješno detektira krajnju lijevu liniju vozne trake. Za okvir (b) sa slike 4.32. model uspješno detektira unutarnje linije vozne trake. Postoji predviđanje

modela linije koja ne može predstavljati liniju vozne trake te se smatra FP primjerom linije vozne trake. Model ne detektira krajnju lijevu liniju vozne trake. Za okvir (c) sa slike 4.32. model djelomično uspješno detektira unutarnje linije vozne trake. Okluzija lijeve unutarnje linije vozne trake uzrokuje FP predviđanje linije.



Sl. 4.32. Vizualizacija predviđenih linija SCNN-ERFNet modela treniranog na CULane trening skupu za 3 okvira iz LLAMAS podatkovnog testnog skupa koji prikazuju različite prometne scenarije s različitim vremenskim uvjetima (a) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (b) ruralno područje, oblačno bijele isprekidane linije, žuta puna linija (c) brza cesta, bijele isprekidane linije, bijele pune linije, sunčano GT-linije (crvena), predviđene linije modela (zeleni), IoU predviđenih linija i GT linija (žuta)

4.5. Završni osvrt na rezultate dobivene testiranjem i evaluacijom različitih metoda za detekciju linija vozne trake na različitim skupovima podataka

Modeli koji koriste metode za detekciju linija vozne trake, a trenirani i testirani na TuSimple podatkovnom skupu imaju preciznost detekcije iznad 95.00%. Razlika preciznosti modela između SCNN-ResNet34, SCNN-VGG16 I SCNN-ERFNet je manja od 2.00%. Isti SCNN modeli trenirani na LLAMAS trening skupu znatno su precizniji (oko 25.00% u prosjeku) od SCNN modela treniranih na CULane trening skupu kada se testiraju na LLAMAS podatkovnom skupu.

TuSimple i LLAMAS podatkovni skupovi slični su po prometnim scenarijima, vremenskim uvjetima i obliku linija voznih traka i stoga su modeli trenirani na TuSimple i LLAMAS podatkovnim skupovima prilagodljiviji međusobnoj zamjeni testnih skupova. SCNN modeli trenirani na TuSimple ili LLAMAS trening skupovima ne detektiraju ispravno linije vozne trake na slikama iz CULane testnog skupa. CULane testni skup sadrži niz slika koje prikazuju prometne scenarije, vremenske uvjete ili oznake linija voznih traka koje nisu zastupljene u trening skupu TuSimple ili LLAMAS podatkovnog skupa.

Prilagodljivost modela promjeni podatkovnog skupa očito ovisi o arhitekturi koja je korištena kao osnova modela za detekciju linija vozne trake te sličnosti trening skupa originalnog podatkovnog skupa te novog, promijenjenog testnog skupa. Na testnom skupu CULane podatkovnog skupa, SCNN-VGG16 model treniran na LLAMAS trening skupu bilježi najbolje rezultate, postignuvši preciznost od 28.39%, što je znatno više od SCNN-ResNet34 modela (19.14%) i SCNN-ERFNet modela (9.35%), ali je i dalje ta preciznost izrazito niska. Na testnom skupu LLAMAS podatkovnog skupa, SCNN-ERFNet model treniran na TuSimple trening skupu daje najbolje rezultate, postignuvši F1 mjeru od 78.30%. Ostali modeli testirani na LLAMAS podatkovnom skupu nisu postigli F1 mjeru veću od 59.28%. Na testnom skupu TuSimple podatkovnog skupa veću ulogu igraju tip i vrsta trening skupa.

Analizirajući rezultate triju modela testiranih u sklopu ovog rada, može se zaključiti da su SCNN-ERFNet modeli najrobustiji na promjenu trening skupa. SCNN-ERFNet modeli se puno bolje prilagođavaju te su precizniji od SCNN-ResNet34 i SCNN-VGG16 modela ukoliko su trening skupovi slični prema prometnim scenarijima, vremenskim uvjetima i oznakama linija voznih traka. U sklopu ovog rada, SCNN-VGG16 modeli trenirani i testirani na CULane ili LLAMAS podatkovnim skupovima pokazali su se preciznijim od SCNN-ResNet34 i SCNN-ERFNet modela u predviđanju linija vozne trake. Za vrijeme izrade diplomskog rada, pojavile su se nove *state-of-the-art* metode koje koriste ResNet101 ili DLA-14 (engl. *Deep Layer Aggregation*) arhitekture kao osnove modela. Rezultati predstavljeni u ovom radu mogli bi se poboljšati koristeći ResNet101 ili DLA-14 arhitekturu zajedno sa SCNN metodom.

5. ZAKLJUČAK

U ovom diplomskom radu testirana su i evaluirana tri različita modela za detekciju linija voznih traka na trima različitim podatkovnim skupovima. CULane, TuSimple i LLAMAS podatkovni skupovi su korišteni za izradu diplomskog rada. Modeli koji su testirani zasnovani su na konvolucijskim neuronskim mrežama RESNet34, VGG16 i ERFNet koje su korištene kao okosnice modela. Opisan je SCNN detektor linija voznih traka zasnovan na semantičkoj segmentaciji, koji omogućuje efikasniju propagaciju informacija na prostornoj razini, kojom su tri spomenute mreže modificirane. Evaluirano je i analizirano ukupno 27 različitih kombinacija model-trening skup-testni skup. Kako bi se mogle provesti sve spomenute kombinacije prilikom evaluacije, bilo je potrebno kreirati dva pretvarača formata zapisa linija voznih traka koji omogućavaju evaluaciju pomoću službenih dostupnih skripti unutar *PyTorchAutoDrive* okvira. Pretvarači su pisani u Python programskom jeziku. Testiranja i evaluacija su izvršene na NVIDIA RTX 3080 12GB grafičkoj kartici. Prilikom evaluacije performansi modela korišten je službeni format zapisa kao i izlazne metrike karakteristične za svaki podatkovni skup. Napravljena je analiza pojedinih okvira iz testnih skupova odabranih podatkovnih skupova i vizualizirani su izlazni rezultati te uspoređeni s GT podacima.

Modeli koji su trenirani na jednostavnim i homogenim podatkovnim skupovima poput TuSimple-a i LLAMAS-a imaju znatno manju uspješnost detektiranja voznih traka na testnom skupu kompleksnog podatkovnog skupa poput CULane podatkovnog skupa. Prilagodljivost modela promjeni podatkovnog skupa ovisi o arhitekturi koja korištena kao osnova modela za detekciju linija vozne trake te sličnosti trening skupa prvotno korištenog podatkovnog skupa te novog, promijenjenog testnog skupa. Sličnost u prometnim scenarijima, vremenskim i cestovnim uvjetima kao i oznakama voznih traka, uzrokuje da modeli trenirani na TuSimple podatkovnom skupu postižu bolje rezultate na LLAMAS podatkovnom skupu nego na CULane podatkovnom skupu. SCNN-ERFNet modeli koji su testirani na LLAMAS podatkovnom skupu, a trenirani na ili TuSimple ili CULane precizniji su više od 18.00% od SCNN-ResNet34 modela. Iz rezultata se može zaključiti da modeli koji postižu visoku preciznost (>95.00%), a koji su trenirani i testirani na jednostavnim podatkovnim skupovima poput TuSimple i LLAMAS nisu ni približno efikasni na znatno kompleksnijem podatkovnom skupu poput CULane-a, koji bolje prezentira realne prometne i cestovne scenarije.

LITERATURA

- [1] TuSimple benchmark, "Tusimple-benchmark/doc/lane_detection-TuSimple/tusimple benchmark GitHub." https://github.com/TuSimple/tusimple-benchmark/tree/master/doc/lane_detection
- [2] X. Pan, J. Shi, P. Luo, X. Wang, and X. Tang, "*Spatial As Deep: Spatial CNN for Traffic Scene Understanding.*", Kina, 2017.
- [3] K. Behrendt and R. Soussan, "*Unsupervised Labeled Lane Markers Using Maps,*" objavljeno u *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, Južna Koreja, 2019., str. 832–839.
- [4] "*The KITTI Vision Benchmark Suite.*" http://www.cvlibs.net/datasets/kitti/eval_road.php, pristup ostvaren 30.6 2022.
- [5] F. Yu, "*BDD100K: A Diverse Driving Dataset for Heterogeneous Multitask Learning.*" , Sjedinjene Američke Države, 2020., pristup ostvaren 26.6.2022.
- [6] Vonsj0210, "*Jiqing Expressway Dataset.*" <https://github.com/vonsj0210/Multi-Lane-Detection-Dataset-with-Ground-Truth> Kina, 2022., pristup ostvaren 26.6.2022.
- [7] C. Y. Low, H. Zamzuri, and S. A. Mazlan, "*Simple robust road lane detection algorithm,*" objavljeno u *2014 5th International Conference on Intelligent and Advanced Systems (ICIAS)*, Malezija, 2014, str. 1–4.
- [8] M. Aly, "*Real time Detection of Lane Markers in Urban Streets,*" objavljeno u *2008 IEEE Intelligent Vehicles Symposium*, Sjedinjene Američke Države, 2008, str. 7–12.
- [9] D. Neven, B. De Brabandere, S. Georgoulis, M. Proesmans, and L. Van Gool, "*Towards End-to-End Lane Detection: an Instance Segmentation Approach.*" Belgija, 2018.
- [10] T. Zheng *et al.*, "*RESA: Recurrent Feature-Shift Aggregator for Lane Detection.*" , Kina, 2021.
- [11] D. Vajak, M. Vranješ, R. Grbić, and D. Vranješ, "*Recent Advances in Vision-Based Lane Detection Solutions for Automotive Applications,*" objavljeno u *2019 International Symposium ELMAR*) 2019, str. 45–50.
- [12] M. ul Hassan, "*VGG16 - Convolutional Network for Classification and Detection,*" <https://neurohive.io/en/popular-networks/vgg16/> , pristup ostvaren (15.6.2022)

- [13] P. Ruiz, “*Understanding and visualizing ResNets*,” *Medium*. <https://towardsdatascience.com/understanding-and-visualizing-resnets-442284831be8>, (pristup ostvaren 15.6.2022)
- [14] E. Romera, J. M. Álvarez, L. M. Bergasa, and R. Arroyo, “*ERFNet: Efficient Residual Factorized ConvNet for Real-Time Semantic Segmentation*,” *IEEE Trans. Intell. Transp. Syst.*, vol. 19, br. 1, str. 263–272, 2018.
- [15] Conda, virtualno okruženje <https://docs.conda.io/projects/conda/en/latest/user-guide/tasks/manage-environments.html> pristup ostvaren 5.11.2022)
- [16] A. Paszke, “PyTorch: An Imperative Style, High-Performance Deep Learning Library.” 2019. (pristup ostvaren 20.5.2022)
- [17] Pytorch, <https://www.datacamp.com/tutorial/investigating-tensors-pytorch> (pristup ostvaren 20.5.2022)
- [18] PytorchAutoDrive, GitHub repozitorij ” <https://github.com/voldemortX/pytorch-auto-drive> (pristup ostvaren 21.11.2021)
- [19] F1-mjera <https://deeptai.org/machine-learning-glossary-and-terms/f-score> (pristup ostvaren 15.1.2022)

SAŽETAK

U radu su opisane najpoznatije baze podataka koje sadrže zapis o stvarnim linijama vozne trake u okvirima video signala snimljenim u vožnji. Dan je pregled i postojećih metoda za detekciju linija vozne trake zasnovanih na dubokom učenju. Potom je napravljena analiza performansi triju metoda za detekciju linija vozne trake zasnovanih na dubokom učenju na trima različitim skupovima podataka. Opisan je način implementacije, testiranja i evaluacije istreniranih modela na različitim skupovima podataka te je dan kritički osvrt na dobivene rezultate. SCNN-VGG16 model se pokazao najboljim kada se trenira i testira na istom skupu podataka. Preciznost je slična kod SCNN-ResNet34 i SCNN-ERFNet modela, no manji broj FP primjera kod SCNN-VGG16 modela uzrokuje točnije predviđanje linija vozne trake. Ukoliko se promjeni testni skup prilikom testiranja modela, rezultati su drugačiji za svaki podatkovni skup. Za CULane podatkovni skup SCNN-VGG-16 model se pokazao kao najprecizniji. Za TuSimple i LLAMAS testni skup, SCNN-ERFNet se pokazao kao najprilagodljiviji promjeni testnog skupa.

Ključne riječi: linije vozne trake, duboko učenje, baze podataka, SCNN, IoU, ResNet34, VGG16, ERFNet

ANALYSIS AND VALIDATION OF MACHINE LEARNING-BASED LANE LINES DETECTION METHODS USING DIFFERENT DATASETS

ABSTRACT

This master thesis describes the most famous databases that contain a record of the actual lines of the traffic lane in the frames of video signals recorded while driving. An overview of the existing methods for the detection of lane lines based on deep learning is given. Then, the performance analysis of the three lane line detection methods based on deep learning was made on three different datasets. The method of implementation, testing and evaluation of trained models on different datasets is described, and a critical review of the obtained results is given. The SCNN-VGG16 model performed best when trained and tested on the same dataset. The accuracy is similar to that of the SCNN-ResNet34 and the SCNN-ERFNet models, but the smaller number of FP examples produced by the SCNN-VGG16 model causes a more accurate prediction of traffic lane lines. If the test set is changed during model testing, the results are different for each dataset. For the CULane dataset, the SCNN-VGG-16 model proved to be the most accurate. For TuSimple and LLAMAS test sets, the SCNN-ERFNet proved to be the most adaptive to test set change.

Keywords: lane lines, deep learning, datasets, SCNN, IoU, ResNet34, VGG16, ERFNet

ŽIVOTOPIS

Grgur Jukić rođen je 21. studenog 1995. godine u Osijeku. Završetkom III. Gimnazije 2014. godine, upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija u Osijeku, smjer računarstvo. 2020. godine uspješno završava preddiplomski studij računarstva te upisuje diplomski sveučilišni studij automobilsko računarstvo i komunikacije.

Potpis:

PRILOZI

- P.4.1. direktorij koji sadrži konfiguracijske datoteke potrebne za testiranje modela (priloženo na DVD-u uz rad)
- P.4.2. *CULane_convertor.py* datoteka (priložena na DVD-u uz rad)
- P.4.3. *TuSimple_convertor.py* datoteka (priloženo na DVD-u uz rad)
- P.4.3. *pytorch_auto_drive* direktorij koji sadrži skripte potrebne za rad okvira (priloženo na DVD-u uz rad)
- P.4.5. direktorij koji sadrži sve istrenirane modele (priloženo na DVD-u uz rad)
- P.4.6. direktorij koji sadrži rezultate vizualizacije slika (priloženo na DVD-u uz rad)