

# Prepoznavanje prometnih znakova primjenom računalnog vida

---

**Pavlinić, Filip Antonio**

**Master's thesis / Diplomski rad**

**2021**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/urn:nbn:hr:119:235925>

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

*Download date / Datum preuzimanja:* **2024-12-29**



*Repository / Repozitorij:*

[Faculty of Transport and Traffic Sciences - Institutional Repository](#)



Sveučilište u Zagrebu  
Fakultet prometnih znanosti

**DIPLOMSKI RAD**

**PREPOZNAVANJE PROMETNIH ZNAKOVA  
PRIMJENOM RAČUNALNOG VIDA**

**TRAFFIC SIGNS RECOGNITION USING COMPUTER  
VISION**

Mentor: izv. prof. dr. sc. Edouard Ivanjko      Student: Filip Antonio Pavlinić

JMBAG: 0135243054

Zagreb, rujan 2021.

Zagreb, 10. svibnja 2021.

Zavod: **Zavod za inteligentne transportne sustave**  
Predmet: **Umjetna inteligencija**

## DIPLOMSKI ZADATAK br. 6457

Pristupnik: **Filip Antonio Pavlinić (0135243054)**  
Studij: **Inteligentni transportni sustavi i logistika**  
Smjer: **Inteligentni transportni sustavi**

Zadatak: **Prepoznavanje prometnih znakova primjenom računalnog vida**

### Opis zadatka:

U svrhu pomoći vozaču u upravljanju vozilom te ostvarivanju sigurnije, jednostavnije i ugodnije vožnje primjenjuju se napredni sustavi za pomoć vozaču ili skraćeno ADAS (eng. Advanced Driver Assistance Systems). ADAS sustavi koriste osjetilne tehnologije kako bi nadzirali kretanje vozila, unutrašnjost vozila i prometne situacije oko vozila. Jedno od najvažnijih osjetila takvih sustava je kamera, a njihovom primjenom omogućeno je prikupljanje više različitih prometnih podataka. Za obradu slika dobivenih s kamera primjenjuju se razne metode iz područja računalnog vida. U ovome radu potrebno je primijeniti neuronske mreže za prepoznavanje prometnih znakova. U sklopu toga potrebno je opisati napredne sustave za pomoć vozaču, objasniti problem prepoznavanja prometnih znakova, implementirati sustav računalnog vida za prepoznavanje prometnih znakova zasnovan na neuronskim mrežama te isti testirati primjenom stvarnih snimaka s kamere iz vozila.

Mentor:

Predsjednik povjerenstva za  
diplomski ispit:

---

izv. prof. dr. sc. Edouard Ivanjko

# ZAHVALE

Zahvaljujem se mentoru izv. prof. dr. sc. Edouardu Ivanjku na danim savjetima i smjernicama tijekom pisanja ovog diplomskog rada. Zahvaljujem se kolegama sa Zavoda za prometno planiranje na pruženim materijalima bez kojih ovaj rad ne bi bio ostvariv. Zahvaljujem se svojoj obitelji, djevojci i svima onima koji su bili uz mene.

# SAŽETAK

**Naslov:** Prepoznavanje prometnih znakova primjenom računalnog vida

Napredni sustavi za pomoć vozaču neizostavan su dio suvremenih vozila. Sustav za prepoznavanje prometnih znakova omogućuje razvoj autonomnih vozila i smanjenje broja prometnih nesreća uzrokovanih nepoštivanjem prometnih pravila. Prometni znakovi razlikuju se prema boji i obliku znaka te simbolima na samome znaku. Za prepoznavanje prometnih znakova koriste se metode iz područja umjetne inteligencije, odnosno računalnog vida. Za pripremu podataka za učenje modela koriste se metode predobrade podatak i metode za proširenje skupa podataka. Sustav za prepoznavanje sastoji se od modela za otkrivanje i modela za klasifikaciju prometnih znakova. YOLO algoritam korišten je za otkrivanje prometnih znakova i predviđanje njihove lokacije. Za klasifikaciju prometnih znakova u 43 kategorije korištene su konvolucijske neuronske mreže. Prepoznavanje prometnih znakova vrši se na stvarnim video snimkama, a sustav prepoznavanja evaluiran je pri različitim brzinama vozila, različitim intenzitetima svjetlosti, na različitim prometnim znakovima u različitim uvjetima očuvanosti i pri različitim položajima promatranja. Evaluacija je pokazala visoku točnost u radu sustava, no i ukazala na probleme rada u vanjskoj okolini i mogućnosti unaprjeđenja.

**Ključne riječi:** napredni sustavi za pomoć vozaču; računalni vid; prometni znakovi; konvolucijske neuronske mreže; YOLO algoritam

# ABSTRACT

**Title:** Traffic Sign Recognition Using Computer Vision

Advanced driver assistance systems are an indispensable part of modern vehicles. The traffic sign recognition system enables the development of autonomous vehicles and the reduction of the number of traffic accidents caused by non-compliance with traffic rules. Traffic signs differ according to the color and shape of the sign and the symbols on the sign itself. Methods in the field of artificial intelligence, i.e., computer vision, are used to recognize traffic signs. Preprocessing and augmentation methods are used to prepare data for learning the model. The recognition system consists of two models, one for detecting and one for classifying traffic signs. The YOLO algorithm was used to detect traffic signs and predict their location. Convolutional neural networks were used to classify traffic signs into 43 categories from cut out bounding boxes. Traffic sign recognition is performed on real videos, and the recognition system was evaluated at different vehicle speeds, different light intensities, on different traffic signs in different preservation conditions and from different observation positions. The evaluation showed high accuracy in the operation of the system, but also pointed out problems working in outdoor environments and opportunities for improvement.

**Key words:** Advanced Driver Assistance Systems; Computer Vision; Traffic Signs; Convolutional Neural Networks; YOLO algorithm

# SADRŽAJ

1. UVOD .....	1
2. NAPREDNI SUSTAVI ZA POMOĆ VOZAČU.....	3
2.1. Podjela ADAS sustava .....	3
2.1.1. Pasivna sigurnost.....	4
2.1.2. Aktivna sigurnost.....	4
2.2. Mjerna osjetila u ADAS sustavima .....	7
2.3. Sustav prepoznavanja prometnih znakova .....	12
3. PROBLEM PREPOZNAVANJA PROMETNIH ZNAKOVA RAČUNALNIM VIDOM.....	15
3.1. Podjela prometnih znakova .....	15
3.2. Problemi kod prepoznavanja prometnih znakova .....	20
3.3. Predobrada slika .....	21
3.3.1. Metode predobrade slike.....	21
3.3.2. Metode za povećanje skupa podataka .....	23
4. PRIMJENA NEURONSKIH MREŽA U PREPOZNAVANJU PROMETNIH ZNAKOVA .....	25
4.1. Konvolucijske neuronske mreže.....	27
4.1.1. Ulazni sloj.....	29
4.1.2. Konvolucijski sloj.....	29
4.1.3. Aktivacijski sloj .....	32
4.1.4. Sloj sažimanja.....	33
4.1.5. Potpuno povezani sloj .....	34
4.2. Učenje neuronskih mreža.....	35
4.3. Mjere uspješnosti obrade podataka u neuronskim mrežama .....	37

5. IZVEDBA SUSTAVA ZA PREPOZNAVANJE PROMETNIH ZNAKOVA.....	40
5.1. Opis alata korištenih za razvoj rješenja .....	40
5.1.1. Google Colaboratory .....	40
5.1.2. NumPy .....	41
5.1.3. OpenCV .....	41
5.1.4. TensorFlow .....	41
5.1.5. Keras .....	41
5.1.6. Darknet .....	42
5.1.7. CUDA.....	42
5.1.8. YOLO algoritam .....	42
5.2. Model za detekciju prometnih znakova.....	44
5.2.1. Opis korištenog skupa podataka .....	44
5.3. Model za klasifikaciju prometnih znakova.....	49
5.4. Sustav za prepoznavanje prometnih znakova .....	56
6. EVALUACIJA SUSTAVA ZA PREPOZNAVANJE PROMETNIH ZNAKOVA .....	57
6.1. Rezultati prepoznavanja prometnih znakova .....	57
6.2. Moguća unaprjeđenja sustav za prepoznavanje prometnih znakova.....	67
7. ZAKLJUČAK .....	69
LITERATURA.....	71
POPIS KRATICA .....	75
POPIS SLIKA.....	76
POPIS TABLICA.....	78



# 1. UVOD

Porastom broja sudionika u prometu dolazi do povećanja važnosti davanja odgovora na pitanja sigurnosti. Odgovor na neka od pitanja sigurnosti mogu dati napredni sustavi za pomoć vozaču i autonomna vozila. Kako bi ovi sustavi raspoznali prometnu situaciju i razumjeli svoju okolinu, služe se kamerama i drugim vidnim osjetilima i raznim metodama iz područja umjetne inteligencije, točnije računalnog vida.

Računalni vid omogućuje vozilu da prepozna prometne znakove. Prepoznavanje se može vršiti na više načina, a u ovome radu ispitan je način podjele sustava na dva dvije komponente. Ove dvije komponente su model za otkrivanje prometnih znakova i model za njihovu klasifikaciju. Svrha ovog rada je istražiti mogućnosti konvolucijskih neuronskih mreža u prepoznavanju prometnih znakova. Cilj ovog rada je izraditi sustav koji će s visokom točnošću prepoznavati prometne znakove na stvarnim snimkama s kamere iz vozila. Naslov diplomskog rada jest: Prepoznavanje prometnih znakova primjenom računalnog vida. Rad je podijeljen u sedam cjelina:

1. Uvod;
2. Napredni sustavi za pomoć vozaču;
3. Problem prepoznavanja prometnih znakova računalnim vidom;
4. Primjena neuronskih mreža u prepoznavanju prometnih znakova;
5. Izvedba sustava za prepoznavanje prometnih znakova;
6. Evaluacija sustava za prepoznavanje prometnih znakova;
7. Zaključak.

Nakon uvodnog poglavlja je u drugome poglavlju prikazana podjela naprednih sustava za pomoć vozaču i navedeni su i opisani neki od najvažnijih primjera ovih sustava. Također su opisana i mjerna osjetila ključna za rad ovih sustava.

Problemi prepoznavanja prometnih znakova računalnim vidom bave se problematikom razlikovanja velikog broja kategorija prometnih znakova i njihovih ključnih značajki što je opisano u trećem poglavlju. Kako bi se prometni znakovi mogli razlikovati pojašnjena je i prikazana podjela prometnih znakova. Prikazane su i najčešće korištene metode za predobradu i proširenje skupa slikovnih podataka te zašto se koje spomenute metode koriste u pripremi slika za učenje.

Nakon upoznavanja s podacima, četvrto poglavlje pojašnjava što su to neuronske mreže, što su i za što se koriste konvolucijske neuronske mreže, kako uče i obrađuju slikovne podatke i kojim se metodama ispituju rezultati njihova učenja.

Peto poglavlje predstavlja izvedbu sustava za prepoznavanje prometnih znakova. U ovome poglavlju prikazan je skup podataka korišten za učenje modela za otkrivanje prometnih znakova i objašnjen rad YOLO algoritma pri predviđanju lokacije prometnih znakova. Prikazan je i skup podataka za klasifikaciju i model konvolucijske neuronske mreže korišten za predviđanje kategorije otkrivenih prometnih znakova. Uz to je prikazano i kako ovaj sustav radi kao cjelina, točnije kako se odvija proces prepoznavanja prometnih znakova.

Evaluacija sustava za prepoznavanje prometnih znakova prikazana je u šestom poglavlju. Evaluacijom su analizirani i prikazani problemi do kojih dolazi pri radu sustava i prikazani su rezultati prepoznavanja nekoliko prometnih znakova na stvarnim video snimkama. Na temelju evaluacije rezultata dani su prijedlozi unaprjeđenja.

Diplomski rad završava zaključkom koji uključuje smjernice za nastavak rada na ovoj temi.

## **2. NAPREDNI SUSTAVI ZA POMOĆ VOZAČU**

Napredni sustavi za pomoć vozaču (engl. Advanced Driver Assistance Systems – ADAS) označavaju sustave koji pružaju podršku vozaču pri upravljanju vozilom. Ovi sustavi razvijeni su kako bi unaprijedili i poboljšali vožnju te povećali sigurnost svih sudionika u prometu. Sačinjava ih skup elektroničkih sustava koji pomažu vozaču u vožnji i tijekom parkiranja. Svoj glavni cilj, povećanje sigurnosti na cestama, ostvaruju smanjujući mogućnost ljudske pogreške. Neki od ovih sustava to izvršavaju upozoravajući vozača na kritične situacije u prometu, dok od vozača očekuju primjerenu reakciju, a neki od njih mogu preuzeti upravljanje nad vozilom i reagirati umjesto samoga vozača kako bi se izbjegla neželjena situacija. Uz povećanje sigurnosti povećavaju i udobnost vožnje, pojednostavljujući je automatizacijom velikog broja procesa koje je vozač morao do sada sam obavljati, čime je smanjeno kognitivno opterećenje vozača.

### **2.1. Podjela ADAS sustava**

Glavna podjela ADAS sustava je na sustave pasivne i sustave aktivne sigurnosti. Pasivna sigurnost obuhvaća sve mjere za smanjenje ozbiljnosti i posljedica nesreće. Aktivna sigurnost obuhvaća tehnička rješenja za, ako je to moguće, potpuno izbjegavanje nesreće. Prema [1] pasivni sustavi sigurnosti su: sigurnosni pojas, zračni jastuk i karoserija vozila. Prema istom izvoru [1], aktivni sustavi sigurnosti su: sustav protiv blokiranja kotača, kontrole proklizavanja, elektronički program stabilnosti, sustav automatskog kočenja, zadržavanja vozila u prometnom traku, automatsku prilagodbu brzine kretanja, sustav inteligentne prilagodbe brzine, nadzora mrtvog kuta, upozoravanje vozača o nailazećim vozilima, prilagođavanje svjetlosnog snopa, noćni vid, prepoznavanje pješaka, prepoznavanje prometnih znakova, upozoravanje vozača u slučaju pospanosti, nadzor vozača, automatski poziv u nuždi i pomoć prilikom parkiranja.

### **2.1.1. Pasivna sigurnost**

Sigurnosni pojas ima ulogu sprječavanja naglog ubrzanja i pomicanja gornjeg dijela tijela putnika čime ga štiti od ozljeđivanja udaranjem u unutrašnje dijelove vozila i sprječava putnika od mogućeg ispadanja iz vozila. Napredni sustavi sigurnosnih pojaseva u suvremenim vozilima u slučaju detekcije sudara unaprijed pritežu sigurnosne pojaseve, uspravljaju sjedalo, otključavaju vozilo itd., kako bi postavili putnika u položaj u kojem je najbolje zaštićen od posljedica nesreće.

Zračni jastuk ugrađen je u vozilo kao dopuna sigurnosnim pojasevima u slučaju nesreće. Automatski se aktivira prilikom nagle promjene brzine i ubrzanja prilikom udara vozila u prepreku. Fleksibilna struktura zračnog jastuka ograničava utjecaj usporenja na putnike unutar vozila i sprječava tijelo putnika od udaranja u čvrste dijelove unutrašnjosti vozila.

Karoserija vozila preuzima kinetičku energiju sudara, preko za to predviđenih deformacijskih zona. Kada se u potpunosti iscrpi mogućnost deformacije karoserije vozila, kinetička energija sudara prenosi se na putnički prostor.

### **2.1.2. Aktivna sigurnost**

Sustav protiv blokiranja kotača (engl. Anti-lock Breaking System – ABS) regulira kočni tlak pojedinih kotača u ovisnosti o njihovoj brzini vrtnje i time sprječavaju blokiranje kotača. Njegov glavni zadatak je osigurati upravljivost vozilom prilikom intenzivnog kočenja, jer su samo kotrljajući kotači upravljivi i prenose bočne sile vođenja.

Sustav kontrole proklizavanja (engl. Traction Control System – TCS) sprječava proklizavanje pogonskih kotača prilikom kretanja vozila i njegovog ubrzavanja. Zadatak ovog sustava je osigurati trajni prijenos pogonskog momenta s kotača na podlogu. Moment koji se prenosi na podlogu ovisi o svojstvima pneumatika i svojstvima same podloge. Ako se prekorače ograničenja koja ova dva uvjeta postavljaju, dolazi do proklizavanja kotača. Ovaj sustav najčešće se primjenjuje kod vozila sa stražnjim pogonom i onih s većim okretnim momentom. Na ovaj način omogućeno je pokretanje vozila i upravljano ubrzavanje pri svakoj brzini, kako ne bi došlo do proklizavanja pogonskih kotača, a posebice u slučaju nepovoljnih vremenskih uvjeta.

Elektronički program stabilnosti (engl. Electronic Stability Program – ESP) ostvaruje uzdužnu i poprečnu stabilizaciju vozila kočenjem pojedinih kotača i intervencijom na upravljački sustav. Na ovaj način sprječava se zanošenje vozila oko vertikalne osi. Zadata ESP-a je nakon gubitka stabilnosti pokušati zadržati vozilo na željenoj putanji.

Sustav automatskog kočenja (engl. Autonomous Emergency Breaking – AEB) ima zadaću smanjiti brzinu nalijetanja na prepreku te time smanjiti broj nesreća, a aktivira se ako vozač ne reagira samostalno.

Sustav zadržavanja vozila u prometnom traku (engl. Lane Keeping Assist - LKA) ima ulogu u sprječavanju slijetanja vozila s ceste ili nenamjerne promjene prometnog traka. Sustav radi na dvije razine: upozoravanje vozača bez poduzimanja dodatnih akcija i aktivan rad u kojem sustav samostalno ispravlja smjer vozila i vraća ga u prometni trak.

Sustav za automatsku prilagodbu brzine kretanja (engl. Adaptive Cruise Control – ACC) ili tempomat, održava odabranu brzinu i udaljenost do vozila ispred. Brzinu održava tako da automatski koči i ubrzava ovisno o udaljenosti vozila ispred. Neki od ovih sustava imaju mogućnost potpunog zaustavljanja i povratka na postavljenu brzinu.

Sustav inteligentne prilagodbe brzine (engl. Intelligent Speed Adaptation – ISA) informira, upozorava i obeshrabruje vozača da prekorači lokalno ograničenje brzine. Podatke o ograničenju brzine dobiva putem globalnog položajnog sustava (engl. Global Positioning System - GPS) i digitalnih karti ograničenja brzine te prepoznavanjem prometnih znakova na cesti.

Sustav nadzora mrtvog kuta (engl. Blind Spot Assist – BSA) upozorava vozača prilikom promjene vozne trake o vozilima koja se nalaze u mrtvom kutu ili će se uskoro pojaviti u tom području.

Sustav za upozoravanje vozača na nailazeća vozila (engl. Cross-Traffic Alerts - CTA) upozorava vozača da mu vozilo prilazi s njegove lijeve ili desne strane. Ovaj sustav može se postavljati na prednji i stražnji dio vozila, no najčešće se postavlja na stražnji dio vozila (engl. Rear Collision Warning – RCW). Na ovaj način povećava se sigurnost kod izlaska vozila s parkirnog mjesta i vožnje unatrag.

Sustav za prilagođavanje svjetlosnog snopa (engl. Adaptive Headlights – AH) inteligentno uključuje i isključuje pojedinačna LED svjetla na svakom faru kako bi precizno upravljao raspodjelom svjetla. Tako može upravljati visinom i širinom snopa te odabrati ne osvjetljivati određene objekte, kako ih ne bi ometala i zasljepljivala jačina svjetla. Također je moguće i podešavanje visine svjetlosnog snopa, pa ovisno o tome da li se vozilo nalazi na uzbrdici ili nizbrdici podiže ili spušta svjetlosni snop kako bi se osigurala optimalna vidljivost.

Noćni vid (engl. Night Vision - NV) omogućuje vozaču da vidi objekte i situacije koje vlastitim okom teško može uočiti za vrijeme noćne vožnje. Dvije su kategorije noćnog vida, aktivan noćni vid emitira infra crvene zrake i pasivni koji se oslanja na toplinsku energiju automobila, životinja i drugih objekata u okolini vozila.

Sustav za prepoznavanje pješaka (engl. Pedestrian Detection – PD) prepoznaje pješake u okolini vozila, kako bi spriječio nastanak nesreće ili smanjio posljedice prometne nesreće u kojoj sudjeluju pješaci. Svoj zadatak izvršava upozoravajući vozača na potencijalne kritične situacije, a ako je to potrebno i sam poduzima radnje koje su potrebne kako bi izbjegao nastanak nesreće.

Sustav prepoznavanja prometnih znakova (engl. Traffic Sign Recognition System - TSR) omogućuje vozilu da prepozna prometne znakove te tako obavještava vozača i upozorava ga na ograničenja i upozorenja na prometnicama, a kod naprednijih slučajeva i upravlja određenim procesima vožnje.

Sustav za upozoravanje vozača u slučaju pospanosti (engl. Driver Drowsiness Detection – DDD) prati aktivnost vozača i upozorava ga zvučnim signalom i grafičkim simbolima na upravljačkoj ploči vozila da napravi stanku za odmor. Kod nekih sustava se vozilo nakon nekog vremena zaustavlja i nije ga moguće pokrenuti dok vozač nije opet sposoban za daljnju vožnju. Takav koncept se posebno koristi kod detekcije alkoholiziranog stanja vozača.

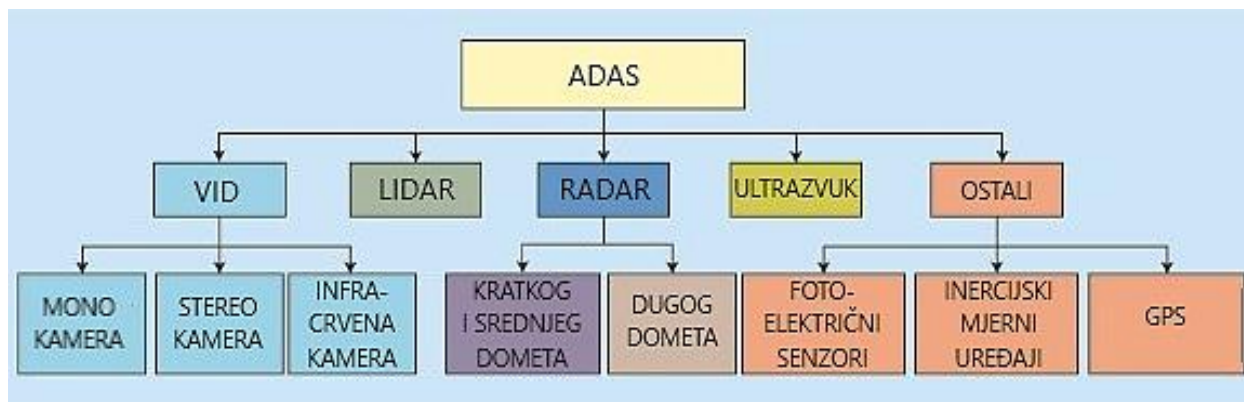
Sustav za nadzor vozača (engl. Driver Monitoring System – DMS) nadzire vozača pomoću kamere smještene unutar vozila te prati na što on obraća pozornost prepoznajući da li su njegove oči usmjerene na cestu ili vozač gleda negdje drugdje. Ovaj sustav upozorava vozača da pozornost usmjeri na cestu putem zvučnih signala, vibracije volana ili treperećih svjetala, a u slučaju da je to potrebno može u potpunosti zaustaviti vozilo.

Automatski poziv u nuždi (engl. e-call system) uspostavlja poziv s hitnom službom ako je vozilo uključeno u tešku prometnu nesreću ili pritiskom na za to namijenjen gumb u vozilu. Uz to što omogućuje brzu komunikaciju sa službom za hitne situacije, također prosljeđuje i podatke o točnoj lokaciji, vremenu nesreće te smjeru vožnje i identifikacijski broj vozila [2].

Sustav za pomoć prilikom parkiranja (engl. Park Assist – PA) informira vozača o slijepim točkama kako bi vozač znao kada treba okretati volan i zaustaviti se. Uz pomoć kamera na stražnjem dijelu vozila omogućuju i bolji pregled okruženja. Napredni oblici ovog sustava mogu u potpunosti samostalno parkirati vozilo koristeći se pritom dostupnim mjernim osjetilima.

## **2.2. Mjerna osjetila u ADAS sustavima**

Razvoj osjetilnih tehnologija ključan je za razvoj ADAS sustava. S povećanjem točnosti i pojeftinjenjem ovih tehnologija pronalazi im se sve veća primjena u automobilskoj industriji. Mjerna osjetila omogućuju vozilu da prikuplja podatke iz okoline. Prema [3] mjerna osjetila se dijele na: monokularne i stereo kamere, infracrvene kamere, lidare, radare kratkog, srednjeg i dalekog dometa, ultrazvučna mjerna osjetila i ostala mjerna osjetila. Podjela mjernih osjetila koja se primjenjuju u ADAS sustavima prikazana je na slici 1.



Slika 1: Podjela mjernih osjetila unutar ADAS sustava

Izvor: [3]

Kamere spadaju u najčešće korištena vidna osjetila u vozilima. ADAS sustavi zasnovani na vidnim osjetilima koriste jednu ili više kamera za prikupljanje slika. Video snimku ili sliku okoline vozila ugrađeni računalni sustav obrađuje i analizira te na njima detektira i prati objekte. U naprednim ADAS sustavima kamere se koriste za nadzor i unutrašnjosti i okoline vozila. Kamere se u suvremenim vozilima sve više primjenjuju zbog njihove niske cijene i jednostavnosti ugradnje. One prikupljaju iz okoline podatke o boji, kontrastu i teksturi, a količina informacija koje mogu prikupiti puno je veća od drugih mjernih osjetila, što im daje jedinstvenu prednost nad drugim mjernim osjetilima. Dva tipa kamera koje se primjenjuju u ADAS sustavima su monokularne i stereo kamere.

Sustavi zasnovani na monokularnim kamerama imaju samo jednu leću, odnosno kameru, pa na svome izlazu daju od jednom i samo jednu sliku. Iz tog razloga sustavi zasnovani na primjeni ove kamere nisu zahtjevniji za obradu slike, za razliku od onih zasnovanih na više kamera. Monokularne kamere imaju široku primjenu, a mogu se koristiti za detekciju prepreka, pješaka, prometnih traka i prometnih znakova. Također se mogu koristiti i za nadzor vozača unutar vozila, za detekciju lica i očiju te analizu pozicije glave vozača. Nedostatak ovih kamera je što ne pružaju informacije o dubini i zbog toga nisu pouzdane za procjenu udaljenosti. Procjena udaljenosti može se ostvariti na osnovi ključnih značajki prikupljene slike i praćenjem pozicije tih značajki dok je kamera u pokretu, no u prometu gdje je točnost informacije o udaljenosti vrlo bitna ne pronalaze takvu primjenu.



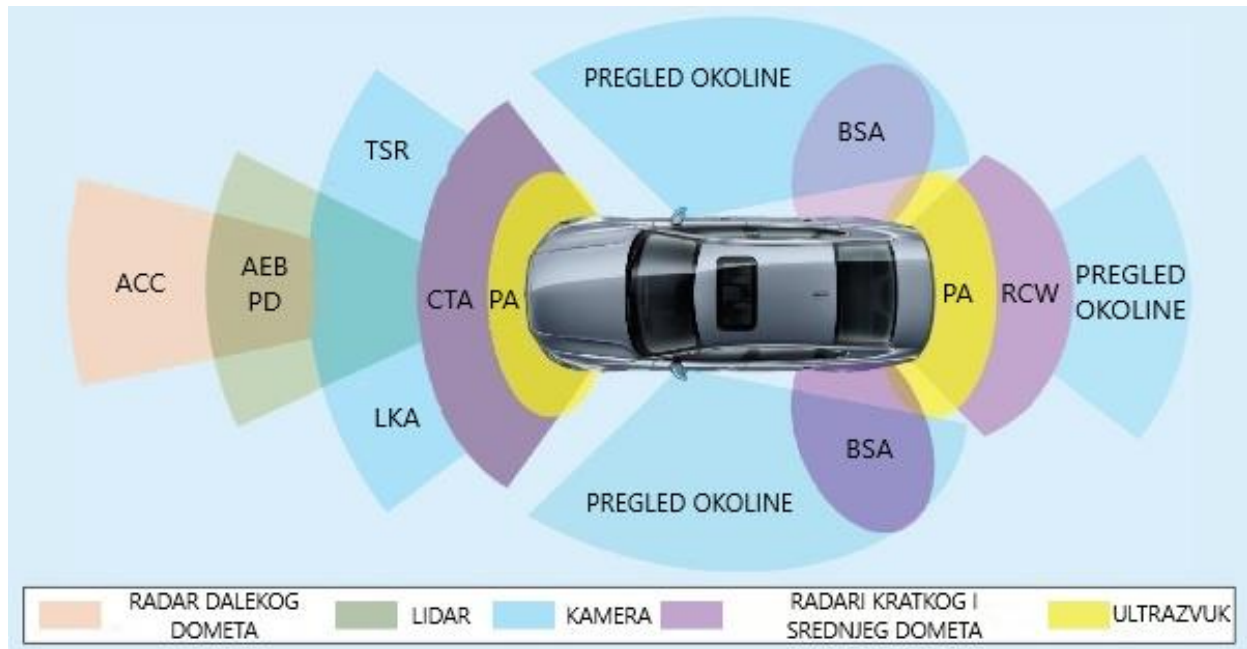
Sustavi zasnovani na stereo kamerama sastoje se od dvije leće, od kojih svaka ima vlastito vidno osjetilo, a oni su odvojeni određenom udaljenošću. Stereo kamere korisne su za prikupljanje trodimenzionalnih podataka iz dvodimenzionalnih ili višedimenzionalnih slika, odnosno procjenu relativne dubine. To im omogućuje spajanje stereo para, odnosno slika iz lijevog i desnog mjernog osjetila, uz primjenu mapa dispariteta (engl. disparity map). Ove kamere se koriste za prepoznavanje prometnih znakova, prometnih traka, pješaka i detekciju prepreka, te procjenu dubine s puno većom točnošću od monokularnih kamera. Međutim stereo sustavi na udaljenostima većim od 30 metara nisu pogodni za procjenu udaljenosti, pa se uglavnom koriste na manjim udaljenostima.

Infracrvene kamere dijele se na dvije vrste. Prvu vrstu predstavljaju aktivne kamere koje koriste izvor svjetla, ugrađen u vozilo, čija je valna duljina blizu spektra infracrvene svjetlosti (od 750 do 1.400 nm). Na ovaj način osvjetljava se okolina bez da su zrake svjetlosti vidljive ljudskom oku. Uz ugrađeni izvor svjetlosti koristi se i digitalna kamera čija je svrha prikupljanje iz okoline reflektiranih zraka svjetlosti. Pasivne infracrvene kamere, koje predstavljaju drugi tip infracrvenih kamera, koriste infracrvena mjerna osjetila. Na njima se svaki piksel može smatrati zasebnim osjetilom topline koje može prikupiti toplinsko zračenje bilo kojeg materijala iz okoline. Za razliku od aktivnih infracrvenih kamera, pasivne ne zahtijevaju posebno osvjetljenje okoline. Međutim ADAS sustavi noćnog vida većinom koriste aktivne infracrvene kamere za prikaz videozapisa na vozačevu zaslonu u uvjetima lošeg osvjetljenja.

Lidar sustavi rade tako da emitiraju laserske zrake u smjeru objekata u svojoj okolini, mjere vrijeme potrebno da se zrake svjetlosti vrte nazad u mjerno osjetilo i izračunavaju na temelju tih podataka udaljenost do objekata u okolini. Ovi sustavi mogu prikupiti informacije potrebne za dobivanje 3D slika u visokoj rezoluciji i rade na udaljenostima puno većim od onih na kojima to mogu sustavi temeljeni na kamerama. Neka lidar osjetila podržavaju pogled na okolinu u 360 stupnjeva uz izrazito precizne informacije o dubini, što omogućuju laseri koji konstantno emitiraju zrake u svim smjerovima. Zbog svojih značajki lidar je postao izrazito popularan u autonomnim vozilima. Najviše se koristi u sustavima automatskog kočenja, detekcije objekata i izbjegavanja objekata, a radi na udaljenostima do 60 metara. Nedostatci lidara su njihova masa, robusnost i visoka cijena te što ne mogu detektirati providne objekte. Također atmosferski uvjeti igraju ulogu u radu ovih sustava, pa kiša, magla ili druge vremenske nepogode mogu utjecati na točnost sustava.

Sustavi zasnovani na radarskim osjetilnim tehnologijama emitiraju mikrovalove i proračunavaju udaljenost i brzinu objekata na temelju izmjerene promjene u frekvenciji reflektiranih valova (tzv. Dopplerov efekt). Zbog veće valne duljine mikrovalova, oni mogu putovati mnogo dalje od svjetlosnih valova, kao što su oni na lidar, pa mogu detektirati objekte na većim udaljenostima. Na radare ne utječu nepovoljni atmosferski uvjeti poput kiše i magle. Cijena im je relativno niska. Ovisno o udaljenosti na kojoj rade dijele se na radare kratkog dometa (od 0,2 do 30 m), radare srednjeg dometa (od 30 do 80 m) i radare dalekog dometa (od 80 do 200 m). Radari kratkog i srednjeg dometa se primjenjuju za detekciju slijepih točaka i upozoravanje o nailasku vozila (CTA i RCW). Ovi sustavi najčešće se ugrađuju u kutove vozila. Radari dalekog dometa koriste se u sustavima za automatsku prilagodbu brzine kretanja i nalaze se najčešće ispod prednjeg branika vozila.

Ultrazvučna mjerna osjetila koriste zvučne valove kako bi izmjerili udaljenost objekata u okolini. Najčešće se koriste za detekciju objekata u neposrednoj blizini vozila, pa se primjenjuju u sustavima za pomoć prilikom parkiranja. Ugrađuju se ispod prednjeg i stražnjeg branika vozila. Neki od do sada navedenih ADAS sustava i mjerna osjetila koja se u njima koriste prikazani su na slici 2.



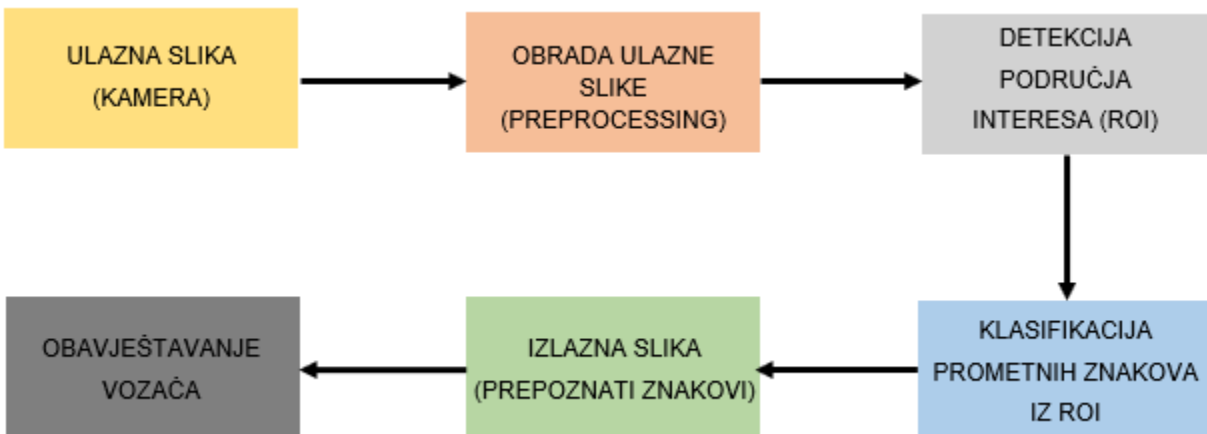
Slika 2: Prikaz mjernih osjetila korištenih u ADAS sustavima i sustava u kojima se koriste

Izvor: [3]

Ostala mjerna osjetila u ADAS sustavima koriste se za nadopunu i poboljšanje funkcionalnosti ranije navedenih mjernih osjetila. U njih spadaju foto-električna mjerna osjetila (engl. Photonic Mixer Device - PMD) koja omogućuju istovremeno brzo otkrivanje svjetlosnih signala i demodulaciju nekoherentnih svjetlosnih signala. PMD podržava i paralelno mjerenje udaljenosti pikselima, što rezultira bržim snimanjem, boljom rezolucijom i informacijama o dubini. U ostala mjerna osjetila spadaju još i inercijski mjerni uređaji (mjerač ubrzanja i žiroskop) i GPS, a najčešće se koriste kako bi se poboljšala mjerenja udaljenosti lidara i radara.

## 2.3. Sustav prepoznavanja prometnih znakova

Sve veći broj ADAS sustava u suvremenim vozilima počinje podržavati prepoznavanje prometnih znakova. Prometni znakovi opisuju i predstavljaju trenutnu situaciju u prometu, ukazuju sudionicima u prometu na opasnosti i poteškoće na koje mogu naići, daju upozorenja i pomažu u navigaciji pružajući korisne informacije, istovremeno čineći promet sigurnijim. Čest problem u prometu je da vozači ne uoče neki prometni znak ili ga ne uoče na vrijeme, a vrlo često iako ga uoče, ne pridržavaju se informacija koje im on pruža. Takvo ponašanje dovodi do nastanka opasnih situacija u prometu. Iz tog razloga u vozila se ugrađuju ADAS sustavi za prepoznavanje prometnih znakova. Oni smanjuju faktor ljudske pogreške i pomažu u održavanju visoke razine sigurnosti na prometnicama pomažući vozaču da se pridržava pravila definiranih prometnim znakovima. Ovi sustavi zasnivaju se na kamerama kao mjernim osjetilima za prikupljanje slika i raznim metodama iz područja računalnog vida za obradu informacija iz istih. Sastavni dijelovi ovoga sustava prikazani su na slici 3.



Slika 3: Sastavni dijelovi sustava prepoznavanja prometnih znakova

Kamere, koje se koriste u ovim sustavima, postavljene su na prednjoj strani vozila, najčešće unutar vozila, iza središnjeg retrovizora, zaštićene vjetrobranskim staklom. Kako je vrlo bitno pravovremeno prepoznati prometni znak, ove kamere imaju mogućnost detekcije objekata na srednjim udaljenostima (do nekih 50 m), a kut koji pokrivaju, to jest njihovo horizontalno vidno polje (engl. Field of View – FoV) kreće se između 70 i 120 stupnjeva. Kadrovi (engl. frames) koje kamere prikupljaju najčešće se predstavljaju u obliku matrica ispunjenih vrijednostima piksela, a svaki kadar sastoji se od tri kanala informacija, to jest crvenih, zelenih i plavih (engl. Red, Green, Blue – RGB) piksela. S obzirom na to da su prometni znakovi statični objekti, sustavi za prepoznavanje prometnih znakova ne zahtijevaju veliki broj kadrova u sekundi (engl. Frames per Second - FPS) da bi obavljali detekciju.

Nakon što se prikupe kadrovi potrebno ih je predobraditi (engl. preprocessing) prije nego se na njima želi izvršiti prepoznavanje prometnih znakova. Tijekom predobrade podataka nastoje se ukloniti značajke koje negativno utječu na prepoznavanje prometnih znakova, a istaknuti one značajke koje na to utječu pozitivno. U to spada otklanjanje šuma, isticanje boja, pretvorba boja iz jednog u drugi skup boja (engl. color space conversion), stabilizacija slike kojom se otklanjaju posljedice drhtanja kamere (engl. jitter), izjednačava neujednačeno osvjetljenje, otklanjaju neželjene sjene te prekomjerna ili nedovoljna ekspozicija.

Nakon što je slika predobrađena, prosljeđuje se dijelu sustava koji se bavi detekcijom objekata. Detekcija prometnih znakova u kadrovima se vrši na osnovi njihovih jedinstvenih značajki, a najčešće su to njihova boja i oblik. Za izvlačenje značajki iz slika se često koriste neuronske mreže, točnije konvolucijske neuronske mreže (engl. Convolutional Neural Network – CNN). Zadaća detekcije je locirati prometni znak i odrediti njegovu veličinu. Kada neuronska mreža pronade u kadru značajke za koje predviđa da pripadaju prometnom znaku, označava ih i označeni isječak prosljeđuje dijelu sustava koji je zadužen za klasifikaciju.

Za klasifikaciju dobivenih isječaka najčešće se koriste konvolucijske neuronske mreža. Klasifikacijom se utvrđuje koji se prometni znak nalazi u isječku. Kada je prometni znak prepoznat dalje se kroz sustav prosljeđuje izlazna slika, s označenim područjem na kojem se nalazi prometni znak i nazivom prepoznatog prometnog znaka.

Sljedeći i posljednji korak je pružanje informacija vozaču o prepoznatom prometnom znaku. Na osnovi tih informacija vozač može prilagoditi svoje ponašanje i upravljanje vozilom propisanim uvjetima. Kod naprednijih ADAS sustava i autonomnih vozila, sustav može sam donijeti odluku o idućoj reakciji i učiniti što je potrebno da prilagodi vozilo pravilima uvjetovanim prepoznatim prometnim znakovima. Sustav prepoznavanja prometnih znakova jedna je od ključnih sastavnica za rad autonomnih vozila. Autonomna vozila predstavlja najnapredniji sustav u kojem se primjenjuje prepoznavanje prometnih znakova. Uz primjenu u autonomnim vozilima, ovaj sustav se još može primjenjivati za praćenje stanja prometne infrastrukture, pa u slučaju da se određeni prometni znak otkrije da je dotrajao, može biti zamijenjen. Također se može koristiti i za automatsko ažuriranje baze cestovnih podataka za slučaj da se na određenoj lokaciji postavi novi prometni znak koji još nije pohranjen [4]. Sve navedene mogućnosti ukazuje koliko su velike mogućnosti primjene sustava za prepoznavanje prometnih znakova te koliko je bitan njihov daljnji razvoj i istraživanje za promet i njegovu sigurnost.


### **3. PROBLEM PREPOZNAVANJA PROMETNIH ZNAKOVA RAČUNALNIM VIDOM**

Računalni vid (engl. Computer Vision - CV) znanstvena je i tehnološka disciplina iz područja umjetne inteligencije koja se bavi izradom sustava za prikupljanje informacija iz vizualnih podataka. Računalni vid se dijeli na prikupljanje i obradu vizualnih podataka te detekciju, prepoznavanje i praćenje objekata unutar tih istih vizualnih podataka. Primjena računalnog vida u ADAS sustavima pomaže računalu u boljem razumijevanju prometnih situacija. Najvažnije osjetilo za čovjeka je u prometu njegov vid. Računalni vid u ADAS sustavima omogućuje prepoznavanje prometnih traka, prometnih svjetala, prometnih znakova, pješaka, vozila i naposljetku autonomiju samih vozila [5].

Prometni znakovi su sredstva koja sudionike u prometu upozoravaju na opasnost, definiraju zabrane, ograničenja i obveze te pružaju potrebne obavijesti za siguran i nesmetan promet. Prometni znakovi su dizajnirani kako bi bili lako uočljivi u složenoj okolini prometnice. Dizajn prometnih znakova u Hrvatskoj definiran je u [6]. Podjela prometnih znakova

Prema [6] prometni znakovi podijeljeni su na: znakove opasnosti, izričitih naredbi, obavijesti, obavijesti za vođenje prometa, dopunske ploče i promjenjive prometne znakove.

Znakovi opasnosti, prikazani na slici 4 označavaju blizinu dijela ceste ili mjesto na cesti na kojem sudionicima u prometu prijeti opasnost. Imaju oblik jednakostraničnog trokuta, kojem je jedan vrh okrenut prema gore, a nasuprotna mu, donja stranica nalazi se u vodoravnom položaju. Osnovna boja ovih znakova je bijela, dok su rubovi jednakostraničnog trokuta crvene boje. Simboli koji se nalaze na znakovima opasnosti crne su boje. U pravilu, se ovi znakovi postavljaju na udaljenosti 150 do 250 m ispred opasnog dijela na cesti. U slučaju da znak nije moguće postaviti na navedenoj udaljenosti, moguće je njegovo postavljanje i na udaljenosti manjoj od 150 m, no u tom slučaju je potrebno znaku pridružiti dopunsku ploču na kojoj je pobliže definirana točna udaljenost do potencijalnog opasnog mjesta.



Slika 4: Znakovi opasnosti

Izvor: [7]

Znakovi izričitih naredbi, prikazani na slici 5 stavljaju do znanja sudionicima u cestovnom prometu zabrane, ograničenja i obaveze. Imaju oblik kruga (osim trokutastog oblika znaka raskrižje s cestom s prednošću prolaska i oktogonalnog oblika znaka stop). Osnovna boja znakova zabrane i ograničenja je bijela, dok su rubovi ovih znakova crveni. Osnovna boja znakova obveze je plava. Simboli na znakovima zabrane i ograničenja su crne boje, dok su simboli na znakovima obveze bijele boje. Znakovi izričitih naredbi postavljaju se neposredno na mjesta na kojima za sudionike u prometu počinje obaveza postupanja po naredbi izraženoj prometnim znakom. Ako je zbog slabe preglednosti ceste ili zbog drugih razloga sigurnosti sudionike u prometu potrebno unaprijed obavijestiti o izričitoj naredbi, znak izričite naredbe može biti postavljen i na određenoj udaljenosti od mjesta od kojega naredba vrijedi.






Slika 5: Znakovi izričitih naredbi

Izvor: [7]

Znakovi obavijesti, prikazani na slici 6 sudionicima u prometu daju potrebne obavijesti o cesti kojom se kreću, nazivima mjesta kroz koja cesta prolazi i udaljenosti do tih mjesta, prestanku važenja prometnih znakova izričitih naredbi te druge obavijesti koje im mogu koristiti. Ovi znakovi mogu imati oblik kruga ili četverokuta. Osnovne boje te simboli i natpisi u sljedećim su kombinacijama: žuta sa crnom, plava s bijelom, crvenom ili zelenom, zelena s bijelom i bijela sa crnom, plavom ili crvenom. Kod privremenog usmjeravanja prometa može se koristiti i narančasta sa crnom.



Slika 6: Znakovi obavijesti

Izvor: [7]

Znakove obavijesti za vođenje prometa obavješćuju sudionike u prometu o pružanju cestovnih smjerova, rasporedu odredišta i vođenju prometa prema njima, raskrižjima i čvorištima na određenom smjeru ceste i udaljenostima do odredišta. Dopunske ploče pobliže određuju značenje prometnog znaka i postavljaju se ispod znaka. Promjenjivi prometni znakovi primjenjuju se kada prometni zahtjevi zahtijevaju promjenjivu prometnu signalizaciju, a mogu biti kontinuirani i nekontinuirani.

### **3.1. Problemi kod prepoznavanja prometnih znakova**

Problemi kod prepoznavanja prometnih znakova su [8]:

1. Boja znakova izbledi s vremenom zbog izloženosti sunčevim zrakama te reagira na onečišćenost zraka;
2. Vidljivost prometnih znakova uvjetovana je atmosferskim uvjetima, pa kiša, snijeg, magla i oblačno vrijeme znatno utječu na smanjenje vidljivosti;
3. Na vidljivost utječe i doba dana, jačina sunčeve svjetlosti te sjene koje na prometnim znakovima stvaraju drugi objekti;
4. Prometne znakove mogu zaklanjati drugi objekti (drveća, zgrade, vozila i pješaci);
5. Prisutnost drugih objekata koji su slične boje i/ili oblika kao prometni znakovi (razni objekti na stambenim objektima, reklame i drugi objekti uz cestu);
6. Prometni znakovi mogu biti oštećeni, pomaknuti, nagnuti i zarotirani;
7. Oblik i rotacija prometnih znakova mijenjaju se s obzirom na kut snimanja kamere, pa su oni puno manje deformirani dok se nalaze bliže središtu vidnog polja kamere nego na njenim bočnim rubovima;
8. Slike prometnih znakova prikupljene iz pokretnog vozila mogu biti zamućene (engl. blur) i pod utjecajem podrhtavanja (engl. jitter) zbog brzine kretanja vozila i vibracija koje se prenose na kameru, najčešće zbog podloge na kojoj vozilo vozi;

9. Sličnost među prometnim znakovima jer je razlika između određenih prometnih znakova predstavlja mala razlika u simbolima;
10. Različite države imaju različite znakove i svi znakovi nisu standardizirani iako je njihov dizajn određen propisanim regulativama;
11. Za učenje detektora i klasifikatora potrebna je velika količina podataka (velik broj različitih prometnih znakova u različitim atmosferskim uvjetima, na slikama visoke razlučivosti).

## **3.2. Predobrada slika**

Problem prepoznavanja prometnih znakova sastoji se od problema detekcije i problema klasifikacije prometnih znakova [9]. Za rješavanje problema detekcije potrebno je u složenoj okolini odrediti lokaciju prometnog znaka na temelju njegove boje i oblika. Za rješavanje problema klasifikacije potrebno je između velikog broja različitih značajki svakog znaka prepoznati koje boje, oblici i simboli pripadaju kojem prometnom znaku. Svaki od ova dva problema za svoje rješavanje zahtjeva drugačiji pristup, pa i navedeni problemi prepoznavanja prometnih znakova drugačije utječu na pronalazak rješenja i točnost svakog od ovih dijelova sustava. Kako bi se otklonili ili barem neki od navedenih problema umanjili, prije učenja sustava za prepoznavanje prometnih znakova, koriste se razne metode iz područja računalnog vida.

### **3.2.1. Metode predobrade slike**

Metode predobrade primjenjuju se na slikama prije njihovog prosljeđivanja neuronskoj mreži. Ove metode primjenjuju se kako bi smanjile negativne utjecaje nekih od problema i istaknule bitne značajke na slikama [9].

Promjena veličine slike (engl. *resize*) primjenjuje se zbog toga što sve slike u skupu podataka prometnih znakova nisu uvijek iste veličine, pa kako bi se prilagodile ulazu u neuronsku mrežu moraju se izjednačiti [10].

Skaliranje sivih tonova (engl. gray scaling) je često korištena metoda u klasifikaciji objekata. S obzirom na to da je kod klasifikacije prometnih znakova manje bitna boja znaka, zbog toga što je veliki broj znakova iste boje i jačina svjetlosti se mijenja od slike do slike i utječe na boju, za klasifikaciju znakova je bitniji njihov oblik, rubovi i oblik simbola koji se na njima nalazi. Ovom metodom dubina slike smanjuje se s tri na jedan, kako se ona pretvara iz RGB prostora boja u prostor boja sačinjen od nijansi sive. Ovaj prostor boja ustvari pruža samo informacije o jačini svjetlosti, pa svaki piksel nosi vrijednost od nula (potpuno crna) do 255 (potpuno bijela). Na ovaj način neuronska mreža treba manje parametara za razlikovanje prometnih znakova, zbog čega je učinkovitija i zahtjeva manju računalnu snagu za obradu slika [11].

Izjednačavanje histograma (engl. histogram equalization) je metoda koja se koristi za povećanje globalnog kontrasta slike pomoću histograma (definira raspodjelu boja na slici) slike. Ovom metodom intenziteti svjetline se mogu bolje raspodijeliti na histogramu. To omogućuje da područja s manjim lokalnim kontrastom dobiju veći kontrast. Izjednačavanje histograma ove rezultate ostvaruje raspoređivanjem najčešćih vrijednosti intenziteta. Ova metoda je najkorisnija na slikama sa svijetlim ili tamnim pozadinama [12].

Normalizacija (engl. normalization) ulaznih slika važan je korak koji osigurava da pikseli na slici imaju sličnu raspodjelu podataka, što ubrzava konvergenciju tijekom treniranja neuronske mreže. S obzirom na to da je za rad s neuronskim mrežama potrebno da vrijednosti piksela budu pozitivne, potrebno je oduzeti srednju vrijednost svih piksela od svakog piksela te dobiveni rezultat podijeliti sa standardnom. Tako se dobiva raspon vrijednosti piksela od nula do 255. Da bi se dobile vrijednosti u rasponu od nula do jedan, potrebno je da su intenziteti piksela u rasponu od nula do 255. Nakon toga vrijednost svakog piksela podijeli se s maksimalnom vrijednošću intenziteta na slici [13].

Ispravljanje smetnji preplitanja slike nastalo zbog kretanja vozila tijekom snimanja kamere može se izvesti odbacivanjem polovice linija te interpolacijom linija koje nedostaju kako je prikazano u [14]. Na ovaj način dobiva se jasnija slika prometnog znaka, na kojoj je moguće vršiti klasifikaciju.

### 3.2.2. Metode za povećanje skupa podataka

Metode za povećanje skupa podataka (engl. augmentation) koriste se kada je potrebno povećati količinu podataka da bi se neuronska mreža bolje naučila, to jest generalizirala. Povećanjem skupa podataka podaci mogu pokrivati veći skup mogućnosti do kojih može doći u stvarnim situacijama, bez da se prikupljaju dodatni podatci. Neke od metoda koje se najčešće primjenjuju su [15]:

- rotacija – slika se rotira kako bi se prilagodila mogućnostima do kojih može doći u stvarnim situacijama, tako se na primjer primjenjuje rotacija da bi neuronska mreža naučila da znak može biti i nagnut u određenu stranu,
- translacija – slika se može translirati po vertikalnoj i horizontalnoj osi, a na ovaj način sprječava se pretjerano prilagođavanje (engl. overfitting) neuronske mreže skupu podataka za treniranje, tako što se pikseli pomiču na drugu poziciju na slici, ovisno o vrsti translacije koja se primjenjuje,
- promjena perspektive (engl. perspective transform) i smicanje (engl. shear) – koriste se kako bi se dobio bolji pogled na potrebne informacije, a koristi se kod prometnih znakova jer se na sličan način njihov oblik mijenja kako se oni približavaju rubu vidnog polja kamere,
- promjena svjetline slike – posvjetljuje ili zatamnjuje sliku, što omogućuje neuronskoj mreži da nauči prepoznavati prometne znakove u uvjetima različitog intenziteta prirodne svjetlosti,
- promjena zasićenja boje na slici (engl. saturation) – koja omogućuje smanjenje ili povećanje intenziteta i isticanja određenih boja,
- promjena kontrasta – koja pomaže u isticanju rubova na slici, što je vrlo bitna značajka kod prepoznavanja prometnih znakova, posebice simbola na njima, kako bi razlike u pikselima između različitih simbola bile jasnije,

- dodavanje šuma slici – smanjuje utjecaj smetnji koje mogu nastati tijekom snimanja kamere, najčešće se koriste Gaussov šum koji može postaviti šum bilo koje vrijednosti između nula i 255, dok šum pod nazivom sol i papar (engl. salt-and-pepper noise) može imati samo vrijednosti nula (crna - papar) i 255 (bijela - sol).

Navedene metode doprinose velikoj uštedi vremena koje je potrebno uložiti za prikupljanje raznovrsnog skupa podataka. Također ove metode vrlo su lako primjenjive, doprinose generalizaciji neuronske mreže smanjenjem pretjeranog prilagođavanja neuronske mreže skupu za učenje i zbog toga znatno povećavaju točnost prilikom primjene naučene mreže na skupu podataka za ispitivanje.



## 4. PRIMJENA NEURONSKIH MREŽA U PREPOZNAVANJU PROMETNIH ZNAKOVA

Umjetne neuronske mreže (engl. Artificial Neural Network – ANN) povezane su i sastavljene po uzoru na strukturu ljudskog mozga od velikog broja jednostavnih procesnih elemenata (neurona). Procesni elementi su povezani na sličan način kao neuroni u kori mozga te ustrojeni u niz slojeva s potpunim ili slučajnim vezama između slojeva. Umjetna neuronska mreža predstavlja primjer funkcioniranja ljudskog mozga. Njena svrha je simuliranje postupka učenja i obrade podataka. Njen skup međusobno povezanih jednostavnih elemenata služi distribuiranoj paralelnoj obradi podataka. Ova svojstva omogućuju joj učenje na temelju iskustva, poopćavanje (engl. Generalization), odjeljivanje bitnog od nebitnog i prepoznavanje uzoraka.

Osnovna jedinica umjetne neuronske mreže je umjetni neuron, a na slici 7 prikazan je njegov model. Umjetni neuron prema [16] sačinjavaju:


- $x_i$  - signali na ulazu u neuron (dendriti),
- $w_i$  - težine na pojedinom ulazu (sinapse),
- $w_0$  - stalni odmak od nule (engl. bias),
- $I$  - zbroj otežanih ulaza (jezgra),
- $\Phi(I)$  - aktivacijska funkcija (jezgra),
- $y$  – izlaz iz neurona (akson).

Zbroj otežanih ulaza dobiva se prema formuli (1):

$$I_j = \sum_{i=1}^n w_{ij}x_i. \quad (1)$$

Izlaz iz neurona dobiva se na temelju zbroja otežanih ulaza i aktivacijske funkcije prema formuli (2):


$$y_j = \Phi(I_j). \quad (2)$$



Slika 7: Model umjetnog neurona, [17]

Arhitektura umjetne neuronske mreže je ta koja pokazuje na koji su način neuroni međusobno spojeni i podijeljeni u slojeve. Prema njoj se definiraju funkcije koje neuronska mreža može izvršavati. Arhitektura umjetne neuronske mreže prikazana je na slici 8. Umjetna neuronska mreža sastoji se od:

- ulaznog sloja – predaje podatke iz okoline neuronskoj mreži,
- unutarnjeg (skrivenog) sloja – nije izravno povezan s okolinom, obrađuje signale, smanjuje dimenzionalnost podataka i prepoznaje uzorke (pojavljuje se kod višeslojnih neuronskih mreža),
- izlaznog sloja – predaje rezultate obrade neuronske mreže u okolinu.

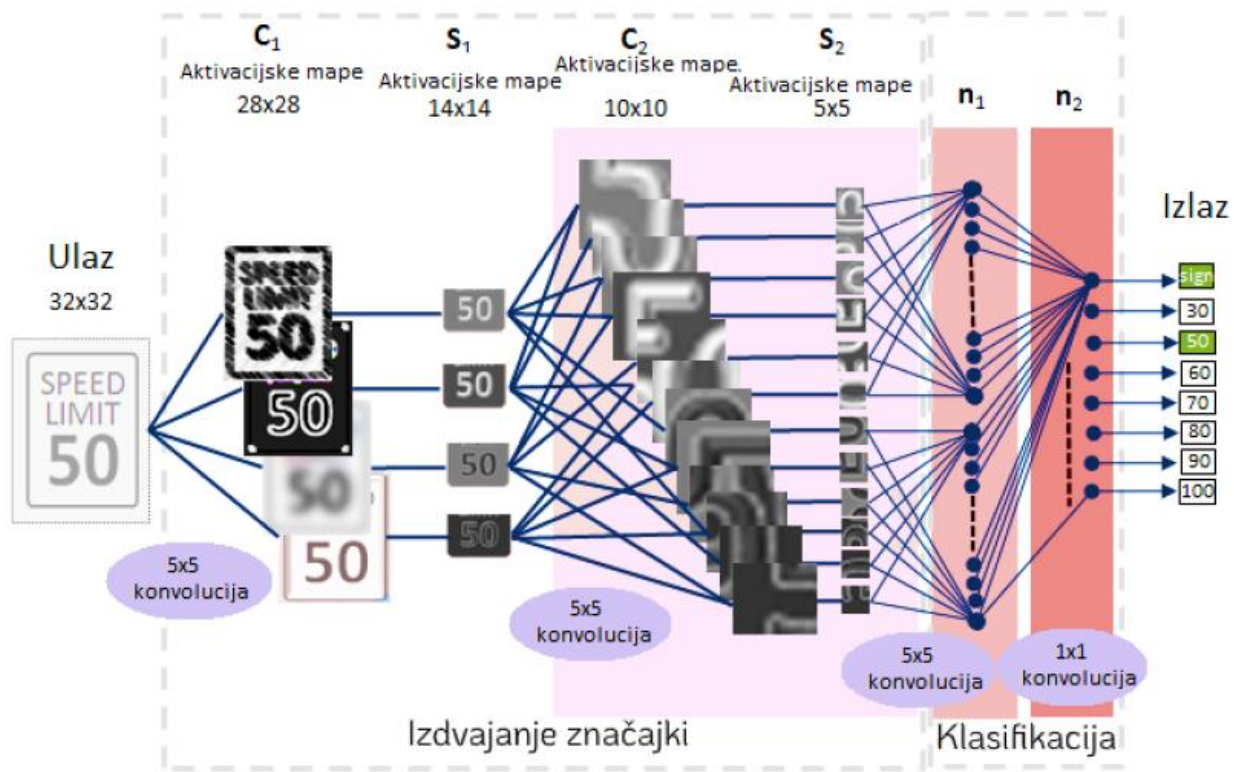


Slika 8: Arhitektura umjetne neuronske mreže

#### 4.1. Konvolucijske neuronske mreže

Problem klasičnih neuronskih mreža je što pohranjuju i samim time obrađuju podatke na isti način kao i računala. Kada bi se za obradu slike u RGB formatu (dubina 3) dimenzija visine 64 piksela i širine 64 piksela željela koristiti klasična neuronska mreža, njen ulaz zaprimio bi 12.288 ulaznih signala ( $64 \times 64 \times 3$ ). To bi značilo da bi ta neuronska mreža imala 12.288 težina, što je za ovako malu sliku velik broj. Kada bi ta ista slika bila veća, na primjer dimenzija  $640 \times 480$ , neuronska mreža bi imala 921.600 težina. Uz dodavanje dodatnih skrivenih slojeva ova bi brojka još više rasla i ukazuje koliko je zahtjevno i dugotrajno učenje klasičnih neuronskih mreža na slikovnim podacima.

Prednost konvolucijskih neuronskih mreža (engl. Convolutional Neural Networks – CNN) je očuvanje prostorne strukture (dimenzionalnosti) ulaznih podataka, zbog čega su jedan od glavnih alata za analiziranje slikovnih podataka [18]. Zbog toga što ove neuronske mreže koriste 3D slojeve potrebno im je puno manje težina, što ubrzava učenje. CNN se sastoje od ulaznog sloja, konvolucijskog sloja, aktivacijskog sloja, sloja sažimanja i potpuno povezanog sloja koji su pobliže pojašnjeni u sljedećim potpoglavljima. U prvim slojevima neuronske mreže, filtri otkrivaju jednostavnije značajke, to jest osnovne oblike poput krugova, kutova i rubova. Što slika dolazi do dubljih konvolucijskih slojeva, filtri otkrivaju složenije i više jedinstvene oblike [19]. Kod prometnih znakova viši konvolucijski slojevi prvo otkrivaju osnovne značajke poput oblika znaka, dok dublji slojevi otkrivaju jedinstvene značajke znaka, kao što su njegovi simboli. Na slici 9 prikazan je primjer konvolucijske neuronske mreže i njenog prepoznavanja prometnog znaka.




Slika 9: Primjer strukture i primjene konvolucijske neuronske mreže nad prometnim znakom ograničenja brzine 50 mph

Izvor: [2]

### 4.1.1. Ulazni sloj

Ulazni sloj učitava sliku u obliku trodimenzionalnog niza podataka koji sadržava vrijednost elemenata slike [21]. Svaka dimenzija odnosi se na određeni kanal boje, kako je prikazano na slici 10. Veličinu slike potrebno je prilagoditi ulazu u mrežu.



Slika 10: Primjer RGB slike veličine 5x5 s prikazom vrijednosti elemenata slike razdijeljenih po kanalima boja, [21]

### 4.1.2. Konvolucijski sloj

Konvolucijski sloj (engl. Convolution Layer) najvažniji je sloj mreže. Ove mreže nazivaju se konvolucijske jer koriste konvoluciju, koja predstavlja matematičku operaciju sa dvije funkcije koje stvaraju treću funkciju. Treću funkciju predstavlja mapa značajki (engl. Feature Map). Konvolucije se obavljaju u konvolucijskom sloju. One su razlog zašto ove neuronske mreže ne ovise o prostoru unutar slike i omogućuju otkrivanje objekta neovisno o tome gdje se on točno u slici nalazi [21]. Konvolucije se izvršavaju klizanjem filtera preko slike dobivene na ulazu. Proces klizanja predstavlja operaciju množenja matrica ili skalarno množenje. Ovaj proces prikazan je na slici 11.

1	0	1	0	1
1	0	0	1	1
0	1	1	0	0
1	0	0	1	0
0	0	1	1	0

ULAZ

0	1	0
1	0	-1
0	1	0

FILTAR


IZLAZ ILI MAPA ZNAČAJKI

1x0	0x1	1x0	0	1
1x1	0x0	0x-1	1	1
0x0	1x1	1x0	0	0
1	0	0	1	0
0	0	1	1	0

$$(1x0)+(0x1)+(1x0)+$$

$$(1x1)+(0x0)+(0x-1)+$$

$$(0x0)+(1x1)+(1x0)$$

$$0+0+0+$$

$$1+0+0+$$

$$0+1+0 = 2$$

2		

1	0x0	1x1	0x0	1
1	0x1	0x0	1x-1	1
0	1x0	1x1	0x1	0
1	0	0	1	0
0	0	1	1	0

$$(0x0)+(1x1)+(0x0)+$$

$$(0x1)+(0x0)+(1x-1)+$$

$$(1x0)+(1x1)+(0x1)$$

$$0+1+0+$$

$$0+0-1+$$

$$0+1+0 = 1$$

2	1	

Slika 11: Primjer procesa operacije konvolucije korištenjem filtra 3x3

U postupku konvolucije filtri se prvotno postavljaju u gornji lijevi kut slike. Vrijednosti filtara se zatim množe s pripadajućim elementima na slici, nakon čega se dobiveni umnošci zbrajaju. Nakon izvršene operacije konvolucije filtri se pomiču udesno, a kada dođu do posljednjeg desnog elementa slike, pomiču se nazad na krajnji lijevi element i spuštaju prema dolje. Nakon svakog pomicanja vrši se konvolucija. Ova radnja se ponavlja dok se ne prođe preko svih elemenata slike. Rezultati svih konvolucija, kako je prikazano na Slika 11 pohranjuju se u mapu značajki.

Ovisno o vrijednostima unutar filtara, kao rezultat se dobivaju različite mape značajki što je korisno za otkrivanje različitih značajki na slici. Konvolucija zadržava prostorni odnos između piksela i uči značajke slike preko sitnih odsječaka koji prelaze preko slike. Konvolucijske neuronske mreže imaju mogućnost korištenja broja filtara koji god da je potreban da se iz slika izvuku bitne značajke. Primjenom više filtara dobiva se više mapa značajki, a mape značajki slažu se jedna na drugu. Dubina filtra jednaka je dubini ulaznih podataka. Veličina filtara može se namještati po potrebi, a najčešće su korištene dimenzije 3x3, 5x5 i 7x7. Vrijednosti koje se nalaze unutar filtara nazivaju se težine i one se tijekom procesa učenja ažuriraju pri svakoj iteraciji.

Hiperparametri konvolucijskog sloja omogućuju uspješno izvršenje operacija konvolucije i zadaju se za svaki konvolucijski sloj zasebno. Prema [21] oni su:

- veličina filtra (engl. filter size) – visina i širina filtara koji se koristi nad elementima slike,
- pomak (engl. stride) – broj koraka za koji se filter pomiče u horizontalnom i vertikalnom smjeru po slici,
- dopunjavanje (engl. padding) – dodaje redove i stupce oko slike čiji elementi imaju zadanu vrijednost nula, kako bi se održale prostorne dimenzije slike, koje se smanjuje primjenom konvolucije,
- dubina (engl. depth) – broj slojeva koji nastaju uslijed primjene filtara i konvolucije nad slikom.

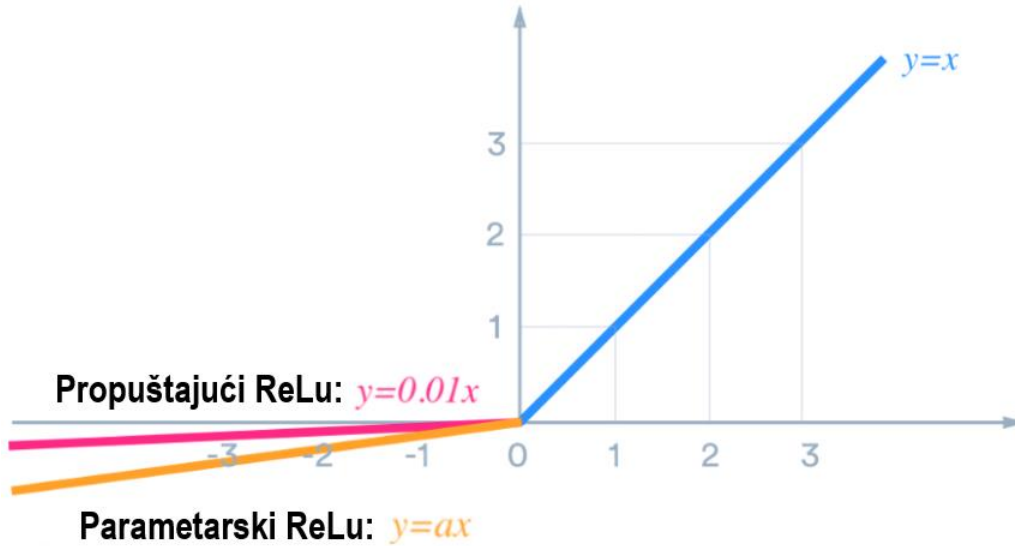
### 4.1.3. Aktivacijski sloj

Aktivacijski sloj (engl. Activation Layer), to jest aktivacijska funkcija (engl. Activation Function) najčešće se implementira unutar konvolucijskog sloja, no može postojati i kao zaseban sloj. Glavna zadaća aktivacijske funkcije je propustiti određene vrijednosti u sljedeći sloj mreže. Spomenute vrijednosti se prosljeđuju kada odgovaraju rezultatu korištene aktivacijske funkcije.

Najpoznatija i najviše upotrebljavana aktivacijska funkcija je ispravljачka linearna funkcija *ReLU* (engl. Rectified Linear Unit). Ona je linearna za sve pozitivne vrijednosti, a nula za sve negativne. Tako znatno olakšava računalne operacije koje je potrebno provesti. Također omogućava bržu pretvorbu, prorjeđuje neurone i povećava vjerojatnost za aktivacijom ispravnog neurona prilikom otkrivanja značajki objekata [21]. Međutim ako je stopa učenja (engl. learning rate) prevelika, može doći do takozvanog problema umirujućeg (engl. Dying) ReLU, gdje neuroni umiru ako zaglave na negativnoj strani i uvijek daju nulu, a jednom kada neuroni postanu negativni vrlo je mala vjerojatnost da će se oporaviti. Ovakvi neuroni ne igraju ulogu u razlikovanju ulaznih podataka i postaju beskorisni. S vremenom tako može doći do toga da veliki dio mreže ustvari nema nikakvu funkciju [21].

Uz ReLU aktivacijsku funkciju postoje još Leaky ReLU i Parametric ReLU aktivacijske funkcije. One su također linearne za sve pozitivne vrijednosti. Propuštajući (engl. Leaky) ReLU rješava problem Dying ReLU, a to čini tako da za negativne vrijednosti ulaza izlaz dobiva množeći ulaz s nekom malom vrijednošću poput 0,02. Zbog svojih karakteristika ova aktivacijska funkcija također ubrzava učenje. Parametarski ReLU je ustvari vrsta Leaky ReLU, koja umjesto da ima unaprijed određen koeficijent s kojim množi ulaz, prepušta neuronskoj mreži da sama otkrije s kojim koeficijentom će pomnožiti ulaz da bi se dobio izlaz. Sve tri navedene aktivacijske funkcije prikazane su na slici 12.






Slika 12: Prikaz aktivacijskih funkcija ReLu, Propuštajući ReLu i Parametarski ReLu  
Izvor: [19]

#### 4.1.4. Sloj sažimanja


Sloj sažimanja (engl. Pooling Layer) smanjuje dimenzije ulaznih podataka u konvolucijskom sloju. Smanjenjem dimenzija smanjuju se zahtjevi za računalnim resursima potrebnim za obradu podataka. To se ostvaruje na način da se izdvajaju najznačajniji podaci u nizu podataka, što omogućava smanjenje neovisnosti na rotaciju i poziciju te smanjenje šuma u samim podacima [23]. Nekoliko je vrsta sažimanja podataka, a ona najpoznatija i najefikasnija je ona prema maksimalnoj vrijednosti (engl. Max Pooling). Sažimanjem po najvećoj vrijednosti iz skupa promatranih vrijednosti (engl. kernel) izdvaja se maksimalna vrijednost i odabire da predstavlja skup iz kojeg je izvučena, kako je prikazano na slici 13.



Slika 13: Grafički prikaz metode sažimanja po maksimalnoj vrijednosti

#### 4.1.5. Potpuno povezani sloj

Dosad navedeni slojevi koriste se za izvlačenje značajki iz slikovnih podataka. Potpuno povezani sloj (engl. Fully Connected Layer), prikazan na slici 14, je taj koji vrši klasifikaciju nad izdvojenim značajkama. Kako bi se to moglo izvesti potrebno je prvo aktivacijske mape pretvoriti u jednodimenzionalan vektor pomoću sloja za sravnavanje (engl. Flatten Layer). U potpuno povezanom sloju svaki ulazni neuron povezan je sa svakim izlaznim neuronom. Na njegovom izlazu postavlja se *softmax* aktivacijska funkcija koja omogućava izvođenje višeklasne klasifikacije. Na izlazu konvolucijske neuronske mreže tako se dobiva vjerojatnost pripadnosti objekta na slici svakoj pojedinoj klasi, a ukupan zbroj vjerojatnosti jednak je jedan [24]. Klasa za koju objekt ima najveću vjerojatnost predviđena je kao klasa kojoj objekt pripada.




Slika 14: Prikaz potpuno povezanog sloja, [21]

## 4.2. Učenje neuronskih mreža

Kod složenijih neuronskih mreža kao što je konvolucijska nije moguće kontrolirati način na koji mreža obrađuje podatke. U tom slučaju ono što je potrebno napraviti je definirati arhitekturu mreže i prije postupka obrade podataka obaviti postupak učenja. Za razliku od klasičnih načina obrade podataka, kod kojih je potrebno postupak obrade podataka analitički razložiti na određeni broj algoritamskih koraka, kod ovog tipa neuronskih mreža to nije slučaj i takav algoritam ne postoji. Znanje o izlazu kao funkciji ulaza pohranjeno je u težinama neuronske mreže. Težine se učenjem postepeno prilagođavaju sve dok izlaz iz mreže provjeren na skupu za ispitivanje ne daje zadovoljavajuće rezultate. Postupak učenja neuronskih mreža je iterativan.

Razlikuju se dva načina učenja, ovisno o tome da li je poznat izlaz prije učenja ili nije. Prvi način je učenje s učiteljem (engl. supervised learning), kod kojeg se učenje provodi kroz primjere u obliku poznatih parova (ulaz, izlaz). Drugi način učenja je učenje bez učitelja (engl. unsupervised learning), kod kojeg mreža uči bez poznavanja izlaza.

Skup primjera za učenje najčešće se dijeli na tri odvojena skupa: skup za učenje (engl. training), skup za ispitivanje (engl. testing) i skup za provjeru (engl. validation). Primjeri iz skupa za učenje služe za podešavanje težina. Pomoću primjera za ispitivanje, tijekom učenja se vrši provjera rada mreže s trenutnim težinama. To se radi kako bi se postupak učenja mogao zaustaviti u trenutku kada mreža počne pokazivati degradaciju performansi. Nakon određenog broja iteracija neuronska mreža može postati stručnjak za obradu podataka iz skupa za učenje, zbog čega gubi svojstvo generalizacije i ostale podatke obrađuje loše. Ova pojava označuje da je mreža pretrenirana (engl. overfitting). Iz tog razloga potrebno je pratiti učenje mreže pomoću skupa za ispitivanje i otkriti u kojoj iteraciji predviđeni izlaz najmanje odstupa od željenog izlaza, kako je prikazano na slici 15. Točnost i preciznost obrade podataka naposljetku se provjerava na skupu za provjeru.



Slika 15: Odstupanje stvarnog izlaza kroz iteracije, [25]

Za učenje umjetnih neuronskih mreža važna su dva pojma: iteracije i epohe. Iteracija predstavlja korak u procesu učenja u kojem se odvija podešavanje težina. Epoha predstavlja jedno predstavljanje cjelokupnog skupa za učenje neuronskoj mreži. Ovisno o broju primjera predočenih neuronskoj mreži za trajanje jedne iteracije razlikuju se [25]:

- pojedinačno učenje (engl. on-line training) – u jednoj iteraciji predočava se samo jedan primjer za učenje, to jest kod predočavanja svakog novog primjera za učenje podešavaju se težine,
- grupno učenje (engl. batch training) – u jednoj iteraciji predočavaju se svi primjeri za učenje, to jest iteracije se podudaraju s epohama.

### 4.3. Mjere uspješnosti obrade podataka u neuronskim mrežama

Za ispravnu evaluaciju rješenja dobivenog procesom učenja koriste se određene mjere koje na smislen način odražavaju njegove performanse. Navedene mjere su:

- preciznost (engl. Precision),
- odziv (engl. Recall),
- F-1 mjera (engl. F-1 Score),
- omjer preklapanja i unije (engl. Intersection over Union - IoU),
- prosječna preciznost (engl. Average Precision – AP),
- srednja prosječna preciznost (engl. mean Average Precision – mAP).

Uz navedene mjere bitno je razjasniti pojmove koji definiraju ispravnost prepoznavanja. Objekt prema tim mjerama može biti:

- točno predviđen (engl. True positive – TP) – objekt koji je trebao biti predviđen je ispravno predviđen,
- netočno predviđen (engl. False positive – FP) – objekt koji nije trebao biti predviđen je predviđen,
- nepredviđen (engl. False negative – FN) – objekt koji je trebao biti predviđen nije predviđen.

Pomoću navedenih parametara (TP, FP, NP) računa se preciznost predviđanja (PR) prema formuli (3):

$$PR = \frac{TP}{TP + FP}. \quad (3)$$

Odziv (OD) označava koliko dobro model predviđa točna predviđanja, a računa se kao omjer svih točnih predviđanja i ukupnog broja predviđanja prema formuli (4):

$$OD = \frac{TP}{TP + FN} \quad (4)$$


F-1 mjera označava mjeru točnosti modela u slučajevima kada rezultati nisu dovoljno jasni iz mjera preciznosti i odziva. F-1 ovisi o ove dvije mjere i računa se prema formuli (5):

$$F1 = 2 * \frac{PR * OD}{PR + OD} \quad (5)$$

IoU u detekciji predstavlja omjer površine preklapanja detektiranog (engl. area of overlap) i stvarnog graničnog okvira objekta (engl. area of union), a računa se prema formuli (6):

$$IoU = \frac{\text{površina preklapanja detektiranog i stvarnog graničnog okvira}}{\text{unija površina detektiranog i stvarnog graničnog okvira}} \quad (6)$$

Grafički prikaz pojašnjenja ovog parametra dan je na slici 16.  $B_1$  predstavlja stvarni granični okvir objekta (engl. ground truth, odnosno poznato točno rješenje), a  $B_2$  predstavlja granični okvir objekta kojeg detektira neuronska mreža.



Slika 16: Grafički prikaz parametra IoU, [24]

Kod predviđanja objekata koristi se još i prosječna preciznost, za čije računanje su potrebne mjere preciznosti i odziva. Ova mjera računa se kao površina ispod krivulje preciznosti ovisne o odzivu prema formuli (7):

$$AP = \int_0^1 p(r)dr. \quad (7)$$

Pomoću mjere prosječne preciznosti računa se srednja prosječna preciznost. Ona se računa kao zbroj prosječnih preciznosti za svaku klasu objekta (ima N klasa) koju je potrebno razlikovati. Ova mjera uspješnosti računa se prema formuli (8):

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i. \quad (8)$$

## **5. IZVEDBA SUSTAVA ZA PREPOZNAVANJE PROMETNIH ZNAKOVA**

U ovome poglavlju detaljno je opisano implementirano rješenje za prepoznavanje prometnih znakova. Rješenje se sastoji od dva dijela, dijela za detekciju prometnih znakova i dijela za njihovu klasifikaciju. U ovome poglavlju također su prikazani korišteni alati te skupovi podataka koji su se koristili za razvoj rješenja.

### **5.1. Opis alata korištenih za razvoj rješenja**

Za razvoj rješenja prepoznavanja prometnih znakova korištena je računalna platforma Google Colaboratory [26]. Programski kôd napisan je u programskom jeziku Python, a pritom su korištene dostupne knjižnice za pomoć pri razvoju rješenja kao što su NumPy, OpenCV, TensorFlow i Keras. Za učenje rješenja zaduženog za detekciju prometnih znakova korišten je programski okvir Darknet. Kako bi se za razvoj ovog rješenja mogla koristiti grafička kartica, korištena je računalna platforma CUDA. Svi korišteni alati opisani su u istoimenim potpoglavljima u nastavku.

#### **5.1.1. Google Colaboratory**

Colab omogućuje stvaranje i dijeljenje bilježnica (engl. notebooks) za pisanje i izvršavanje Python kôda u Internet okruženju. Colab je izgrađen na temelju Jupyter bilježnice, što znači da su Colab bilježnice ustvari Jupyter bilježnice udomaćene (engl. hosted) na Colabu ili ti Google disku [26]. Prednosti Google Colaba su što ne zahtijeva skoro nikakve konfiguracije prije početka pisanja kôda i omogućuje korisnicima besplatan pristup snažnim grafičkim karticama kao što su NVIDIA K80, P100, P4, T4, V100 i A100 (u radu je korištena P100 grafička kartica) [27]. Uz snažne grafičke kartice pruža i veliku količinu radne memorije i integraciju s ostalim Google uslugama. Na ovaj način omogućuje puno brže treniranje neuronskih mreža i ostalih algoritama. Također s obzirom na to da su svi podaci spremjeni u oblaku, ne postoji vjerojatnost za gubljenjem podataka.



### **5.1.2. NumPy**

NumPy je prema [28] knjižnica otvorenog koda čiji je cilj omogućiti znanstveno računanje unutar programskog jezika Python. Glavna prednost ove knjižnice je što pruža podršku za rad s velikim, višedimenzionalnim poljima (engl. arrays) i posjeduje veliku kolekciju naprednih matematičkih funkcija.

### **5.1.3. OpenCV**

OpenCV predstavlja knjižnicu računalnog vida otvorenog kôda (engl. Open Source Computer Cision Library). OpenCV je razvijen kako bi omogućio razvoj aplikacija iz područja računalnog vida i ubrzao primjenu računalnog vida u komercijalne svrhe. Ova knjižnica sadrži više od 2.500 optimiziranih algoritama, klasičnih i vrhunskih algoritama strojnog učenja [29]. Ovi algoritmi mogu se koristiti za prepoznavanje, detekciju, klasifikaciju, obradu slikovnih podataka te u brojne druge svrhe. Pruža podršku za C++, Python, Javu i MATLAB.

### **5.1.4. TensorFlow**

TensorFlow je prema [30] knjižnica otvorenog koda za razvoj modela strojnog učenja. Može se koristiti za niz zadataka, no glavnu primjenu pronalazi u učenju i zaključivanju (engl. inference) dubokih neuronskih mreža. Ovaj alat pruža podršku za Python i C++ programske jezike.

### **5.1.5. Keras**

Keras je aplikacijsko programsko sučelje (engl. Application Programming Interface – API) za duboko učenje napisan u Pythonu, koji radi na vrhu platforme za strojno učenje TensorFlow [31]. Razvijen je s naglaskom na omogućavanju brzog eksperimentiranja s dubokim neuronskim mrežama. Mogućnost što bržeg prelaska od ideje do rezultata ključna je za dobro istraživanje. Keras sadrži velik broj često korištenih sastavnih dijelova neuronske mreže poput slojeva, aktivacijskih funkcija, optimizatora itd. Keras smanjuje kognitivno opterećenje programera kako bi mu omogućio da se usredotoči na dijelove problema koji su doista važni.

### **5.1.6. Darknet**

Darknet je prema [32] programski okvir otvorenog kôda napisan primjenom programskog jezika C i CUDA računalne platforme. Predstavlja brz alat, jednostavan za instalaciju, s mogućnošću obrade podataka unutar procesora računala i grafičke kartice. Omogućuje implementaciju neuronskih mreža visokih performansi i ovome radu omogućio je izradu rješenja za detekciju objekata temeljenog na YOLO sustavu.


### **5.1.7. CUDA**

CUDA predstavlja platformu za obradu opće namjene na Nvidijinim grafičkim karticama. Izvršavanje zadataka nije potrebno izvoditi uzastopno, već se oni mogu izvoditi paralelno s drugim zadacima na grafičkoj kartici [33]. To omogućuje znatno ubrzanje procesa i kod učenja neuronskih mreža znatno smanjuje vrijeme učenja.

### **5.1.8. YOLO algoritam**

YOLO (engl. You Only Look Once) algoritam jedan je od najsuvremenijih algoritama za detekciju objekata. YOLO je izrazito brz i omogućuje detekciju objekata u stvarnome vremenu. Svoje mogućnosti pokazao je ostvarivši vrhunske rezultate na COCO skupu podataka (skup podataka od 80 kategorija objekata – osoba, vozila, životinja, prehrambenih proizvoda itd.) [34].

Prema [35] svi YOLO modeli namijenjeni su detekciji objekata. Modeli za detekciju objekata učeni su da gledaju sliku i traže određenu kategoriju objekata. Kada je kategorija pronađena, objekti se ograde graničnim okvirom (engl. bounding box) i njihova kategorija je identificirana. Druga rješenja za detekciju objekata većinom se svode na prenamjenu klasifikatora ili lokalizatora, koji primjenjuju model na slici na više mjesta u različitim mjerilima te područje slike s visokim bodovanjem smatraju detekcijama. YOLO primjenjuje jednu neuronsku mrežu na cijelu sliku, dijeli sliku na regije i predviđa granične okvire te vjerojatnosti za svaku od regija [36]. Granični okvir određuju vjerojatnost predviđanja, lokacija središta okvira određena s  $x$  i  $y$  koordinatama te visina (engl. height -  $h$ ) i širina (engl. width -  $w$ ) graničnog okvira [37]. Težine graničnih okvira predstavljaju predviđene vjerojatnosti. Prikaz primjene ove mreže na ulaznoj slici dan je na slici 17.



Slika 17: Prikaz primjene YOLO mreže na ulaznoj slici

Kako YOLO gleda cijelu sliku u vrijeme ispitivanja, predviđanja su zasnovana na globalnom kontekstu prikazanom na slici. Također YOLO daje predviđanja uz jednu mrežnu procjenu (engl. One Stage Detector), dok sustavi poput R-CNNa (engl. Region Based Convolutional Neural Network) vrše tisuće procjena na jednoj slici. Zbog toga je YOLO brži 1.000 puta od R-CNNa i 100 puta brži od Fast R-CNNa.

## 5.2. Model za detekciju prometnih znakova

U ovome poglavlju opisana je izrada modela za detekciju prometnih znakova te dodatne postavke koje je bilo potrebno podesiti da bi se dobilo dobiveno rješenje i skup podataka koji je korišten za učenje i ispitivanje rješenja. Otkrivanje prometnih znakova složen je problem zbog potrebe za razdvajanjem velikog broja značajki u okolini prometnog znaka od samih značajki prometnog znaka [38]. Također zbog kretanja vozila oni se pojavljuju na više udaljenosti i u više veličina, pa je potrebno razviti sustav koji otkriva prometne znakove različitih veličina [39]. Za rješavanje problema detekcije prometnih znakova odabran je YOLO algoritam, zbog njegove brzine i točnosti.

### 5.2.1. Opis korištenog skupa podataka

Skup podatak koji je korišten prilikom izrade modela za rješavanje problema detekcije je izmijenjeni *German Traffic Sign Detection Benchmark* (GTSDDB). Ovaj skup podataka sastoji se od 740 slika za razliku od izvornog GTSDDB skupa podataka koji ima 900 slika. Korišteni skup podataka ima manje slika jer u izvornom skupu podataka postoje slike na kojima nema prometnih znakova. Slike su snimljene s prednje kamere na vozilu i na slikama se nalazi između jednog i šest znakova. Širina slika je 1.360 piksela, a visina slika iznosi 800 piksela, dok u izvornom skupu podataka veličine slika variraju između 16x16 i 128x128. Slike su dostupne u više uvjeta, pa omogućuju detekciju prometnih znakova u različitim vremenskim uvjetima i pri različitim intenzitetima svjetlosti i na različitim udaljenostima. Izvorni skup podataka moguće je preuzeti u PPM formatu, a korišteni skup podataka kako bi se mogao koristiti s YOLO algoritmom, prebačen je u YOLO format. Prebacivanje u YOLO format zahtjeva prebacivanje slika iz PPM formata u JPG format, te zapisivanje anotacija, koje označavaju prometne znakove na slikama, u zaseban TXT dokument za svaku sliku. Primjer jedne slike iz skupa podataka prikazan je na slici 18.



Slika 18: Primjer slike iz skupa podataka za detekciju prometnih znakova

Prometni znakovi unutar ovoga skupa podataka podijeljeni su na četiri kategorije:

- znakove zabrane,
- znakove opasnosti,
- znakove obveze,
- ostale znakove.

Kako se skup podataka sastoji od 43 različita znaka, njihova podjela u navedene kategorije prikazan je na slici 19.





Slika 19: Prikaz podjele znakova u četiri kategorije za detekciju

Izvor: [40]

Nakon upoznavanja sa skupom podataka sljedeći je korak učenje YOLO algoritma. Učenje YOLO algoritma većim je djelom automatizirano, zbog čega je potrebno izmijeniti samo nekoliko parametara kako bi se algoritam prilagodio skupu podataka i kako bi se moglo započeti učenje.

Parametri koje je bilo potrebno prilagoditi unutar konfiguracijske datoteke za treniranje YOLO algoritma su sljedeći:

- stopa učenja (engl. learning rate) postavljena je na 0,001,
- kut pod kojim se nasumično rotiraju slike tijekom treniranja (engl. angle) postavljen je na nula,
- nasumična promjena zasićenja boja na slici (engl. saturation) postavljena je na 1.5,
- nasumična promjena svjetline na slici (engl. exposure) postavljena je na 1.5,
- nasumična promjena boje na slikama (engl. hue) postavljena je na 0.1,
- broj slika koje se tijekom jedne iteracije koristiti za treniranje (engl. batch) postavljen je na 64,
- veličina podgrupe u koje su podijeljene slike tijekom treniranja (engl. subdivisions) također je postavljena na 64, što označava da se slike ne učitavaju paralelno, već se od jednom učitava samo jedna slika, što je postavljeno zbog nemogućnosti grafičke kartice da podnese paralelno učitavanje slika i zbog toga se proces učenja odvija puno sporije (broj paralelno učitavanih slika dobivamo dijeleći broj slika u jednoj iteraciji za učenje s brojem podgrupa),
- kao aktivacijska funkcija korištena je Leaky ReLu,
- širina (engl. width) i visina (engl. height) ulaza u mrežu postavljene su na 800,
- konačan broj iteracija (engl. max batches) postavljen je na 8.000 (definira se kao broj klasa pomnožen s 2.000),
- broj koraka (engl. steps) na kojima se mijenja stopa učenja, tako da se množi s unaprijed određenim koeficijentom (engl. scales=0,1), postavljen je na 6.400 i 7.200 (jer se postavlja na 80% i 90% vrijednosti konačnog broja iteracija),

- broj klasa je postavljen na četiri,
- svaki od filtara prije svakog YOLO sloja postavljen je na 27 (broj filtara odgovara broju klasa uvećanom za pet i zatim pomnoženom sa tri).

Nakon postavljanja parametara proces učenja može se započeti. U ovome diplomskom radu za učenje YOLO algoritma korištene su težine prethodno naučene na COCO skupu podataka. Korištenje prethodno naučenih težina preporuča se zbog smanjenja vremena učenja. Također kako COCO skup podataka pokriva velik broj različitih vrsta objekata, među kojima se nalaze i prometni znakovi, pogodan je za učenje prometnih znakova. Ukupni skup podataka prije početka učenja podijeljen je na dva djela, dio za učenje koji se sastoji od 630 slika i dio za ispitivanje koji se sastoji od 110 slika.

Nakon završetka procesa učenja dobivena je srednja prosječna preciznost (mAP) od 98% i srednja vrijednost gubitka (engl. average loss) od 0,0775. Ovi rezultati pokazuju da je rješenje za detekciju vrlo dobro naučeno, a rezultat detekcije prometnih znakova na naučenoj mreži prikazan je na slici 20. Sa slike 20 vidljivo je da algoritam vrlo dobro otkriva prometne znakove, međutim problemi do kojih dolazi su da označava i refleksiju prometnih znakova na haubi automobila. Također kako se prometni znak udaljava od središta slike i izlazi iz vidnog polja, tako ga okvir više ne označava ispravno. Do ovih problema dolazi jer na podacima za učenje nije vidljiv poklopac motora automobila, pa neuronska mreža nije naučila da se refleksija prometnog znaka ne označava kao prometni znak. Također u skupu podataka za učenje nema dovoljno slika s prometnim znakovima na rubu vidnog polja, kako bi neuronska mreža naučila i iz te drugačije perspektive otkrivati prometni znak. Rješenje ovih problema tako je moguće proširenjem skupa podataka s navedenim primjerima te ponovnim učenjem neuronske mreže.





Slika 20: Rezultati detekcije prometnih znakova YOLO algoritmom

### 5.3. Model za klasifikaciju prometnih znakova

U ovome podpoglavlju opisana je izrada modela za klasifikaciju prometnih znakova te dodatne postavke koje je bilo potrebno podesiti da bi se dobilo dobiveno rješenje i skup podataka koji je korišten za učenje i ispitivanje rješenja. Za rješavanje problema klasifikacije korištena je duboka konvolucijska neuronska mreža.

Skup podataka koji je korišten za učenje neuronske mreže je *German Traffic Sign Recognition Benchmark* (GTSRB). Ovaj skup podataka sastoji se od 51.839 slika izrezanih prometnih znakova. Dimenzije slika su 32x32, a skup je podijeljen na tri djela. Prvi dio za učenje sastoji se od 34.799 slika, drugi dio za provjeru sastoji se od 4.410 slika i treći dio za ispitivanje sastoji se od 12.630 slika. Cijeli skup podataka sastoji se od 43 kategorije prometnih znakova. Svi prometni znakovi koji se nalaze u skupu podataka prikazani su na slici 19. Dodatan prikaz svih prometnih znakova na primjerima iz skupa podataka poredanih po broju kategorije dan je na slici 21. Prikaz koliko primjera sadrži koja kategorija prometnih znakova dan je na slici 22.



Kako bi se skup podatak pripremio za učenje, proveden je postupak predobrade. U predobradi se koristilo skaliranje sivih tonova, izjednačavanje histograma i normalizacija. Proces predobrade slika prikazan je na slici 23.




Slika 23: Prikaz procesa predobrade skupa za učenje

Nakon predobrade podataka skup podataka je bilo potrebno proširiti, s obzirom na to da je distribucija podataka po kategorijama neujednačena, pa neke kategorije imaju i skoro 10 puta manje primjeraka nego druge. Za proširenje skupa podataka korištene su:

- 10 postotna nasumična translacija po horizontalnoj i vertikalnoj osi,
- 20 postotno nasumično zumiranje,
- 10 postotno nasumično smicanje,
- nasumična rotacija od 10 stupnjeva.

Za rješavanje problema klasifikacije korištena je duboka konvolucijska neuronska mreža. Kako je vidljivo iz slike 24 model za klasifikaciju prometnih znakova sastoji se od šest konvolucijskih slojeva, a nakon svakog drugog sloja slijedi sloj sažimanja. Korištena aktivacijska funkcija je ReLu. Nakon prvog i trećeg sloja sažimanja nalazi se ispusni sloj (engl. dropout layer), koji nasumično odbacuje 50% neurona, kako bi se izbjeglo pretjerano prilagođavanje mreže. Na kraju mreže nalaze se sloj sravnivanja, još jedan sloj za odbacivanje i potpuno povezani sloj koji vrši klasifikaciju. Tablični prikaz korištene neuronske mreže i podaci o svakom sloju dani su u tablici 1.



Slika 24: Prikaz modela za klasifikaciju prometnih znakova i toka podataka kroz naučenu neuronsku mrežu

Tablica 1: Prikaz modela za klasifikaciju i informacija o slojevima unutar mreže

<b>Sloj (vrsta)</b>	<b>Izlazne dimenzije</b>	<b>Broj značajki</b>
prvi konvolucijski sloj (Conv2D)	(28, 28, 32)	832
drugi konvolucijski sloj (Conv2D)	(24, 24, 32)	25.632
sloj sažimanja (MaxPooling2D)	(12, 12, 32)	0
ispusni sloj (Dropout)	(12, 12, 32)	0
treći konvolucijski sloj (Conv2D)	(8, 8, 64)	51.264
četvrti konvolucijski sloj (Conv2D)	(8, 8, 64)	36.928
sloj sažimanja (MaxPooling2D)	(4, 4, 64)	0
peti konvolucijski sloj (Conv2D)	(4, 4, 128)	73.856
šesti konvolucijski sloj (Conv2D)	(4, 4, 128)	147.584
sloj sažimanja (MaxPooling2D)	(2, 2, 128)	0
ispusni sloj (Dropout)	(2, 2, 128)	0
sloj spravljanja (Flatten)	(512)	0
ispusni sloj (Dropout)	(512)	0
potpuno povezani sloj (Dense)	(43)	22.059
<b>Ukupni broj značajki: 358.155</b>		

Iz tablice 1 vidljivo je kako se po svakom sloju (engl. layer) mijenjaju broj filtara (zadnji broj unutar zagrada) i dimenzije slike (prvi i drugi broj unutar zagrada) u stupcu oblik (engl. shape). Prema dubljim slojevima, kako se povećava broj filtara, vidljivo je da se povećava i broj značajki (engl. parameters) na temelju kojih mreža uči. Ukupni broj parametara (engl. total parameters) iznosi 358.155.

Nakon što je skup podataka obrađen i neuronska mreža dizajnirana, može se započeti proces učenja. Kod učenja je broj slika koji se koristi pri svakoj iteraciji postavljen na 64, a broj epoha je postavljen na 20. Nakon završetka učenja, u dvadesetoj epohi, ostvareni su sljedeći rezultati: točnost učenja od 97,17%, točnost provjere od 99,18% i konačna točnost ispitivanja od 97,37%. Dodatne mjere uspješnosti po kategorijama prometnih znakova prikazane su u tablici 2.

Tablica 2: Mjere uspješnosti klasifikatora po kategorijama prometnih znakova

	preciznost	odziv	F-1 mjera	broj korištenih primjeraka
Ograničenje brzine (20km/h)	1.00	1.00	1.00	30
Ograničenje brzine (30km/h)	0.99	1.00	0.99	240
Ograničenje brzine (50km/h)	1.00	1.00	1.00	240
Ograničenje brzine (60km/h)	0.98	1.00	0.99	150
Ograničenje brzine (70km/h)	0.99	1.00	1.00	210
Ograničenje brzine (80km/h)	1.00	0.97	0.99	210
Prestanak ograničenja brzine(80km/h)	0.98	1.00	0.99	60
Ograničenje brzine (100km/h)	0.99	1.00	1.00	150
Ograničenje brzine (120km/h)	1.00	0.99	0.99	150
Zabrana pretjecanja	1.00	1.00	1.00	150
Zabrana pretjecanja za teretna vozila	1.00	1.00	1.00	210
Raskrižje sa sporednom cestom	0.99	1.00	0.99	150
Cesta s prednošću prolaza	1.00	1.00	1.00	210
Raskrižje s cestom s prednošću prolaza	1.00	1.00	1.00	240
Obavezno zaustavljanje	1.00	1.00	1.00	90
Zabrana prometa u oba smjera	1.00	0.98	0.99	90
Zabrana prometa za teretna vozila	1.00	0.97	0.98	60
Zabrana prometa u jednom smjeru	0.98	1.00	0.99	120
Opasnost na cesti	1.00	0.99	1.00	120
Opasan zavoj u lijevo	1.00	0.93	0.97	30
Opasan zavoj u desno	1.00	0.87	0.93	60
Opasan dvostruki zavoj	0.98	0.90	0.94	60
Neravan kolnik	1.00	1.00	1.00	60
Sklizak kolnik	0.88	0.98	0.93	60
Suženje kolnika s desne strane	1.00	1.00	1.00	30
Radovi na cesti	0.98	0.99	0.99	150
Nailazak na prometna svjetla	0.98	1.00	0.99	60
Pješaci na cesti	1.00	1.00	1.00	30
Djeca na cesti	1.00	1.00	1.00	60
Biciklisti na cesti	1.00	0.97	0.98	30
Poledica	0.94	1.00	0.97	60
Divljač na cesti	0.99	1.00	0.99	90
Prestanak svih zabrana	1.00	1.00	1.00	30
Obavezno skretanje u desno	1.00	1.00	1.00	90
Obavezno skretanje u lijevo	1.00	1.00	1.00	60
Obavezan smjer ravno	0.98	1.00	0.99	120
Dopušteni smjerovi ravno i desno	1.00	1.00	1.00	60
Dopušteni smjerovi ravno i lijevo	1.00	1.00	1.00	30
Obavezno obilaženje s desna	1.00	1.00	1.00	210
Obavezno obilaženje s lijeva	1.00	1.00	1.00	30
Kružni tok prometa	1.00	1.00	1.00	60
Prestanak zabrane pretjecanja	1.00	1.00	1.00	30
Prestanak zabrane pretjecanja za teretna vozila	1.00	0.97	0.98	30
točnost			0.99	4410
makroskopski prosjek	0.99	0.99	0.99	4410
težinski prosjek	0.99	0.99	0.99	4410



## 5.4. Sustav za prepoznavanje prometnih znakova

Nakon što su model za detekciju prometnih znakova i model za klasifikaciju prometnih znakova uspješno naučeni na skupovima podataka prometnih znakova, sljedeći korak je spajanje tih dvaju modela i prepoznavanje prometnih znakova na video zapisima snimljenim kamerom na prednjoj strani vozila. Spomenuti videozapisi snimljeni su u 25 okvira po sekundi pri razlučivosti 1.920x1.080. Završni sustav za prepoznavanje prometnih znakova i procesi unutar njega prikazani su na slici 25.



Slika 25: Prikaz sustava za prepoznavanje prometnih znakova i procesa u prepoznavanju prometnih znakova



## **6. EVALUACIJA SUSTAVA ZA PREPOZNAVANJE PROMETNIH ZNAKOVA**

Konačni rezultat spoja sustava za detekciju prometnih znakova i sustava za klasifikaciju prometnih znakova u ovome je radu sustav za prepoznavanje prometnih znakova. Kao izlaz sustava za prepoznavanje dobiven je videozapis s označenim graničnim okvirima na predviđenim prometnim znakovima, a iznad svakog graničnog okvira naveden je i naziv predviđenog prometnog znaka.

### **6.1. Rezultati prepoznavanja prometnih znakova**

Sustav za prepoznavanje prometnih znakova ispitan je na stvarnim video zapisima. Rješenje se nastojalo ispitati u što većem broju uvjeta, pa su tako ispitani slučajevi s:

- različitim prometnim znakovima, onima koji se nalaze i onima koji se ne nalaze u skupu podataka za učenje te onima koji se nalaze, ali su drugačijeg dizajna od onih na kojima je mreža učena,
- prometnim znakovima u različitom stanju očuvanosti, znakovima kojima nedostaje dio simbola, izbljedjelim i nečistim znakovima,
- različitim brojem prometnih znakova u jednome okviru,
- različitim intenzitetima svjetlosti,
- različitim kutovima pod kojima se znak promatra,
- različitim brzinama kretanja vozila,
- očuvanim i oštećenim kolnicima.

Tijekom primjene sustava za prepoznavanje prometnih znakova ostvareni su različiti rezultati ovisno o uvjetima na video zapisima. Velik broj postojećih prometnih znakova ne nalazi se u skupu podataka za klasifikaciju. Zbog toga ti znakovi nisu prepoznati. S obzirom na to da je otkrivanje prometnih znakova zasnovano ponajviše na njihovim oblicima, bez obzira na to što se ne nalaze u skupu za klasifikaciju i nisu prepoznati, znakovi su otkriveni i njihova lokacija je označena graničnim okvirom na izlaznom video zapisu.

Uz to što velik broj kategorija prometnih znakova nije uvršten u skup podataka za učenje, također razne varijacije znakova nisu korištene pri učenju. Tako je na slici 26 vidljivo kako je prometni znak koji najavljuje nailazak na prometna svjetla koja su postavljena vertikalno prepoznat, dok nailazak na prometna svjetla postavljena horizontalno sustav ne prepoznaje. Prometni znak koji označava opasan dvostruki zavoj često ne bi bio prepoznat ako je prometnim znakom najavljen prvo desni zavoj, a onda lijevi, kako je prikazano na slici 27. U skupa za učenje najavljen je prvo lijevi, a zatim desni zavoj, što u ovom slučaju dovodi do problema pri prepoznavanju. Također zbog razlike u dizajnu brojke šest, kod znakova ograničenja brzine 60, ova kategorija znakova nije niti jednom ispravno prepoznata, kako je vidljivo na slici 28, već su joj najčešće predviđene kategorije bile ograničenja brzine 50 i 80.



Slika 26: Razlike u prepoznavanju varijacija znaka nailazak na prometna svjetla



Slika 27: Razlike u prepoznavanju varijacija znaka opasan dvostruki zavoj



Slika 28: Prikaz problema u prepoznavanju ograničenja brzine 60

Sustav je pokazao vrlo dobre rezultate prepoznavši sve varijacije prometnog znaka raskrižja sa sporednom cestom, kako je vidljivo na slici 29. Ovi su znakovi ispravno prepoznati neovisno o tome da li se radi o nailasku na sporednu cestu samo s lijeva ili samo s desna ili nailaska na sporednu cestu i s lijeve i s desne strane. Također u video zapisima za ispitivanje svi prometni znakovi koji označavaju radove na cesti, umjesto bijelog središta imaju narančasto središte, što nije utjecalo na točnost prepoznavanja i oni su unatoč razlici svi prepoznati, kako je vidljivo na slici 30.





Slika 29: Prepoznavanje varijacija prometnog znaka raskrižje sa sporednom cestom



Slika 30: Prepoznavanje prometnog znaka radovi na cesti

Kod prepoznavanja znaka zabrane prometa u oba smjera uočeno je da su ovi znakovi bili veliki dio okvira zamijenjeni za druge znakove oblika kruga, kao što su znakovi ograničenja brzine i znakovi koji označavaju kružni tok prometa. Problem može predstavljati to što su ovi znakovi bili postavljeni u videozapisu puno niže nego što su obično prometni znakovi postavljeni, na zaprekama koje označavaju radove na cesti, kao što je vidljivo iz slike 31. Znakovi koji označavaju kružni tok prometa najčešće i jesu postavljeni na ovoj visini. Znak obveze obilaženja s desne strane također je vrlo često postavljen puno niže, a da na njega ne utječe visina dokazano je na slici 32, gdje je ispravno prepoznat lagano zaklonjen, postavljen uz tlo i naslonjen na zid. To ukazuje da na prepoznavanje nekih znakova može imati ulogu visina na kojoj je znak postavljen, ponajviše zbog kuta pod kojim se znak promatra. Razliku između znakova zabrane prometa u oba smjera i znakova ograničenja brzine, čini jedino broj unutar znaka na znakovima ograničenja brzine, što može biti razlog pogrešnog prepoznavanja znakova zabrane prometa u oba smjera.



Slika 31: Prikaz problema prilikom prepoznavanja znaka zabrana prometa u oba smjera





Slika 32: Prepoznavanje zaklonjenog znaka obavezno obilaženje s desna

Što se tiče očuvanosti znakova, u videozapisima je učen znak zabrane pretjecanja bez crvenog simbola automobila. Na njemu nije izvedeno ispravno prepoznavanje, što je vidljivo iz slike 33. Zbog nezadovoljavajućih rezultata prepoznavanja ove kategorije prometnog znaka u dobrom stanju očuvanosti, nije utvrđeno koliko je velik utjecaj navedenog nedostatka na rezultate prepoznavanja. Znakovi zabrane pretjecanja najčešće su bili krivo prepoznati kao znakovi ograničenja brzine i znakovi koji označavaju kružni tok prometa. Međutim znakovi koji označavaju zabranu prometa za autobuse, koji se ne nalaze u skupu podataka za učenje, u svim slučajevima su prepoznati kao znak zabrane pretjecanja. Razlika između ova dva znaka vrlo je mala, s obzirom na to da su simboli na oba znaka pravokutnog oblika i jedino što ih razlikuje je mali razmak između dva pravokutnika na znaku zabrane pretjecanja, koji ne postoji na znaku zabrane prometa autobusima jer simbol čini jedan veliki pravokutnik. Ovaj slučaj može ukazivati na lošu rezoluciju slika na kojima je model za klasifikaciju učen, s obzirom na to da ne može razlikovati dovoljno dobro rubove simbola na prometnim znakovima, zbog čega dolazi do pogrešaka u prepoznavanju na snimkama koje su puno veće rezolucije.

Nekoliko znakova, poput ograničenja brzine 30 i suženja kolnika s desne strane zatečeni su prekriveni zemljanom prašinom, kao što je prikazano na slici 34. Kod ograničenja brzine 30 to nije utjecalo na prepoznavanje, dok kod suženja s desne strane je imalo utjecaj. Izblijedili prometni znakovi nisu imali znatan utjecaj na prepoznavanje, ali se razlika u odnosu na novije i očuvanije prometne znakove može zamijetiti. Sjene koje su padale na znakove nisu utjecale na smanjenje točnosti prepoznavanja, a jači intenziteti svjetlosti koji bi utjecali na rad sustava nisu zabilježeni u video zapisima. Rotacija prometnih znakova utjecala je na rezultate prepoznavanja, pa se prepoznavanje određenih znakova vršilo s puno manjom točnošću, kako se pogled na prometne znakove mijenjao i dok su se oni približavali rubu vidnoga polja.




Slika 33: Prikaz problema prepoznavanja znaka zabrane pretjecanja





Slika 34: Prepoznavanje nečistih prometnih znakova

Izuzet svih problema prilikom prepoznavanja određenih prometnih znakova, na slikama 26, 27, 28, 29, 30, 32, 34, 35 i 36 vidljivo je kako sustav vrlo dobro prepoznaje većinu prometnih znakova. Sustav vrlo dobro prepoznaje znakove i na većim udaljenostima, na kojima su znakovi vrlo mali, kao što je vidljivo na slici 35, gdje je znak pješaci na cesti ispravno prepoznat pri brzini od 50 km/h na okvirnoj udaljenosti od 30 metara. Za neke znakove odlučeno je da rezultati prepoznavanja nisu zadovoljavajući zbog toga što nisu u dovoljnom broju okvira, koji su bili prepoznati, bili ispravno prepoznati. Također sustav za prepoznavanje prometnih znakova pokazao je da broj prometnih znakova u okviru ne utječe na rezultate prepoznavanja te je u jednom trenutku prepoznato bilo u okvirima pet prometnih znakova, kao što je vidljivo na slici 36. Na slici 36 može se vidjeti kako su u isto vrijeme prepoznati znakovi opasnosti na cesti, znakovi ograničenja brzine 50 i znak divljač na cesti. S obzirom na veliki broj okvira po sekundi i visoku razlučivost video zapisa, brzina i oštećeni kolnici nisu stvarali probleme sustavu prepoznavanja.



Slika 35: Prikaz dometa rada sustava prepoznavanjem znaka pješaci na cesti



Slika 36: Prikaz utjecaja prepoznavanja većeg broja prometnih znakova na rezultate prepoznavanja



## 6.2. Moguća unaprjeđenja sustav za prepoznavanje prometnih znakova

Mogućnost unaprjeđenja sustava ponajviše se očituje u unaprjeđenju skupova podataka na kojima je sustav učen. Kod modela za otkrivanje prometnih znakova, skup podataka za učenje sastoji se od svega 740 slika, što je vrlo mali broj reprezentativnih primjeraka za sve stvarne situacije u kojima je moguće zateći prometne znakove. Uz više primjeraka prometnih znakova, u skup podataka mogu se umetnuti i slike na kojima nema prometnih znakova. U skupu podataka za učenje vrlo je mali broj vidljivih poledina prometnih znakova, zbog čega su one na osnovi svog oblika prepoznate kao prometni znakovi, slika 37. Također u skupu podataka za učenje nije vidljiv poklopac motora automobila, na kojoj se mogu vidjeti refleksije znakova, kao na slici 37, pa ih model nije naučio raspoznavati od stvarnih prometnih znakova. Sustav bi se proširenjem skupa podataka za otkrivanje naučio bolje raspoznavati objekte koji nisu prometni znakovi i time bi se smanjio broj netočnih predviđanja, poput onih vidljivih na slici 37.



Slika 37: Problem netočnih predviđanja kod prepoznavanja prometnih znakova

Sljedeća moguća poboljšanja očituju se u boljoj prilagodbi i proširenju skupa podataka za klasifikaciju. Prvi problem ovog skupa podataka predstavlja neujednačen broj primjeraka po kategorijama prometnih znakova. Drugi problem predstavlja mali broj dostupnih kategorija prometnih znakova u korištenom skupu podataka, zbog čega se neki znakovi nisu mogli ispravno razlikovati, jer razlike nisu naučene. Ovaj problem dovodi i do nemogućnosti sustava da prepozna različite inačice prometnih znakova. Nedovoljan broj različitih primjeraka jedno je od glavnih ograničenja u primjeni duboki neuronskih mreža na velikom skupu kategorija prometnih znakova [42]. Treći problem predstavlja velika razlika u rezoluciji slika, što ujedno utječe i na veliku razliku u broju različitih značajki koje na slikama neuronska mreža može naučiti. Ovaj problem posebice je uočljiv kada se normalizira veličina slika na dimenzije 32x32. Moguće je povećati dimenzije i vršiti učenje i klasifikaciju na slikama većih dimenzija, poput 64x64 ili 128x128, no to bi izravno utjecalo na povećanje broja ukupnih značajki mreže, povećalo računalne zahtjeve za obradom podataka i znatno produljilo vrijeme učenja. Četvrti problem je loš kontrast na većem dijelu primjeraka, zbog čega su slabije izraženi rubovi na objektima, što otežava prepoznavanje ključnih značajki. Peti problem predstavlja zamućenost određenog dijela prometnih znakova, uzrokovanu brzinom kretanja vozila, što onemogućuje razlikovanje piksela i samim time razlikovanje bitnih značajki.

Rješenjem navedenih problema znatno bi se smanjio broj slučajeva u kojima sustav za prepoznavanje ne može razlikovati značajke znaka i ispravno ga prepoznati, a povećala bi se i stabilnost prepoznavanja kroz okvire video zapisa. Također bi bio smanjen utjecaj očuvanosti prometnih znakova na ispravnost prepoznavanja i omogućilo bi se prepoznavanje prometnih znakova na još većim udaljenostima. Uz proširenje skupova podataka za otkrivanje i klasifikaciju prikupljanjem novih podataka u višoj rezoluciji, preporučuje se dodatno ispitivanje utjecaja primjene metoda za predobradu i proširenje skupova podataka na novim skupovima podataka.

## 7. ZAKLJUČAK

Napredni sustavi za pomoć vozaču vrlo su važni za sigurnost prometa. Oni predstavljaju novi korak u nastojanju čovjeka da poveća razinu sigurnosti u prometu i smanji broj prometnih nesreća. Jedna od važnijih primjena ovih sustava prepoznata je u prepoznavanju prometnih znakova. Napredni sustavi za pomoć vozaču zasnovani na prepoznavanju prometnih znakova pomažu vozaču da se pridržava prometnih pravila definiranih prometnim znakovima.

Za potrebe ovoga rada izrađen je sustav za prepoznavanje prometnih znakova. Sustav se sastoji od dva dijela. Prvi dio čini YOLO algoritam za otkrivanje prometnih znakova, a drugi duboka konvolucijska neuronska mreža za klasifikaciju prometnih znakova. Svaki od modela učen je na svom skupu podataka. Model za otkrivanje izrađen je da otkriva prometne znakove na temelju njihove boje i oblika te označava njihovu lokaciju graničnim okvirima. Tako označeni granični okviri izrezuju se i prosljeđuju sustavu za klasifikaciju. Ovaj sustav zatim na temelju oblika i simbola predviđa kojoj kategoriji pripada prometni znak iz izrezane slike.

Djelovanje sustava za prepoznavanje prometnih znakova evaluirano je na stvarnim video snimkama s kamere iz vozila. Evaluacijom sustava napravljen je uvid u utjecaj kvalitete, raznolikosti i broja primjeraka unutar skupova za učenje na konačne rezultate. Zaključeno je da mali broj primjeraka prometnih znakova u većem broju kategorija znatno utječe na točnost prepoznavanja. Utjecaj ima i mala rezolucija primjeraka u skupovima za učenje. Posebice je utjecaj rezolucije vidljiv na skupu podataka za učenje modela za klasifikaciju, kod kojeg je vrlo bitno raspoznavanje sitnih ključnih značajki simbola na prometnim znakovima. Također je vidljiv i utjecaj pojedinih situacija na prepoznavanje prometnih znakova. Vidljivo je kako sustav prepoznaje prometne znakove iste kategorije, ali različitoga dizajna te neodržavane prometne znakove. S obzirom na rezultate prepoznavanja može se reći da sustav vrlo dobro prepoznaje prometne znakove, no zbog nekolicine problema poput prepoznavanja poledine prometnog znaka ili refleksije prometnog znaka na haubi automobila prepoznate su mogućnosti unaprjeđenja.

Mogućnosti unaprjeđenja implementiranog prepoznavanja znakova ponajviše su prepoznate u proširenju skupova podataka za učenje. Predlaže se proširenje skupa za klasifikacija kategorijama prometnih znakove koje nisu dostupne, različitim inačicama prometnih znakova i ono najvažnije, slikama u visokoj rezoluciji. To je potrebno kako bi neuronska mreža mogla bolje razlikovati piksele, a samim time prikupiti i više jedinstvenih značajki. Proširenje skupa podataka za otkrivanje sljedeći je prijedlog unaprjeđenja. Ono je moguće povećanjem broja primjeraka prometnih znakova i znakova na različitim udaljenostima, promatranih pod različitim kutovima. Moguće je i proširenje skupa slikama s refleksijama prometnih znakova i njihovim poleđinama, kako bi neuronska mreža naučila raspoznavati ih od pravih prometnih znakova. Nakon proširenja skupova podataka i evaluacije utjecaja proširenja skupova podataka na rad sustava, predlaže se ispitivanje primjene metoda predobrade podataka za dodatno povećanje točnosti prepoznavanja.

# LITERATURA

- [1] Centar za vozila Hrvatske. Napredni sustavi za podršku pri upravljanju vozilom, Zagreb, 2021.
- [2] European Road Safety Observatory. Advanced driver Assistance systems, 2016.
- [3] Kukkala V. K., Tunnell J., Pasricha S., Bradley T., Advanced Driver-Assistance Systems: A path toward autonomous vehicles, IEEE consumer electronics magazine, rujan 2018; str.18-25.
- [4] Andrić K., Pregled sustava za automatsko prepoznavanje prometnih znakova, Završni rad, Zagreb: Fakultet prometnih znanosti; 2021.
- [5] Ayachi R., Afif M., Said Y., Ben Abdelali A., Traffic Sign Recognition Based on Scaled Convolutional Neural Network For Advanced Driver Assistance System, IEEE 4<sup>th</sup> International Conference on Image Processing, Applications and Systems, 2020; str. 149-154.
- [6] Pravilnik o prometnim znakovima, signalizaciji i opremi na cestama (NN 33/05, 64/05, 155/05, 14/11).
- [7] Signal Systems službena web stranica. Preuzeto sa: [http://signalsistem.hr/wp-content/uploads/2015/01/katalog\\_mali.pdf](http://signalsistem.hr/wp-content/uploads/2015/01/katalog_mali.pdf) [Pristupljeno: kolovoz 2021.].
- [8] Fleyeh H., Dougherty M., Road and Traffic Sign Detection and Recognition; Advanced OR and AI Methods in Transportation; str. 645-653.
- [9] Sun Y., Ge P., Liu D., Traffic Sign Detection and Recognition Based on Convolutional Neural Network, Chinese Automation Congress, 2019; str. 2851-2854.
- [10] YML agencija za digitalne proizvode i dizajn web stranice. Preuzeto sa: <https://medium.com/ymedialabs-innovation/data-augmentation-techniques-in-cnn-using-tensorflow-371ae43d5be9> [Pristupljeno: kolovoz 2021.]
- [11] Radu M.D., Costea I.M., Stan V.A., Automatic Traffic Sign Recognition Artificial Intelligence – Deep Learning Algorithm, 12<sup>th</sup> International Conference on Electronics, Computers and Artificial Intelligence, 2020; str. 1-4.
- [12] Geeks for geeks portal. Preuzeto sa: <https://www.geeksforgeeks.org/histograms-equalization-opencv/> [Pristupljeno: kolovoz 2021.].
- [13] Becoming Human web članci i istraživanja iz područja umjetne inteligencije. Preuzeto sa: <https://becominghuman.ai/image-data-pre-processing-for-neural-networks-498289068258> [Pristupljeno: kolovoz 2021.].

- [14] Kovaček I., Sustav za detekciju i raspoznavanje prometnih znakova, Zagreb: Fakultet elektrotehnike i računarstva; 2010.
- [15] Towards data science portal. Preuzeto sa: <https://towardsdatascience.com/data-augmentation-compilation-with-python-and-opencv-b76b1cd500e0> [Pristupljeno: kolovoz 2021.].
- [16] Lodhi A., Singhal S., Massoudi M., Car Traffic Sign Recognizer Using Convolutional Neural Network CNN, Proceedings of the 6<sup>th</sup> International Conference on Inventive Computation Technologies, 2021; str. 577-582.
- [17] Ivanjko E., Uvod u neuronske mreže, Nastavni materijali iz kolegija Umjetna inteligencija, Zagreb: Fakultet prometnih znanosti; 2020.
- [18] Mačkić K., Primjena neuronskih mreža u fizici i informatici, Diplomski rad, Zagreb: Prirodoslovno – matematički fakultet, Fizički odsjek; 2009.
- [19] Mijić D., Algoritam za autonomnu vožnju zasnovan na prepoznavanju prometnih znakova, Diplomski rad, Osijek: Fakultet elektrotehnike, računarstva i informacijskih tehnologija; 2019.
- [20] Texas Instruments službena web stranica. Preuzeto sa: [https://e2e.ti.com/blogs\\_/b/behind\\_the\\_wheel/posts/ai-in-automotive-practical-deep-learning](https://e2e.ti.com/blogs_/b/behind_the_wheel/posts/ai-in-automotive-practical-deep-learning) [Pristupljeno: kolovoz 2021.].
- [21] Matoš I., Klasifikacija prometnih znakova korištenjem konvolucijskih neuronskih mreža, Diplomski rad, Osijek: Fakultet elektrotehnike, računarstva i informacijskih tehnologija; 2020.
- [22] Medium platforma. Preuzeto sa: <https://medium.com/@danqing/a-practical-guide-to-relu-b83ca804f1f7> [Pristupljeno: kolovoz 2021.].
- [23] Towards data science portal. Preuzeto sa: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> [Pristupljeno: kolovoz 2021.].
- [24] Mikulić F., Automatsko zaustavljanje vozila na osnovu prometne signalizacije, Diplomski rad, Osijek: Fakultet elektrotehnike, računarstva i informacijskih tehnologija; 2019.
- [25] Dalbelo Bašić B., Čupić M., Šnajder J., Umjetne neuronske mreže, Nastavni materijali iz kolegija Umjetna inteligencija, Zagreb: Fakultet elektrotehnike i računarstva; 2008.
- [26] Google Colaboratory službena web stranica. Preuzeto sa: <https://research.google.com/colaboratory/faq.html> [Pristupljeno: kolovoz 2021.].



- [27] Google Cloud službena web stranica. Preuzeto sa: <https://cloud.google.com/gpu> [Pristupljeno: kolovoz 2021.].
- [28] NumPy službena web stranica. Preuzeto sa: <https://numpy.org/doc/stable/user/whatisnumpy.html> [Pristupljeno kolovoz 2021.].
- [29] OpenCV službena web stranica. Preuzeto sa: <https://opencv.org/about/> [Pristupljeno: kolovoz 2021.].
- [30] GitHub službena web stranica. Preuzeto sa: <https://github.com/tensorflow/tensorflow> [Pristupljeno: kolovoz 2021.].
- [31] Keras službena web stranica. Preuzeto sa: <https://keras.io/about/> [Pristupljeno: kolovoz 2021.].
- [32] YOLO Pjerdie web stranica razvojnog okvira Darknet. Preuzeto sa: <https://pjreddie.com/darknet/> [Pristupljeno: kolovoz 2021.].
- [33] Nvidia službena web stranica. Preuzeto sa: <https://developer.nvidia.com/cuda-zone%20%5b> [Pristupljeno: kolovoz 2021.].
- [34] Roboflow službena web stranica. Preuzeto sa: <https://blog.roboflow.com/a-thorough-breakdown-of-yolov4/> [Pristupljeno: kolovoz 2021.].
- [35] Pjerdie web stranica razvojnog okvira Darknet. Preuzeto sa: <https://pjreddie.com/darknet/yolo/> [Pristupljeno: kolovoz 2021.].
- [36] Novak B., Ilić V., Pavković B., YOLOv3 Algorithm with additional convolutional neural network trained for traffic sign recognition, Zoomin Innovation in Consumer Technologies Conference, 2020; str. 165-168.
- [37] Wand H., Yu H., Traffic Sign Detection Algorithm based on improved YOLOv4, IEEE 9<sup>th</sup> joint International Information Technology and Artificial Intelligence Conference, 2020; str. 1946-1950.
- [38] Ruta A., Porikli F., Watanabe S., Li Y., In-vehicle camera traffic sign detection and recognition. Machine Vision and Applications, 2009, str. 359-375.
- [39] Chiung-Yao F., Sei-Wang C., Chiou-Shann F., Road-Sign Detection and Tracking, IEEE Transactions on Vehicular Technology, 2003; vol. 52, br. 5: str. 1329-1341.
- [40] Lihua W., Kang-Hyun J., Traffic sign recognition and classification with modified residual networks. IEEE/SICE International Symposium on System Integration. 2017; str. 835-840.

- [41] Saleh S., Khwandah S. A., Mumtaz A., Heller A., Hardt W., Traffic Signs Recognition and Distance Estimation using a Monocular Camera. Actual Problems of System and Software Engineering, Rusija, Moskva; 2019.
- [42] Tabernik D., Skočaj D., Deep Learning for Large-Scale Traffic-Sign Detection and Recognition, IEEE Transactions on Intelligent Transportation Systems, 2020; vol. 21, br. 4: str. 1427-1440.

## POPIS KRATICA

ABS	sustav protiv blokiranja kotača (engl. Anti-lock Breaking System)
ACC	sustav za automatsku prilagodbu brzine kretanja (engl. Adaptive Cruise Control)
ADAS	napredni sustavi za pomoć vozaču (engl. Advanced Driver Assistance Systems)
AEB	sustav automatskog kočenja (engl. Autonomous Emergency Breaking)
AH	sustav za prilagođavanje svjetlosnog snopa (engl. Adaptive Headlights)
ANN	umjetna neuronska mreža (engl. Artificial Neural Network)
AP	prosječna preciznost (engl. Average Precision)
API	aplikacijsko programsko sučelje (engl. Application Programming Interface)
BSA	sustav nadzora mrtvog kuta (engl. Blind Spot Assist)
CNN	konvolucijska neuronska mreža (engl. Convolutional Neural Network)
CTA	sustav za upozoravanje vozača na nailazeća vozila (engl. Cross-Traffic Alerts)
CV	računalni vid (engl. Computer Vision)
DDD	sustav za upozoravanje vozača u slučaju pospanosti (engl. Driver Drowsiness Detection)
DMS	sustav za nadzor vozača (engl. Driver Monitoring System)
ESP	elektronički program stabilnosti (engl. Electronic Stability Program)
FN	lažno negativan, nepredviđen (engl. False negative)
FOV	horizontalno vidno polje (engl. Field of View)
FP	lažno pozitivan, netočno predviđen (engl. False positive)
FPS	broj kadrova u sekundi (engl. Frames per Second)
GPS	globalni položajni sustav (engl. Global Positioning System)
GTSDB	German Traffic Sign Detection Benchmark
GTSRB	German Traffic Sign Recognition Benchmark
ISA	sustav inteligentne prilagodbe brzine (engl. Intelligent Speed Adaptation)
LKA	sustav zadržavanja vozila u prometnom traku (engl. Lane Keeping Assist)
mAP	srednja prosječna preciznost (engl. mean Average Precision)
NV	noćni vid (engl. Night Vision)
PA	sustav za pomoć prilikom parkiranja (engl. Park Assist)
PD	sustav za prepoznavanje pješaka (engl. Pedestrian Detection)
PMD	foto-električna mjerna osjetila (engl. Photonic Mixer Device)
RCW	stražnji sustav za upozoravanje vozača na nailazeća vozila (engl. Rear Collision Warning)
RGB	crvena, zelena, plava (engl. Red, Green, Blue)
TCS	sustav kontrole proklizavanja (engl. Traction Control System)
TP	točno predviđen (engl. True positive)
TSR	sustav prepoznavanja prometnih znakova (engl. Traffic Sign Recognition System)

# POPIS SLIKA

Slika 1: Podjela mjernih osjetila unutar ADAS sustava .....	8
Slika 2: Prikaz mjernih osjetila korištenih u ADAS sustavima i sustava u kojima se koriste .....	11
Slika 3: Sastavni dijelovi sustava prepoznavanja prometnih znakova.....	12
Slika 4: Znakovi opasnosti .....	16
Slika 5: Znakovi izričitih naredbi .....	17
Slika 6: Znakovi obavijesti .....	19
Slika 7: Model umjetnog neurona.....	26
Slika 8: Arhitektura umjetne neuronske mreže .....	27
Slika 9: Primjer strukture i primjene konvolucijske neuronske mreže nad prometnim znakom ograničenja brzine 50 mph .....	28
Slika 10: Primjer RGB slike veličine 5x5 s prikazom vrijednosti elemenata slike razdijeljenih po kanalima boja.....	29
Slika 11: Primjer procesa operacije konvolucije korištenjem filtra 3x3 .....	30
Slika 12: Prikaz aktivacijskih funkcija ReLu, Propuštajući ReLu i Parametarski ReLu .....	33
Slika 13: Grafički prikaz metode sažimanja po maksimalnoj vrijednosti.....	33
Slika 14: Prikaz potpuno povezanog sloja .....	34
Slika 15: Odstupanje stvarnog izlaza kroz iteracije.....	36
Slika 16: Grafički prikaz parametra IoU .....	38
Slika 17: Prikaz primjene YOLO mreže na ulaznoj slici .....	43
Slika 18: Primjer slike iz skupa podataka za detekciju prometnih znakova .....	45
Slika 19: Prikaz podijele znakova u četiri kategorije za detekciju.....	46
Slika 20: Rezultati detekcije prometnih znakova YOLO algoritmom .....	49
Slika 21: Primjeri prometnih znakova iz skupa podataka za klasifikaciju prometnih znakova.....	50
Slika 22: Distribucija podataka za učenje .....	50
Slika 23: Prikaz procesa predobrade skupa za učenje .....	51
Slika 24: Prikaz modela za klasifikaciju prometnih znakova i toka podataka kroz naučenu neuronsku mrežu .....	52
Slika 25: Prikaz sustava za prepoznavanje prometnih znakova i procesa u prepoznavanju prometnih znakova.....	56
Slika 26: Razlike u prepoznavanju varijacija znaka nailazak na prometna svjetla.....	59
Slika 27: Razlike u prepoznavanju varijacija znaka opasan dvostruki zavoj .....	59
Slika 28: Prikaz problema u prepoznavanju ograničenja brzine 60.....	60

Slika 29: Prepoznavanje varijacija prometnog znaka raskrižje sa sporednom cestom.....	61
Slika 30: Prepoznavanje prometnog znaka radovi na cesti .....	61
Slika 31: Prikaz problema prilikom prepoznavanja znaka zabrana prometa u oba smjera.....	62
Slika 32: Prepoznavanje zaklonjenog znaka obavezno obilaženje s desna.....	63
Slika 33: Prikaz problema prepoznavanja znaka zabrane pretjecanja .....	64
Slika 34: Prepoznavanje nečistih prometnih zrakova .....	65
Slika 35: Prikaz dometa rada sustava prepoznavanjem znaka pješaci na cesti.....	66
Slika 36: Prikaz utjecaja prepoznavanja većeg broja prometnih znakova na rezultate prepoznavanja .....	66
Slika 37: Problem netočnih predviđanja kod prepoznavanja prometnih znakova.....	67

## **POPIS TABLICA**

Tablica 1: Prikaz modela za klasifikaciju i informacija o slojevima unutar mreže .....	53
Tablica 2: Mjere uspješnosti klasifikatora po kategorijama prometnih znakova .....	55



Sveučilište u Zagrebu  
Fakultet prometnih znanosti  
10000 Zagreb  
Vukelićeva 4

## IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj \_\_\_\_\_ diplomski rad  
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na  
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.  
Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz  
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.  
Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj  
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.  
Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu \_\_\_\_\_ diplomskog rada  
pod naslovom **Prepoznavanje prometnih znakova primjenom računalnog vida**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom  
repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 9/9/2021

Student/ica:

F.A. Pavlinić  
(potpis)