



UNIVERZITET U BANJOJ LUCI
ELEKTROTEHNIČKI FAKULTET



Vladimir Lekić

Obrada signala senzora autonomnih vozila korišćenjem vještačkih neuronskih mreža

DOKTORSKA DISERTACIJA

Banja Luka, 2020.



UNIVERSITY OF BANJA LUKA
FACULTY OF ELECTRICAL ENGINEERING



Vladimir Lekić

Highly-Automated-Vehicle Sensors Signal Processing Using Artificial Neural Networks

DOCTORAL DISSERTATION

Banja Luka, 2020.

Informacije o mentoru i disertaciji

Mentor:

Dr. Zdenka Babić, redovni profesor
Univerzitet u Banjoj Luci, Elektrotehnički fakultet

Naslov doktorske disertacije:

Obrada signala senzora autonomnih vozila korišćenjem vještačkih neuronskih mreža

Rezime:

U ovoj disertaciji pokazano je da se korišćenjem vještačkih neuronskih mreža, dovođenjem senzorskih mjerena jednog modaliteta na ulaz modela, na izlazu mogu dobiti vještačka senzorska mjerena drugog modaliteta. Obilježja sadržana u ulaznim signalima na taj način transformišu se u prostor obilježja izlaznog signala. U disertaciji ovaj proces naziva se transformacija obilježja. Osnovni doprinos ove disertacije je novi, nenadgledani metod mašinskog učenja, takozvana uslovna generativna suparnička mreža sa više generatora, koji omogućava ovakvu transformaciju obilježja. Analizom karakteristika senzora i metoda fuzije i interpretacije senzorskih mjerena, dolazi se do zaključka da se, za nadgledanje okruženja visoko automatizovanih vozila, slike dobijene kamerama koriste kao glavni nosioci semantičkih informacija. Istovremeno, zbog relativno jednostavnog procesa anotacije slika, na raspolaganju stoji veliki broj javno dostupnih anotiranih skupova podataka koji omogućavaju obučavanje algoritama mašinskog učenja visokog kapaciteta. Kamere su, sa druge strane, osjetljive na otežane radne uslove, kao što su loše ili prekomjerno osvjetljenje ili nepovoljne meteorološke pojave, pa je uz njih potrebno koristiti senzore koji se zasnivaju na drugačijem mjernom principu. Radari se zbog visoke pouzdanosti rada u gotovo svim meteorološkim uslovima nameću kao logično rješenje. Međutim, mjerena radara, za razliku od slika dobijenih kamerom, do sada se nisu pokazala pogodna za prepoznavanje i semantičku klasifikaciju objekata. Upravo radi toga, eksperimentalna analiza, u ovoj disertaciji predloženog metoda transformacije obilježja, izvršena je korišćenjem mjerena radarskog senzora kao ulaznog signala i slika kao izlaznog signala. Obučena uslovna generativna suparnička mreža sa više generatora, sa predstavljenim novim radarskim mjerenjima na ulazima generatora, u mogućnosti je da generiše vještačke slike, nezavisno od kamera koje eventualno postoje u senzorskoj konfiguraciji visoko automatizovanog vozila. U disertaciji je pokazano da generisane, vještačke slike kvalitativno i kvantitativno sadrže obilježja okruženja detektovana radarom, te da ih je moguće koristiti za semantičku segmentaciju ili regresiju korišćenjem nekih od nadgledanih algoritama mašinskog učenja.

Ključne riječi: autonomna vozila, mašinsko učenje, GAN, generative suparničke mreže, fuzija informacija, Dempster-Šaferova teorija, semantička segmentacija

Naučna oblast: Inženjerstvo i tehnologija

Naučno polje: Elektrotehnika, elektronika i informaciono inženjerstvo

Klasifikaciona oznaka: T 121

Tip odabrane licence Kreativne zajednice: CC BY-SA

Information about mentor and dissertation

Mentor:

Dr. Zdenka Babić, full-time professor
University of Banja Luka, Faculty of electrical engineering

Title of doctoral dissertation:

Highly-Automated-Vehicle Sensors Signal Processing Using Artificial Neural Networks

Abstract:

In this dissertation, it is shown that by using artificial neural networks, based on the inputs of sensor measurements of one modality, at the output it is possible to obtain the artificial sensor measurements of another modality. This process is called feature transformation, as the features from one feature space are transformed into the features in another feature space. To enable feature transformation, in this dissertation is introduced a new, unsupervised machine learning model, so-called Conditional Multi-Generator Generative Adversarial Network. By analyzing the sensor's characteristics and methods for fusion and interpretation of sensor measurements one easily concludes that for the environment perception of the highly-automated vehicles, images from the cameras are the main semantic information carrier in the system. Due to the simplicity of image annotation, there are many publicly available annotated sets of images that enable the use of high capacity machine learning algorithms, namely deep neural networks. Cameras are on the other side sensitive to bad lighting and harsh weather conditions. Having another type of sensor in the sensor configuration is, therefore, a must. Due to their robustness to almost all weather conditions, radars impose themselves as a natural solution. Radar measurements, on the other hand, are not particularly useful for object detection and semantic classification. Because of this, experimental analysis of, in this dissertation proposed feature transformation method, has been performed using radar measurements as a source feature space and images as target feature space. In this case, a trained neural network with radar measurements at its input can generate a camera-like images at its output. In dissertation is also shown that generated artificial images qualitatively and quantitatively contain the features of the environment detected by the radar and that such images are a good input for the high-capacity machine learning algorithms for semantic segmentation and object detection.

Keywords: autonomous vehicles, machine learning, GAN, generative adversarial networks, sensor fusion, Dempster-Shefer Theory, semantic segmentation

Scientific area: Engineering and technology

Scientific field: Electrical, electronic and information engineering

Classification code: T 121

Creative Commons license type: CC BY-SA

Zahvalnice

Disertacija „Obrada signala senzora autonomnih vozila korišćenjem vještačkih neuronskih mreža“ većim djelom nastala je u toku višegodišnjeg, istraživačkog rada na projektima visoko automatizovanih sistema vožnje firmi *Elektrobit Automotive GmbH* i *Mercedes-Benz Cars & Vans AG*. Kolegama iz obje firme, posebno dr Markus Thomu, dr Lars Kruegeru i Daniel Wiensu želio bih iskazati zahvalnost na svim korisnim savjetima i razgovorima koji su značajno uticali na moj istraživački put.

Veliku zahvalnost dugujem dr Zdenki Babić, redovnom profesoru Elektrotehničkog fakulteta, Univerziteta u Banjoj Luci, na ukazanom povjerenju, nesebičnoj pomoći, na svim savjetima i trudu da ova disertacija ugleda svjetlo dana.

Takođe, želio bih da izrazim zahvalnost profesorima i kolegama: dr Nikoli Tesliću, dr Vladimiru Risojeviću, dr Mariju Muštri i dr Alekseju Avramoviću, na svim datim komentarima i sugestijama koji su uvelike uticali na konačni sadržaj ove disertacije.

Najveću zahvalnost dugujem svojoj porodici. Majci Radmili i ocu Jovanu zahvaljujem se na neprekidnoj i bezuslovnoj podršci. Supruzi Ivani i sinovima Davidu i Filipu neizmjerno se zahvaljujem na ukazanom povjerenju i strpljenju koje su pokazali u toku izrade ove disertacije.

Vladimir Lekić

Januar, 2020.

Ulm, Njemačka

Supruzi
Ivani
i sinovima
Davidu i Filipu.

Sadržaj

Informacije o mentoru i disertaciji	i
Information about mentor and dissertation	ii
Zahvalnice	iii
Posveta	iv
Spisak tabela	ix
Spisak slika	x
1 Uvod	1
1.1 Nadgledanje okruženja sistemskog vozila	3
1.1.1 Statičke karakteristike senzora	3
1.1.2 Senzorska konfiguracija visoko automatizovanih vozila	5
1.2 Fuzija i interpretacija senzorskih mjerena	6
1.3 Doprinos disertacije	10
1.4 Organizacija disertacije	11
1.5 Publikacije	12
2 Arhitektura sistema automatizovane vožnje	13
2.1 Vještina upravljanja automobilom	13
2.2 Funkcionalna arhitektura sistema automatizovane vožnje	15
2.3 Funkcionalna bezbjednost prema standardu ISO 26262	18

SADRŽAJ

2.3.1	Specifikacija bezbjednosnih ciljeva	20
2.3.2	Ispunjavanje zahtjeva za funkcionalnu bezbjednost	21
2.3.3	Prevazilaženje praznina u sljedivosti bezbjednosnih zahtjeva	23
2.3.4	Problem validacije i verifikacije vještačkih neuronskih mreža	23
3	Materijal i metodologija	26
3.1	Dempster-Šaferova rešetka dokaza	26
3.2	Ekstrinsični i intrinsični parametri kamere	31
3.3	Skup podataka PennCOSYVIO	33
3.4	Skup podataka za obučavanje algoritama za transformaciju obilježja	35
3.5	Skup podataka za obučavanje algoritama za semantičku segmentaciju	40
3.5.1	ADE20K	40
3.5.2	Imagenet	41
3.5.3	MNIST	42
3.6	Metodologija testiranja	43
4	Generativne suparničke mreže	45
4.1	Teorija igara i igre sa nultom sumom	46
4.2	Arhitektura generativnih suparničkih mreža	47
4.3	Obučavanje generativnih suparničkih mreža	48
4.4	DCGAN	50
4.5	Eksperimentalni rezultati i diskusija	52
5	Uslovne generativne suparničke mreže	54
5.1	Uslovne generativne suparničke mreže	54
5.2	cDCGAN	55
5.3	Eksperimentalni rezultati i diskusija	56
6	Informacione generativne suparničke mreže	58

SADRŽAJ

6.1	Značaj latentnih promjenljivih	58
6.2	GAN-ovi zasnovani na maksimizaciji uzajamne informacije	61
6.2.1	Varijaciona minoranta uzajamne informacije	61
6.2.2	Regularizacija GAN-ova minorantom uzajamne informacije .	64
6.3	Arhitektura Info-GAN-ova	65
6.4	Eksperimentalni rezultati i diskusija	66
7	Uslovne generativne suparničke mreže sa više generatora	69
7.1	Mješavina GAN-ova	70
7.2	Uslovne generativne suparničke mreže sa više generatora	72
7.3	Diskusija	74
8	Transformacija obilježja i semantička fuzija senzorskih mjerena različitih modaliteta	76
8.1	Transformacija obilježja	76
8.2	Eksperimentalni pristup i postavka eksperimenta	79
8.3	Validacija transformacije obilježja	82
8.3.1	Objektivna ocjena kvaliteta generisanih slika	82
8.3.2	Subjektivna ocjena generisanih slika	85
8.4	Principi semantičke fuzije senzorskih mjerena različitih modaliteta	89
8.5	Diskusija rezultata	90
9	Zaključak	94
	Bibliografija	96
	Biografija autora	104
	Izjava o autorstvu	105

**Izjava kojom se ovlašćuje Univerzitet u Banjoj Luci da
doktorsku disertaciju učini javno dostupnom**

106

**Izjava o identičnosti štampane i elektronske verzije
doktorske disertacije**

107

Spisak tabela

1.1 Stepeni automatizacije motornih vozila prema SAE J3016, BASt i NHTSA normama.	2
2.1 Kategorizacija rizika prema ISO 26262 standardu.	21
2.2 Mehanizmi za detekciju greške na nivou softverske arhitekture . . .	22
8.1 Odgovori na opšta pitanja.	87
8.2 Rezultati statističke analize odgovora na detaljna pitanja 4-9. . .	88
8.3 Odgovori na pitanja o položaju vozila i kvalitetu generisanih obilježja scene.	89

Spisak slika

SPISAK SLIKA

3.2 Primjer Dempster-Šafereve rešetke dokaza. Slika (a) prikazuje preslikavanje boja u uvjerenje o stanju zauzetosti ćelije rešetke. Slike (b) i (c) predstavljaju dva kanala ili sloja Dempster-Šaferove rešetke dokaza, odnosno stepen uvjerenosti u (b) slobodno stanje i (c) zauzeto stanje ćelija rešetke.	31
3.3 Koordinatni sistemi potrebni za proces kalibracije kamere.	32
3.4 Primjer slike iz PennCOSYVIO skupa podataka i primjer upotrebe intrinsičnih parametara kamere za reprojekciju slike na jediničnu sferu.	34
3.5 Reprojekcija piksela slike prikazane na Slici 3.4a na zemljinu ravan.	35
3.6 Podjela dostupnih podataka na podatke za obučavanje, validaciju i testiranje.	36
3.7 Anotirane slike. Anotacija se vrši iscrtavanjem poligona (žute linije) oko piksela koji pripadaju istoj semantičkoj klasi - u ovom slučaju slobodan prostor ispred sistemskog vozila. Odabrani pikseli osjenčeni su takođe žutom bojom.	36
3.8 Prvi skup primjera slika iz skupa podataka za obučavanje. U svakom redu prikazani su slika dobijena kamerom i Dempster-Šaferova rešetka dokaza. Slojevi rešetke dokaza su prikazani na jednoj RGB slici, kod koje R-kanal i G-kanal predstavljaju uvjerenje u stanje zauzeća i stanje slobode ćelije rešetke, respektivno.	38
3.9 Drugi skup primjera slika iz skupa podataka za obučavanje. Kao i na prethodnoj Slici 3.8, u svakom redu prikazani su slika dobijena kamerom i Dempster-Šaferova rešetka dokaza. Slojevi rešetke dokaza su prikazani na jednoj RGB slici, kod koje R-kanal i G-kanal predstavljaju uvjerenje u stanje zauzeća i stanje slobode ćelije rešetke, respektivno.	39

SPISAK SLIKA

3.10 Primjeri slika iz ADE20K skupa podataka. U ovom skupu podataka prisutne su slike scena zatvorenog i otvorenog prostora. Na slici lijevo prikazana je stvarna slika, a na desnoj njena anotacija.	40
3.11 Primjeri slika iz Imagenet skupa podataka. Slike iz ovog skupa su različitih dimenzija. Ispod svake slike data je klasifikacija prikazane scene.	42
3.12 Primjeri slika iz MNIST skupa podataka.	43
4.1 Arhitektura generativne suparničke mreže. Cilj obučavanja je da se generator nauči generisati slike koje su slične onima iz skupa za obučavanje. Diskriminatore se, sa suparničke strane, obučava da nauči razlikovati generisane od pravih slika.	48
4.2 Arhitektura DCGAN mreže. Ulagani vektor slučajnog šuma \mathbf{z} projektuje se nizom slojeva transponovane konvolucije (eng. <i>transposed convolution</i> ili <i>fractional-strided convolution</i>) u sliku. Nizom slojeva konvolucije i potpuno povezanim slojem - fcn (eng. <i>fully-connected layer</i>) diskriminatore projektuje stvarnu x ili generisano sliku $G(\mathbf{z}, \theta_G)$ u vjerovatnoću pripadnosti stvarnom skupu slika.	51
4.3 Primjeri generisanih slika rukom pisanih cifara. Slike su generisane korišćenjem DCGAN mreže, obučene na MNIST skupu podataka. Na slici su prikazana dva skupa generisanih slika grupisanih u matrice dimenzija 8×8	52
5.1 Arhitektura uslovne generativne suparničke mreže. Za razliku od GAN-ova, uslovne generativne suparničke mreže imaju, preko uslovnih promjenljivih, mogućnost kontrolisanog učenja zajedničke distribucije.	55
5.2 Arhitektura cDCGAN mreže dobijena jednostavnom transformacijom ulaza DCGAN mreže.	56

5.3 Primjeri generisanih slika rukom pisanih cifara. Slike su generisane korišćenjem cDCGAN mreže, obučene na MNIST skupu podataka. Na slici su prikazana dva skupa generisanih slika grupisanih u matrice dimenzija 10×10	57
6.1 Arhitektura Info-GAN mreže sa dva latentna koda c_1 i c_2	65
6.2 Primjeri generisanih slika rukom pisanih cifara korišćenjem InfoGAN modela sa tri latentna koda nakon 50 epoha obučavanja. Na prikazanim slikama diskretni kod \mathbf{c}_1 mijenja se po redovima, dok se promjene neprekidnih kodova \mathbf{c}_2 i \mathbf{c}_3 vrše po kolonama.	67
6.3 Primjeri generisanih slika rukom pisanih cifara korišćenjem InfoGAN modela sa tri latentna koda nakon 80 epoha obučavanja. Na prikazanim slikama diskretni kod \mathbf{c}_1 se mijenja po redovima, dok se promjene neprekidnih kodova \mathbf{c}_2 i \mathbf{c}_3 vrše po kolonama.	67
7.1 Arhitektura MGAN mreže.	70
7.2 Arhitektura CMGGAN mreže sa jednim diskriminatorom, N generatora i $M = \binom{N}{2} = N(N - 1)/2$ klasifikatora.	73
8.1 Transformacija obilježja sadržanih u radarskim mjeranjima i slikama dobijenih kamerom korišćenjem CMGGAN mreže.	77
8.2 Pregled koraka evaluacije CMGGAN mreže za transformaciju obilježja i semantičku fuziju slika dobijenih kamerom i mjerena radara.	79
8.3 Detaljna arhitektura dubokih neuronskih mreža kojima se modeluju funkcije generatora, klasifikatora i diskriminatora CMGGAN mreže.	81
8.4 FID mjera u toku obučavanja CMGGAN, InfoGAN i CGAN mreža, za dvije vrijednosti gradijentnog koraka i najoptimalnije vrijednosti hiper-parametera λ i γ . Što je vrijednost FID mjere niža smatra se da je mreža bolja.	83

8.5 Srednja Žakardova ili mIoU mjera nakon svake epohe obučavanja CMGGAN mreže. Punom zelenom i isprekidanom crvenom linijom prikazana je vrijednost mIoU FCN i PSPNET anotacija stvarnih slika iz skupa za validaciju, respektivno.	84
8.6 Primjeri parova stvarnih i generisanih slika korišćenih za subjektivnu ocjenu kvaliteta generisanih slika. Kod svakog od četiri para slika gornja slika predstavlja stvarnu sliku kamere, a donja slika sliku generisanu CMGGAN mrežom na osnovu radarskih rešetki dokaza. . .	86
8.7 Princip automatske anotacije radarske rešetke dokaza korišćenjem CMGGAN-ova.	89
8.8 Princip fuzije piksela generisane i stvarne slike dobijene kamerom u cilju povećanja vjerodostojnosti mjerena.	90
8.9 Slike generisane instancama CMGGAN mreže koje su ostvarile najveći mIoU. Odozgo prema dole, na objema slikama vrste predstavljaju: stvarne slike, generisane slike i radarske rešetke dokaza. Posmatrano slike po kolonama, generisane slike su generisane CMGGAN mrežom na osnovu radarskih rešetki. Radarske rešetke dokaza su, u toku faze obučavanja mreže, sa stvarnim slikama činile par za obučavanje.	91
8.10 Uporedni prikaz ručno i automatski anotiranih slika iz skupa za obučavanje i slika generisana korišćenjem CMGGAN mreže. . . .	92

Glava 1

Uvod

Riječ automobil nastala je krajem 19. vijeka i u francuskom pojmu „voiture automobile“, korišćena je da ukaže na razliku između parno pogonjenih i, tada uobičajenih, zaprežnih vozila. Sama riječ izvedena je iz grčke riječi *αυτος* („sam, samostalno, lično, vlastiti“) i latinske riječi *mobilis* („pokretan, promjenljiv“). Riječ „autonomno“ kovanica je dvije grčke riječi *αυτος* i *νόμος* („zakon, nametnuti zakon“), a u kontekstu autonomnih vozila, *νόμος* ili zakon pod kojim vozilo *αυτος* ili samostalno obavlja vozni zadatak definisan je i programiran od strane čovjeka [2].

Autonomno vozilo potrebno je posmatrati kao najviši stepen automatizacije vožnje, lišeno bilo kakve forme samostalnog odlučivanja. Tako ni istraživanja u oblasti autonomne vožnje ne treba shvatiti kao potragu za nekom formom opšte vještačke inteligencije, koja bi bila u stanju da samostalno, poštujući uobičajene društvene norme upravlja motornim vozilom, već kao traženje optimalne kombinacije tehnologija koje bi, pod važećim normama u automobilskoj industriji, omogućile motornom vozilu samostalno ispunjavanje voznih zadataka. U disertaciji se radi toga umjesto izraza autonomno vozilo radije koriste izrazi automatizovano ili visoko automatizovano vozilo.

O tome šta jedno vozilo čini automatizovanim, potrebno je usaglasiti mišljenja svih interesnih grupa uključenih u razvoj istih. Upravo radi toga, radna grupa BASt (njem. Bundesanstalt für Straßenwesen - BASt) pri njemačkoj saveznoj vladu je još 2010. godine definisala 5 stepeni automatizacije vožnje [3]. Slično njima, i američka NHTSA (eng. *National Highway Traffic Safety Administration*) definiše 5 stepeni automatizacije [4]. Međutim, kategorizacija koja potiče od Udruženja automobilskih inženjera - SAE (eng. *Society of Automotive Engineers*) je u međuvremenu postala opšte prihvaćena i de-facto standard prilikom opisivanja automatizovanih sistema vožnje. Normom SAE J3016 [5] definisano je 6 stepeni automatizacije. Pre-gled svih navedenih kategorizacija je dat u Tabeli 1.1.

Cilj ovakvih kategorizacija se svodi na definisanje uloge vozača u toku vožnje ili takozvanog dinamičkog voznog zadatka (eng. *DDT - Dynamic Driving Task*). Kao

Tabela 1.1: Stepeni automatizacije motornih vozila prema SAE J3016, BASt i NHTSA normama.

SAE stepen	SAE naziv	SAE opis	Upravljanje vozilom i kontrola ubrzanja vozila	Nadgledanje okruženja vozila	Kontrola nad vozilom u slučaju nužde	Mogućnosti sistema	BASt stepen	NHTSA stepen
Vozac nadgleda okruženje vozila								
0	Bez automatizacije	Svi aspekti vožnje u potpunosti su pod kontrolom vozača.	Vозач	Vозач	Vозач	ne postoje	Vозач	0
1	Sistemi za pomoć vozaču	Informacijsima dobijenim nadgledanjem okruženja vozila sistem preuzima kontrolu nad upravljanjem vozilom ili ubrzanjem vozila. Od vozača se očekuje da izvršava sve preostale zadatke tokom vožnje.	Vозач i sistem	Vозач	Vозач	Sistem je u mogućnosti da preuzeme neke od voznih zadataka.	Sistemi za pomoć vozaču	1
2	Djelimična automatizacija	Informacijsima dobijenim nadgledanjem okruženja vozila jedan ili više sistema za pomoć vozaču preuzimaju kontrolu nad upravljanjem i ubrzanjem vozila. Od vozača se očekuje da izvršava sve preostale vozne zadatke.	Sistem	Vозач	Vозач	Sistem je u mogućnosti da preuzeme neke od voznih zadataka.	Djelimična automatizacija	2
Sistem automatske vožnje (sistem) nadgleda okruženje vozila								
3	Uslovna automatizacija	Sistem automatske vožnje preuzima kontrolu nad svim aspektima vožnje. Od vozača se u slučaju potrebe očekuje primjerena reakcija.	Sistem	Sistem	Vозач	Sistem je u mogućnosti da preuzeme neke od voznih zadataka.	Visok stepen automatizacije	3
4	Visoka automatizacija	Sistem automatske vožnje preuzima kontrolu nad svim aspektima vožnje. Od vozača se u slučaju potrebe ne očekuje primjerena reakcija.	Sistem	Sistem	Sistem	Sistem je u mogućnosti da preuzeme neke od voznih zadataka.	Potpuna automatizacija	
5	Potpuna automatizacija	Sistem automatske vožnje, u svim mogućim uslovima vožnje, preuzima kontrolu nad svim aspektima vožnje.	Sistem	Sistem	Sistem	Sistem je u mogućnosti da preuzeme sve vozne zadatke.	-	3/4

Što se vidi u Tabeli 1.1, prema SAE J3016 proces prenosa kontrole nad vozilom sa čovjeka na sistem podijeljen je na šest nivoa, od 0 (bez automatizacije) do 5 (potpuna automatizacija). U toku pisanja ove disertacije postignuti stepen automatizacije kod nekih tržišnih modela vozila je tek 2.

Posmatrajući tabelu nije pogrešno reći da savremeni automobili, uz sav tehnološki napredak ostvaren u međuvremenu, još uvijek nisu dostigli stepen automatizacije koji su imala zaprežna vozila. Istraživanja u ovoj oblasti nije nedostajalo, i ona se vrše još od relativno rane faze razvoja automobila. Tsukuba Research Laboratories iz Japana su prvi pokušaj automatizacije vožnje izveli još u 70. godinama prošlog vijeka. Između 1987. i 1995. i Evropska Unija u okviru programa Prometheus izdvaja značajna sredstva za istraživanje u ovoj oblasti. Danas je fascinacija visoko automatizovanim sistemima vožnje izraženija nego ikada prije. Finansirani od strane velikih IT (eng. *Information Technology*) kompanija i proizvođača automobila, veoma mali je broj univerziteta i istraživačkih instituta koji se ne bave ovom tematikom. Međutim, iako značajan faktor, pokretačka snaga razvoja ovakvih sistema nije samo novac. Uspješna primjena algoritama mašinskog učenja u raznim industrijskim oblastima stvorila je kritičnu masu inženjera i naučnika, koja se usudila da povjeruje u ideju da se primjenom iste ili veoma slične tehnologije može riješiti i problem postizanja potpuno automatizovane vožnje.

Na osnovu prethodne diskusije, nameće se pitanje: „Zbog čega još uvijek nije dosegnut 5 stepen automatizacije vožnje?“. U automobilskoj industriji problem nisu samo performanse algoritama za obradu signala senzora, već i proces njihove validacije i verifikacije. Izvršavanje tog procesa je preduslov za ispunjavanje važećih bezbjednosnih normi, a pokazuje se da je problem validacije i verifikacije vještackih neuronskih mreža izuzetno težak problem. Pored softvera, slični zahtjevi postoje i za hardver, ali i za, isto tako važne, procese upravljanje ljudskim resursima, kvalitetom i slično. Dakle, odgovor na postavljeno pitanje bi jednostavno mogao biti - zbog izuzetne složenosti problema i konteksta u kojem se problem rješava.

1.1 Nadgledanje okruženja sistemskog vozila

U trenutku pisanja ove disertacije tehnologija, na žalost, još uvijek nije na nivou koji bi omogućio opšteprihvaćeno, bezbjedno funkcionisanje sistema za automatizovanu vožnju. Problemi su posebno izraženi kod funkcionalnih komponenata zaduženih za nadgledanje ili percepciju okruženja vozila. Kod viših stepeni automatizacije, za obradu i interpretaciju dobijenih mjernih podataka mahom se koriste nadgledani algoritmi mašinskog učenja za čije je uspješno obučavanje neophodno obezbijediti velike skupove anotiranih senzorskih mjerena.

1.1.1 Statičke karakteristike senzora

Automatizovana vozila opremljena su velikim brojem različitih tipova električnih senzora za nadgledanje okruženja. Karakteristike senzora direktno utiču na performanse cijelog sistema. U automobilskoj industriji često se govori o robusnosti senzora. Robusnost predstavlja osobinu onih sistema čije radne karakteristike ostaju unutar zadatih granica u svim, pa i otežanim, radnim uslovima [6]. Radni uslovi sistema mogu biti eksplicitno zadati, ali takođe nepoznati i neizvjesni. Robusnost senzora je veoma širok pojam, pa se isto tako i koristi da se opišu opšte karakteristike senzora. Na primjer, za kameru je izvjesno da će imati degradiranu funkcionalnost u slučaju neadekvatnog osvjetljenja CMOS senzora (uslijed zaprljanosti sočiva, slabog ili prejakog vanjskog osvjetljenja i slično), pa se kaže da kamera nije robusna na promjene vanjskog osvjetljenja. Potrebno je napomenuti da pojam robusnosti nije definisan u Međunarodnom rječniku metrologije [7].

Mjerljive karakteristike senzora zadaju se statičkim i dinamičkim parametrima [7–9]. Na primjer, često se upotrebljavaju sljedeći statički parametri senzora: tačnost mjerena, preciznost mjerena, rezolucija senzora i osjetljivost senzora. Ovi parametri definišu se na sljedeći način:

- Tačnost mjerena predstavlja bliskost slaganja rezultata mjerena i usvojene tačne vrijednosti mjerene veličine. Pojam „tačnost mjerena“ ne predstavlja veličinu koja bi se mogla kvantifikovati brojnom vrijednošću [7], već se kaže da je mjerena tačnije ako je greška mjerena mala. Greška mjerena ϵ definije se kao vrijednost razlike izmjerene vrijednosti y i usvojene tačne vrijednosti mjerene veličine x , odnosno $\epsilon = y - x$. Pored greške mjerena, za izražavanje tačnosti mjerena koristi se često i relativna greška mjerena izražena u procentima

$$\eta = \frac{y - x}{x} \cdot 100\%, \quad (1.1)$$

pri čemu označke x i y imaju isto značenje kao i kod definicije greške mjerena.

- Preciznost mjerena predstavlja bliskost slaganja izmjerenih vrijednosti dobijenih tokom ponovljenih mjerena istog fizičkog fenomena pod istim mernim uslovima. Preciznost mjerena se numerički izražava statističkim mjerama, kao što su standardna devijacija, varijansa ili koeficijent varijacije.

1.1. Nadgledanje okruženja sistemskog vozila

- Rezolucija senzora izražava sposobnost senzora da jasno razlikuje dvije bliske vrijednosti mjerne veličine. Za opisivanja kvaliteta digitalne kamere pojam rezolucije često se upotrebljava kao sinonim za pikselsku rezoluciju (broj piksela digitalne slike). Međutim, kvalitet digitalne kamere bolje opisuju: prostorna rezolucija (broj nezavisnih vrijednosti piksela po jedinici dužine), spektralna rezolucija (izražava mogućnost senzora da razlikuje različite spektralne komponente mjernog signala), vremenska rezolucija (broj mjerena po jedinici vremena) i radiometrijska rezolucija (izražava sposobnost senzora da razlikuje male promjene reflektovane ili emitovane energije). Prostorna rezolucija često se daje i za radare i lidare, i to obično kao ugaona rezolucija po horizontali i vertikali vidnog polja.
- Osjetljivost predstavlja prvi izvod izlazne po ulaznoj veličini. Prag osjetljivosti senzora definiše se kao najmanja promjena ulaznog signala koja izaziva najmanju promjenu izlaznog signala, koja se može opaziti i registrovati pomoću senzora bez dodatnih uređaja [10]. Što je prag osjetljivosti niži, senzor je osjetljiviji. Na primjer, prema standardu EMVA 1288 (eng. *EMVA - European Machine Vision Association*) [11], osjetljivost senzora kamere definiše se preko praga osjetljivosti. U skladu sa tom definicijom, često se kaže da je kamera osjetljiva ako može da registruje sliku slabo osvjetljene scene.

Dinamičke karakteristike senzora opisuju dinamičko ponašanje mjernog sistema. U disertaciji se pretpostavlja da se mjerena veličina mijenja sporo, pa se tako i u nastavku razmatraju samo statički parametri senzora.

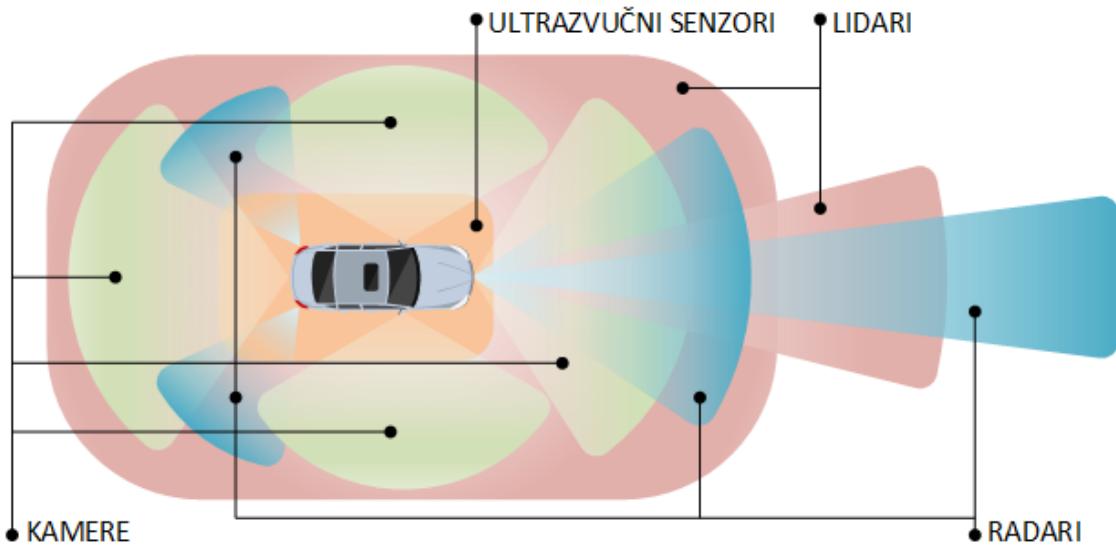
Foto senzori savremenih digitalnih kamera, visoke pikselske, prostorne, vremenske i radiometrijske rezolucije, daju veoma precizna i tačna mjerena, pa se stoga u sistima visoko automatizovane vožnje koriste za detekciju malih objekata na kolovozu (takozvanog izgubljenog tereta ili eng. *lost cargo*) [12], prepoznavanje vertikalne i horizontalne signalizacije, za praćenje objekata, predikciju namjere pješaka [13] i slično. Tačnost mjerena zavisi od uslova pod kojima se mjerena vrši, a koje obično odstupa od uslova pod kojima je izvršena kalibracija. Kalibracija kamere vrši se u strogo kontrolisanim uslovima (opterećenje vozila, pritisak u gumama i slično). Rezultat kalibracije kamere su ekstrinsični i intrinsični parametri¹ kamere [14]) i oni su obično sastavni dio softvera čija funkcionalnost zavisi od slika snimljenih kamerom. Na primjer, neka mjerni princip koji koristi mono kameru za detekciju i praćenje pješaka počiva na prepostavci da je svjet ravna površ. Ukoliko u toku eksploracije sistema dođe do minimalnog pomjeranja kamere, potrebno je izvršiti ponovnu kalibraciju senzora, jer originalna ekstrinsična kalibracija više ne odgovara novom položaju senzora. Kod kamere je međutim osnovni problem što u slučaju nepovoljnog vanjskog osvjetljenja daju beskorisna mjerena. Radari sa druge strane imaju nisku tačnost, preciznost i rezoluciju, ali su veoma robusni na nepovoljne meteorološke pojave. Radari zbog toga imaju, već od pojave prvih generacija sistema za pomoć vozaču, veoma važnu ulogu u funkcionalnim komponentama za detekciju i praćenje objekata u prostoru.

¹Više o ekstrinsičnim i intrinsičnim parametrima kamere dato je u Glavi 3.

1.1. Nadgledanje okruženja sistemskog vozila

1.1.2 Senzorska konfiguracija visoko automatizovanih vozila

Na Slici 1.1 dat je primjer senzorske konfiguracije visoko automatizovanog vozila. Kao što se vidi, u senzorskoj konfiguraciji nalazi se veliki broj različitih vrsta sen-



Slika 1.1: Primjer senzorske konfiguracije visoko automatizovanih vozila.

zora. Pored prikazanih, u upotrebi su još i mikrofoni i GPS senzori. Kako se radi o velikom broju senzora, osim problema obrade rezultata mjerjenja, posebne izazove predstavljaju vremenska sinhronizacija mjerjenja i čuvanje velike količine mjernih podataka.

Princip rada ultrazvučnih senzora je zasnovan na piezoelektričnom efektu. Ovi senzori se koriste za mjerjenje udaljenosti objekata koji se nalaze u neposrednom okruženju vozila, u zavisnosti od izvedbe i do 3 metra. Pouzdanost mjerjenja zavisi od tipa reflektujuće površine objekata. Problem predstavljaju uglavnom materijali koji dobro absorbiraju ultrazvučni talas, na primjer neke vrste odjevnih predmeta. Takođe, ultrazvučni senzori su podložni i uticaju akustičkih smetnji iz okruženja.

Radari (eng. *Radio Detection and Ranging*) su elektromagnetski sistemi za otkrivanje prisustva, prepoznavanje, određivanje položaja i brzine kretanja objekata u prostoru [15]. Funkcionišu na principu emitovanja elektromagnetskog talasa određenog talasnog oblika, i detekciji osobina reflektovanog talasa. Za auto industriju na raspolaganju stoje četiri frekvencijska opsega: 21,65 – 26,65 GHz, 24,0 – 24,25 GHz, 76 – 77 GHz i 77 – 81 GHz. Na tržištu danas dominiraju radari u 76,5 GHz opsegu. Radari imaju visoku pouzdanost rada u gotovo svim meteorološkim uslovima. U današnjim sistemima za pomoć vozaču radari se koriste za detekciju objekata na udaljenostima i do 250 metara od sistemskog vozila, pa su shodno tome našli široku primjenu u sistemima za održavanje odstojanja od drugih vozila, automatsko kočenje i slično. Nedostaci su im niska pouzdanost rada u zatvorenim prostorima (tuneli), slaba detekcija malih objekata, podložnost uticaju smetnji drugih radar-

1.2. Fuzija i interpretacija senzorskih mjerena

skih sistema. Takođe, radari, za razliku od kamera, nisu pogodni za prepoznavanje i semantičku klasifikaciju objekata.

Lidar (eng. *Light Detection and Ranging*) je optički mjerni sistem za otkrivanje prisustva, prepoznavanje i određivanje položaja objekata u prostoru. Za razliku od radara, lidari koriste elektromagnetne talase iz ultravioletnog, infracrvenog, pa i vidljivog frekvencijskog opsega svjetlosti. Najčešće korišćeni mjerni princip je zasnovan na metodi „vrijeme leta“ (eng. *time of flight*). Vremensko trajanje od emitovanja do prijema svjetlosnog impulsa je proporcionalno radikalnoj udaljenosti između senzora i detektovanog objekta. U slučaju prisustva reflektujuće površine, reflektovani svjetlosni impulsi registruju se svjetlosnim senzorom. Udaljenost od objekta data je sa $d = \frac{c t}{2}$, pri čemu je d udaljenost u metrima, c brzina svjetlosti u m/s i t vrijeme u sekundama. Iako zasnovani na vrlo jednostavnom mjernom principu, lidare karakteriše veoma kompleksna konstrukcionalna izvedba. Pored toga, na funkciju lidara utiču različite atmosferske pojave. Na primjer kapljice magle ili kiše reflektuju odaslate svjetlosne impulse, time dajući pogrešnu informaciju o prisustvu objekta.

Današnja saobraćajna infrastruktura prije svega prilagođena je čovjekovom vizuelnom sistemu, pa je tako i važne informacije i uputstva za pravilno odvijanje saobraćaja, u vidu saobraćajnih znakova, svjetlosne signalizacije i oznaka na samoj kolovoznoj traci, moguće detektovati senzorima čije radne karakteristike približno odgovaraju onima ljudskog oka. Sistemi mono i stereo kamera su još od prvih sistema za pomoć vozaču prisutni u senzorskoj arhitekturi vozila. Mahom su to kamere vrlo visoke pikselske, prostorne, vremenske i radiometrijske rezolucije. Međutim, kamere su veoma osjetljive na nepovoljne vanjske uticaje, uzrokovane, na primjer, lošim osvjetljenjem ili meteorološkim pojavama.

1.2 Fuzija i interpretacija senzorskih mjerena

Posmatrajući uspjehe algoritama dubokog učenja i dubokih neuronskih mreža u gotovo svim industrijskim oblastima [16–18], stiže se utisak da se njihovom primjenom može riješiti i veliki broj složenih problema interpretacije senzorskih mjerena (na primjer semantička segmentacija radarskih mjerena ili određivanje disparitetnih mapa na osnovu slika mono kamere). Međutim, već nakon kratkog opisa različitih vrsta senzora u prethodnom odjeljku, jasno je da se tek kombinovanjem ili fuzijom senzorskih mjerena može ostvariti visok nivo pouzdane percepcije okruženja vozila. Klasična fuzija senzorskih mjerena dobro je poznata oblast probabilitičke robottike [19]. Problem klasične fuzije senzorskih mjerena predstavlja fuzija senzorskih mjerena različitih modaliteta², jer da bi se ostvarila semantička fuzija informacija, pored toga što mjerena moraju biti prostorno, geometrijski i vremenski usaglašena, mjerena se moraju dovesti u zajednički semantički prostor.

²Prema rječniku [20] „modalitet“ označava način na koji se nešto dešava ili vrši. U disertaciji se pod „mjerena različitih modaliteta“ podrazumijevaju mjerena različitih fizičkih veličina, na primjer svjetlosti iz vidljivog ili infracrvenog spektra, zvuka i slično.

1.2. Fuzija i interpretacija senzorskih mjerena

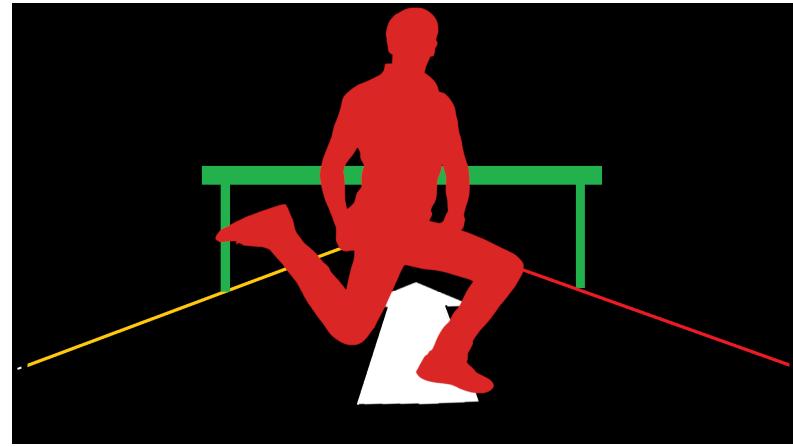
Postoji više pristupa za rješavanje problema fuzije mjernih podataka različitih modaliteta. U sistemima za pomoć vozaču, dakle kod sistema sa nižim stepenom automatizacije, uobičajeno je jedan od senzora koristiti za generisanje mjernih hipoteza, a drugi za njihovu verifikaciju [21, 22]. Ovakav pristup karakterističan je za praćenje pokretnih objekata (pješaka, automobila, biciklista i slično) nekim od algoritama za praćenje, na primjer Kalmanovim filtrom [23, 24]. Na sljedećem primjeru biće prikazan slučaj kada se kao generator mjernih hipoteza koristi kamera, međutim slična analiza može se izvršiti i za slučaj kada se za generisanje mjernih hipoteza koristi radar. Na Slici 1.2 prikazani su: pokazni, rukom generisani primjer slike, reprojekcija³ slike na zemljinu ravan i rukom generisana radarska mjerena iste scene koju prikazuje i slika. Posmatrajući idealizovanu sliku datu na Slici 1.2a, položaj tijela⁴ pješaka može se tumačiti kao klečeći, dalje od kamere ili u skoku, bliže kameri⁵. Pod pretpostavkom da je dostupna odgovarajuća kalibracija kamere i da je izvršena semantička segmentacija date slike, položaj pješaka moguće je odrediti reprojekcijom na zemljinu ravan najbliže dodirne tačke pješaka sa kolovozom. Reprojekcija dijela slike prikazana je na Slici 1.3b. Kako se pješak nalazi u skoku, njegova pozicija biće netačno reprojektovana dalje prema horizontu. Dakle, hipoteza o postojanju pješaka biće generisana, ali sa pogrešno određenom pozicijom pješaka. Samim tim, uslijed odstupanja mjerena, mjerna hipoteza ne može biti potvrđena radarskim mjeranjima. Takođe, radarska mjerena prikazana na Slici 1.2c ukazuju na prisustvo jednog ili više objekata iza pješaka, ali hipoteza o postojanju objekata u pozadini neće biti ni generisana jer su na slici objekti skriveni iza pješaka. Jasno je da se dio obilježja sadržanih u samim mjeranjima (radarske detekcije objekata u pozadini) ovakvim pristupom fuzije nepovratno gubi. Takođe, problem detekcije, drugih, takođe važnih elemenata saobraćajne infrastrukture, kao što su mostovi i tuneli, ovakvim pristupom ne može se riješiti. Sa jedne strane objekti iznad linije horizonta ne mogu se projektovati na zemljinu ravan, a sa druge strane, zbog niske prostorne rezolucije po visini, radarske detekcije uzvišenih objekata veoma su nepouzdane.

³Korišćena motoda kojom je izvršena reprojekcija piksela slike na zemljinu ravan biće opisana u Glavi 3.

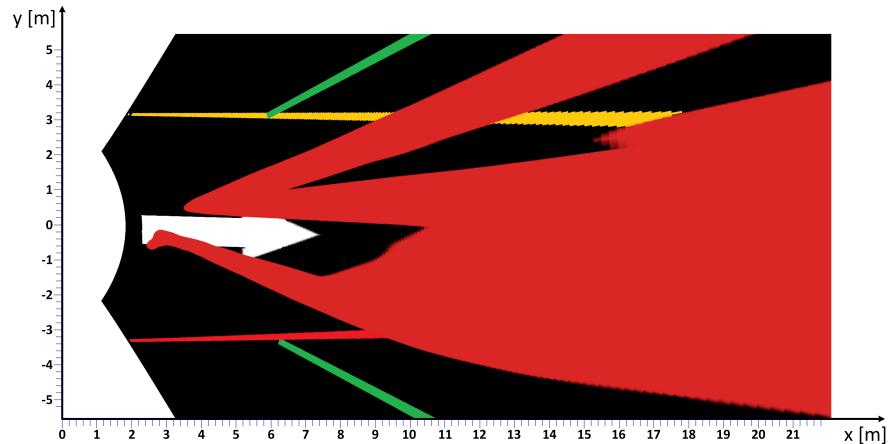
⁴Ovdje se zbog odnosa veličina objekata na slici jasno radi o pješaku koji skače. Međutim, mašinskim putem tu činjenicu veoma je teško utvrditi.

⁵Ovakva i slične situacije veoma su česte. Sličan efekat postiže se ako se pješak nalazi na uzvišenju ili na biciklu. Takođe, vrlo često algoritmi za semantičku segmentaciju noge pješaka pogrešno klasificuju kao oznake na kolovozu ili sam kolovoz.

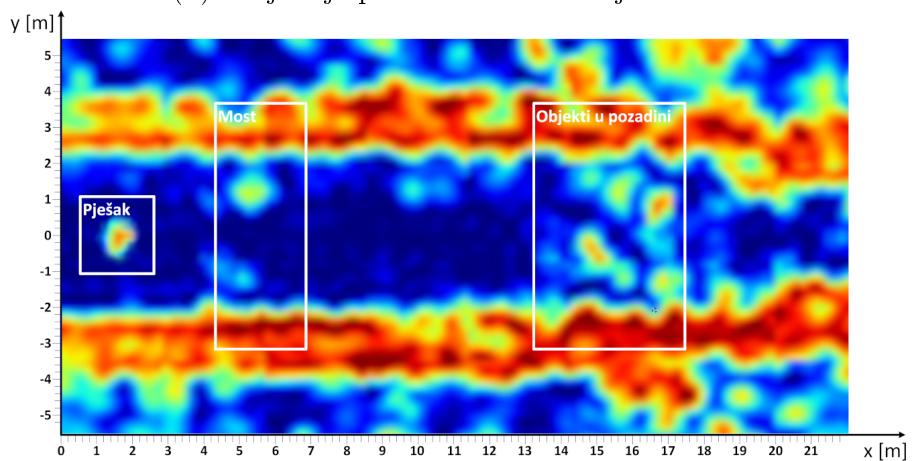
1.2. Fuzija i interpretacija senzorskih mjerena



(a) Pješak u skoku neposredno ispred kamere



(b) Projekcija piksela slike na zemljinu ravan

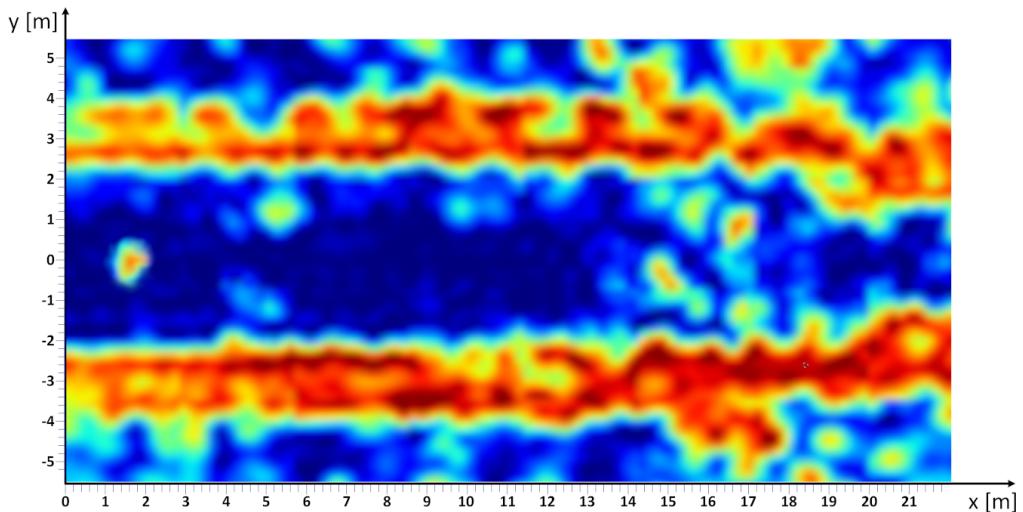


(c) Detekcije radara projektovane na zemljinu ravan

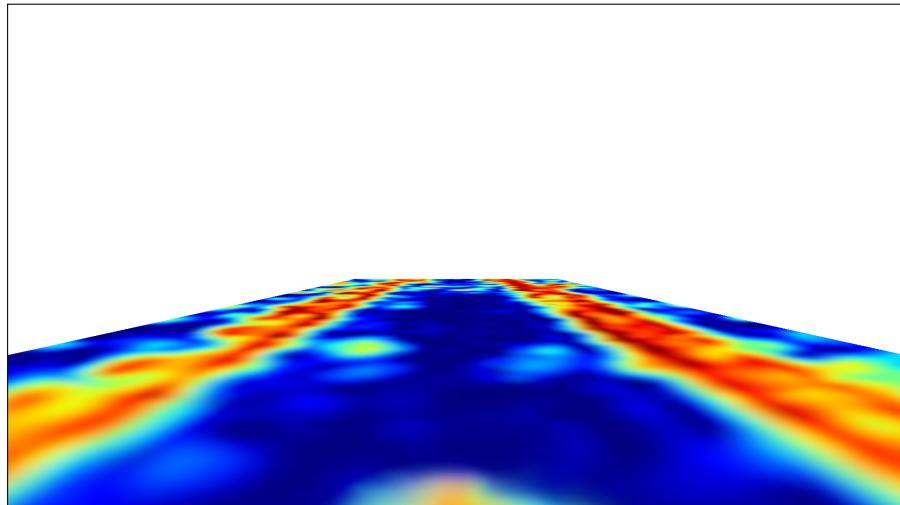
Slika 1.2: Pokazni, rukom generisani primjeri slike, njene reprojekcije na zemljinu ravan i rukom generisana radarska mjerena iste scene. Na Slici (a), za razliku od radarskih mjerena prikazanih na Slici (c), objekti u pozadini skriveni su iza pješaka. Na osnovu radarskih mjerena, veoma teško je utvrditi kojoj semantičkoj klasi pripada detektovani objekat. Takođe, rezolucija radara po visini je veoma niska, pa su i detekcije mosta manje vjerovatne.

1.2. Fuzija i interpretacija senzorskih mjerena

Drugačiji pristup sastoji se u projekciji mjerena jednog senzora u mjerni oblik drugog senzora. Na primjer, projekcijom radarskih ili lidarskih mjerena na projekcionu ravan slike [25–28]. Ovakav princip projekcije, koristeći rukom generisana radarska mjerena iz prethodnog primjera, prikazan je na Slici 1.3. Formiranjem vještačke



(a) Detekcije radara projektovane na zemljinu ravan



(b) Projekcija radarskih mjerena na ravan slike

Slika 1.3: Primjer projekcije radarskih mjerena na ravan slike. Radarske detekcije pješaka na Slici (a) vidljive su na Slici (b) samo djelimično jer projekcija pješaka na zemljinoj ravni nije u vidnom polju kamere čija kalibracija je iskorišćena za projekciju.

slike otvara se mogućnost korišćenja algoritama mašinskog učenja visokog kapaciteta za regresiju graničnih okvira ili semantičku klasifikaciju piksela. Međutim, kao što se vidi na Slici 1.3b, problem kod ovakvog pristupa je što se vještačka slika dosta razlikuje od slika dobijenih kamerom iz skupa podataka za obučavanje nadgledanih algoritama mašinskog učenja. Na primjer, za detekciju slobodne kolovozne površine autori u [29] pribjegavaju fuziji lidarskih mjerena i slika dobijenih

1.3. Doprinos disertacije

kamerom korišćenjem uslovnih slučajnih polja (eng. *CRF - Conditional Random Fields*). Prvi korak algoritma sastoji se u projekciji lidarskih mjerena na ravan slike, a zatim se korišćenjem CRF algoritma vrši fuzija semantičkih klasa piksela originalne i vještačke slike. Dakle, preduslov za fuziju je postojanje velikog skupa anotiranih lidarskih mjerena. Na žalost, anotacija lidarskih, ali i radarskih mjerena, je veoma složen, a samim tim i skup proces. U jednom ciklusu mjerena, na primjer jednom rotacijom lidara ili jednim osvjetljenjem radara, dobija se skup mjernih tačaka koji je vrlo teško prezentovati u obliku pristupačnom anotatoru. Pod pojmom anotacije podrazumijeva se dodjeljivanje semantičkih klasa pojedinačnoj mjernoj tački ili klasteru mjernih tačaka. Da bi anotatori mogli prepoznati različite klase detektovanih objekata, senzorska mjerena im se obično prezentuju uparena sa slikom kamere. Mali broj anotiranih podataka, uglavnom lošeg kvaliteta, ogleda se u lošim performansama algoritama za regresiju i klasifikaciju. Istraživači i inženjeri u ovoj oblasti se zbog toga ograničavaju tek na objekte čija se pripadnost nekoj klasi relativno lako može anotirati [30], te na modele manjeg kapaciteta [31].

1.3 Doprinos disertacije

U ovoj disertaciji biće pokazano da je korišćenjem vještačkih neuronskih mreža, na osnovu ulaznih senzorskih mjerena jednog modaliteta, na izlazu moguće dobiti vještačka senzorska mjerena drugog modaliteta. Na taj način se obilježja sadržana u ulaznim signalima transformišu u prostor obilježja izlaznog signala. U disertaciji se ovaj proces naziva transformacija obilježja. Osnovni doprinos ove disertacije je novi, neneadgledani model mašinskog učenja, takozvana uslovna generativna suparnička mreža sa više generatora - CMGGAN (eng. *Conditional Multi-Generator Generative Adversarial Network*) [32], kojim se ovakva transformacija omogućava. Važna karakteristika CMGGAN modela je da se njegovo obučavanje regularizuje uslovom maksimalne zajedničke informacije ulaznih i izlaznih signala, osiguravajući time da se obilježja prisutna na ulazu nalaze i na izlazu modela. Na taj način prevazilaze se, u prethodnom odjeljku opisani problem gubitka informacija koji nastaju uslijed fuzije senzorskih mjerena različitih modaliteta i problem nedostatka obilježja koji nose semantičku informaciju u transformisanim obilježjima.

Analizom karakteristika senzora i metoda fuzije i interpretacije senzorskih mjerena datim u prethodnim odjeljcima, jasno je da se za nadgledanje okruženja sistemskog vozila slike dobijene kamerama koriste kao glavni nosioci semantičke informacije. Zbog jednostavnosti anotacije slika, na raspolaganju stoji veliki broj javno dostupnih anotiranih skupova podataka [33,34] koji omogućavaju obučavanje algoritama mašinskog učenja visokog kapaciteta, na primjer dubokih neuronskih mreža, dubokih Bajesovih mreža i sličnih. U više testnih okruženja pokazano je da takvi algoritmi u mnogim slučajevima postižu rezultate klasifikacije i regresije koji su iznad prosječnih ljudskih mogućnosti [35]. Kamere su, sa druge strane, osjetljive na otežane radne uslove, kao što su loše ili prekomjerno osvjetljenje ili nepovoljne meteorološke pojave, pa je uz njih, za percepciju voznog okruženja potrebno koristiti senzore koji se zasnivaju na drugaćijem mernom principu. Radari se zbog

visoke pouzdanosti rada u gotovo svim meteorološkim uslovima nameću kao logično rješenje. Međutim, mjerenja radara, za razliku od slika dobijenih kamerom, do sada se nisu pokazala pogodna za prepoznavanje i semantičku klasifikaciju objekata. Upravo radi toga, eksperimentalna analiza, u ovoj disertaciji predloženog metoda transformacije obilježja, izvršena je korišćenjem mjerenja radarskog senzora kao ulaznog signala i slika kao izlaznog signala. U tom slučaju, obučene neuronske mreža, sa predstavljenim novim radarskim mjerenjima na njihovim ulazima, u mogućnosti su da generišu vještačke slike, nezavisno od kamera koje eventualno postoje u senzorskoj konfiguraciji visoko automatizovanog vozila. Biti će pokazano da generisane vještačke slike kvalitativno i kvantitativno sadrže obilježja okruženja detektovana radarom, te da ih je moguće koristiti za semantičku segmentaciju ili regresiju korišćenjem nekih od nadgledanih algoritama mašinskog učenja koji su obučeni javno dostupnim skupovima anotiranih slika. Proces fuzije vještačkih i stvarnih slika dobijenih kamerom u tako dobijenom semantičkom prostoru u disertaciji se naziva semantička fuzija.

1.4 Organizacija disertacije

Osnovna tema ove disertacije je obrada signala senzora visoko automatizovanih vozila korišćenjem vještačkih neuronskih mreža. U cilju razumijevanja okruženja u kojem se ovi algoritmi mašinskog učenja izvršavaju, u Glavi 2 opisana je opšta arhitektura sistema automatizovane vožnje. Pored toga, opisane su neke specifičnosti razvoja softvera u automobilskoj industriji, a koje neposredno utiču na izbor modela mašinskog učenja.

Preduslov za uspješno obučavanje vještačkih neuronskih mreža su veliki skupovi anotiranih podataka. U Glavi 3 dat je pregled svih skupova podataka korišćenih za obučavanje modela predstavljenih u ovoj disertaciji.

Povećanje kvaliteta i veličine skupova anotiranih podataka je važno i taj proces se treba prevashodno posmatrati kao veoma važan metod regularizacije obučavanja modela. Međutim, veoma teško je odabrat primjere koje je potrebno anotirati da bi model u fazi eksploatacije dobro generalizovao. Na primjer, slika koja prikazuje urbanu saobraćajnu scenu obično sadrži više od 70% piksela koji predstavljaju kolovoz, nebo, krošnje drveća i slično, te veoma mali broj piksela koji predstavljaju pješake i objekte malih dimenzija, a koji su bitni za planiranje trajektorije vozila. Za očekivati je da će i model obučavan na takvim podacima imati lošije performanse pri detekciji pješaka nego, na primjer, neba. Međutim, ako se ulazni podaci posmatraju kao realizacije nekog slučajnog procesa, odnosno kao realizacije neke višedimenzionalne slučajne promjenljive, put ka većem broju važnih obilježja mogao bi biti razumijevanje, odnosno učenje gustine raspodjele te slučajne promjenljive. Poznavanjem gustine raspodjele moglo bi se generisati nove slike, koje po svojim karakteristikama odgovaraju karakteristikama slika iz skupa za obučavanje. Matematički modeli koji imaju za cilj učenje distribucije vjerovatnoće nazivaju se probabilistički generativni modeli. Veoma važna skupina generativnih modela ko-

ji se mogu aproksimirati dubokim neuronskim mrežama nazivaju se generativne suparničke mreže i predstavljene su u Glavi 4.

Neke vrste generativnih suparničkih mreža moguće je obučiti tako da se dovođenjem odgovarajućih uslovnih promjenljivih na njihove ulaze, na izlazu dobijaju signali sa obilježjima koja su od interesa. U disertaciji je predstavljeno nekoliko arhitektura koje to omogućavaju. U Glavi 5 predstavljene su uslovne generativne mreže, koje kao uslovne promjenljive koriste anotacije iz skupa za obučavanje. U Glavi 6 predstavljene su generativne suparničke mreže zasnovane na maksimizaciji zajedničke informacije dvije slučajne promjenljive: ulaznog latentnog koda i generisane slike. Pri tome se latentni kod, za razliku od uslovnih generativnih suparničkih mreža, otkriva automatski u procesu obučavanja.

Analizom pomenutih uslovnih generativnih modela pokazuje se da njima nije moguće ispuniti sve ciljeve sadržane u hipotezi disertacije, odnosno da se omogući transformacija obilježja i semantička fuzija mjerena različitim modalitetama - uslovne generativne suparničke mreže zahtjevaju anotirane podatke, dok je latentne kodove informacionih generativnih modela izuzetno teško tumačiti i koristiti. U Glavi 7 predstavljene su uslovne generativne suparničke mreže sa više generatora, kojima je moguće prevazići pomenute nedostatke dosadašnjih uslovnih generativnih modela.

U Glavi 8 razmatra se mogućnost transformacije obilježja i semantičke fuzije slika dobijenih kamerom i radarskih mjerena korišćenjem uslovne suparničke mreže sa tri generatora. Validacija predloženih metoda fuzije podataka izvršena je detaljnom eksperimentalnom analizom zasnovanom na objektivnim i subjektivnim ocjenama kvaliteta generisanih slika.

1.5 Publikacije

Istraživanja prezentovana u ovoj disertaciji većim dijelom nastala su u toku rada na projektima realizacije visoko automatizovanih sistema vožnje firmi Elektrobit Automotive GmbH i Mercedes-Benz Cars and Vans AG. Fuzija mjerena različitim modalitetama korišćenjem varijacionih optimizacionih nivo-skup metoda objavljena je još u [36]. U ranoj fazi istraživačkog rada na obradi senzorskih mjerena, nivo-skup metode su se zbog velike kompleksnosti i velikog broja hiper-parametara pokazale neadekvatnima za ovu primjenu. U daljem toku istraživanja, neuronske mreže u kompleksnom domenu nametnule su se kao prirodno rješenje za klasifikaciju radarskih mjerena, koja su po svojoj prirodi takođe kompleksne veličine. Iako je dio istraživanja o dubokim neuronskim mrežama u kompleksnom domenu objavljen u [37], zbog nemogućnosti regularizacije procesa obučavanja ovih mreža, dobijeni rezultati nisu se pokazali dovoljno kvalitetnim da nađu mjesto u ovoj disertaciji. Sa druge strane, ovo istraživanje otvorilo je put prema novim mogućnostima analize i razumijevanju radarskih podataka. Istraživanja posvećena transformaciji obilježja i semantičkoj fuziji radarskih mjerena i slika dobijenih kamerom djelimično su predstavljena u [38] i [32]. Teorijska osnova i prošireni rezultati ovog istraživanja dati su u nastavku ove disertacije.

Glava 2

Arhitektura sistema automatizovane vožnje

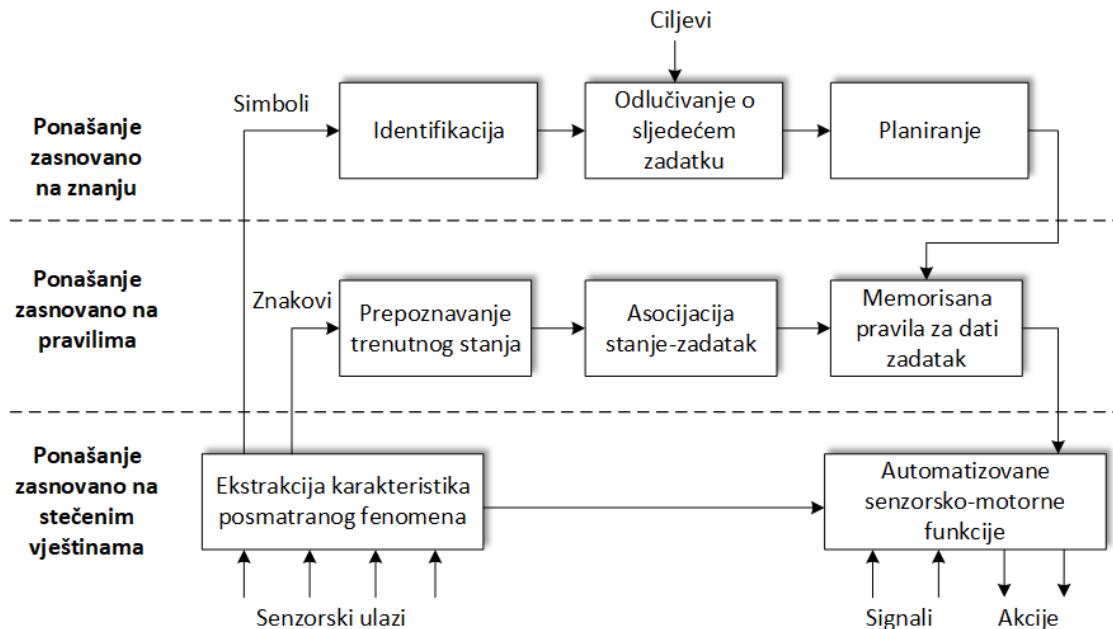
Da bi se djelimično razjasnila složenost problematike razmatrane u disertaciji, u ovoj glavi data je analiza ljudskih vještina potrebnih za upravljanje automobilom. Dalje je prikazana funkcionalna arhitektura sistema visoko automatizovane vožnje inspirisana ovom analizom. Na kraju, razmatraju se bezbjednosni rizici koje, potencijalno neispravni, visoko automatizovani sistemi vožnje predstavljaju za ostale učesnike u saobraćaju.

2.1 Vještina upravljanja automobilom

Najveća inspiracija za razvoj sistema koji bi omogućili visoko automatizovano kretanje motornih vozila je svakako sam čovjek - vozač. U toku izvršavanja nekog zadatka, pa i vožnje, ponašanje ili djelovanje čovjeka nije zasnovano samo na povratnim informacijama dobijenim u toku same radnje, već i na iskustvu dobijenom u prijašnjim pokušajima izvršavanja istog ili sličnog zadatka. U radu [1] autor kategorizuje ljudsko ponašanje prema učinkovitosti, i to u tri kategorije: ponašanje zasnovano na stečenim vještinama, ponašanje zasnovano na naučenim pravilima i ponašanje zasnovano na znanju. Ilustracija datih kategorija ponašanja data je na Slici 2.1.

Ponašanje zasnovano na stečenim vještinama predstavljaju senzorsko-motorne funkcije koje se izvršavaju automatski, bez svjesne kontrole. Svi pokreti i akcije su brzi, djeluju sinhronizovano i svrsishodno. U suštini, aktivnosti čovjeka se na ovom nivou mogu posmatrati kao integrisana sekvenca vještina, ukomponovanih za dati zadatak. Pojavom greške u toku izvršavanja funkcije (na primjer kod tenisera neočekivani početni položaj tijela prilikom izvođenja servisa), u pozitivnu povratnu spregu se uključuje signal greške između trenutnog i očekivanog stanja koje je sadržano u internoj reprezentaciji svijeta. Signal greške se dalje koristi za izbor novih ili adaptaciju postojećih automatizovanih senzorsko-motornih funkcija. Po-

2.1. Vještina upravljanja automobilom



Slika 2.1: Kategorizacija ljudskog ponašanja prema Rasmussenu [1].

našanje se zasniva dakle, na pozitivnoj povratnoj sprezi i na veoma fleksibilnom i efikasnom modelu svijeta. Za upravljanje automobilom, vještine na ovom nivou performansi su ključne za, na primjer, stabilizaciju vozila uslijed proklizavanja ili izbjegavanje iznenadnih prepreka.

Na sljedećem nivou učinkovitosti ponašanja - ponašanju zasnovanom na pravilima, kompozicija akcija ili vještina je određena memorisanim pravilima ili procedurama. Do pravila se može doći empirijski, u toku komunikacije sa drugim osobama, ili se može izvesti kroz misaono rješavanje problema ili planiranje. Funkcije na ovom nivou nisu pod direktnom kontrolom cilja, već kroz povratnu spregu pod kontrolom višeg konceptualnog nivoa. Ponekad cilj nije eksplicitno ni zadat, već se pravila ponašanja okidaju implicitno u zavisnosti od situacije. Može se reći da je ovakav vid ponašanja karakterističan kada se osoba nalazi u poznatom okruženju. Na primjer, za upravljanje automobilom, pod ovu kategoriju ponašanja bi se moglo svrstati funkcije za odabir odgovarajuće saobraćajne trake ili prilagođavanje brzine vozila važećim saobraćajnim propisima. Na takve funkcije odredište putovanja nema nikakav ili vrlo mali uticaj.

U nepoznatim situacijama, sa kojima se osoba suočava u okruženju za koje ne postoje memorisana pravila ponašanja, ponašanje prelazi na sljedeći, viši konceptualni, ali manje učinkovit nivo. Ponašanje na ovom nivou je pod direktnom kontrolom cilja i zasnovano je na stečenom znanju. Za definisani cilj i na osnovu rezultata dobijenih analizom okruženja, traži se optimalan plan za postizanje toga cilja. Optimalan plan se dobija izborom jednog od više razmatranih planova metodom pokušaja i pogrešaka ili konceptualno, razumijevanjem funkcionalnih osobina okoline, a zatim predviđanjem efekata koje bi razmatrani plan mogao imati na istu.

2.2. Funkcionalna arhitektura sistema automatizovane vožnje

Za upravljanje automobilom, pod ovu kategoriju ponašanja spada na primjer navigacija ili računanje optimalne putanje vozila u toku izvođenja manevra paralelnog parkiranja (koje se često svede na metod pokušaja i pogrešaka).

Ovdje je interesantno razmotriti ulogu i vrstu informacija koje se razmjenjuju sa okolinom, ali i između različitih kategorija ponašanja. Činjenica je da informacija ili indikacije iz okruženja mogu biti doživljene različito za različite posmatrače. Na primjer, na nivou ponašanja zasnovanog na stečenim vještinama, informacije iz okruženja se primaju kao prostorno-vremenski signali, koji predstavljaju kvantitativne indikatore prostorno-vremenskog stanja okruženja. Na nivou ponašanja zasnovanog na pravilima, informacija se prima u formi znakova. Informacija se definiše kao znak ako se koristi da aktivira ili modificuje predefinisane akcije ili kognitivni sadržaj. Znakovi se odnose na situacije ili primjereni ponašanje definisano konvencijom ili prethodnim iskustvom - ne odnose se na koncepte i ne predstavljaju funkcionalne osobine okoline. Međutim, da bi bila korisna za kauzalno rezonovanje, odnosno za predviđanje ili objašnjavanje nepoznatog ponašanja okoline, informacija mora imati formu simbola. Simboli se odnose na koncepte vezane za funkcionalne osobine, ideje ili odnose, i kao takvi mogu biti korišćeni za rezonovanje. Potrebno je dodati da se signali, a samim tim i znakovi i simboli ne mogu smatrati apsolutno pouzdanim.

2.2 Funkcionalna arhitektura sistema automatizovane vožnje

Prirodno je primijeniti rezultate analize vještina vozača koje su potrebne za upravljanje vozilom i na definisanje funkcionalne arhitekture sistema automatizovane vožnje. Funkcionalna arhitektura predstavlja specifikaciju planiranih funkcionalnih komponenata i komunikacije između njih u cilju postizanja željenog ponašanja sistema. SAE J3016 definiše tri vrste komponenata koje se mogu naći u jednom takvom sistemu:

- Operativne komponente, odgovorne za lateralno (skretanjem) i longitudinalno (ubrzavanjem ili usporavanjem) upravljanje vozilom.
- Taktičke komponente, odgovorne za planiranje i izvršavanje menevara, prepoznavanje, klasifikaciju i izbjegavanje objekata, definisanje trajektorije, reakciju na saobraćajne događaje (u smislu povećanja uočljivosti vozila generisanim zvučnim ili svjetlosnim signala i slično) itd.
- Strateške komponente, odgovorne za planiranje puta (određivanje destinacije, vremena polaska, najbolje rute itd.).

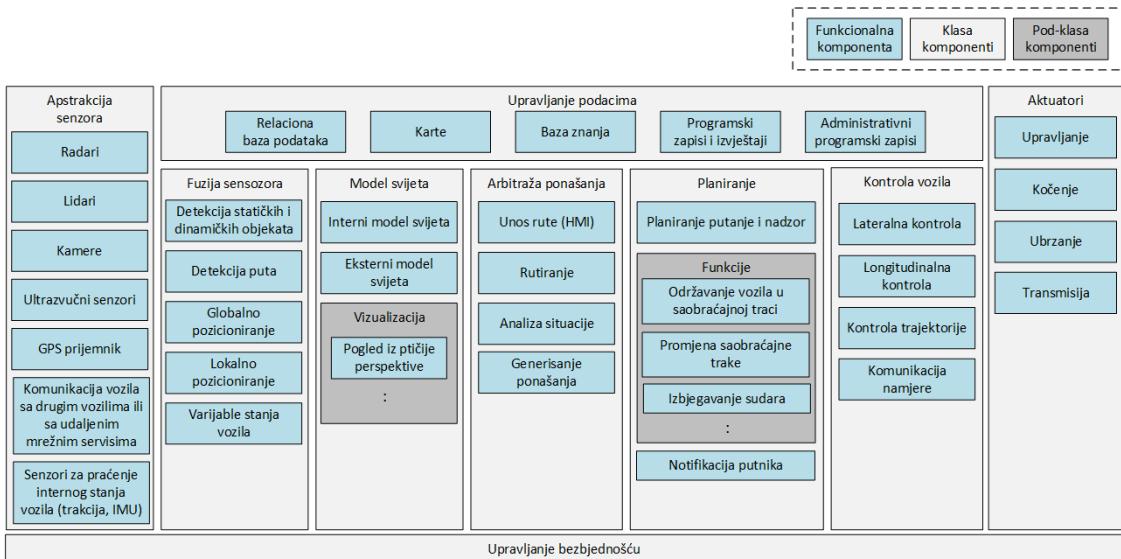
Već na osnovu ove kategorizacije funkcionalnih komponenata, može se zaključiti da SAE J3016 preslikava kategorizaciju ljudskog ponašanja prema učinkovitosti datu u prethodnom odjeljku. SAE J3016 za svaku klasu komponenata definiše

2.2. Funkcionalna arhitektura sistema automatizovane vožnje

i funkcionalnost koja mora biti automatizovana da bi se dostigao najviši stepen automatizacije vožnje.

Da bi sistem automatizovane vožnje bio u stanju da izvršava taktičke i strateške zadatke u funkcionalnu arhitekturu mora biti ukomponovana i interna reprezentacija okruženja vozila. Takođe, kao što je već prikazano na Slici 2.1, bilo bi poželjno da je komunikacija između funkcionalnih komponenata sistema organizovana hijerarhijski, na osnovu semantičkog značenja informacija. Na taj način komponente na nižem nivou hijerarhije imaju ograničeno semantičko razumijevanje ulaznih signala, ali su u stanju da generišu ulaze za komponente koje su na višem nivou hijerarhije, time produbljujući njihovo semantičko znanje i razumijevanje okruženja.

Uzimajući u obzir navedene zahtjeve, autori u [39] predlažu funkcionalnu arhitekturu sistema automatizovane vožnje koja je prikazana na Slici 2.2. Tok informacija



Slika 2.2: Funkcionalna softverska arhitektura sistema automatizovane vožnje.

na dijagramu je sa lijeva na desno, od senzora prema aktuatorima. Kao što se vidi, ova arhitektura oslikava i SAE J3016 klasifikaciju funkcionalnih komponenata. Komponente kontrole vozila i aktuatori obavljaju operativne funkcije. Komponente planiranje predstavljaju SAE J3016 taktičke funkcije, dok komponente zadužene za arbitražu ponašanja izvršavaju strateške funkcije.

Za osmatranje okoline (na primjer za detekciju i određivanje položaja objekata u okruženju vozila) i za određivanje relativnog položaja sistemskog vozila u odnosu na druge objekte iz okruženja (lokaciju), automatizovana vozila koriste različite tipove električnih senzora. Da bi se objedinio pristup senzorskim mjerjenjima, ali i ograničilo potrebno ekspertsко znanje potrebno za obradu senzorskih podataka kod funkcionalnih komponenata drugih klasa, pristup senzorskim podacima je potrebno apstrahovati. Apstrakcija senzora uključuje softverske interfejsne prema senzorima, te moguće funkcije adaptacije ili konverzije mjerjenja u oblik potreban za njihovu pravilnu interpretaciju.

2.2. Funkcionalna arhitektura sistema automatizovane vožnje

Električne senzore karakteriše niz parametara, kao na primjer: osjetljivost, preciznost, selektivnost, opseg i rezolucija. Funkcionalne komponente zadužene za fuziju senzorskih mjerena imaju zadatak da kombinuju velike skupove mjernih podataka heterogenih senzora u cilju prevazilaženja konstrukcijskih ili principijelnih nedostataka svakog od pojedinačnih senzora. Ovdje se pravi razlika između stacionarnih i dinamičkih objekata (pješaci, druga vozila), i objekata koji ne predstavljaju prepreke vožnji, ali čije semantičko značenje (na primjer sabraćajni znaci, semafori i slično) imaju neposredan uticaj na vozni zadatak.

Model svijeta predstavlja kompletnu sliku internog i eksternog stanja (okruženja) vozila, detektovanog senzorima visoko automatizovanog vozila. Podatke dobijene od fuzije je moguće kombinovati sa podacima u dijeljenoj memoriji (na primjer kartama) kako bi se model svijeta upotpunio sa podacima vezanim za geografsku poziciju vozila. Model svijeta je takođe pogodno mjesto za vizuelizaciju podataka, omogućavajući time uvid u performanse primjenjenih algoritama za percepцију, otkrivanje grešaka u toku razvoja i eksploracije sistema, i slično.

Funkcionalne komponente iz klase Arbitraža ponašanja zadužene su za predikciju okruženja, na primjer predikciju kretanja pješaka ili drugih vozila, i generisanje ponašanja sistemskog vozila. Sa izračunatim parametrima okruženja, zadatak sistema je da izabere plan ponašanja koji omogućava dostizanje zadatog odredišta bez ugrožavanja saobraćajne bezbjednosti. Komponenta za interakciju čovjeka i mašine (eng. *Human Machine Interface - HMI*) omogućava unos željenog odredišta. Nakon promjene odredišta, komponenta za globalno rutiranje računa novu putanju kretanja vozila i trigeruje novo generisanje ponašanja.

Planiranje putanje predstavlja svaki manevar koje sistemsko vozilo mora da izvede kako bi zadovoljilo izabrano ponašanje. Komponente za planiranje putanje i nadzor imaju zadatak da generišu trajektoriju vozila bez prepreka. Za sisteme do i uključujući 4. stepen automatizacije, koji nisu u mogućnosti da bezbjedno ispunе zahtjeve potrebne za potpunu automatizaciju vožnje (5. stepen), kontrola nad vozilom u nebezbjednim situacijama prelazi na vozača. U tu svrhu ova klasa uključuje i komponentu za notifikaciju vozača ili putnika.

Funkcionalne komponente za kontrolu vozila su zadužene za navođenje vozila planiranim trajektorijom. Kontrolni moduli za lateralno i longitudinalno kretanje upravljaju aktuatorskim funkcijama kočenja, ubrzavanja i transmisije. Ukoliko planirana trajektorija uključuje promjenu koja zahtjeva signalizaciju, komunikacioni mehanizmi sa vanjskim svijetom se trigeraju preko komponente za komunikaciju namjere.

Visoko automatizovana vozila koriste i generišu velike skupove podataka. Potreba za takvim funkcijama predstavljena je blokom za upravljanje podacima. Na primjer, globalna lokalizacija zahtjeva internu memoriju za karte, algoritmi mašinskog učenja zahtjevaju internu memoriju za čuvanje obučenih modela (baza znanja), interni stanje vozila zahtjeva napredne mehanizme za generisanje programskih zapisa i izvještaja (administrativni programski zapisi predstavljaju programske zapise

propisane od strane zakonodavca).

Da bi se pravilno opisala klasa veoma važnih funkcionalnih komponenata za upravljanje bezbjednošću potrebno je razumijeti proces nastajanja softvera u automobilskoj industriji i bezbjednosne norme koje je pri tome potrebno ispuniti. Sa tim na umu, u sljedećem odjeljku je, u razumnim okvirima, predstavljen međunarodni standard ISO 26262 koji definiše okvir za upravljenje rizikom prilikom razvoja hardvera i softvera, a koji je specifičan za automobilsku industriju. Na ovom mjestu je važno primijetiti da upravljenje bezbjednošću dotiče sve komponente date funkcionalne arhitekture sistema.

2.3 Funkcionalna bezbjednost prema standardu ISO 26262

U najopštijem smislu pojam bezbjednosti (eng. *safety*) podrazumijeva odsustvo nevolje ili opasnosti, bez obzira na njihov uzrok. Pored riječi bezbjednost, u srpskom jeziku je u upotrebi još i riječ sigurnost (eng. *security*). Iako se ove dvije riječi u svakodnevnoj upotrebi često koriste kao sinonimi (na primjer za oba pojma u njemačkom jeziku koristi se ista riječ - *Sicherheit*), sigurnost ipak predstavlja širi pojam od bezbjednosti, zato što osim odsustva opasnosti obuhvata i izvjesnost, samopouzdanje, pa i lakomislenost [40]. U ovoj disertaciji pojam bezbjednosti se posmatra u kontekstu uticaja nekog sistema ili komponente motornog vozila na bezbjednost učesnika u saobraćaju. S tim u vezi definise se i pojam funkcionalne bezbjednosti (eng. *functional safety*), i to kao način minimizacije opasnosti uzrokovane nekim (možda neispravnim) sistemom. Za jedan takav sistem pravilno je reći: „sistem sa zahtjevima za funkcionalnu bezbjednost“. Takođe treba praviti razliku između funkcionalne bezbjednosti i bezbjednosnih sistema (eng. *safety systems*). Na primjer, vazdušni jastuk je bezbjednosni sistem koji ima zahtjeve za funkcionalnu bezbjednost (ne smije se greškom aktivirati). Sistem za automatsko parkiranje je sistem koji ima zahtjeve za funkcionalnu bezbjednost (kada je aktivan ne smije da ugrozi učesnike u saobraćaju), ali nije bezbjednosni sistem.

Kao ni većinu životnih pojava, čovjek ni bezbjednost ne doživljava kategorički, kao binaran pojam. Odnosno, nije uobičajeno razlikovati samo dva stanja bezbjednosti: bezbjedno ili nebezbjedno stanje. Radije se tada govori o većem ili manjem riziku koju opasan događaj u datoј situaciji predstavlja. Uzimajući u obzir ozbiljnost posljedica koje opasan događaj može izazvati i vjerovatnoću pojave opasnog događaja za datu situaciju, rizik se može definisati kao:

$$Rizik = Ozbiljnost \cdot P(Opasan\ događaj \mid Situacija) \quad (2.1)$$

Primjenom Bajesove teoreme¹ na vjerovatnoću pojave opasnog događaja za datu

¹Bajesova teorema matematički se izražava jednačinom $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$, pri čemu su A i B slučajni događaji, a $P(B) \neq 0$.

2.3. Funkcionalna bezbjednost prema standardu ISO 26262

situaciju, $P(Opasan\ događaj \mid Situacija)$, prethodna jednačina može se pisati kao:

$$Rizik \sim Ozbiljnost \cdot P(Opasan\ događaj) \cdot P(Situacija \mid Opasan\ događaj). \quad (2.2)$$

U prethodnoj jednačini imenilac $P(Situacija)$ je izostavljen jer je konstantan za bilo koji opasan događaj, te kao takav ne utiče na relativnu vrijednost rizika. U literaturi koja obrađuje problematiku bezbjednosti (na primjer [41]) uobičajeno je jednačinu (2.2) pisati na sljedeći način:

$$Rizik = Ozbiljnost \cdot (Učestalost \cdot Vjerodostojnost), \quad (2.3)$$

jer se apriorna vjerovatnoća pojave opasnog događaja $P(Opasan\ događaj)$ može posmatrati kao učestalost njegovog pojavljivanja, dok je njegova vjerodostojnost² za datu situaciju data sa $P(Situacija \mid Opasan\ događaj)$.

Prirodno je tako posmatrati i funkcionalnu bezbjednost. Kao referentna veličina za ocjenu funkcionalne bezbjednosti koristi se granica dozvoljenog rizika. Neki sistem može se smatrati dovoljno bezbjednim, ukoliko se rizik njegove upotrebe nalazi ispod te granice. Granica dozvoljenog rizika je određena aktuelnim stanjem nauke i tehnologije. Aktuelnim stanjem nauke i tehnologije smatra se sva javno dostupna literatura (u obliku knjiga, časopisa, standarda i drugih), a koja se odnosi na datu problematiku.

Zakonodavci u mnogo slučajeva ne propisuju eksplicitno bezbjednosne norme sa kojima proizvođači automobila moraju usaglašavati svoje proizvode i proizvodne procese. Međutim, primjena takvih normi je implicitno obavezujuća. Na primjer, u njemačkom Građanskom zakoniku stoji odredba (§BGB 823 Schadenersatzpflicht) o obveznoj nadoknadi štete ukoliko se uslijed nemara ugrozi nečiji život, tijelo, zdravlje, sloboda, vlasništvo ili neko drugo pravo. Dakle, postoji obaveza (eng. *due-diligence*) primjene tehnologije koja odgovara aktuelnom stanju nauke i tehnologije, sve drugo može se smatrati nemarom.

Zahtjeve za funkcionalu bezbjednost električnih, elektronskih i programabilnih elektronskih sistema obuhvata tehnička norma IEC/EN 61508 [42]. Za automobilsku industriju je relevantna, iz nje izvedena, ISO 26262 norma [43]. ISO 26262 obuhvata definicije, smjernice, te proizvodne i kontrolne procedure za postizanje funkcionalne bezbjednosti električnih i elektronskih (E/E) komponenata. ISO 26262 definije bezbjednost kao „odsustvo nerazumnog (ili neopravdanog, neprihvatljivog) rizika“. Funkcionalna bezbjednost je prema ovom standardu definisana kao „odsustvo nerazumnog rizika uslijed opasnosti izazvane kvarom na E/E sistemu“, dok je nerazumno rizik definisan kao „rizik koji je neprihvatljiv prema važećim socijalnim i moralnim načelima“.

²Vjerodostojnjost (eng. *likelihood*) nije isto što i vjerovatnoća. U zavisnosti od problema koji se modeluje, izraz $P(Situacija \mid Opasan\ događaj)$ može se posmatrati dvojako: kao vjerovatnoća pojave situacije za dati opasan događaj ili kao vjerodostojnjost opasnog događaja za datu situaciju.

2.3.1 Specifikacija bezbjednosnih ciljeva

Posmatranjem nekog sistema ili funkcionalne komponente sa najvišeg nivoa apstrakcije, definiše se bezbjednosni cilj (eng. *safety goal*). Na primjer, „Funkcionalna komponenta Longitudinalna kontrola ne smije pokrenuti neželjenu proceduru kočenja vozila koja bi mogla dovesti do opasnosti“ primjer je jednog bezbjednosnog cilja funkcionalne komponente Longitudinalna kontrola. Svakom bezbjednosnom cilju mora se dodijeliti i bezbjedno stanje (eng. *safe state*). Za prethodni primjer bezbjedno stanje bi moglo biti „Onemogućena funkcija Longitudinalna kontrola“. Smisao ispunjavanja bezbjednosnih ciljeva ogleda se u smanjivanju rizika identificovanih, potencijalno opasnih, situacija ispod granice dozvoljenog rizika i odnosi se na sve funkcije i podfunkcije koji direktno ili indirektno mogu da utiču na posmatranu funkciju. Bezbjednosni cilj obično nije moguće ispuniti direktno, već se, analizom potencijalnog rizika, iz njega izvode bezbjednosni zahjevi (eng. *safety requirements*) nižeg nivoa.

Bezbjednosni ciljevi mogu biti zadati za različite kategorije rizika, tako da je neke bezbjednosne ciljeve lakše, a neke teže ispuniti. ISO 26262 standard definiše metodologiju za analizu i klasifikaciju potencijalno rizičnih situacija na osnovu tri parametra rizika:

- *Učestalost* izlaganja (eng. *exposure*) rizičnoj situaciji. Učestalost situacije može biti: veoma niska, niska, srednja ili visoka.
- *Upravljivost* (eng. *controllability*) funkcionalnim otkazom hardverskih ili softverskih komponenata u cilju izbjegavanja rizične situacije. Upravljivost pri tome može biti: jednostavna, normalna ili teška (ili nemoguća).
- *Ozbiljnosc* štete (eng. *severity*) izazvane rizičnom situacijom. Ozbiljnosc štete je pri tome proporcionalna težini potencijalnih povreda.

Rezultat analize i klasifikacije rizika je nivo potencijalnog rizika. Potencijalni rizik moguće je kvantifikovati jednim od pet nivoa: QM (eng. *Quality Management*), ASIL-A, ASIL-B, ASIL-C i ASIL-D (eng. *ASIL - Automotive Safety Integrity Level*), pri čemu ASIL-A odgovara najmanjem riziku, a ASIL-D najvećem. Suštinski, do ASIL nivoa dolazi se zamjenjujući u jednačini (2.3) *Vjerodostojnost* konceptom *Upravljivosti* [44]:

$$ASIL = Ozbiljnosc \times (Učestalost \times Upravljivost). \quad (2.4)$$

Takva definicija rizika je sasvim opravdana, jer mnogo je lakše analizirati i testirati upravljivost softverom ili hardverom u slučaju otkaza, nego analizirati vjerodostojnost pojave otkaza. Osim toga, analiza vjerodostojnosti pojave otkaza teško može dati konkretne smjernice za dizajn hardvera ili softvera. U Tabeli 2.1 dat je detaljan pregled nivoa rizika, i načina na koji se oni utvrđuju.

Standard ISO 26262 za svaki od navedenih nivoa potencijalnog rizika normativno zadaje mjere potrebne za izbjegavanje ili prevazilaženje sistemskih i slučajnih funk-

2.3. Funkcionalna bezbjednost prema standardu ISO 26262

Tabela 2.1: Kategorizacija rizika prema ISO 26262 standardu.

Ozbiljnost moguće štete	Učestalost situacije	Upravljivost		
		C1 (jednostavna)	C2 (normalna)	C3 (teška ili nemoguća)
S1 (lakše do umjerene povrede)	E1 (veoma niska)	QM	QM	QM
	E2 (niska)	QM	QM	QM
	E3 (srednja)	QM	QM	ASIL-A
	E4 (visoka)	QM	ASIL-A	ASIL-B
S2 (teže i povrede opasne po život uz veliku vjerovatnoću preživljavanja)	E1 (veoma niska)	QM	QM	QM
	E2 (niska)	QM	QM	ASIL-A
	E3 (srednja)	QM	ASIL-A	ASIL-B
	E4 (visoka)	ASIL-A	ASIL-B	ASIL-C
S3 (povrede opasne po život uz malu vjerovatnoću preživljavanja)	E1 (veoma niska)	QM	QM	ASIL-A
	E2 (niska)	QM	ASIL-A	ASIL-B
	E3 (srednja)	ASIL-A	ASIL-B	ASIL-C
	E4 (visoka)	ASIL-B	ASIL-C	ASIL-D

cionalnih otkaza, sa ciljem da nakon primjene tih mjera preostali rizik leži ispod granice dozvoljenog rizika. Kod ASIL-D kategorije potrebno je naravno primijeniti više procedura i mjera da bi se ispunili zadati bezbjednosni zahtjevi, nego kod, na primjer, kategorije ASIL-A. Ako je rizik kategorizovan sa QM, dovoljna je primjena nekog od standarda za upravljanjem kvalitetom i primjena ISO 26262 nije neophodna (mada je ponekad poželjna). U automobilskoj industriji to je obično Automotive SPICE [45], izведен iz međunarodnog ISO/IEC 15504 (SPICE) standarda. Ovdje međutim treba napomenuti da je ponekad mnogo teže ispuniti QM standarde nego ISO 26262.

Primjer procedura za detekciju greške na nivou softverske arhitekture je dat u Tabeli 2.2. Simboli u tabeli imaju sljedeće značenje:

- „++“ označava da je upotreba metode visoko-preporučena za identifikovani ASIL;
- „+“ označava da je upotreba metode preporučena za identifikovani ASIL;
- „o“ označava da upotreba metode nema posebne preporuke za upotrebu za identifikovani ASIL.

Zadati bezbjednosni ciljevi se dalje razlažu na sve nivoje hardverske i softverske sistemske arhitekture. Svakoj pasivnoj ili aktivnoj funkcionalnoj komponenti u vozilu, koja ima mogućnost da ugrozi zadati bezbjednosni cilj, dodjeljuju se zahtjevi za funkcionalnu bezbjednost (eng. *safety requirements*).

2.3.2 Ispunjavanje zahtjeva za funkcionalnu bezbjednost

Nakon što su za neki proizvod izvršeni analiza i kategorizacija bezbjednosnog rizika, zadati bezbjednosni ciljevi i, iz bezbjednosnih ciljeva izvedeni, zahtjevi za funkcionalnu bezbjednost, prema ISO 26262 potrebno je utvrditi da su ti isti ciljevi i

2.3. Funkcionalna bezbjednost prema standardu ISO 26262

Tabela 2.2: Mehanizmi za detekciju greške na nivou softverske arhitekture

Metode	ASIL			
	A	B	C	D
1a Provjera dozvoljenog opsega vrijednosti ulaznih i izlaznih podataka	++	++	++	++
1b Provjera vjerodostojnosti ^a	+	+	+	++
1c Otkrivanje grešaka u podacima ^b	+	+	+	+
1d Eksterni monitoring ^c	o	+	+	++
1e Monitoring kontrolnog toka	o	+	++	++
1f Diversifikovan softverski dizajn	o	o	+	++

^a Provjera vjerodostojnosti se može vršiti poređenjem signala sa onima dobijenim referentnim modelom, provjerom podrazumijevanih vrijednosti ili poređenjem signala dobijenih iz više izvora.

^b Otkrivanje grešaka u podacima se može vršiti kodovima za otkrivanje grešaka i redundantnim skladištenjem podataka.

^c Eksterni monitoring se može vršiti ASIC kolom ili nekom drugom softverskom komponentom za nadzor (eng. *watchdog*).

zahtjevi i ispunjeni. To istovremeno znači da su prema ISO 26262 standardu dokumentovanje korišćenog algoritma i specifikacija korišćenog hardvera potrebni ali ne i dovoljni uslovi da bi se sistem kvalifikovao funkcionalno bezbjednim. Za kvalifikaciju sistema funkcionalno bezbjednim potrebno je izvršiti i njegovu validaciju i verifikaciju.

U cilju validacije, rješenje, i sve njegove komponente, moraju biti jednoznačno povezane sa zadatim zahtjevima za funkcionalnu bezbjednost, u vidu specifikacije (dokumentacije). Takva logička veza između implementacije i zahtjeva za funkcionalnu bezbjednost se naziva sljedivost zahtjeva (eng. *requirements traceability*). Validacija treba da odgovori na pitanje: „Da li je razvijen sistem koji ispunjava zadati bezbjednosti cilj?“. Potpuna specifikacija sistema je neophodna i za verifikaciju rješenja. Za razliku od validacije, verifikacija treba da odgovori na pitanje: „Da li je sistem razvijen ispravno?“. Takvu dokumentaciju za kompleksne sisteme, kao što je sistem automatizovane vožnje čija je funkcionalna arhitektura data na Slici 2.2, je veoma teško napisati.

Već dati primjer bezbjednosnog cilja „Funkcionalna komponenta Longitudinalna kontrola ne smije pokrenuti neželjenu proceduru kočenja vozila koja bi mogla dovesti do opasnosti.“ može poslužiti da se ukaže na problematiku koja se ovdje javlja. Kao što je već pomenuto, potrebno je pokazati sljedivost bezbjednosnih zahtjeva na svim nivoima implementacije rješenja. U konkretnom primjeru, funkcionalnom komponentom „Longitudinalna kontrola“ upravlja jedna od komponenata zaduženih za planiranje. Komponente planiranja koriste rezultate arbitraže poнаšanja, koje sa druge strane koriste informacije modela svijeta. Model svijeta se formira korišćenjem algoritama za detekciju objekata, između ostalih i pješaka. Specifikacija, a samim tim i verifikacija sistema mora da obuhvati sve moguće položaje, svih mogućih pješaka u okruženju sistemskog vozila. To naravno nije moguće, pa se ovdje govori o prazninama u sljedivosti bezbjednosnih zahtjeva.

2.3.3 Prevazilaženje praznina u sljedivosti bezbjednosnih zahtjeva

Naizgled, problem praznina u sljedivosti bezbjednosnih zahtjeva bi se mogao riješiti primjenom statističkih metoda. Na primjer, u prethodnom primjeru moguće je upotrijebiti algoritam koji stohastički modeluje položaj pješaka. Stvarni položaj pješaka nikada nije poznat, već se rekurzivno procjenjuje nizom mjerena. Razlika između procijenjenog i izmjerrenog položaja pješaka naziva se rezidualna greška, pa se tako i vjerovatnoća pogrešne procjene algoritma naziva vjerovatnoća rezidualne greške. Vjerovatnoća rezidualne greške može da se posmatra kao konfiguracioni parametar algoritma, i to tako da niža vrijednost vjerovatnoće znači viši stepen automatizacije vožnje. Međutim, ovdje se nameće pitanje, koja je prihvatljiva vrijednost vjerovatnoće rezidualne greške u slučaju visoko i potpuno automatizovanih vozila? Na žalost, ISO 26262 ne daje odgovor na ovo pitanje. Iako se ISO 26262 bavi kvantitativnom (učestanost pojave kvarova) i kvalitativnom (identifikacija kvarova) analizom kvarova hardvera, na nivou softvera, pojava grešaka se tretira samo kvalitativnom analizom. To je naravno sasvim razumljivo, jer pogrešno je očekivati da Međunarodna organizacija za standardizaciju, ISO, preuzme odgovornost definisanja dozvoljene vjerovatnoće rezidualne greške softverskih algoritama, koji eventualno mogu dovesti do fatalnih posljedica za učesnike u saobraćaju.

Agresivan marketing kompanija koje učestvuju u realizaciji sistema automatske vožnje daje opravdan utisak da dozvoljenu vjerovatnoću rezidualne greške u stvari propisuje javno mnijenje. Na inženjerima i istraživačima je da obezbjede dovoljnu količinu pouzdanih podataka i dokaza koji će kod javnog mnijenja podići nivo povjerenja u novu tehnologiju i učiniti je opšte prihvatljivom. To znači da bi rješenje problema praznina u sljedivosti bezbjednosnih zahtjeva koje nastaju korišćenjem algoritama mašinskog učenja, onda bilo prilagođeni standard, koji odražava prihvaćene društvene norme [46–49]. Do tada, jedno od rješenja vidi se u jednostavnom ograničavanju saobraćajnih situacija u kojima se automatizovano vozilo može koristiti, pa se onda na primjer može govoriti o sistemu automatizovane vožnje stepena 4, čija je funkcionalna bezbjednost sertifikovana samo na tačno određenoj geografskoj lokaciji, parkingu ili slično.

2.3.4 Problem validacije i verifikacije vještačkih neuronskih mreža

Važeće norme razvoja softvera u automobilskoj industriji polaze od činjenice da se algoritam programira. Sa druge strane, vještačka neuronska mreža se obučava skupom podataka za obučavanje i testira skupom podataka za testiranje. Ovakav način „programiranja“ algoritma podacima otvara mnoga pitanja na koja je u toku validacije potrebno odgovoriti. Naravno, pored validacije pojedinačnih funkcionalnih komponenata potrebno je izvršiti i validaciju cjelokupnog sistema.

Još krajem osamdesetih godina prošlog vijeka, pokazano je da je problem donošenja odluke, da li postoje težinski koeficijenti neuronske mreže sa dva sloja i tri neurona,

2.3. Funkcionalna bezbjednost prema standardu ISO 26262

takvi da mreža generiše izlazne vrijednosti koji su konzistentni nad cijelim skupom za obučavanje, NP–kompletan [50]. I pored toga, validacija modela vještačkih nevronskih mreža je u naučnoj zajednici još uvijek veoma aktuelan problem. Pitanja na koja je u toku validacije potrebno odgovoriti mogu se grubo podijeliti na pitanja koja se odnose na izbor modela i na pitanja koja se odnose na pravilan izbor elemenata skupa za obučavanje. Osnovna pitanja koja se odnose na izbor modela su:

- Kako će mreža reagovati na ulaze koji nisu viđeni u toku obučavanja, odnosno, da li mreža generalizuje dovoljno dobro?
- Da li je obučavanjem postignut globalni ili lokalni minimum funkcije gubitka?

Postignuti rezultati nekih modela vještačkih nevronskih mreža za klasifikaciju slika mogu se tumačiti kao da je princip obučavanja minimizacijom greške na skupu za obučavanje jedini razlog generalizacije modela, te da validacija, odnosno opravданje za ovakav princip indukcije nije potrebna. Vladimir Vapnik takvo tumačenje procesa učenja naziva primjenjena analiza procesa učenja [51]. Rezultati ovakvog „bezbjednog“ pristupa procesu učenja dostupni su već odavno (na primjer softver za prepoznavanje lica, obradu govora i slično), a kako je već pomenuto, upravo ovi rezultati okidač su i za pokušaje primjene vještačkih nevronskih mreža u sistemima visoko automatizovane vožnje - sistema koji mogu da ugroze bezbjednost čovjeka. Za ovakve sisteme, mnogo prikladniji pristup analizi procesa učenja bio bi princip indukcije za koji je, da bi bio korišćen, neophodno potvrditi da je bolji od svih drugih principa indukcije. Ovakav pristup naziva se teoretski pristup analizi procesa učenja. Osnovni ciljevi ovog pristupa su pronađenje induktivnog principa kojim se ostvaruje najbolja generalizacija, a potom i konstrukcija algoritama koji taj princip realizuju. Rezultat teoretskog pristupa analizi procesa učenja je statistička teorija učenja. U automobilskoj industriji preovladava primjenjena analiza procesa učenja, a neizvjesnost oko izbora modela želi se smanjiti povećanjem broja i raznovrsnosti elemenata skupa za obučavanje! Takav pristup odgovore na pitanja koja se odnose na pravilan izbor skupa za obučavanje čini još važnijima. Osnovna pitanja ovdje su:

- Da li je skup podataka za obučavanje dovoljan i prikladan za definisani domen problema?
- Da li je mreža naučila stvarna obilježja dostupna u podacima ili u procesu donošenja odluke koristi obilježja koja su im veoma bliska ali ne odražavaju stvarnu prirodu problema?

Neizvjesnost oko izbora parametara modela ili samog modela odražava nesigurnost u aposteriorno uvjerenje modela oko izračunatog ishoda. Ta vrsta neizvjesnosti se u literaturi naziva epistemička neizvjesnost. Epistemička neizvjesnost se može smanjiti statističkom analizom mjernih podataka, odnosno boljim razumijevanjem problema i u skladu sa tim izborom boljeg modela, ali problem je što ne^c postoje

^cVelike nade polagane su na duboke Bayesove mreže kao modele koje bi omogućili mjerjenje

2.3. Funkcionalna bezbjednost prema standardu ISO 26262

modeli neuronskih mreža koji mogu mjeriti ovaj vid neizvjesnosti. Kada bi takav model postojao, ulaz za koji je epistemička neizvjesnost visoka bi se mogao uzeti u skup za obučavanje. Time bi i problem visoko automatizovane vožnje postao mnogo jednostavniji, ali ne i riješen. Naime, postoji još jedan vid neizvjesnosti koji se odnosi na same podatke, takozvana aleatorička neizvjesnost. Aleatorička neizvjesnost se identificira kao inherentna stohastičnost fizičkog fenomena koji se posmatra, te kao takva predstavlja sve nepoznate parametre posmatranog fenomena. Pod ovaj pojam mogu se svrstati razne vrste šumova, suparničkih primjera (eng. *adversarial examples*) i slično, a koji se mogu javiti u toku korišćenja neuronske mreže, a nisu se mogli predvidjeti (a samim tim niti modelovati) u toku obučavanja.

Smanjenje aleatoričke neizvjesnosti vidi se u fuziji informacija sadržanih u senzorskim mjeranjima različitih modaliteta, odnosno, pretpostavlja se da se korišćenjem obilježja prisutnih u mjeranjima jednog modaliteta mogu bolje tumačiti mjeranja koja potiču od senzorskih mjeranja drugog modaliteta. Klasične metode fuzije mjeranja različitih modaliteta obično su zasnovane na svođenju mjeranja svih senzora na zajednički, prostiji, matematički model pojave koja se mjeri, na primjer modelovanjem pojave vektorom stanja čije su komponente slučajne promjenljive raspodijeljene prema nekoj analitičkoj raspodjeli. Fuzijom vektora stanja raznorodnih senzora, obično korišćenjem nekog od principa rekurzivne estimacije, cilj je da se dobije pouzdana informacija o stvarnom stanju okruženja. Na primjer, nadzor bliske okoline (na primjer do $2m$) vozila vrši se ultrazvučnim senzorima, radarima i kamerama, a korišćenjem mjeranja ovih senzora odluka o zauzetosti prostorne koordinate donosi se tek nakon višestruke provjere hipoteze o zauzetosti. Ovakav tok informacija preslikava i funkcionalna softverska arhitektura sistema automatske vožnje. Međutim, jasno je da se takvim, preuranjenim, pristupom fuziji nepovratno gubi dio informacija koje su sadržane u originalnim mjeranjima, a koje bi se mogle iskoristiti za donošenja pouzdanijih procjena vektora stanja.

epistemičke neizvjesnosti, međutim pokazuje se da one sa povećanjem broja podataka ne konvergiraju asymptotski, što je osnovna odlika bajesovske aproksimacije [52, 53].

Glava 3

Materijal i metodologija

Za uspješno obučavanje modela mašinskog učenja koji su predstavljeni u ovoj disertaciji, uključujući i predloženu metodu za transformaciju obilježja i semantičku fuziju senzorskih mjerena različitih modaliteta, neophodni su odgovarajući skupovi anotiranih podataka za obučavanje. U tu svrhu će, pored javno dostupnih, biti korišćeni i podaci prikupljeni u toku eksperimentalne vožnje razvojnim putničkim vozilom. Skup podataka za obučavanje sastoji se od uparenih slika dobijenih dokumentacionom kamerom^a i mjerena radarskih senzora kratkog i dugog dometa. Slike dobijene kamere zadržane su u izvornom obliku, dok su radarska mjerena, kao što će biti prikazano u nastavku, transformisana u oblik pogodan za dalju obradu konvolucionim neuronskim mrežama. Dio prikupljenih slika anotiran je korišćenjem javno dostupnog LabelMe servisa za anotiranje podataka [54]. Ovako anotirane slike, zajedno sa uparenim radarskim mjeranjima iskorišćeni su za eksperimentalnu analizu predloženih principa fuzije.

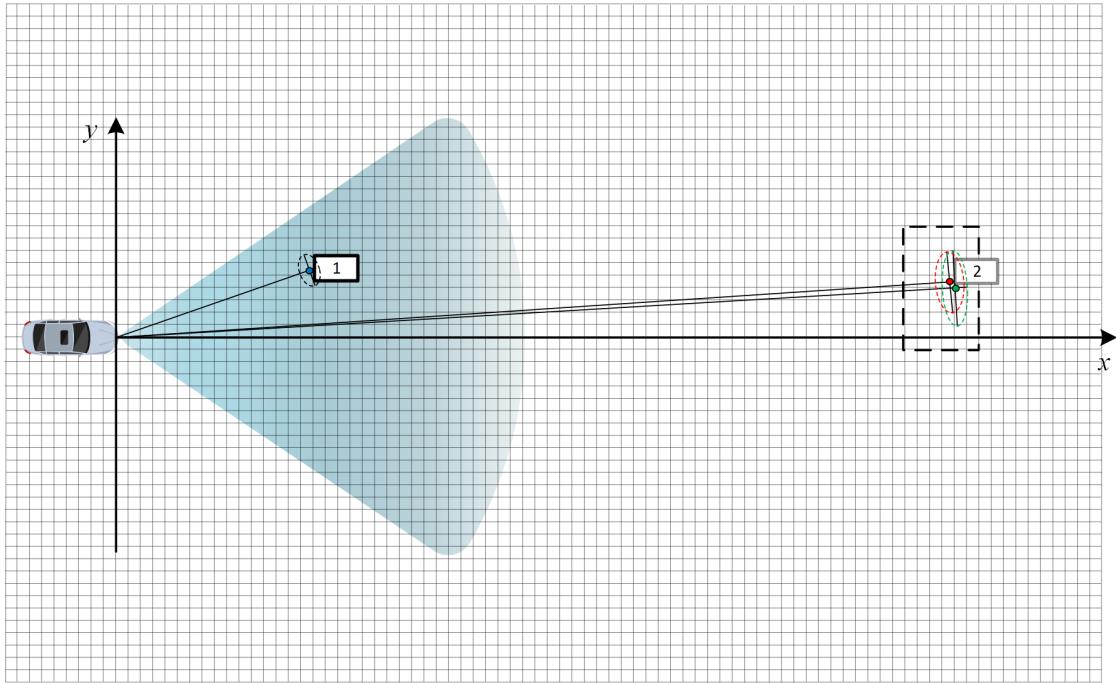
3.1 Dempster-Šaferova rešetka dokaza

Radare karakteriše visoka pouzdanost rada u gotovom svim meteorološkim uslovima, ali i niska tačnost, preciznost i rezolucija. Na Slici 3.1 prikazana su dva mjerna ciklusa radara. U mjernom ciklusu k , radar detektuje dva stacionarna objekta na lokacijama (x_1^k, y_1^k) i (x_2^k, y_2^k) . U mjernom ciklusu $k + 1$ radar detektuje samo jedan od objekata, ali ovaj put na drugoj lokaciji (x_2^{k+1}, y_2^{k+1}) . Izmjerene prostorne koordinate detektovanih objekata modeluju se kao slučajne promjenljive, zadate slučajnim vektorom \mathbf{x} i dvodimenzionalnom Gausovom gustinom vjerovatnoće:

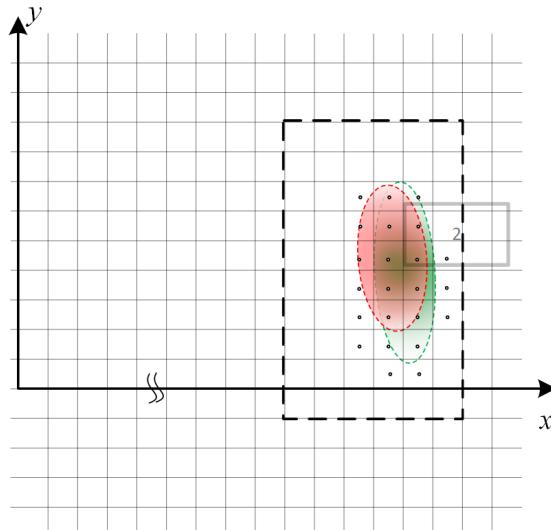
$$p(\mathbf{x}) = \frac{1}{2\pi} (\det \boldsymbol{\Sigma})^{-1/2} \exp \left[-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right], \quad (3.1)$$

^aDokumentacione kamere prisutne su u senzorskoj konfiguraciji automatizovanih vozila samo u toku razvojne faze. Njihov zadatak je da obezbjede dodatne informacije o okruženje vozila u toku testiranja primarnih senzora, čija mjerena, bez dodatne obrade, nije moguće vizuelno interpretirati (na primjer mjerena radara).

3.1. Dempster-Šaferova rešetka dokaza



(a) Položaj objekata u prostoru i pripadajuća mjerena.



(b) Dvije uzastopne detekcije istog objekta, prikazane uvećano.

Slika 3.1: Dva mjerna ciklusa radara. Elipsama se želi ukazati na slučajnu prirodu radarskih mjerena. U ovom primjeru izmjerene koordinate modeluju se Gausovom gustočnom vjerovalnoću.

gdje su sa

$$\mathbf{x} = \begin{bmatrix} x \\ y \end{bmatrix}, \mu = \begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix}, \Sigma = \begin{bmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_y\sigma_x & \sigma_y^2 \end{bmatrix}, \quad (3.2)$$

3.1. Dempster-Šaferova rešetka dokaza

dati slučajni vektor položaja, vektor očekivanih vrijednosti položaja detektovanog objekta i matrica kovarijansi, respektivno. Koordinate položaja detektovanog objekta, x i y , predstavljaju slučajne promjenljive čija očekivanja su data sa μ_x i μ_y , respektivno. Standardne devijacije slučajnih promjenljivih x i y date su sa σ_x i σ_y , respektivno.

Pod pretpostavkom da se položaj i kretanje sistemskog vozila^b u svakom trenutku može pouzdano odrediti korišćenjem inercijalnog senzora - IMU (eng. *Inertial Measurement Unit*), kompleksni problem simultane lokalizacije i mapiranja - SLAM (eng. *Simultaneous Localization and Mapping*) može se svesti na jednostavniji problem mapiranja [19]. Rešetke zauzetosti (eng. *occupancy grid*) su popularna familija algoritama za mapiranje okruženja sistemskog vozila. Osnovna ideja rešetki zauzetosti sastoji se u reprezenaciji okruženja dvodimenzionalnom, ravnomjerno izdijeljenom prostornom rešetkom. Ćelije rešetke zauzimaju jednaku površinu u prostoru. Površina ćelije zadaje se u zavisnosti od prostorne rezolucije senzora, a njene vrijednosti kreću se od $0.01\text{ m} \times 0.01\text{ m}$ do $1\text{ m} \times 1\text{ m}$. Neka je rešetka zauzetosti sastavljena od N ćelija. Svaka od N ćelija rešetke zauzetosti opisana je vjerovatnoćom zauzetosti dijela prostora kojeg ćelija zauzima^c. Neka su sva dostupna mjerena senzora^d za nadgledanje okruženja sistemskog vozila, od početnog trenutka mjerena 1 do nekog trenutka t , data sa $\mathbf{z}_{1:t}$. Takođe, pretpostavlja se da je u svakom trenutku poznat i položaj sistemskog vozila u odnosu na neki referentni koordinatni sistem i da je to znanje, od početnog trenutka mjerena 1 do trenutka t , dato sa $\mathbf{x}_{1:t}$. Računanje rešetke zauzetosti \mathbf{m} u trenutku t zasniva se na određivanju uslovne aposteriorne vjerovatnoće:

$$p(\mathbf{m}|\mathbf{z}_{1:t}, \mathbf{x}_{1:t}). \quad (3.3)$$

Neka je sa m_i označena ćelija rešetke sa indeksom i . Tada se rešetka \mathbf{m} može predstaviti sa:

$$\mathbf{m} = \{m_1, m_2, \dots, m_i, \dots, m_N\}. \quad (3.4)$$

Pod jakom pretpostavkom da su ćelije rešetke m_i statistički nezavisne, problem određivanja rešetke zauzetosti svodi se na određivanje vjerovatnoće zauzetosti svake pojedinačne ćelije:

$$p(\mathbf{m}|\mathbf{z}_{1:t}, \mathbf{x}_{1:t}) = \prod_i p(m_i|\mathbf{z}_{1:t}, \mathbf{x}_{1:t}). \quad (3.5)$$

Vjerovatnoću zauzetosti ćelije moguće je odrediti korišćenjem binarnog Bajesovog filtra [55–57] ili korišćenjem Dempsterovog pravila kombinovanja dokaza. Dempsterovo pravilo kombinovanja izvedeno je iz takozvane Dempster-Šaferove teorije dokaza [58–60]. U ovoj disertaciji se za računanje rešetke dokaza koristi upravo ova

^bSistemsko vozilo se u literaturi ponekad naziva i ego–vozilo.

^cĆelijama je moguće pridružiti različite attribute ili vektor stanja, koji pogodno opisuju tu jedinicu prostora (na primjer, informacije o visini, semantičkoj klasi objekta i slično).

^dNa primjer, ako se radi o radaru, RCS (eng. *Radar Cross Section*) detektovanog objekta može se koristiti za računanje vjerovatnoće prisustva objekta.

3.1. Dempster-Šaferova rešetka dokaza

teorija, pa se shodno tome i rešetka zauzetosti naziva rešetka dokaza (eng. *evidence grid*).

Dempster-Šaferova teorija, teorija dokaza ili teorija funkcija uvjerenosti, može se shvatiti kao uopštenje bajesovske^e interpretacije teorije vjerovatnoće, prema kojoj se vjerovatnoća interpretira kao subjektivni stepen uvjerenosti u neki događaj (što odgovara i čovjekovom shvatanju pojma vjerovatnoće). Na primjer, prema bajesovskoj interpretaciji, da bi se izračunala vjerovatnoća hipoteze \mathcal{H} o zauzetosti neke tačke u prostoru, u svjetlu novih, relevantnih dokaza \mathcal{D} , prethodno je potrebno zadati apriornu vjerovatnoću hipoteze $P(\mathcal{H})$. Primjenom Bajesove teoreme dolazi se do izraza za aposteriornu vjerovatnoću hipoteze $P(\mathcal{H}|\mathcal{D}) \propto P(\mathcal{D}|\mathcal{H})P(\mathcal{H})$. U sljedećem ciklusu mjerena, kao apriorna vjerovatnoća hipoteze uzima se aposteriorna vjerovatnoća hipoteze iz prethodnog ciklusa mjerena.

Formalno, Dempster-Šaferova teorija posmatra sva moguća stanja nekog sistema. Neka su ta stanja predstavljena elementima skupa X . Elementi partitivnog skupa 2^X predstavljaju sva moguća stanja u kojima se sistem može naći. Na primjer, neka X predstavlja sva moguća stanja zauzetosti tačke u prostoru, odnosno $X = \{F, O\}$. Stanje F označava da je tačka slobodna, a stanje O da je tačka zauzeta. Partitivni skup dat je onda sa:

$$2^X = \{\emptyset, \{F\}, \{O\}, \{F, O\}\}. \quad (3.6)$$

Element $\{F, O\}$ partitivnog skupa označava nepoznato stanje sistema.

Svakom elementu partitivnog skupa 2^X , odnosno stanju sistema, može se dodijeliti masa uvjerenosti u to stanje - BM (eng. *Belief Mass*):

$$m: 2^X \rightarrow [0, 1]. \quad (3.7)$$

Funkcija m naziva se osnovno pridruživanje uvjerenosti - BBA (eng. *Basic Belief Assignment*), ako ispunjava sljedeće uslove:

1. $m(\emptyset) = 0$ i
2. $\sum_{A \in 2^X} m(A) = 1$.

Masa $m(A)$ elementa A partitivnog skupa 2^X proporcionalna je količini svih relevantnih i dostupnih dokaza koji podržavaju tvrdnju da se sistem nalazi u stanju A , ali ne i nekom podskupu stanja A . Na primjer, masom $m(\{F, O\}) = 1$ izražava se nepostojanje dokaza koji podržavaju tvrdnju da je tačka u prostoru slobodna ili zauzeta. U tom slučaju su $m(F) = m(O) = 0$.

Dempsterovo pravilo kombinovanja dvije BBA funkcije, m_1 i m_2 , omogućava rekurzivno izračunavanje mase uvjerenosti, i dato je sljedećom formulom:

^eBajesovska interpretacija vjerovatnoće se razlikuje od frekventističke interpretacije. Prema frekventističkoj interpretaciji vjerovatnoća se tretira kao relativna frekvencija događaja u beskonačno dugoj seriji opita.

3.1. Dempster-Šaferova rešetka dokaza

1. $m_{1,2}(\emptyset) = 0$ i
2. $m_{1,2}(A) = \frac{1}{1-K} \sum_{B \cap C = A \neq \emptyset} m_1(B)m_2(C).$

Pri čemu veličina $K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C)$ predstavlja mjeru konflikta između dva skupa masa.

Na primjeru prikazanom na Slici 3.1, koraci algoritma fuzije informacija o zauzetosti ćelije rešetke dokaza su:

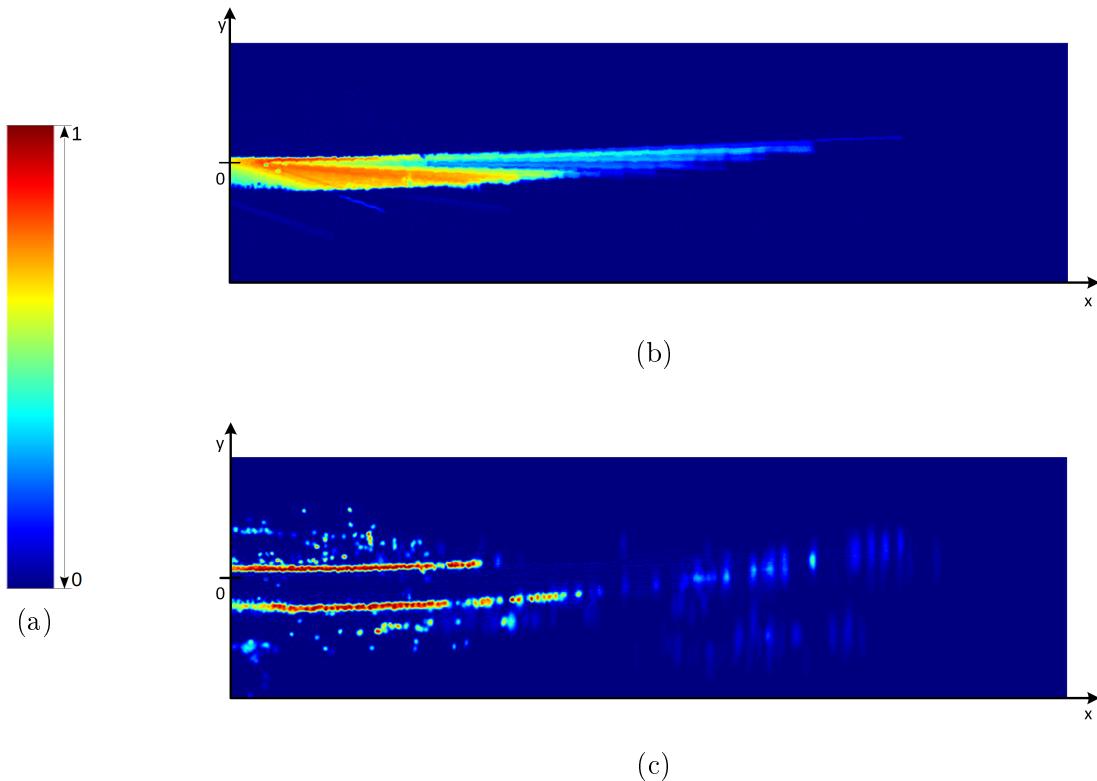
1. Kako je potrebno čuvati informaciju o 2 stanja zauzetosti za $M \times N$ ćelija rešetke, rešetku dokaza u memoriji računara potrebno je modelovati sa dvije matrica brojeva \mathbf{m}_F^k i \mathbf{m}_O^k dimenzija $M \times N$, za slobodno i zauzeto stanje zauzetosti, respektivno.
2. Uvjerenost u slobodno i zauzeto stanje ćelije (i,j) ($(i,j) \in \{1,2,\dots,M\} \times \{1,2,\dots,N\}$) u mjernom ciklusu k dato je masama $m_F^k(i,j)$ i $m_O^k(i,j)$, respektivno. Dok je uvjerenost u nepoznato stanje u mjernom ciklusu k dato masom $m_X^k(i,j) = m_{\{F,O\}}^k(i,j) = 1 - m_F^k(i,j) - m_O^k(i,j)$.
3. Svi elementi matrice imaju početne vrijednosti $m_F^0(i,j) = m_O^0(i,j) = 0$, što odražava i subjektivno uvjerenje o zauzetosti prije početka mjerjenja.
4. Mjerenjem radara u ciklusu $k + 1$ dobijaju se procjene masa slobodnog i zauzetog stanja $\hat{m}_F^{k+1}(i,j)$ i $\hat{m}_O^{k+1}(i,j)$, respektivno.
5. Nove mase zauzetosti dobijaju se kombinovanjem trenutnih i procijenjenih masa, odnosno rekursivnom primjenom Dempsterovog pravila kombinovanja:

$$m_F^{k+1}(i,j) = \frac{m_F^k(i,j)\hat{m}_F^{k+1}(i,j) + m_F^k(i,j)\hat{m}_X^{k+1}(i,j) + m_X^k(i,j)\hat{m}_F^{k+1}(i,j)}{1 - m_F^k(i,j)\hat{m}_O^{k+1}(i,j) - m_O^k(i,j)\hat{m}_F^{k+1}(i,j)} \quad (3.8)$$

i

$$m_O^{k+1}(i,j) = \frac{m_O^k(i,j)\hat{m}_O^{k+1}(i,j) + m_O^k(i,j)\hat{m}_X^{k+1}(i,j) + m_X^k(i,j)\hat{m}_O^{k+1}(i,j)}{1 - m_F^k(i,j)\hat{m}_O^{k+1}(i,j) - m_O^k(i,j)\hat{m}_F^{k+1}(i,j)} \quad (3.9)$$

Primjeri tako dobijenih Dempster-Šeferovih rešetki dokaza dati su na Slici 3.2. Veća vrijednost boje piksela slike 3.2b, odnosno slike 3.2c, predstavlja veću masu slobodnog, odnosno zauzetog stanja ćelije. Na slikama rešetki ilustrovan je i koordinatni sistem senzora. Sistemsko vozilo orijentisano je u pozitivnom smjeru x ose. Rešetke dokaza, pored prostornog rasporeda detektovanih objekata, ukazuju i na to da je pouzdanost detekcija manja sa većom udaljenošću objekata od vozila. Takođe, primjer pokazuje i da je koristeći samo rešetke dokaza vrlo teško utvrditi semantičke klase (kolovoz, drvo, most i slične) detektovanih objekata.

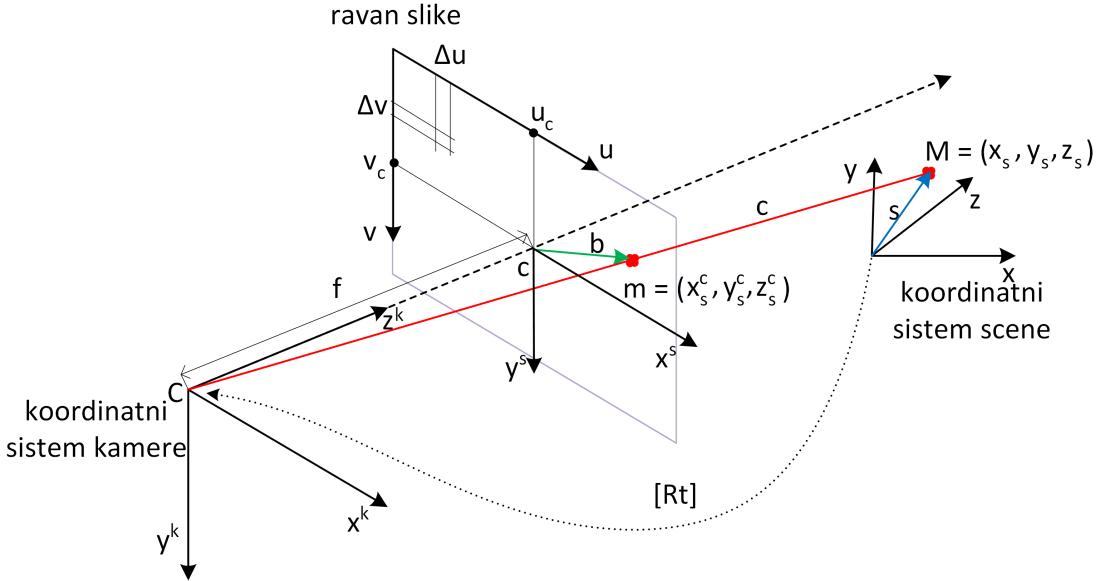


Slika 3.2: Primjer Dempster-Šafereve rešetke dokaza. Slika (a) prikazuje preslikavanje boja u uvjerenje o stanju zauzetosti celije rešetke. Slike (b) i (c) predstavljaju dva kanala ili sloja Dempster-Šaferove rešetke dokaza, odnosno stepen uvjerenosti u (b) slobodno stanje i (c) zauzeto stanje celija rešetke.

3.2 Ekstrinsični i intrinsični parametri kamere

U opštem slučaju, kalibracija mjernog instrumenta može se posmatrati kao proces poređenja rezultata mjerena dobijenih mjernim instrumentom koji se kalibriše i rezultata mjerena dobijenih mjernim instrumentom poznate tačnosti [7]. Kalibracijom senzora određuju se ekstrinsični i intrinsični parametri senzora [61]. Ekstrinsični parametri senzora opisuju položaj i orijentaciju koordinatnog sistema senzora u odnosu na eksterni, referentni koordinatni sistem. Analiza metoda fuzije i interpretacije senzorskih mjerena u uvodnoj Glavi 1 ukazuje na važnost tačnih ekstrinsičnih parametara kamere. Klasične metode fuzije koriste ekstrinsične parametre za izračunavanje projekcije koordinata mjernih tačaka iz koordinatnog sistema jednog senzora u koordinatni sistem drugog senzora. Intrinsični parametri kamere su parametri modela kamere koji opisuje vezu između koordinata mjerne tačke u koordinatnom sistemu kamere i koordinata te tačke projektovane na ravan slike (kod kamere to su na primjer žižna duljina sočiva, distorzioni parametri sočiva i slično). Na Slici 3.3 prikazan je model sintetičke kamere (eng. *pinhole camera model*) i koordinatni sistemi potrebni za njenu kalibraciju [62]. Prema oznakama sa

3.2. Ekstrinsični i intrinsični parametri kamere



Slika 3.3: Koordinatni sistemi potrebni za proces kalibracije kamere.

slike^f, odnosi između koordinatnog sistema kamere (C, x^k, y^k, z^k) i koordinatnog sistema slike (c, x^s, y^s) dati su sa:

$$x^s = \frac{x^k f}{z^k} \quad \text{i} \quad y^s = \frac{y^k f}{z^k}. \quad (3.10)$$

Koristeći homogene koordinate, prethodna jednačina može se zapisati u obliku:

$$\begin{bmatrix} Sx^s \\ Sy^s \\ S \end{bmatrix} = \begin{bmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x^k \\ y^k \\ z^k \\ 1 \end{bmatrix}, \quad (3.11)$$

pri čemu vrijedi $S = z^k$. U prethodnoj jednačini parametar f predstavlja žižnu daljinu sočiva. Faktor S naziva se faktor skaliranja. Koordinate piksela slike (u, v) mogu se pisati na sljedeći način:

$$u = u_c + \frac{x^s}{\Delta u} \quad \text{i} \quad v = v_c + \frac{y^s}{\Delta v}, \quad (3.12)$$

gdje su sa Δu i Δv date širina i visina piksela, respektivno, a sa u_c i v_c koordinate piksela u kojem se nalazi središte koordinatnog sistema slike i kroz koji prolazi

^fKao inspiracija za Sliku 3.3 i matematičku analizu kalibracije u nastavku poslužila je analiza kalibracije sintetičke kamere dostupna na Internet stranici http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/OWENS/LECT9.

3.3. Skup podataka PennCOSYVIO

optička osa kamere z^k . Uvrštavanjem (3.10) u (3.12) i sređivanjem dobija se:

$$\begin{bmatrix} Su \\ Sv \\ S \end{bmatrix} = \begin{bmatrix} \frac{f}{\Delta u} & 0 & u_c & 0 \\ 0 & \frac{f}{\Delta v} & v_c & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x^k \\ y^k \\ z^k \\ 1 \end{bmatrix}, \quad (3.13)$$

pri čemu vrijedi $S = z^k$. Iz prethodne jednačine vidi se da postoji pet parametra kamere koje je potrebno odrediti kalibracijom: žižna daljina f , širina piksela Δu , visina piksela Δv i pikselske koordinate optičkog centra kamere u_c i v_c . Ovi parametri ne zavise od pozicije i orijentacije kamere u prostoru, te se stoga nazivaju intrinsični parametri.

U praksi, prostorni koordinatni sistem scene ili svijeta (O, x, y, z) nije usaglašen sa prostornim koordinatnim sistemom kamere (C, x^k, y^k, z^k) . Ako su koordinate homogenizovane, transformaciju iz jednog u drugi koordinatni sistem moguće je predstaviti jednom matricom transformacije. Projekcija koordinata mjerne tačke iz koordinatnog sistema scene u ravan slike može se onda pisati na sljedeći način:

$$\begin{bmatrix} Su \\ Sv \\ S \end{bmatrix} = \begin{bmatrix} \frac{f}{\Delta u} & 0 & u_c & 0 \\ 0 & \frac{f}{\Delta v} & v_c & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} r_{1,1} & r_{1,2} & r_{1,3} & t_1 \\ r_{2,1} & r_{2,2} & r_{2,3} & t_2 \\ r_{3,1} & r_{3,2} & r_{3,3} & t_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}, \quad (3.14)$$

pri čemu vrijedi $S = z^k$. Parametri $r_{i,j}$ u prethodnoj jednačini opisuju orijentaciju kamere u prostoru scene, a parametri t_i položaj kamere u odnosu na koordinatni početak scene. Ovi parametri nazivaju se zbog toga ekstrinsični parametri kamere.

Skraćeno, jednačina (3.14) može se pisati na sljedeći način:

$$\tilde{\mathbf{u}} = \mathbf{P} \cdot [\mathbf{R}\mathbf{t}] \cdot \tilde{\mathbf{M}}, \quad (3.15)$$

gdje vektor $\tilde{\mathbf{u}}$ predstavlja homogene pikselske koordinate, matrica \mathbf{P} perspektivnu projekciju, matrica \mathbf{R} rotaciju i vektor \mathbf{t} translaciju, vektor $\tilde{\mathbf{M}}$ homogene koordinate mjerne tačke u koordinatnom sistemu scene.

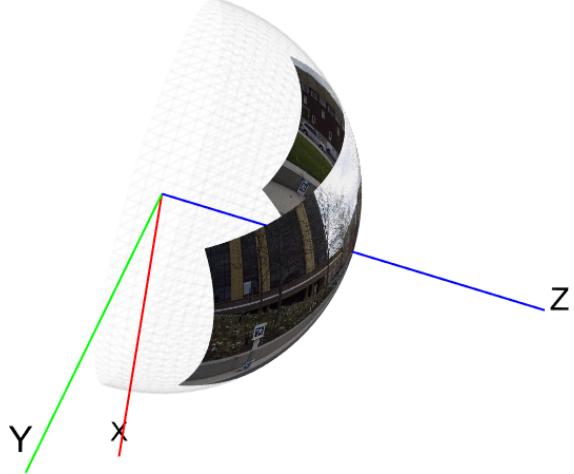
3.3 Skup podataka PennCOSYVIO

Skup podataka PennCOSYVIO [63] primjer je skupa podataka koji uz slike sadrži i ekstrinsične i intrinsične parametre korišćenih kamera. Korišćene kamere su tipa „GoPro Hero 4 Black“, pikselske rezolucije 1920×1080 piksela i vidnog polja od $69,5$ deg po vertikali i $118,2$ deg po horizontali. U ovoj disertaciji iskorišćeni su samo intrinsični parametri jedne kamere da bi se u uvodnoj Glavi 1 ukazalo na probleme klasične fuzije mjernih podataka dobijenim različitim vrstama senzora.

3.3. Skup podataka PennCOSYVIO



(a) Slika snimljena kalibriranim kamerom



(b) Reprojekcija piksela slike na jediničnu sferu

Slika 3.4: Primjer slike iz PennCOSYVIO skupa podataka i primjer upotrebe intrinskih parametara kamere za reprojekciju slike na jediničnu sferu.

Na Slici 3.4 prikazana je jedna slika iz tog skupa i korišćeni omnidirekcijski model kamere [64]. Reprojekcija piksela slike na jediničnu sferu izvršena je korišćenjem intrinskih parametara kamere korišćene za snimanje slike i programske biblioteke OCamLib [65].

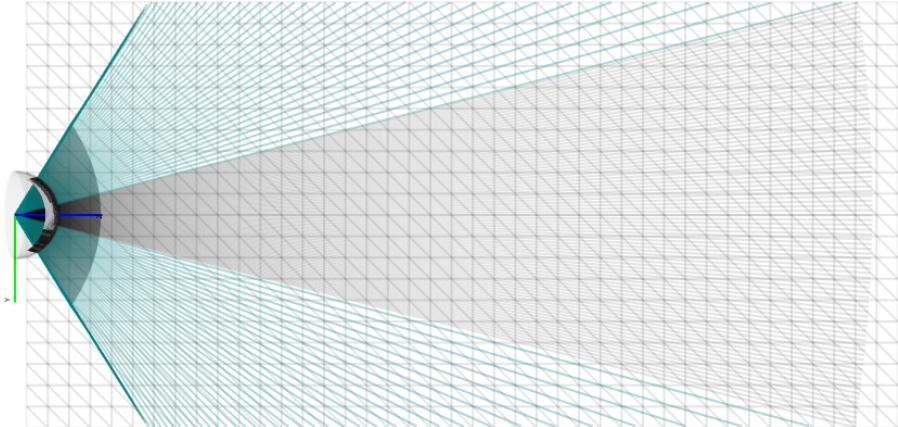
Neka važi pretpostavka da je zemlja ravna površ. Takođe, neka je y osa koordinatnog sistema kamere (na Slici 3.3 to je osa y^k) normalna na zemljinu ravan i neka se koordinatni početak tog sistema nalazi na udaljenosti^g 1,2 m iznad zemljine ravni. Svi pikseli slike koji su prema omnidirekcijskom modelu kamere reprojektovani^h na jediničnu sferu i imaju pozitivnu vrijednost y koordinate, mogu se reprojektovati i na zemljinu ravan. Koordinate tačaka na zemljinoj ravni na koje se pikseli reprojektuju su tačke presjeka zemljine ravni i prave koja prolazi kroz koordinatni

^gTa udaljenost odgovara otprilike položaju kamere kada se nosi u visini struka.

^hObično se kaže da se merna tačka iz prostora projektuje na ravan slike, zato se projekcija u obrnutom smjeru naziva reprojekcija.

3.4. Skup podataka za obučavanje algoritama za transformaciju obilježja

početak i odgovarajuću tačku na jediničnoj sferi. Ovaj proces ilustrovan je na Slici 3.5. Ako je pretpostavka o položaju kamere tačna (visina i orijentacija), na osnovu



(a) Način reprojekcije slike



(b) Slika reprojektovana na zemljinu ravan

Slika 3.5: Reprojekcija piksela slike prikazane na Slici 3.4a na zemljinu ravan.

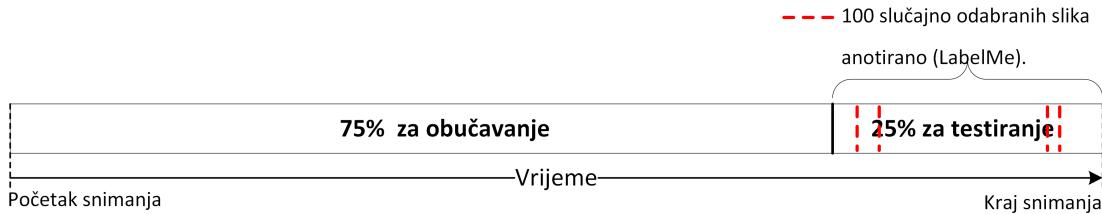
reprojektovane slike moguće je izvršiti mjerjenje udaljenosti objekata od senzora. Sa slike se može zaključiti da je ovakav način mjerjenja udaljenosti pouzdan za mjerjenje udaljenosti do manjih objekata koji se nalaze u neposrednoj blizini vozila (do 10 m), gdje pretpostavka o ravnoj zemljinoj površi nije narušena.

3.4 Skup podataka za obučavanje algoritama za transformaciju obilježja

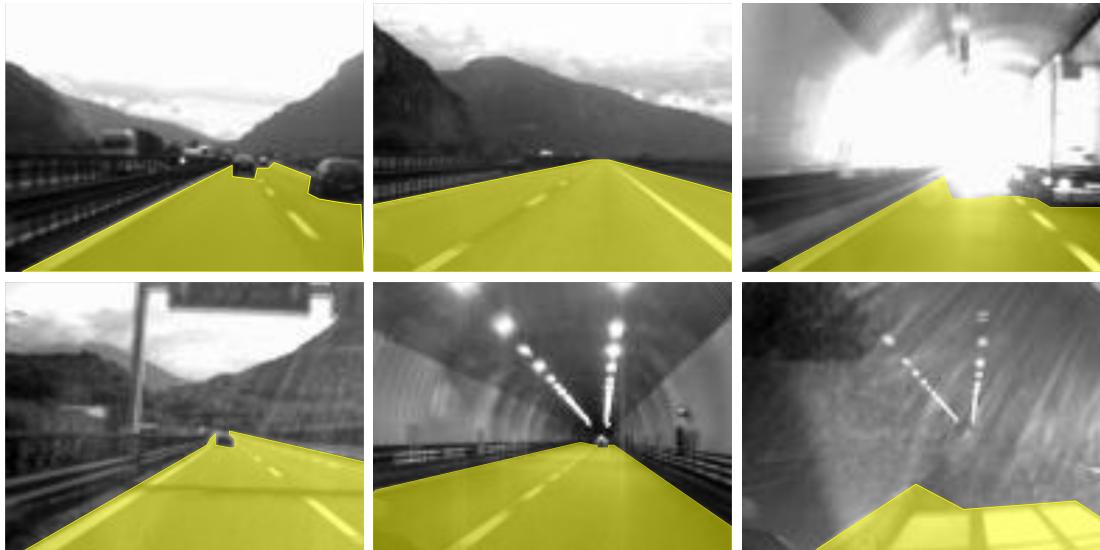
Kao što je već pomenuto u uvodnom dijelu, skup podataka za obučavanje, validaciju i testiranje korišćenih algoritma mašinskog učenja prikupljen je u toku eksperimentalne vožnje auto–putem. Trajanje vožnje iznosilo je približno 5 minuta i u tom periodu izvršeno je 9850 uzastopnih i sinhronizovanih mjerjenja radarem i kamerom. Stacionarna mjerjenja radara fuzionirana su korišćenjem algoritma predstavljenog

3.4. Skup podataka za obučavanje algoritama za transformaciju obilježja

u odjeljku 3.1 u Dempster-Šaferovu rešetku dokaza, veličine ćelija $30\text{ cm} \times 30\text{ cm}$. Slike su dimenzija 384×288 piksela, i zadržane su u izvornom obliku. Kao što



Slika 3.6: Podjela dostupnih podataka na podatke za obučavanje, validaciju i testiranje.



Slika 3.7: Anotirane slike. Anotacija se vrši iscrtavanjem poligona (žute linije) oko piksela koji pripadaju istoj semantičkoj klasi - u ovom slučaju slobodan prostor ispred sistemskog vozila. Odabrani pikseli osjenčeni su takođe žutom bojom.

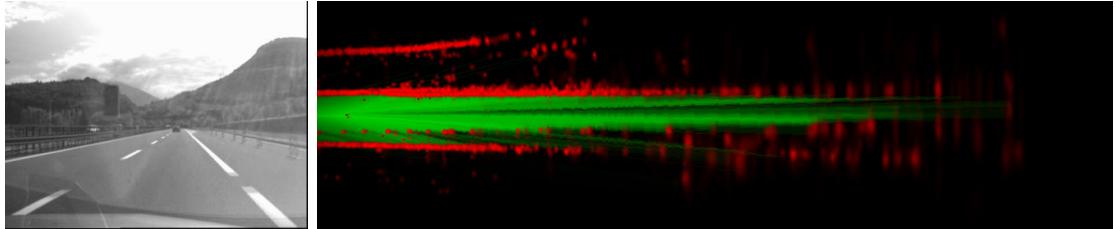
je prikazano na Slici 3.6, 75% prikupljenih podataka iskorišćeno je za obučavanje algoritama, dok je preostalih 25% iskorišćeno za testiranje i validaciju. Slučajnim odabirom, iz testnog skupa izdvojeno je 100 slika. Na tim slikama anotirani su pikseli koji predstavljaju slobodan prostor ispred sistemskog vozila. Anotacija slika izvršena je korišćenjem javno dostupnog LabelMe alata za anotaciju slika [54] iscrtavanjem granica slobodnog prostora. Primjeri slika, sa anotiranim poligonima, i na osnovu poligona izračunatim maskama koje prikazuju slobodan prostor, dati su na Slici 3.7.

Primjeri slika iz skupa podataka za obučavanje dati su na slikama 3.8 i 3.9. Za razliku od rešetke dokaza čija su dva sloja na Slici 3.2 prikazana *jet* mapom boja, ovdje su oba sloja predstavljena jednom RGB slikom. RGB slike su dimenzija 896×256 piksela. Uzimajući u obzir da su i dužina i širina svake ćelije rešetke

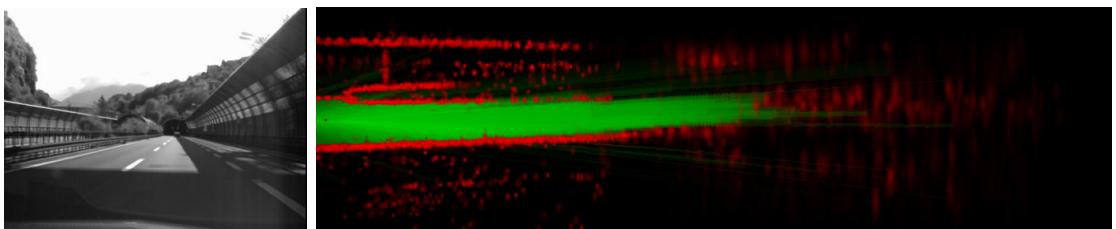
3.4. Skup podataka za obučavanje algoritama za transformaciju obilježja

jednake 30 cm, rešetke dokaza iz skupa za obučavanje pokrivaju prostor dimenzija $268,8 \text{ m} \times 76,8 \text{ m}$. Prikazani primjeri slika i rešetki dokaza dobro ukazuju na problematiku koja se javlja kod oba senzora. Kamere su jako osjetljive na promjenu vanjskog osvjetljenja, dok radar generiše višeznačna mjerena u zatvorenim prostorima. Takođe, vidljivo je da radari uspješno diskriminišu pokretnе objekte. Kako se radi o stacionarnoj rešetki dokaza, to je naravno i poželjno.

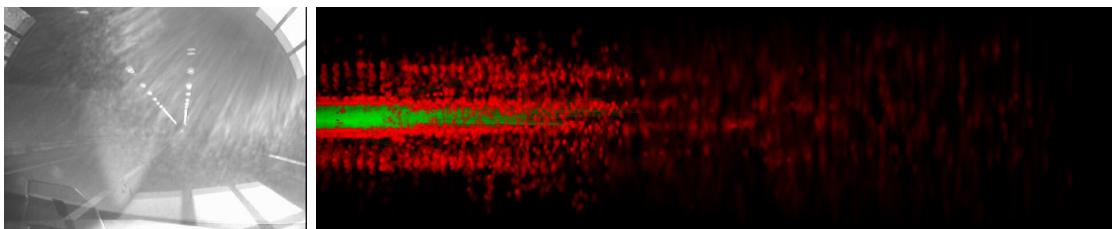
3.4. Skup podataka za obučavanje algoritama za transformaciju obilježja



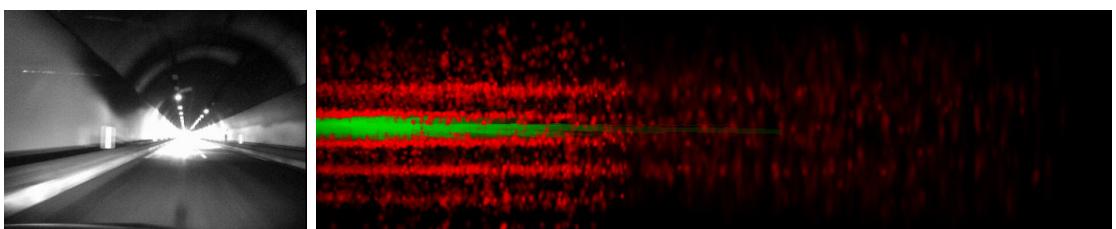
(a) Kamera se nalazi u unutrašnjosti sistemskog vozila, kvalitet slike narušen je uslijed nepovoljnih svjetlosnih refleksija od vjetrobransko staklo. Radar je u mogućnosti da detektuje zaštitnu ogradu i na sporednom kolovozu.



(b) Slika je jasna, međutim, zbog visoke zaštitne ograde kolovoz nije ravnomjerno osvijetljen. Kako se radi o sceni prije ulaska u tunel, zbog loše rezolucije radara po visini, pojedine ćelije rešetke dokaza koje pokrivaju oblast tunela prikazuju zauzeto stanje.



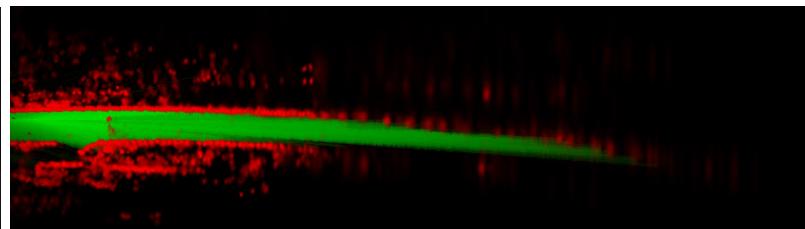
(c) Na samom ulasku u tunel slika je uslijed nepovoljnih refleksija veoma lošeg kvaliteta. Kod radara do izražaja dolazi loša prostorna rezolucije radara po visini, ali i efekat mnogostrukih propagacija emitovanih elektromagnetskih talasa.



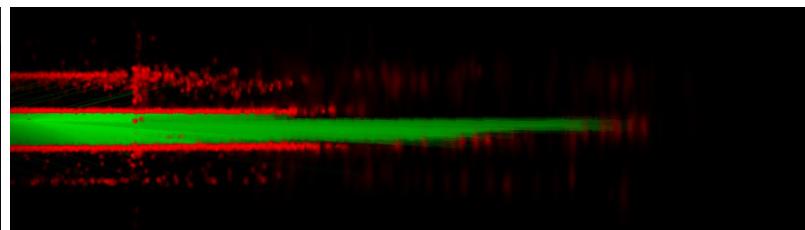
(d) U samom tunelu, slika je jasna. Mjerena radara su u tunelima veoma nepouzdana.

Slika 3.8: Prvi skup primjera slika iz skupa podataka za obučavanje. U svakom redu prikazani su slika dobijena kamerom i Dempster-Šaferova rešetka dokaza. Slojevi rešetke dokaza su prikazani na jednoj RGB slici, kod koje R-kanal i G-kanal predstavljaju uvjerenje u stanje zauzeća i stanje slobode ćelije rešetke, respektivno.

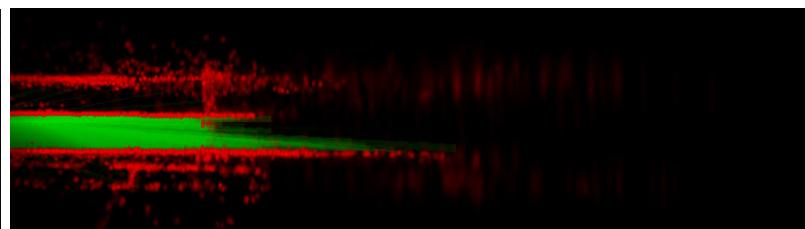
3.4. Skup podataka za obučavanje algoritama za transformaciju obilježja



(a) Na izlasku iz tunela slika je jako svijetla. Mjerenja radara su jasnija, ali se saobraćajni znak detektuje kao objekat na putu.



(b) Na slici se vidi da se ispred sistemskog vozila nalazi izdignuta metalna konstrukcija. Mjerenja radara ukazuju na postojanje stacionarnog objekta na putu.



(c) Na slici se vidi da se ispred sistemskog vozila nalazi izdignuta metalna konstrukcija i drugo putničko vozilo. Mjerenja radara ukazuju na postojanje stacionarnog objekta na putu.

Slika 3.9: Drugi skup primjera slika iz skupa podataka za obučavanje. Kao i na prethodnoj Slici 3.8, u svakom redu prikazani su slika dobijena kamerom i Dempster-Šaferova rešetka dokaza. Slojevi rešetke dokaza su prikazani na jednoj RGB slici, kod koje R-kanal i G-kanal predstavljaju uvjerenje u stanje zauzeća i stanje slobode rešetke, respektivno.

3.5 Skup podataka za obučavanje algoritama za semantičku segmentaciju

Postoji veliki broj javno dostupnih skupova podataka za obučavanje modela mašinskog učenja. Neki od tih skupova podataka imaju specifičnu namjenu. Na primjer, za obučavanje modela za semantičku klasifikaciju piksela slika koje prikazuju saobraćajne scene [33,34]. Naravno, dostupni su i skupovi koji nemaju neku specifičnu namjenu [35, 66]. U disertaciji se za validaciju predloženog rješenja za semantičku fuziju podataka iskorišćeni skupovi anotiranih slika ADE20K i Imagenet. Pored ovih skupova podataka, za teoretsku analizu algoritama mašinskog učenja korišćenih u disertaciji, korišćen je MNIST skup podataka [67]

3.5.1 ADE20K



(a) Scena zatvorenog prostora.



(b) Scena otvorenog prostora.

Slika 3.10: Primjeri slika iz ADE20K skupa podataka. U ovom skupu podataka prisutne su slike zatvorenog i otvorenog prostora. Na slici lijevo prikazana je stvarna slika, a na desnoj njena anotacija.

ADE20Kⁱ skup slika sadrži 20210 slika za obučavanje, 2000 slika za validaciju i

ⁱ<https://groups.csail.mit.edu/vision/datasets/ADE20K>

3.5. Skup podataka za obučavanje algoritama za semantičku segmentaciju

3000 slika za testiranje. Rezolucija slika iznosi 1280×960 piksela. Slike su gusto^j anotirane u 150 semantičkih klasa. Primjeri slika iz ovog skupa prikazani su na Slici 3.10.

Osnovni cilj autora ADE20K bio je da stvore skup gusto anotiranih objekata što raznovrsnijih scena. Anotaciji velikog broja slika obično prethodi definisanje hijerarhije klasa objekata koji se anotiraju (na primjer [33,68]). Međutim, pokazuje se da se prilikom anotacije veoma često pojavljuju nove klase objekata, koje ne pripadaju predefinisanoj hijerarhiji. Za razliku od ovakvog pristupa, autori ADE20K hijerarhiju klasa formiraju u toku same anotacije. Broj stepeni hijerarhije ograničen je na 3. Na primjer, na slici koja sadrži automobil, pored automobila anotiraju se vrata i ručice vrata (naravno ako su na slici vidljivi). Takođe, anotiraju se instance objekata i relativan položaj objekata na slici. ADE20K skup od 22210 anotiranih slika sadrži 434826 anotiranih instanci objekata, podijeljenih u 2693 klase. Poređenja radi, Cityscapes [33] skup 25000 slika sadrži 65385 instanci objekata, podijeljenih u 30 klasa, dok COCO [68] skup 123287 anotiranih slika sarži 886284 anotiranih instanci objekata, podijeljenih u 91 klasu.

3.5.2 Imagenet

Imagenet je možda i najpopularniji skup slika za obučavanje nadgledanih algoritama mašinskog učenja za klasifikaciju slika. Od 2010. godine organizuju se godišnja takmičenja - ILSVRC (eng. *ImageNet Large Scale Visual Recognition Challenge*), na kojima se ocjenjuju i porede performanse algoritama za detekciju i klasifikaciju objekata i scena sadržanih u Imagenet skupu podataka. Skup podataka Imagenet sadrži oko 14 miliona slika klasifikovanih u 20000 kategorija. Mnogi dijeli mišljenje da je upravo ovaj skup slika zaslužan za današnju popularnost algoritama mašinskog učenja. Slike u skupu su različitih dimenzija, a nekoliko primjera prikazano je na Slici 3.11.

^jKod gusto anotiranih slika, za razliku od grubo anotiranih, svakom pikselu slike dodijeljuje se klasa kojoj piksel pripada. Kod gusto anotiranih slika mora se računati sa greškama anotacije, pogotovo na granicama objekata.

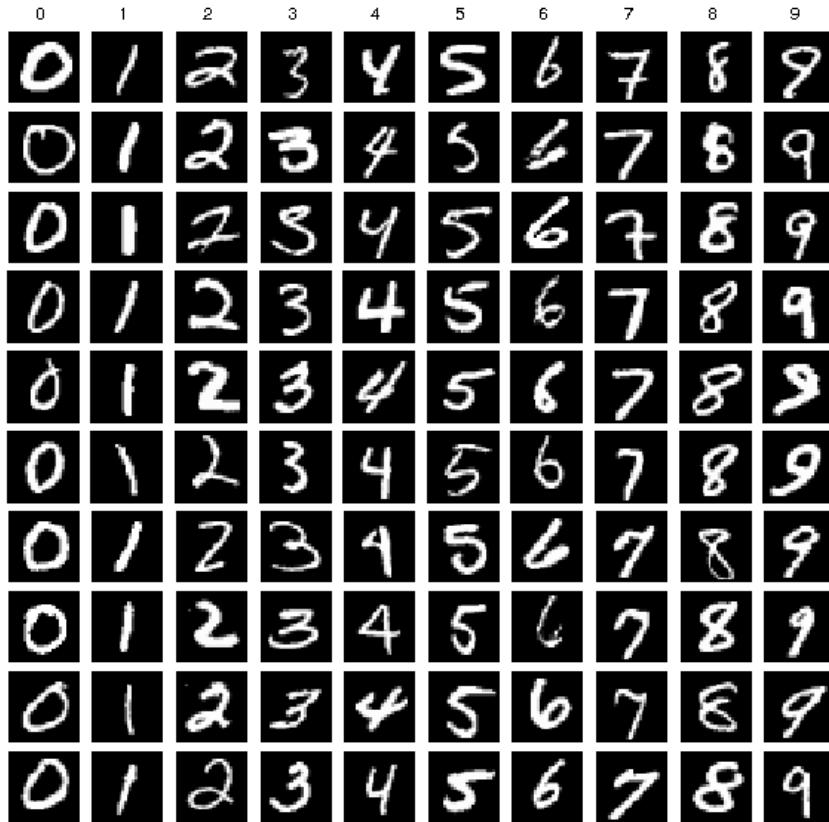
3.5. Skup podataka za obučavanje algoritama za semantičku segmentaciju



Slika 3.11: Primjeri slika iz Imagenet skupa podataka. Slike iz ovog skupa su različitih dimenzija. Ispod svake slike data je klasifikacija prikazane scene.

3.5.3 MNIST

Skup podataka MNIST je skup slika rukom pisanih cifara. Slike u skupu su veličine 28×28 piksela. Skup za obučavanje sadrži 60000 uzoraka, dok skup za testiranje sadrži dodatnih 10000 uzoraka. Uzorci skupa prikazani su na Slici 3.12



Slika 3.12: Primjeri slika iz MNIST skupa podataka.

3.6 Metodologija testiranja

Algoritam za transformaciju obilježja, koji će biti predstavljen u nastavku disertacije, na osnovu radarskih mjerena generiše vještačke slike. Da bi tako generisane slike mogle da se koriste za semantičku fuziju, one moraju da sadrže sva obilježja koja su sadržana i u radarskim mjerenjima, ali i da izgledaju kao slike dobijene snimanjem kamerom u vidljivom dijelu spektra. Neophodno je, dakle, da se eksperimentalnom analizom izvrši procjena kvaliteta i raznovrsnosti generisanih slika. Uobičajeni pristup za davanje takve procjene, a koji će biti korišćen i u ovoj disertaciji, je da se na dovoljno velikom uzorku ispitanika izvrši subjektivna analiza generisanih primjeraka. Međutim, postoje i objektivne mjere koje je moguće iskoristiti u tu svrhu. Dvije poznate objektivne mjere kvaliteta generisanih slika su Inception Score - IS [69] i Fréchet Inception Distance - FID [70].

Formalno, neka slučajna promjenljiva x predstavlja sliku i neka slučajna promjenljiva y predstavlja obilježja sadržana na toj slici^k. Takođe, pretpostavlja se da postoji model ekstrakcije obilježja y iz slike x , opisan aposteriornom gustinom vjerovatnoće

^kOvdje se implicitno prepostavlja da postoji generator slika koji može da generiše sliku x na osnovu nepoznatih obilježja sadržanih u ulaznom signalu generatora z . Takođe, generator slika za bilo koja obilježja prisutna u ulaznom signalu generatora z mora da generiše uvijek odgovarajuću sliku, pa je opisana ocjena kvaliteta generisanih slika ujedno i ocjena kvaliteta generatora.

3.6. Metodologija testiranja

$p(y|x)$. Ako je za bilo koju sliku x vjerovatnoća ekstrakcije pripadajućih obilježja y velika, smatra se da su slike kvalitetne. Ako se kvalitet generisane slike posmatra na ovakav način, za kvalitetne slike slučajne promjenljive x i y moraju da imaju nisku uslovnu entropiju $H(y|x)$, jer tada je ekstraktoru obilježja potrebna minimalna količina informacija da na osnovu slike x izvrši pravilnu ekstrakciju obilježja y . Istovremeno, generisane slike moraju da sadrže što raznovrsnija obilježja, a koja su, idealno, sa tom raznovrsnošću prisutna i u stvarnosti. Odnosno, marginalna gustina $p(y)$ treba da bude što je moguće uniformnija ili, što je isto, entropija slučajne promjenljive y mora da bude što veća. Mjera kvaliteta IS jednostavno mjeri Kulbek-Laiblerovu ili KL divergenciju (eng. *Kullback-Leibler divergence*) te dvije distribucije, odnosno

$$\text{IS} = \exp(\mathbb{E}_x [D_{KL}(p(y|x) || p(y))]). \quad (3.16)$$

Veća vrijednost IS mjere znači bolji kvalitet generisane slike. Autori u [69] za računanje pomenutih funkcija gustine vjerovatnoće koriste Inception-v3 neuronsku mrežu [71] koja je prethodno obučena na Imagenet skupu slika. Međutim, to je i glavni nedostatak IS mjere - distribucija $p(y|x)$ se računa na osnovu generisanih slika, a ne na osnovu nezavisno anotiranih slika iz skupa za testiranje. Zbog toga autori u [70] predlažu FID mjeru, koja je data sa

$$\text{FID} = \|\mu_r - \mu_g\|^2 + \text{Tr} \left(\Sigma_r + \Sigma_g - 2 (\Sigma_r \Sigma_g)^{1/2} \right), \quad (3.17)$$

gdje Tr predstavlja trag matrice, a $X_r \sim \mathcal{N}(\mu_r, \Sigma_r)$ i $X_g \sim \mathcal{N}(\mu_g, \Sigma_g)$ predstavljaju 2048-dimenzionalne aktivacije pool3 sloja Inception-v3 neuronske mreže za klasifikaciju slika za stvarne (iz testnog skupa) i generisane primjerke slika, respektivno. I u ovom slučaju, Inception-v3 je prethodno obučena na Imagenet skupu podataka (Imagenet skup podataka opisan je u odjeljku 3.5.2). Manja vrijednost FID mjere znači bolji kvalitet generisane slike.

Da bi se demonstrirala mogućnost predloženog algoritma za semantičku fuziju podataka, u toku eksperimentalne analize vrši se semantička klasifikacija piksela generisanih slika i slika iz tesnog skupa. Semantička klasifikacija se vrši korišćenjem neuronskih mreža koje su prethodno obučene na ADE20K skupu podataka, opisanog u odjeljku 3.5.1. Za ocjenu rezultata klasifikacije koristi se Žakardov indeks¹ [72]. Žakardov indeks definiše mjeru sličnosti između konačnih skupova A i B na sljedeći način:

$$J(A, B) = \frac{A \cap B}{A \cup B}. \quad (3.18)$$

U ovoj disertaciji skup A predstavljaju anotirani pikseli slika iz testnog skupa opisanog u odjeljku 3.4, dok se njihova uparena radarska mjerena koriste za generisanje vještačkih slika. Skup B dobijen je semantičkom segmentacijom generisanih slika.

¹Žakardov index (eng. *Jaccard index*) poznat je u literaturi još kao količnik presjeka i unije ili IoU (eng. *Intersection over Union*).

Glava 4

Generativne suparničke mreže

Neka je vektorom \mathbf{x} predstavljena vrijednost ulaza, a vektorom \mathbf{y} vrijednost izlaza nekog sistema S . Nakon određenog broja parova ulaza i izlaza, zadatak algoritma nadgledanog mašinskog učenja sastoji se u predikciji vrijednosti vektora \mathbf{y} za nove vrijednosti \mathbf{x} . Opisani problem naziva se regresija kada su elementi vektora \mathbf{y} neprekidne promjenljive, odnosno klasifikacija kada su elementi vektora \mathbf{y} diskretne promjenljive.

Ako se vektori \mathbf{x} i \mathbf{y} posmatraju kao slučajne promjenljive, predikciju vrijednosti \mathbf{y} moguće je vršiti ako je poznata uslovna gustina vjerovatnoće $p(\mathbf{y}|\mathbf{x})$, odnosno:

$$\hat{\mathbf{y}} = \arg \max_{\mathbf{y}} p(\mathbf{y}|\mathbf{x}). \quad (4.1)$$

Matematički modeli koji ponašanje nekog sistema modeluju uslovnom gustinom vjerovatnoće $p(\mathbf{y}|\mathbf{x})$ nazivaju se probabilistički diskriminativni modeli. Deterministički diskriminativni modeli [73], sa druge strane, ne tretiraju vektore \mathbf{x} i \mathbf{y} kao slučajne promjenljive, te njihov odnos modeluju funkcijom $\mathbf{y} = f(\theta; \mathbf{x})$, gdje su sa θ dati parametri modela. Funkcija f se još naziva i diskriminantna funkcija, a duboke neuronske mreže su se pokazale kao veoma efikasne metode za određivanje parametara θ te funkcije. Drugi primjeri diskriminativnih modela su metod potpornih vektora, logistička regresija, linearna regresija, K najbližih susjeda i slični.

Diskriminativni modeli vrše predikciju samo na osnovu statistike dostupne u skupu za obučavanje. Njima se u toku obučavanja ne pokušava razumijeti raspodjela vjerovatnoće ulaznih podataka $p(\mathbf{x})$, već odrediti razlike ili granice između klasa koje ti podaci predstavljaju. Međutim, nekada je veoma korisno da model posjeduje mogućnost generisanja novih podataka, koji po svojim statističkim osobinama liče na ulazne podatke. Na primjer, neka je \mathbf{x} slučajni vektor obilježja koji opisuje pješaka i neka su elementi tog vektora: položaj pješaka u prostoru, njegove dimenzije, smjer i brzina kretanja i njegova namjera. Što je slučajni vektor \mathbf{x} kompletniji, sistem za detekciju pješaka bi, uključivanjem novih mjerjenja \mathbf{y} , mogao bolje da procjeni njegov sljedeći položaj. Za takav jedan sistem potrebno je, dakle, poznavati $p(\mathbf{x})$ i

4.1. Teorija igara i igre sa nultom sumom

$p(\mathbf{y}|\mathbf{x})$, odnosno zajedničku funkciju gustine vjerovatnoće

$$p(\mathbf{x}, \mathbf{y}) = p(\mathbf{y}|\mathbf{x}) \cdot p(\mathbf{x}). \quad (4.2)$$

Matematički modeli koji ponašanje nekog sistema modeluju zajedničkom gustinom vjerovatnoće $p(\mathbf{x}, \mathbf{y})$ nazivaju se probabilistički generativni modeli ili samo generativni modeli. Problem određivanja ove gustine vjerovatnoće je po pravilu vrlo težak problem. Kao što se vidi iz (4.2), proporcionalno težak problemu određivanja $p(\mathbf{x})$. Generativne suparničke mreže [74, 75] ili GAN-ovi (eng. *Generative Adversarial Networks*) su osmišljene upravo za obučavanje generativnih modela.

4.1 Teorija igara i igre sa nultom sumom

Teorija igara je oblast primjenjene matematike koja se bavi matematičkim modelovanjem međusobne interakcije igrača u toku procesa donošenja strateških odluka u toku igre [76]. Proces obučavanja generativnih suparničkih mreža zasniva se na principima ove teorije.

Igre su opisane skupom pravila i mogu se podijeliti prema različitim kriterijumima. Na primjer:

- prema interesu igrača - na primjer kooperativne i nekooperativne igre,
- prema karakteru funkcije plaćanja - na primjer igre sa konstantnom i promjenjivom sumom,
- prema broju igrača,
- prema karakteru i opsegu informacija dostupnih igračima - na primjer igre sa potpunom ili nepotpunom informacijom.

Zbog značaja za dalje izlaganje, detaljnije će biti pomenute samo nekooperativne i igre sa konstantnom sumom. Kod nekooperativnih igara, igrači su suparnici, odnosno, interesi igrača su u potpunoj suprotnosti. Kod igara sa konstantom sumom, suma ukupnog plaćanja ostaje konstantna bez obzira na izbor poteza bilo kojeg od igrača. Igre sa nultom sumom (eng. *zero-sum games*) su specijalan slučaj igara sa konstantom sumom. Kod igara sa nultom sumom, suma ukupnog plaćanja jednaka je nuli, odnosno, dobitak jednog igrača jednak je sumi gubitaka drugih igrača. Primjeri nekooperativnih igara sa nultom sumom su poker i šah.

Formalno, neka je igrač A u mogućnosti da bira jednu od svojih m raspoloživih strategija a_i iz skupa strategija $S_A = \{a_1, a_2, \dots, a_m\}$ i neka je igrač B u mogućnosti da bira jednu od svojih n raspoloživih strategija b_j iz skupa strategija $S_B = \{b_1, b_2, \dots, b_n\}$. Dobitak igrača A dat je funkcijom $\delta_A(a_i, b_j)$, a gubitak igrača B dat je funkcijom $\gamma_B(a_i, b_j)$. Za igre sa nultom sumom vrijedi:

$$\delta_A(a_i, b_j) + \gamma_B(a_i, b_j) = 0. \quad (4.3)$$

4.2. Arhitektura generativnih suparničkih mreža

Neka važi pretpostavka da su igračima dostupne informacije o raspoloživim strategijama oba igrača. Igrač A može da ostvari zagarantovani dobitak izborom strategije kojom maksimizuje svoj minimalni dobitak, odnosno:

$$\hat{\delta}_A = \max_{a_i} \min_{b_j} \delta_A(a_i, b_j). \quad (4.4)$$

Navedena strategija maksimizacije minimalnog dobitka igrača A naziva se maximin strategija odlučivanja. Sa druge strane, igrač B minimizuje svoj gubitak korišćenjem minimax strategije, odnosno minimizacijom svog maksimalnog gubitka:

$$\hat{\gamma}_B = \min_{b_j} \max_{a_i} \gamma_B(a_i, b_j). \quad (4.5)$$

Uvijek važi:

$$\hat{\delta}_A \leq \hat{\gamma}_B, \quad (4.6)$$

odnosno, zagarantovani dobitak igrača A je manji ili jednak od najvećeg mogućeg gubitka igrača B . Prethodna nejednakost ukazuje na to da je igrač koji slijedi minimax strategiju u boljoj poziciji jer ima mogućnost da minimizuje svoj gubitak znajući koji potez je odigrao drugi igrač.

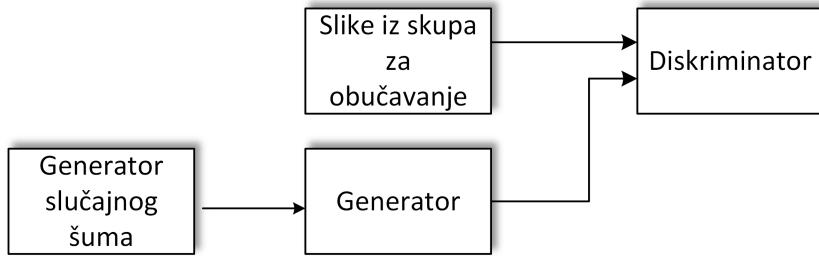
Rješenje nekooperativne igre dva ili više igrača, pod uslovima da su svim igračima poznate strategije drugih igrača i da ni jedan igrač ne ostvaruje dobitak ako mijenja svoju strategiju, dato je Nešovom ravnotežom (eng. *Nash equilibrium*). Nešova ravnoteža čini skup izabranih strategija i odgovarajućih dobitaka. Dva igrača su u Nešovoj ravnoteži ako je svaki donio najbolju moguću odluku, uvezvi u obzir odluku protivnika. Minimax strategija odlučivanja (4.5) je primjer Nešove ravnoteže. Takođe, saobraćaj u nekom gradu bi se odvijao u Nešovoj ravnoteži ako bi svi učesnici u saobraćaju poštivali saobraćajne propise, ali i učestvovali u istoj „igri“ vožnje.

Algoritmi mašinskog učenja za segmentaciju slike ili praćenje dinamičkih objekata obično djeluju u izolaciji. Iako je koncept nagrade, u vidu funkcije greške, prisutan u toku obučavanja algoritama, za uspješnu obuku navedeni koncepti iz teorije igara nisu potrebni. Međutim, arhitektura generativnih suparničkih mreža sastoji se od dvije neuronske mreže. Samim tim postavlja se pitanje koja su pravila njihovog uzajamnog djelovanja u toku obučavanja algoritma. Ideja autora u [74] je da mreže igraju nekooperativnu (suparničku) minimax igru sa nultom sumom.

4.2 Arhitektura generativnih suparničkih mreža

Na Slici 4.1 prikazana je arhitektura generativne suparničke mreže. Uloge suprotstavljenih igrača imaju diskriminator i generator, koji su zadati parameterski, funkcijama $D(\mathbf{x}, \theta_D)$ i $G(\mathbf{z}, \theta_G)$, respektivno. Slučajnim vektorom \mathbf{x} predstavljene su vrijednosti ulaza diskriminatora D . Kako diskriminator uzima uzorke iz skupa slika za obučavanje, to znači da je domen slučajnog vektora \mathbf{x} skup \mathcal{X} svih slučajnih događaja koje može registrovati kamera. Jedna slika x iz skupa za obučavanje je

4.3. Obučavanje generativnih suparničkih mreža



Slika 4.1: Arhitektura generativne suparničke mreže. Cilj obučavanja je da se generator nauči generisati slike koje su slične onima iz skupa za obučavanje. Diskriminatore se, sa suparničke strane, obučava da nauči razlikovati generisane od pravih slika.

realizacija jednog od tih događaja. Vektor \mathbf{x} zadat je gustinom raspodjele vjerovatnoće $p_{\mathcal{X}}(\mathbf{x})$. Taj odnos označava se u nastavku disertacije sa $\mathbf{x} \sim p_{\mathcal{X}}(\mathbf{x})$. Slično, slučajnim vektorom $\mathbf{z} \sim p_{\mathcal{Z}}(\mathbf{z})$, zadate su vrijednosti ulaza generatora G . Vektora θ_D i θ_G predstavljeni su parametri diskriminatora i generatora, respektivno, koje je potrebno odrediti.

Generator $G(\mathbf{z}, \theta_G)$ ima zadatak da preslikava realizacije \mathbf{z} slučajne promjenljive $\mathbf{z} \sim p_{\mathcal{Z}}(\mathbf{z})$ u slike x koje su realizacije slučajne promjenljive $\mathbf{x} \sim p_{\mathcal{X}}(\mathbf{x})$. Da bi generator mogao uspješno da obavi zadatak generisanja slika, mora što vjernije da modeluje gustinu $p_{\mathcal{X}}(\mathbf{x})$. Gustina vjerovatnoće koju generator uči označava se sa $p_G(\mathbf{x})$. Funkcija diskriminatora je da utvrdi da li je slika x uzorak prave $\mathbf{x} \sim p_{\mathcal{X}}(\mathbf{x})$ ili generisane slučajne promjenljive $\mathbf{x} \sim p_G(\mathbf{x})$. Dakle, strategija generatora je da generiše što vjernije slike, dok je strategija diskriminatora da maksimizuje tačnost klasifikacije stvarnih i generisanih slika.

4.3 Obučavanje generativnih suparničkih mreža

Funkcije diskriminatora i generatora se obično modeluju dubokim konvolucionim mrežama. Slijedeći principe nadgledanog učenja [73], za funkcije $D(\mathbf{x}, \theta_D)$ i $G(\mathbf{z}, \theta_G)$ definiše se funkcija greške koja mjeri odstupanje predviđenih i stvarnih ili željenih vrijednosti ciljne promjenljive. Kako diskriminator i generator igraju nekooperativnu igru, potrebno je da se diskriminator obučava minimizacijom funkcije greške $J_D(\theta_D, \theta_G)$ mijenjajući samo parametre θ_D . Analogno, generator se obučava minimizacijom funkcije greške $J_G(\theta_D, \theta_G)$ mijenjajući samo parametre θ_G . Rješenje igre je Nešova ravnoteža. U ovom kontekstu Nešova ravnoteža je par (θ_D, θ_G) koji je lokalni minimum funkcija grešaka J_D i J_G .

Proces obučavanja mreža diskriminatora i generatora sastoji se u simultanoj primjeni algoritma stohastičkog gradijentnog spusta - SGD (eng. *Stochastic Gradient Descent*). U svakom koraku obučavanja, iz pripadajućih gustina odabiru se vektori \mathbf{x} i \mathbf{z} , te se simultanom primjenom SGD algoritma prilagođavaju parametri θ_D i θ_G sa ciljem minimizacije grešaka J_D i J_G , respektivno.

4.3. Obučavanje generativnih suparničkih mreža

Kako je već pomenuto, strategija diskriminadora je maksimizacija vjerovatnoće tačne klasifikacije stvarnih i generisanih slika. To znači da je diskriminator u suštini binarni klasifikator. Uobičajeno je da se funkcija greške binarnih klasifikatora zadaje sa:

$$J_D(\theta_D, \theta_G) = -\mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] - \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}} [\log (1 - D(G(\mathbf{z}, \theta_G), \theta_D))]. \quad (4.7)$$

Ovakva funkcija greške naziva se unakrsnom entropijom (eng. *cross-entropy*). Kako se radi o igri sa nultom sumom, funkcija greške generatora jednaka je negativnoj funkciji greške diskriminadora, odnosno:

$$J_G(\theta_D, \theta_G) = -J_D(\theta_D, \theta_G). \quad (4.8)$$

Ovdje je potrebno napomenuti da se u jednom koraku minimizacije greške (4.7) optimizuju samo vrijednosti parametara diskriminadora θ_D . Analogno, u jednom koraku minimizacije greške (4.8) optimizuju se samo vrijednosti parametara generatora θ_G .

U kontekstu teorije igara, igra se može modelovati funkcijom koja predstavlja nagrađu diskriminadora. Kako je nagrada veća ako je funkcija greške manja, onda je:

$$V(\theta_D, \theta_G) = -J_D(\theta_D, \theta_G). \quad (4.9)$$

Kako je cilj generativnih suparničkih mreža učenje generativne gustine $p_{\mathcal{G}}(\mathbf{x})$ koja što vjernije aproksimira stvarnu gustinu $p_{\mathcal{X}}(\mathbf{x})$, za generator se bira optimalna, minimax strategija, odnosno:

$$\hat{\theta}_G = \min_{\theta_G} \max_{\theta_D} V(\theta_D, \theta_G). \quad (4.10)$$

Uvrštavanjem (4.7) u (4.9) dobija se:

$$\begin{aligned} V(\theta_D, \theta_G) &= \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] + \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}} [\log (1 - D(G(\mathbf{z}, \theta_G), \theta_D))] \\ &= \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] + \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{G}}} [\log (1 - D(\mathbf{x}, \theta_D))] \\ &= \int_{\mathbf{x}} \left(p_{\mathcal{X}} \log D((\mathbf{x}, \theta_D) dx + p_{\mathcal{G}} \log (1 - D(\mathbf{x}, \theta_D)) \right) dx. \end{aligned} \quad (4.11)$$

Jednostavno se pokazuje da je ekstrem funkcije $y = a \log y + b \log(1 - y)$ dat sa $\hat{y} = a/(a + b)$. Na osnovu (4.11), to znači da je za bilo koji generator, optimalna vrijednost diskriminadora:

$$\hat{D}(\mathbf{x}, \theta_D) = \frac{p_{\mathcal{X}}(\mathbf{x})}{p_{\mathcal{X}}(\mathbf{x}) + p_{\mathcal{G}}(\mathbf{x})}. \quad (4.12)$$

To je takođe intuitivno jasno. Jer se optimalna vrijednost parametara diskriminadora θ_D , za bilo koji dati generator, dostiže kada diskriminator više nije u stanju da razlikuje uzorke koji potiču od generatora od onih koji potiču iz skupa za

obučavanje, odnosno kada je vrijednost izlaza diskriminatora $D_{\mathbf{x} \sim p_G}(\mathbf{x}, \theta_D)$ jednaka 0,5. Na osnovu (4.12), takav slučaj se ima kada je $p_{\mathcal{X}}(\mathbf{x}) = p_G(\mathbf{x})$. Iz ovoga proizilazi da se optimizacijom diskriminatora implicitno optimizuje i generator. Formalno, ako se (4.12) uvrsti u (4.10), dobija se:

$$\begin{aligned}\hat{\theta}_G &= \min_{\theta_G} \max_{\theta_D} V(\theta_D, \theta_G) \\ &= \min_{\theta_G} \left(\mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} \left[\log \hat{D}(\mathbf{x}, \theta_D) \right] + \mathbb{E}_{\mathbf{x} \sim p_G} \left[\log (1 - \hat{D}(\mathbf{x}, \theta_D)) \right] \right) \\ &= \min_{\theta_G} \left(\mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} \left[\log \frac{p_{\mathcal{X}}(\mathbf{x})}{p_{\mathcal{X}}(\mathbf{x}) + p_G(\mathbf{x})} \right] + \mathbb{E}_{\mathbf{x} \sim p_G} \left[\log \frac{p_G(\mathbf{x})}{p_{\mathcal{X}}(\mathbf{x}) + p_G(\mathbf{x})} \right] \right).\end{aligned}\quad (4.13)$$

U prethodnoj jednačini, dva člana koja je potrebno minimizovati imaju oblik sličan Kulbek-Laiblerovoju ili KL divergenciji. KL divergencija gustina p i q definiše se kao razlika logaritama gustina vjerovatnoće p i q , a koristi se kao mjera sličnosti dvije funkcije distribucije vjerovatnoće. Definisana je sa:

$$D_{KL}(p \parallel q) = \int_{-\infty}^{\infty} p(x) \log \left(\frac{p(x)}{q(x)} \right) dx = \mathbb{E} \left[\log \frac{p(x)}{q(x)} \right]. \quad (4.14)$$

KL divergencija je nesimetrična funkcija, odnosno $D_{KL}(p \parallel q) \neq D_{KL}(q \parallel p)$. Simetrična mjera sličnosti dvije distribucije naziva se Jensen-Šenonova (JS) divergencija (eng. *Jensen-Shannon divergence*) i definiše se sa:

$$\begin{aligned}D_{JS}(p \parallel q) &= \frac{1}{2} D_{KL} \left(p \parallel \frac{1}{2}(p+q) \right) + \frac{1}{2} D_{KL} \left(q \parallel \frac{1}{2}(p+q) \right) \\ &= \frac{1}{2} \mathbb{E} \left[\log \frac{2p(x)}{p(x) + q(x)} \right] + \frac{1}{2} \mathbb{E} \left[\log \frac{2q(x)}{p(x) + q(x)} \right].\end{aligned}\quad (4.15)$$

Poređenjem izraza za JS divergenciju (4.15) i jednačine (4.13), jednostavno je pokazati da vrijedi:

$$\hat{\theta}_G = \min_{\theta_G} \left(2 D_{JS}(p_{\mathcal{X}} \parallel p_G) - 2 \log 2 \right). \quad (4.16)$$

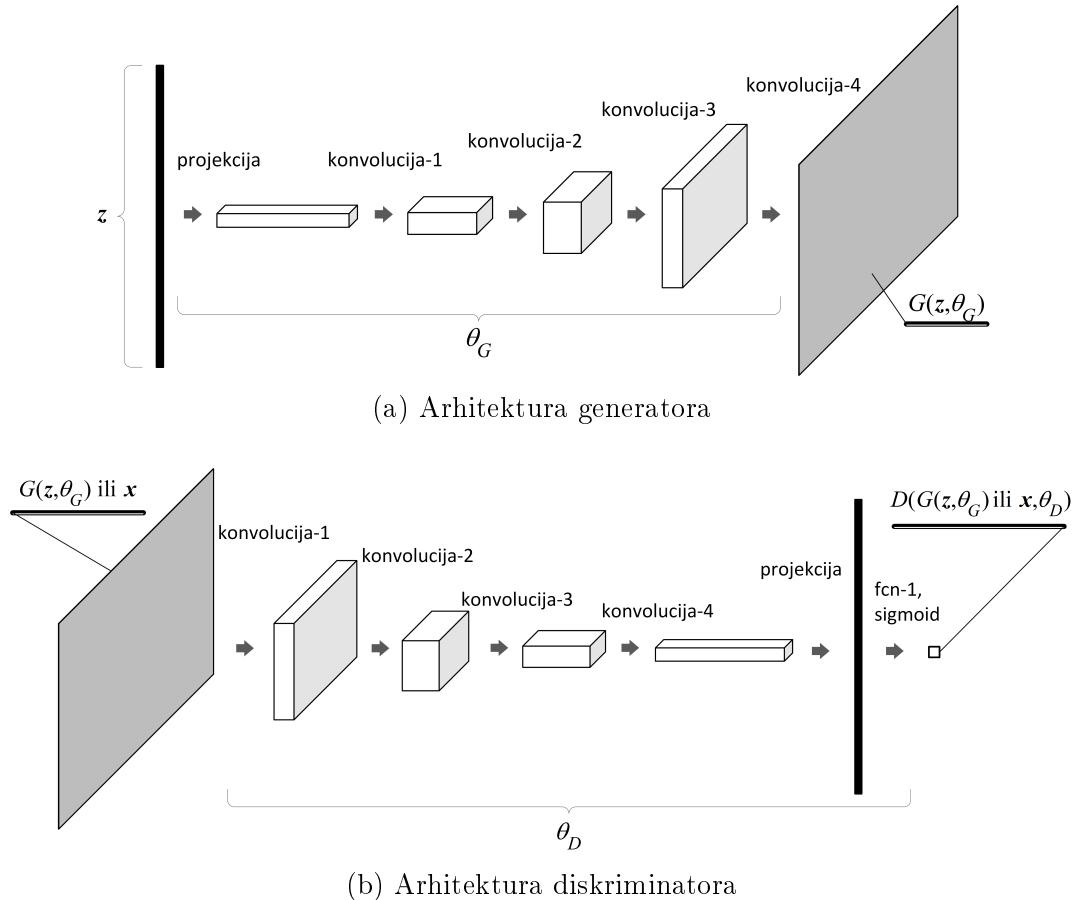
Konačno, ako je $p_G = p_{\mathcal{X}}$, JS divergencija jednaka je nuli, pa je iz (4.16) optimalno rješenje igre dato sa:

$$\min_{\theta_G} \max_{\theta_D} V(\theta_D, \theta_G) = -2 \log 2. \quad (4.17)$$

4.4 DCGAN

Generativne suparničke mreže se mogu shvatiti kao okvir za modeliranje generativnih funkcija gustine vjerovatnoće (4.2). Teoretski, generator može da se modeluje bilo kojom diferencijabilnom funkcijom. Međutim, ukoliko izbor padne na duboke neuronske mreže, pokazuje se da izbor određenih slojeva neuronske mreže, načina regularizacije obučavanja, funkcije greške, te redoslijed obučavanja diskriminatora

4.4. DCGAN



Slika 4.2: Arhitektura DCGAN mreže. Ulagani vektor slučajnog šuma \mathbf{z} projektuje se nizom slojeva transponovane konvolucije (eng. *transposed convolution* ili *fractional-strided convolution*) u sliku. Nizom slojeva konvolucije i potpuno povezanim slojem - fcn (eng. *fully-connected layer*) diskriminator projektuje stvarnu x ili generisanu sliku $G(\mathbf{z}, \theta_G)$ u vjerovatnoću pripadnosti stvarnom skupu slika.

i generatora [77] imaju ključnu ulogu za uspješnu obuku modela. Radfordov model generatora i diskriminadora, zasnovan na dubokim konvolucionim mrežama - DCGAN [78] (eng. *Deep Convolutional GANs*) prikazan je na Slici 4.2. Na prikazanoj slici, radi preglednosti, izostavljeni su neki važni konstrukcijski detalji slojeva generatora i diskriminadora.

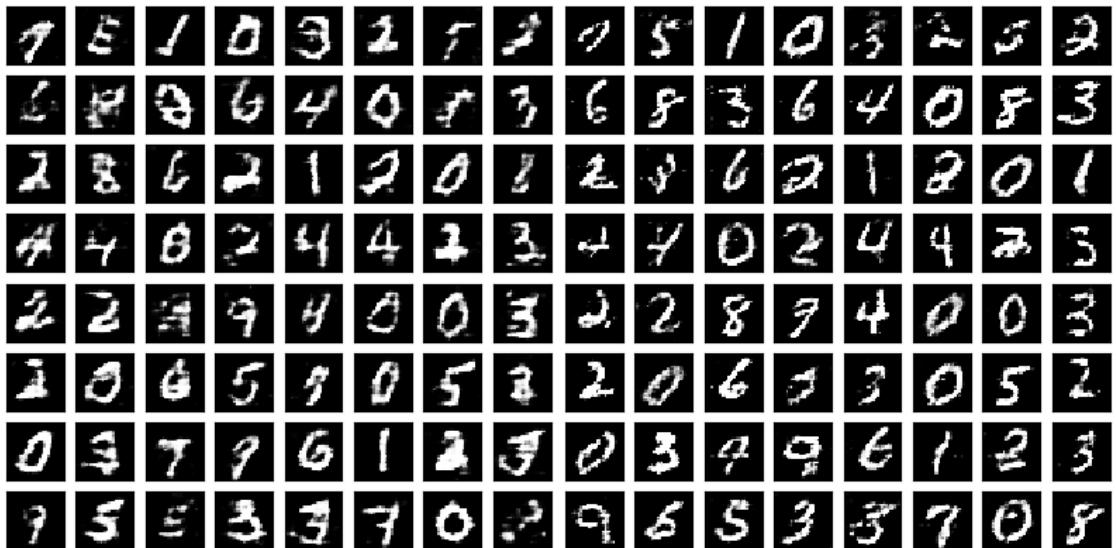
Većina polaznih arhitektura dubokih neuronskih mreža izvedene su iz arhitektura mreža koje su se u praksi pokazale kao uspješne. Međutim, zbog specifičnosti treninga GAN mreža, neke standardne slojeve dubokih mreža potrebno je izostaviti ili zamijeniti drugim slojevima. Osnovne smjernice za konstrukciju stabilnih DCGAN-ova mogu se sumirati u sljedećih nekoliko tačaka:

1. Preporučuje se sve agregacione slojeve (eng. *pooling layers*) diskriminadora zamijeniti sa slojevima konvolucije, a agregacione slojeve generatora sa slojevima transponovane konvolucije. Sloj agregacije u suštini predstavlja diskretizacija

cioni proces, kojim se vrši deterministička prostorna decimacija (eng. *spatial down-sampling*) izlaza prethodnog sloja neuronske mreže. Prostorna decimacija vrši se usrednjavanjem ili računanjem maksimuma određenog broja izlaza neurona jednog sloja neuronske mreže. Time se postiže smanjenje računske zahtjevnosti u toku obučavanja, ali na žalost uzrokuje i smanjenje fleksibilnosti modela. Zamjenom agregacionog sloja slojem konvolucije i transponovane konvolucije, diskriminator i generator su u mogućnosti da nauče prostornu decimaciju i interpolaciju.

2. Preporučuje se korišćenje metode unutrašnje standardizacije^a (eng. *Batch-Norm* ili *Batch Normalization*) [79], osim prije izlaznog sloja generatora i prije ulaznog sloja diskriminatora.
3. Preporučuje se uklanjanje svih skrivenih, potpuno povezanih slojeva.
4. Preporučuje se korišćenje ReLU aktivacionih funkcija u mreži generatora, osim na izlaznom sloju koji koristi tanh aktivacionu funkciju [80].
5. Preporučuje se korišćenje LeakyReLU aktivacije u mreži diskriminatora [80].

4.5 Eksperimentalni rezultati i diskusija



Slika 4.3: Primjeri generisanih slika rukom pisanih cifara. Slike su generisane korišćenjem DCGAN mreže, obučene na MNIST skupu podataka. Na slici su prikazana dva skupa generisanih slika grupisanih u matrice dimenzija 8×8 .

Na Slici 4.3 prikazane su generisane slike rukom pisanih cifara, dobijene korišćenjem DCGAN mreže obučene na MNIST skupu podataka [67]. Kao što se vidi, u većini

^aUnutrašnja standardizacija je popularna tehnika normalizacije ulaznog signala neurona na nultu srednju vrijednost i jediničnu varijansu.

4.5. Eksperimentalni rezultati i diskusija

slučajeva moguće je prepoznati o kojoj cifri se radi. Međutim, DCGAN model nema kontrolni parametar kojim se može ciljano generisati pojedina cifra. Kod osnovnog modela predstavljenog na Slici 4.1, ulazne vrijednosti generatora realizacije su slučajnog vektora šuma, i oni nisu sinhronizovani sa slikama iz skupa za obučavanje. U glavama 5, 6 i 7 biće predstavljena neka od rješenja problema kontrolabilnosti GAN-ova.

Generativne suparničke mreže su u slučaju složenijih, multimodalnih distribucija ulaznih signala, podložne problemu kolapsa modova (eng. *mode collapse*). Naime, da bi se u toku obučavanja modela dostiglo optimalno rješenje (4.17), dovoljno je da se generator obuči da generiše samo jedan mod multimodalne distribucije $p_{\mathcal{X}}(\mathbf{x})$ ulaznih podataka. Efektivno to znači da generator preslikava sve ili većinu ulaznih vrijednosti \mathbf{z} u istu izlaznu vrijednost \mathbf{x} . Taj problem je ekvivalentan problemu generalizacije algoritama mašinskog učenja. Uobičajeni pristup ostvarivanju bolje generalizacije nekog modela je regularizacija procesa obučavanja. Autori [78] pokazuju da standardne tehnike regularizacije (na primjer Dropout, L1, L2, Batch-Norm, veći skup za obučavanje itd.) ne sprečavaju pojavu ovog problema. U Glavi 7 biće predstavljena jedna od mogućnosti prevazilaženja ovog problema.

Glava 5

Uslovne generativne suparničke mreže

Proširenjem ulaza generatora dodatnim upravljačkim signalom kojim bi se moglo uticati na karakteristike izlaznog signala, omogućile bi se mnoge praktične primjene generativnih suparničkih mreža. Za skup podataka MNIST, upravljački signal bi na primjer mogao biti diskretna promjenljiva c koja uzima vrijednosti iz skupa $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$. Ideja je da se dovođenjem promjenljive $c = i$ na upravljački ulaz generatora, u idealnom slučaju, na izlazu dobije slika rukom pisane cifre i koja po svojim karakteristikama odgovara slikama iz skupa za obučavanje. U ovom i sljedećem odjeljku biće predstavljene dvije popularne metode realizacije te ideje.

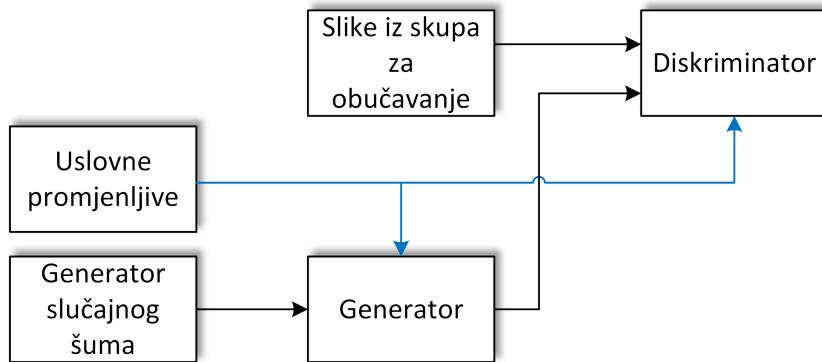
5.1 Uslovne generativne suparničke mreže

Put ka rješenju pomenutog problema upravljalivosti GAN-ova autori u [61] vide u dovođenju dodatnih, uslovnih, informacija na ulaze generatora i diskriminatora. Predložena arhitektura uslovnih generativnih suparničkih mreža - CGAN (eng. *Conditional GANs*) prikazana je na Slici 5.1.

Ako se vrijednosti novih upravljačkih ulaza generatora i diskriminatora predstave slučajnim vektorom $\mathbf{y} \sim p_{\mathbf{y}}$, strategija obučivanja uslovnih generativnih suparničkih mreža, prateći oznake iz Glave 4, definisana je na sljedeći način:

$$\begin{aligned} \min_{\theta_G} \max_{\theta_D} V(\theta_D, \theta_G) &= \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}, \mathbf{y}' \sim f(p_{\mathbf{y}})} [\log D(\mathbf{x}, \theta_D \mid \mathbf{y}')] \\ &\quad + \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}, \mathbf{y} \sim p_{\mathbf{y}}, \mathbf{y}' \sim f(p_{\mathbf{y}})} [\log (1 - D(G(\mathbf{z}, \theta_G \mid \mathbf{y}), \theta_D) \mid \mathbf{y}')]. \end{aligned} \tag{5.1}$$

Slučajne promjenljive $\mathbf{x} \sim p_{\mathcal{X}}$ i $\mathbf{z} \sim p_{\mathcal{Z}}$ predstavljaju ulazni signal čija se raspodjela želi naučiti i izvor slučajnog šuma, respektivno. Funkcija $f(p_{\mathbf{y}})$ predstavlja linearnu transformaciju gustine raspodjele slučajnog vektora \mathbf{y} .



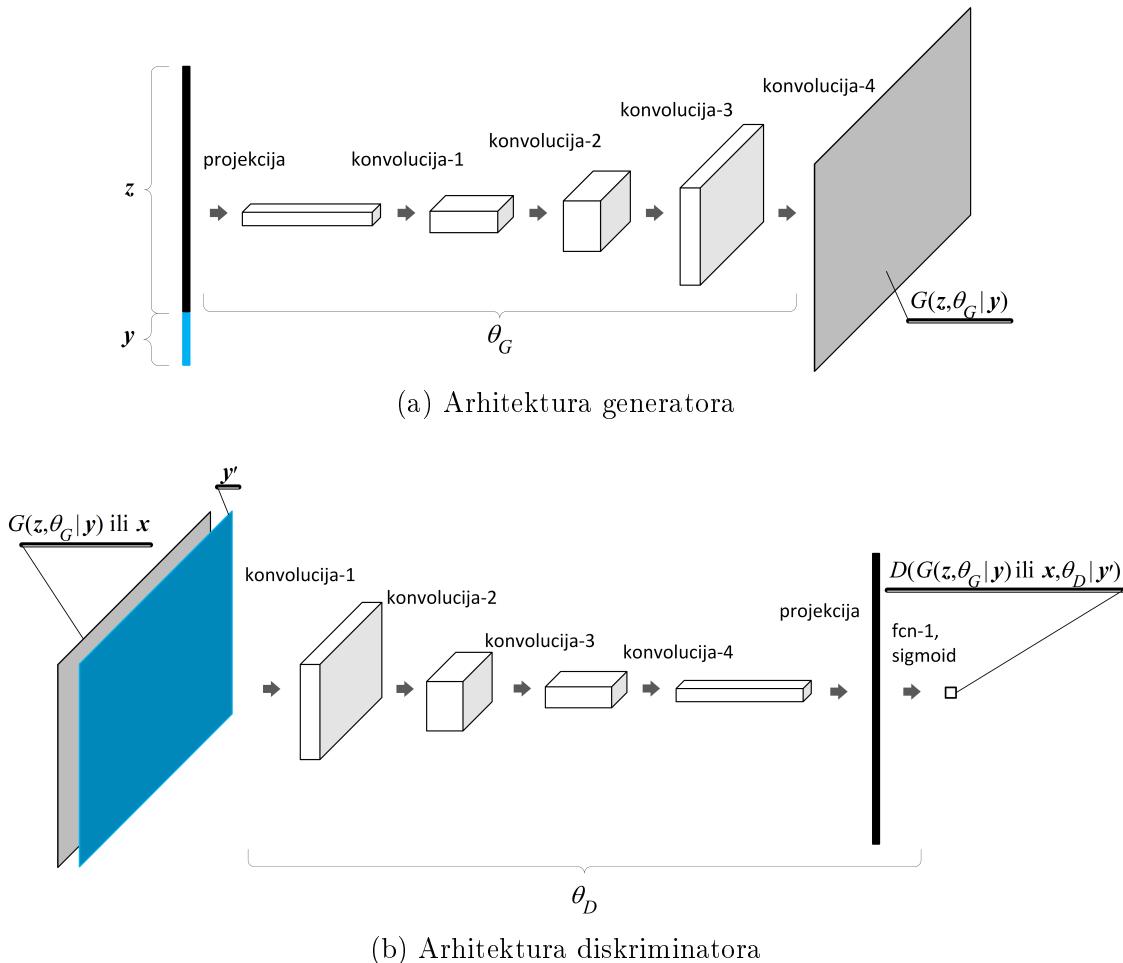
Slika 5.1: Arhitektura uslovne generativne suparničke mreže. Za razliku od GAN-ova, uslovne generativne suparničke mreže imaju, preko uslovnih promjenljivih, mogućnost kontrolisanog učenja zajedničke distribucije.

5.2 cDCGAN

Generator DCGAN mreže predstavljene u Glavi 4 može se, prostim ulančavanjem ulaznog vektora \mathbf{z} i uslovnog vektora \mathbf{y} , upotrijebiti i kao generator uslovnih GAN-ova. U slučaju diskriminadora situacija je nešto složenija. Izlaz generatora $G(\mathbf{z}, \theta_G | \mathbf{y})$ je slika, istih dimenzija kao i slika iz skupa za obučavanje. Da bi se uslovni vektor \mathbf{y} mogao koristiti kao uslovna promjenljiva diskriminadora, potrebno ga je transformisati u oblik pogodan za ulančavanje sa izlaznim vektorom generatora ili slikom. Na Slici 5.2 prikazana je arhitektura na taj način transformisane DCGAN mreže, koja se u literaturi naziva i cDCGAN (eng. *conditional DCGAN*) mreža.

Upravljački signal moguće je dovesti na bilo koji sloj mreže. Međutim, eksperimentalna analiza [81] pokazuje da se upravo ulančavanjem ulaznih slojeva generatora i diskriminadora sa uslovnim vektorm postižu najbolji rezultati obučavanja cDCGAN-ova. Takvi rezultati eksperimentalne analize objašnjavaju se činjenicom da generator i diskriminator, u tom slučaju, uslovnu promjenljivu „vide“ već u ranoj fazi obrade ulaznih signala. Ovakva arhitektura cDCGAN mreže biće korišćena i u eksperimentalnoj analizi u nastavku disertacije.

5.3. Eksperimentalni rezultati i diskusija



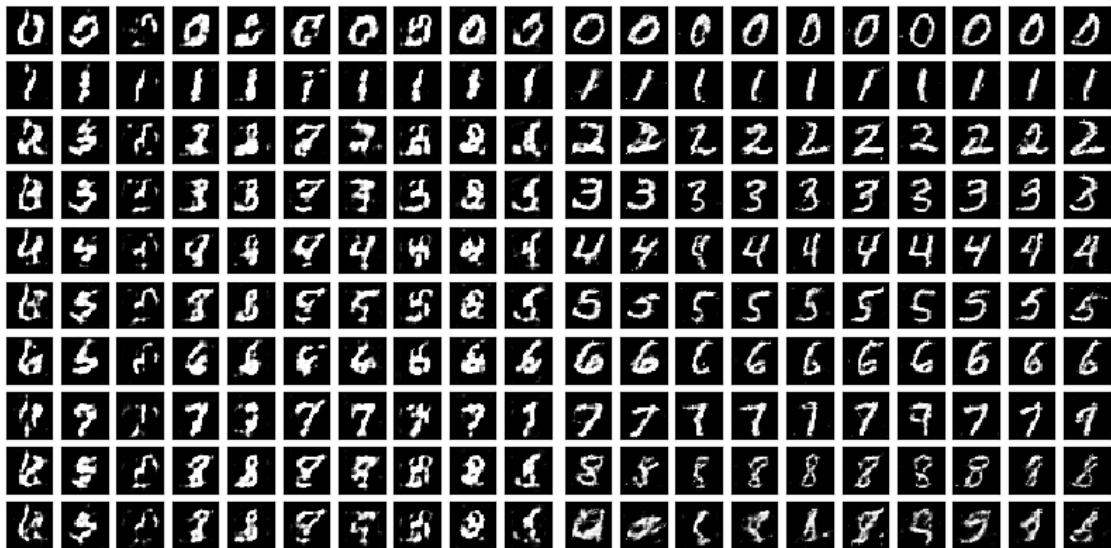
Slika 5.2: Arhitektura cDCGAN mreže dobijena jednostavnom transformacijom ulaza DCGAN mreže.

5.3 Eksperimentalni rezultati i diskusija

Eksperimentalna analiza prethodno opisane cDCGAN mreže izvršena je korišćenjem MNIST skupa podataka. Kao uslovne promjenljive korišćene su anotacije slika rukom pisanih cifara dekadnog sistema, i to korišćenjem koda 1–od– 10^a . Kodom 1–od–10, 0 se koduje kao 0000000001, 1 kao 0000000010 i tako do cifre 9 koja se koduje kao 1000000000.

Za razliku od klasičnih DCGAN-ova, generisane slike mogu se sada grupisati prema uslovnoj promjenljivoj. Rezultati nakon 1 i 25 epoha obučavanja cDCGAN mreže prikazani su na Slici 5.3. Većina cifara prepoznatljiva je već nakon 25 epoha obučavanja. Poređenjem sa rezultatima klasičnih DCGAN-ova, generisane slike

^aKod 1–od– N (eng. *one-hot*) je vrlo jednostavna reprezentacija N obilježja nekog signala nizom od N bitova. Svako obilježje predstavljeno je jednim elementom niza. Pri tome, signal u svakom trenutku može da sadrži samo jedno od N obilježja. Ukoliko je obilježje prisutno u signalu, odgovarajući bit ima vrijednost logičke jedinice, dok ostalih $N - 1$ bitova imaju vrijednost logičke nule.



(a) Nakon 1. epohe obučavanja

(b) Nakon 25. epohe obučavanja

Slika 5.3: Primjeri generisanih slika rukom pisanih cifara. Slike su generisane korišćenjem cDCGAN mreže, obučene na MNIST skupu podataka. Na slici su prikazana dva skupa generisanih slika grupisanih u matrice dimenzija 10×10 .

cDCGAN-ova vizuelno imaju bolji kvalitet. Najlošije rezultate generator postiže prilikom generisanja cifara 7 i 9, koje su i pisane rukom veoma slične.

Pokazuje se, [81], da je generisanje detaljnih obilježja ujedno i osnovni nedostatak uslovnih generativnih suparničkih mreža. Pored toga, ovi modeli su jako osjetljivi na šum anotacije [82], odnosno, u prisustvu pogrešno anotiranih slika, za datu uslovnu promjenljivu, CGAN-ovi generišu uzorke iz pogrešnih klasa. Takođe, veliki nedostatak ovih modela je što je za njihovo obučavanje neophodno koristiti anotirane skupove podataka. U nastavku će biti prikazani generativni modeli kojima se to može izbjegći.

Glava 6

Informacione generativne suparničke mreže

U prethodnoj Glavi 5 prikazan je princip obučavanja cDCGAN mreže, koja kao uslovnu promjenljivu koristi anotacije cifara iz skupa za obučavanje. Anotacije slike, osim vrijednosti same cifre, mogu da sadrže i druge podatke o slici. To može na primjer biti karakter kaligrafskih linija koje sačinjavaju cifru: prava, kriva, energetična, blaga ili izlomljena linija. Takva, opsežna anotacija rukom pisanih cifara bila bi veoma skupa. Ali da tako anotirani skup podataka i postoji, garancije da su upravo te karakteristike pisanih cifara potrebne za njihovu uspješnu klasifikaciju ili generisanje ne postoje. Takođe, ovdje se algoritam oslanja na stručnost anotatora, a poznato je da je jedan od osnovnih problema ekspertskega sistema upravo kvantifikacija znanja [83].

6.1 Značaj latentnih promjenljivih

Mogućnost da se distribucija vjerovatnoće ulaznih podataka izrazi kroz zajedničku distribuciju sa M latentnih promjenljivih veoma je korisna. Na primjer, za radarska mjerena, latentne promjenljive bi mogle biti semantičke klase otkrivenih objekata: pješak, automobil, most i slično. Formalno se to može izraziti na sljedeći način:

$$p(\mathbf{x} \mid \theta) = \sum_{i=1}^M p(\mathbf{x}, z_i \mid \theta) = \sum_{i=1}^M p(z_i)p(\mathbf{x} \mid z_i, \theta), \quad (6.1)$$

U prethodnoj jednačini je sa z_i označena realizacija latentne promjenljive $\mathbf{z} \sim p(\mathbf{z})$, sa θ parametri modela i sa $\mathbf{x} \sim p_{\mathcal{X}}$ slučajni ulazni vektor. Latentna promjenljiva pri tome može biti neprekidnog ili diskretnog (kategoričkog) tipa. Na primjeru računanja maksimalne vjerodostojnosti, biće pokazano da je procjena parametara modela sa latentnim promjenljivim izuzetno težak problem.

Ako se u skupu za obučavanje ima N realizacija, x_i , slučajnog ulaznog vektora \mathbf{x} ,

6.1. Značaj latentnih promjenljivih

parametri modela mogu se odrediti računanjem maksimalne vrijednosti funkcije vjerodostojnosti parametara modela θ :

$$\mathcal{L}(\theta) = \prod_{i=1}^N p(x_i | \theta). \quad (6.2)$$

odnosno:

$$\hat{\theta} = \arg \max_{\theta} \mathcal{L}(\theta). \quad (6.3)$$

Pronalaženje maksimuma funkcije vjerodostojnosti i pronalaženja minimuma negativne vrijednosti logaritma vjerodostojnosti je isto, odnosno:

$$\hat{\theta} = \arg \max_{\theta} \mathcal{L}(\theta) = \arg \min_{\theta} (-\log \mathcal{L}(\theta)) = \arg \min_{\theta} \left(-\sum_{i=1}^N \log p(x_i | \theta) \right). \quad (6.4)$$

Uvrštavanjem (6.1) u (6.4) ima se

$$\hat{\theta} = \arg \min_{\theta} \left(-\sum_{i=1}^N \log \sum_{j=1}^M p(x_i, z_j | \theta) \right). \quad (6.5)$$

Kao što je već pomenuto, rješavanje (6.5) je veoma teško [84]. Ako je na primjer zajednička distribucija $p(\mathbf{x}, \mathbf{z} | \theta)$ eksponencijalnog tipa, nakon sumiranja, marginalna distribucija $p(\mathbf{x} | \theta)$ to obično nije. Prisustvo sume, dakle, sprečava direktno dejstvo logaritma na zajedničku distribuciju, što rezultuje kompleksnim izrazima za rješavanje (6.5), ali i sprečava upotrebu optimizacionog metoda gradijentnog spusta. Kada bi za svaku x_i na neki način bilo moguće opaziti i z_i , onda bi problem (6.5) bio jednostavniji, odnosno:

$$\hat{\theta} = \arg \min_{\theta} \left(-\sum_{i=1}^N \log p(x_i, z_i | \theta) \right). \quad (6.6)$$

Kako je promjenljiva \mathbf{z} latentna, odnosno ne može se opaziti niti izmjeriti, znanje koje se ima o njoj sadržano je u aposteriornoj distribuciji $p(\mathbf{z} | \mathbf{x}, \theta)$. Postavlja se pitanje da li je \mathbf{z} na neki način moguće aproksimirati? Jedan od mogućih odgovora ogleda se u računanju aproksimacije $q(\mathbf{z} | \mathbf{x})$ nepoznate distribucije $p(\mathbf{z} | \mathbf{x}, \theta)$. Latentne promjenljive bi tada bile realizacije slučajne promjenljive raspodijeljene prema toj aproksimiranoj distribuciji.

Uobičajeno je da se za mjeru sličnosti dvije distribucije koristi KL-divergencija. U ovom slučaju je poželjno da KL-divergencija aproksimativne i stvarne distribucije

6.1. Značaj latentnih promjenljivih

bude što manja, odnosno:

$$\begin{aligned}
 D_{KL}(q(\mathbf{z} \mid \mathbf{x}) \parallel p(\mathbf{z} \mid \mathbf{x}, \theta)) &= -\mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} \left[\log \frac{p(\mathbf{z} \mid \mathbf{x}, \theta)}{q(\mathbf{z} \mid \mathbf{x})} \right] \\
 &= -\mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{z} \mid \mathbf{x}, \theta) - \log q(\mathbf{z} \mid \mathbf{x})] \\
 &= -\mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{x}, \mathbf{z} \mid \theta) - \log p(\mathbf{x} \mid \theta) - \log q(\mathbf{z} \mid \mathbf{x})] \\
 &= -\underbrace{\mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{x}, \mathbf{z} \mid \theta) - \log q(\mathbf{z} \mid \mathbf{x})]}_{\text{LB}(\mathbf{x}, \mathbf{z}, \theta)} + \log p(\mathbf{x} \mid \theta)
 \end{aligned} \tag{6.7}$$

Marginalizovana gustina $p(\mathbf{x} \mid \theta)$ se u kontekstu Bayesove statistike često još naziva validnost modela^a (eng. *model evidence*) ili samo validnost, i ona u jednačini (6.7) ne zavisi od aproksimativne distribucije q . To znači, ako se želi minimizovati $D_{KL}(q(\mathbf{z} \mid \mathbf{x}) \parallel p(\mathbf{z} \mid \mathbf{x}, \theta))$ potrebno je maksimizovati $\text{LB}(\mathbf{x}, \mathbf{z}, \theta)$. Veličina $\text{LB}(\mathbf{x}, \mathbf{z}, \theta)$ se naziva minoranta validnosti modela - ELBO (eng. *evidence lower-bound*) i definiše se na različite načine [85], u zavisnosti od tumačenja:

$$\begin{aligned}
 \text{LB}(\mathbf{x}, \mathbf{z}, \theta) &= \mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{x}, \mathbf{z} \mid \theta) - \log q(\mathbf{z} \mid \mathbf{x})] \\
 &= \mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{x}, \mathbf{z} \mid \theta)] + H(q(\mathbf{z} \mid \mathbf{x})) \\
 &= \log p(\mathbf{x} \mid \theta) - D_{KL}(q(\mathbf{z} \mid \mathbf{x}) \parallel p(\mathbf{z} \mid \mathbf{x}, \theta)).
 \end{aligned} \tag{6.8}$$

Na primjeru maksimalne vjerodostojnosti parametara modela, minoranta validnosti modela može se iskoristiti u rekurzivnoj proceduri procjene parameterata. U svakoj iteraciji k algoritma, za sve elemente iz skupa za obučavanje x_i , izborom neke fiksne vrijednosti parametara θ^k modela, računa se aproksimacija aposteriorne distribucije kao $q(\mathbf{z} \mid \mathbf{x}) = p(\mathbf{z} \mid \mathbf{x}, \theta^k)$. Sa tako dobijenom $q(\mathbf{z} \mid \mathbf{x})$, računa se očekivana vrijednost funkcije vjerodostojnosti parametara modela:

$$Q(\theta \mid \theta^k) = \mathbb{E}_{\mathbf{z} \sim q(\mathbf{z} \mid \mathbf{x})} [\log p(\mathbf{x}, \mathbf{z} \mid \theta)]. \tag{6.9}$$

Dalje se maksimizacijom (6.9) dobijaju nove vrijednosti parametara modela

$$\theta^{k+1} = \arg \max_{\theta} Q(\theta \mid \theta^k). \tag{6.10}$$

Time se jedna iteracija algoritma završava. Predstavljeni rekurzivni algoritam zove se algoritam maksimizacije očekivanja - EM (eng. *Expectation–Maximization*).

Ako se (6.9) uvrsti u (6.8) ima se:

$$\text{LB}(\mathbf{x}, \mathbf{z}, \theta) = Q(\theta \mid \theta^k) + H(q(\mathbf{z} \mid \mathbf{x})). \tag{6.11}$$

Kako drugi član desne strane prethodne jednakosti ne zavisi od parametara modela, maksimizacijom (6.9) maksimizuje se i ELBO.

^aJer što je ova aproksimacija bliža stvarnoj gustini, model je korektniji ili validniji.

6.2 GAN-ovi zasnovani na maksimizaciji uzajamne informacije

Jednostavnim ulančavanjem signala šuma sa latentnim kodom koji je ujedno i anotacija ulaznog signala, kao kod uslovnih GAN-ova, ne može se garantovati da će generator u toku obučavanja otkriti sva skrivena obilježja ulaznih podataka. Pretpostavku, da bi uslovni GAN-ovi imali bolje rezultate kada bi se koristile dodatne anotacije je teško provjeriti, jer veoma je teško, ako ne i nemoguće, doći do kompletног skupa anotacija. Poželjno bi dakle bilo, da se latentne promjenljive otkriju automatski, bez potrebe za anotiranjem ulaznih podataka. Na osnovu analize latentnih promjenljivih u prethodnom odjeljku, za očekivati je da će se indukcija latentnih varijabli zasnivati, slično kao i kod EM-algoritma, na maksimizaciji minorante neke veličine.

6.2.1 Variaciona minoranta uzajamne informacije

Neka su \mathbf{x} i \mathbf{y} diskretne slučajne promjenljive iz dva proizvoljna mjerljiva prostora \mathcal{X} i \mathcal{Y} , respektivno. Entropija slučajne promjenljive \mathbf{x} definisana je sa:

$$H(\mathbf{x}) = - \sum_{\mathbf{x} \in \mathcal{X}} p(\mathbf{x}) \log p(\mathbf{x}). \quad (6.12)$$

Uslovna entropija slučajne promjenljive \mathbf{y} za dato \mathbf{x} definisana je sa:

$$H(\mathbf{y} | \mathbf{x}) = - \sum_{\mathbf{x} \in \mathcal{X}} \sum_{\mathbf{y} \in \mathcal{Y}} p(\mathbf{x}, \mathbf{y}) \log p(\mathbf{y} | \mathbf{x}). \quad (6.13)$$

Uzajamna informacija [86] slučajnih promjenljivih \mathbf{x} i \mathbf{y} definisana je sa:

$$I(\mathbf{x}, \mathbf{y}) = \sum_{\mathbf{x} \in \mathcal{X}} \sum_{\mathbf{y} \in \mathcal{Y}} p(\mathbf{x}, \mathbf{y}) \log \frac{p(\mathbf{x}, \mathbf{y})}{p(\mathbf{x})p(\mathbf{y})}. \quad (6.14)$$

Veličina $I(\mathbf{x}, \mathbf{y})$ može se posmatrati i kao mjera statističke povezanosti slučajnih promjenljivih \mathbf{x} i \mathbf{y} , pa se može izraziti i preko Kulbek-Laiblerove divergencije sa:

$$I(\mathbf{x}, \mathbf{y}) = D_{KL}(p(\mathbf{x}, \mathbf{y}) \| p(\mathbf{x})p(\mathbf{y})). \quad (6.15)$$

Za uzajamnu informaciju važi $I(\mathbf{x}, \mathbf{y}) \geq 0$, pri čemu znak jednakosti važi samo ako su slučajne promjenljive \mathbf{x} i \mathbf{y} nezavisne. U tom slučaju je i Kulbek-Laiblerova divergencija jednaka nuli.

Većina problema estimacije potiče od činjenice da je uzajamna informacija (6.14) obično nelinearna funkcija nepoznate zajedničke gustine vjerovatnoće $p(\mathbf{x}, \mathbf{y})$. Na primjer, neka \mathcal{X} predstavlja skup svih prostornih tačaka koje mogu da reflektuju elektromagnetski talas, a \mathcal{Y} niz mjernih tačaka dobijen u jednom ciklusu mjerjenja toga prostora radarskim senzorom. Prostor \mathcal{Y} se onda može modelovati kao pre-

brojivi skup diskretnih radarskih mjerena, a \mathcal{X} kao skup funkcija u \mathbb{R}^3 . Ako se ima N mjerena $\{\mathbf{x}_i, \mathbf{y}_i\}$, $1 \leq i \leq N$, postavlja se pitanje koliko dobro se može procijeniti informacija koju radarski senzor daje o okolnom prostoru? Ako je veza između \mathcal{X} i \mathcal{Y} suviše kompleksna, problem je veoma težak i za malo N . U praksi, inženjeri često kompleksnost problema umanjuju nizom aproksimacija i heuristika. Takvim pristupom, primjena senzora ograničena je tek na specifičnu funkciju, koja se aktivira samo u strogo definisanim i kontrolisanim uslovima. Ovakav način obrade senzorskih mjerena prihvatljiv je za sisteme za pomoć vozaču, ali ne i za visoko automatizovana vozila (stepena automatizacije većeg od 3). Pored toga, dio korisnih informacija sadržanih u mjerjenjima se, takvim aproksimacijama i heuristikama, nepovratno gubi.

Pristup rješavanju kompleksnog problema procjene uzajamne informacije, može se pojednostaviti ukoliko se umjesto direktne procjene uzajamne informacije procjenjuje sistem minoranti uzajamne informacije [87], odnosno:

$$\text{LB}_I(\mathbf{x}, \mathbf{y}) = I(S(\mathbf{x}), T(\mathbf{y})) \leq I(\mathbf{x}, \mathbf{y}), \quad (6.16)$$

gdje su funkcije S i T proizvoljne funkcije sa istim područjem vrijednosti kao \mathbf{x} i \mathbf{y} , respektivno. Minoranta (6.16) ne postavlja nikakve restrikcije na izbor S i T . One se mogu parametrizovati dubokim neuronskim mrežama ili nizom funkcija S_N i T_N . Bez obzira na izbor parametrizacije, ideja se sastoji u tome da minoranta L_I monotono raste sa veličinom i raznovrsnošću dostupnog skupa podataka N za obučavanje.

Jednačina (6.14) se može dati i na drugačiji način:

$$\begin{aligned} I(\mathbf{x}, \mathbf{y}) &= H(\mathbf{x}) - H(\mathbf{x} | \mathbf{y}) \\ &= \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y} | \mathbf{x})} [\log p(x | y)]] + H(\mathbf{x}) \\ &= \mathbb{E}_{y \sim p(\mathbf{y})} [\mathbb{E}_{x \sim p(\mathbf{x} | y)} [\log p(x | y)]] + H(\mathbf{x}) \\ &= \mathbb{E}_{y \sim p(\mathbf{y})} \left[\mathbb{E}_{x \sim p(\mathbf{x} | y)} \left[\log \left(\frac{p(x | y)}{q(x | y)} q(x | y) \right) \right] \right] + H(\mathbf{x}) \\ &= \mathbb{E}_{y \sim p(\mathbf{y})} \left[\mathbb{E}_{x \sim p(\mathbf{x} | y)} \left[\log \frac{p(x | y)}{q(x | y)} \right] + \mathbb{E}_{x \sim p(\mathbf{x} | y)} [\log q(x | y)] \right] + H(\mathbf{x}) \\ &= \mathbb{E}_{y \sim p(\mathbf{y})} [D_{KL}(p(x | y) \| q(x | y)) + \mathbb{E}_{x \sim p(\mathbf{x} | y)} [\log q(x | y)]] + H(\mathbf{x}). \end{aligned} \quad (6.17)$$

Kako je $D_{KL}(p(y | x) \| q(y | x)) \geq 0$, ima se da je:

$$I(\mathbf{x}, \mathbf{y}) \geq \mathbb{E}_{y \sim p(\mathbf{y})} [\mathbb{E}_{x \sim p(\mathbf{x} | y)} [\log q(x | y)]] + H(\mathbf{x}). \quad (6.18)$$

Aproksimacionom distribucijom $q(\mathbf{x} | \mathbf{y})$ uspješno je izbjegnuto računanje nepoznate distribucije $p(\mathbf{x} | \mathbf{y})$, ali za računanje unutrašnjeg očekivanja u nejednakosti (6.18) i dalje su neophodne realizacije x slučajne promjenljive $\mathbf{x} \sim p(\mathbf{x} | \mathbf{y})$.

Ako se pretpostavi da je \mathbf{y} funkcija slučajne promjenljive \mathbf{x} i slučajnog šuma \mathbf{z} , odnosno $\mathbf{y} = G(\mathbf{z}, \mathbf{x})$, odabirati $y \sim G(\mathbf{z}, \mathbf{x})$ onda znači prvo odabirati $x' \sim p(\mathbf{x})$, a

zatim $y \sim G(\mathbf{z}, x')$. Jednačina (6.18) onda postaje:

$$\begin{aligned} I(\mathbf{x}, G(\mathbf{z}, \mathbf{x})) &\geq \mathbb{E}_{y \sim G(\mathbf{z}, \mathbf{x})} [\mathbb{E}_{x \sim p(\mathbf{x}|y)} [\log q(x | y)]] + H(\mathbf{x}) \\ &= \mathbb{E}_{x' \sim p(\mathbf{x})} [\mathbb{E}_{y \sim G(\mathbf{z}, x')} [\mathbb{E}_{x \sim p(\mathbf{x}|y)} [\log q(x | y)]]] + H(\mathbf{x}) \\ &= \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim G(\mathbf{z}, x)} [\mathbb{E}_{x' \sim p(\mathbf{x}|y)} [\log q(x' | y)]]] + H(\mathbf{x}). \end{aligned} \quad (6.19)$$

Lema 6.1. Za dvije slučajne promjenljive \mathbf{x} i \mathbf{y} i funkciju $f(x, y)$, gdje su $x \sim p(\mathbf{x})$ i $y \sim p(\mathbf{y})$, važi:

$$\mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y}|x)} [f(x, y)]] = \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y}|x)} [\mathbb{E}_{x' \sim p(\mathbf{x}|y)} [f(x', y)]]]. \quad (6.20)$$

Dokaz.

$$\begin{aligned} \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y}|x)} [f(x, y)]] &= \sum_x \sum_y p(x, y) f(x, y) \\ &= \sum_x \sum_y p(x, y) f(x, y) \sum_{x'} p(x' | y) \\ &= \sum_x \sum_y p(y) p(x | y) f(x, y) \sum_{x'} p(x' | y) \\ &= \sum_x \sum_y p(x | y) f(x, y) \sum_{x'} p(y) p(x' | y) \\ &= \sum_x \sum_y p(x | y) f(x, y) \sum_{x'} p(x', y) \\ &= \sum_x \sum_y p(x | y) f(x, y) \sum_{x'} p(x') p(y | x') \\ &= \sum_{x'} p(x') \sum_y p(y | x') \sum_x p(x | y) f(x, y) \\ &= \mathbb{E}_{x' \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y}|x')} [\mathbb{E}_{x \sim p(\mathbf{x}|y)} [f(x, y)]]] \\ &= \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim p(\mathbf{y}|x)} [\mathbb{E}_{x' \sim p(\mathbf{x}|y)} [f(x', y)]]]. \end{aligned} \quad (6.21)$$

□

Korišćenjem rezultata Leme 6.1, nejednakost (6.19) se može pisati kao:

$$\begin{aligned} I(\mathbf{x}, G(\mathbf{z}, \mathbf{x})) &\geq \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim G(\mathbf{z}, x)} [\mathbb{E}_{x' \sim p(\mathbf{x}|y)} [\log q(x' | y)]]] + H(\mathbf{x}) \\ &= \underbrace{\mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim G(\mathbf{z}, x)} [\log q(x' | y)]]}_{\text{LB}_I(G, q)} + H(\mathbf{x}) \end{aligned} \quad (6.22)$$

Veličina

$$\text{LB}_I(G, q) = \mathbb{E}_{x \sim p(\mathbf{x})} [\mathbb{E}_{y \sim G(\mathbf{z}, x)} [\log q(x | y)]] \quad (6.23)$$

naziva se varijaciona minoranta uzajamne informacije $I(\mathbf{x}, G(\mathbf{z}, \mathbf{x}))$, a predstavljena metoda njenog određivanja varijaciona maksimizacija informacije (eng. *variational*

information maximization). Pogodnim izborom gustine raspodjele $p(\mathbf{x})$, na primjer izborom Gausove gustine raspodjele, slučajnu promjenljivu \mathbf{x} moguće je analitički odabirati. Takav izbor distribucije i način odabiranja predstavlja svojevrstan trik, koji se i u literaturi naziva trik reparametrisacije.

6.2.2 Regularizacija GAN-ova minorantom uzajamne informacije

Kod informacionih generativnih mreža - InfoGAN-ova [88], slično uslovnim GAN-ovima, autori razlažu ulaz na dva dijela: vektor šuma \mathbf{z} i latentni kod \mathbf{c} . Ideja korišćenja latentnog koda zasniva se na želji da se istaknu bitna latentna semantička obilježja ulaznih podataka. Latentni kodovi se pri tome indukuju maksimizacijom zajedničkog informacionog sadržaja kojeg posjeduju generator i diskriminator.

Neka je $\{c_1, c_2, \dots, c_M\}$ skup slučajnih, nezavisnih, latentnih promjenljivih. Zajednička gustina vjerovatnoće data je onda sa $p(\mathbf{c}) = p(c_1, c_2, \dots, c_M) = \prod_{i=1}^M p(c_i)$. Da bi se u toku obučavanja izbjegla mogućnost da generator ulazni latentni kod ne uzima u obzir, odnosno da bi se izbjeglo da generator umjesto uslovne $p_G(\mathbf{x} | \mathbf{c})$ nauči marginalnu gustinu $p_G(\mathbf{x})$ (tada bi važilo $p_G(\mathbf{x} | \mathbf{c}) = p_G(\mathbf{x})$), potrebno je da količina uzajamnog informacionog sadržaja između latentnog koda \mathbf{c} i generatora $G(\mathbf{z}, \mathbf{c})$ bude što je moguće veća. Količina uzajamnog informacionog sadržaja se u kontekstu teorije informacija, kao što je dato u prethodnom odjeljku 6.2.1, predstavlja uzajamnom informacijom:

$$I(\mathbf{c}; G(\mathbf{z}, \mathbf{c})) = H(\mathbf{c}) - H(\mathbf{c} | G(\mathbf{z}, \mathbf{c})). \quad (6.24)$$

Ako se u jednačini (6.23) \mathbf{x} i \mathbf{y} zamijene sa \mathbf{c} i $G(\mathbf{z})$, respektivno, dobija se sljedeći izraz za minorantu uzajamne informacije $I(\mathbf{c}; G(\mathbf{z}, \mathbf{c}))$:

$$\text{LB}_I(G, q) = \mathbb{E}_{c \sim p(\mathbf{c})} [\mathbb{E}_{x \sim G(\mathbf{z}, c)} [\log q(c | x)]] . \quad (6.25)$$

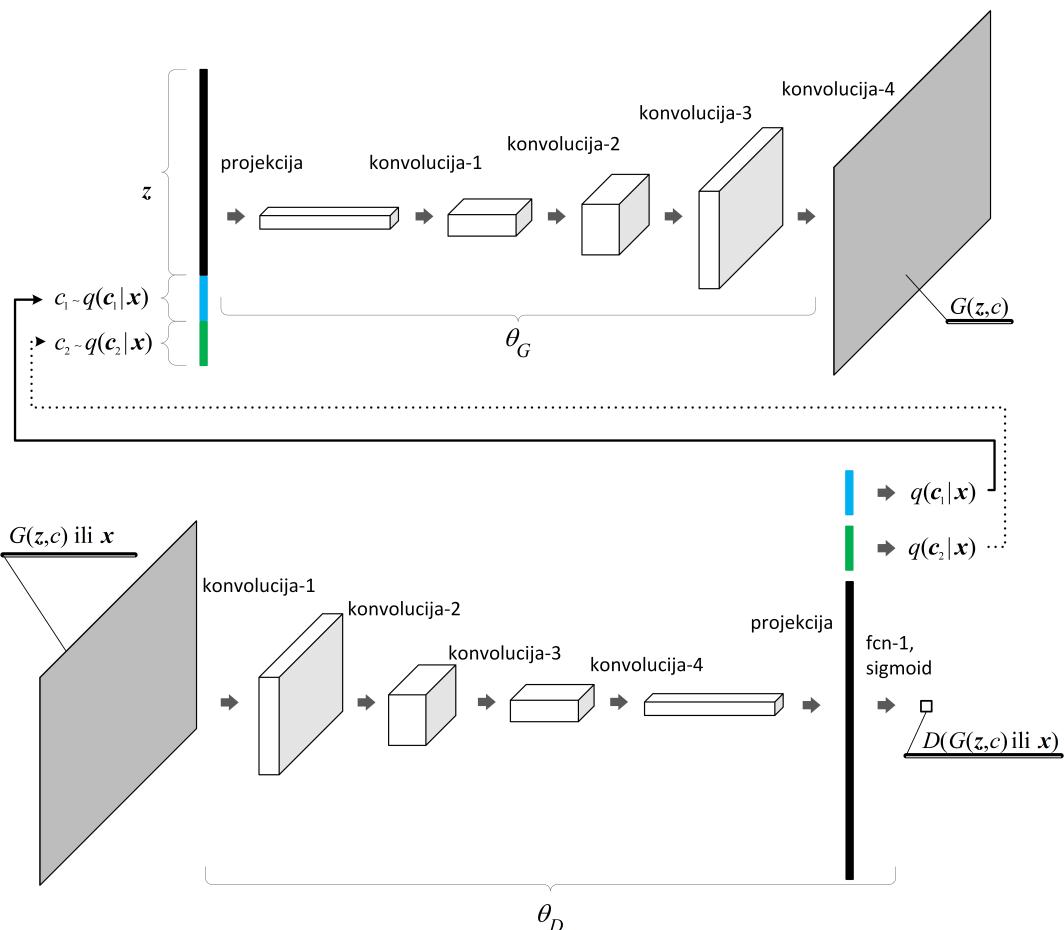
Autori u [88] koriste količinu uzajamne informacije (6.25) kao regularizacioni član (uveden kao Lagranžov koeficijent) optimizacionog problema generativnih suparničkih mreža, odnosno:

$$\min_{\theta_G} \max_{\theta_D} V_I(\theta_D, \theta_G) = \min_{\theta_G} \max_{\theta_D} (V(\theta_D, \theta_G) - \lambda \text{LB}_I(G, q)) . \quad (6.26)$$

Pri tome je $V(\theta_D, \theta_G)$ minimax strategija data u Glavi 4 sa:

$$V(\theta_D, \theta_G) = \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] + \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}} [\log (1 - D(G(\mathbf{z}, \theta_G), \theta_D))] . \quad (6.27)$$

6.3. Arhitektura Info-GAN-ova



Slika 6.1: Arhitektura Info-GAN mreže sa dva latentna koda c_1 i c_2 .

6.3 Arhitektura Info-GAN-ova

Na Slici 6.1 prikazan je primjer arhitekture Info-GAN modela sa dva letentna koda c_1 i c_2 . Aproksimativna distribucija $q(\mathbf{c} | \mathbf{x})$ je parametrizovana kao neuronska mreža, koja sa diskriminatorm $D(\mathbf{x})$ dijeli sve konvolucione slojeve. Tek posljedni, potpuno-povezani slojevi mreže su nezavisni. Ako se uporedi sa arhitekturama GAN-ova i uslovnih GAN-ova, datim na slikama 4.1 i 5.2, respektivno, vidi se da arhitektura Info-GAN-ova u odnosu na njih dodaje tek neznatni udio u računskoj kompleksnosti modela.

Na Slici 6.1 namjerno su izostavljeni tipovi nelinearnosti, posljednjeg, potpuno-povezanog sloja mreže $q(\mathbf{c} | \mathbf{x})$, jer njihov izbor zavisi od tipa latentnih kodova. U slučaju diskretnih latentnih kodova uobičajen izbor nelinearnosti je takozvana funkcija mekog maksimuma (eng. *softmax*). Funkcija mekog maksimuma preslikava

neki vektor $\mathbf{x} = [x_1, \dots, x_N]$ u vektor istih dimenzija na sljedeći način:

$$\text{softmax}(\mathbf{x}) = \left[\frac{e^{x_1}}{\sum_{i=1}^N e^{x_i}}, \dots, \frac{e^{x_N}}{\sum_{i=1}^N e^{x_i}} \right].$$

Za neprekidne latentne kodove izbor je mnogo veći i zavisi od tipa stvarne distribucije $p(\mathbf{c} | \mathbf{x})$.

6.4 Eksperimentalni rezultati i diskusija

Eksperimentalna analiza Info-GAN-ova je izvršena nad skupom podataka MNIST. Arhitektura eksperimentalnog modela prati arhitekturu mreže iz prethodnog odjeljka, s tim da se umjesto dva, koriste tri latentna koda \mathbf{c}_1 , \mathbf{c}_2 i \mathbf{c}_3 . Diskretnim latentnim kodom \mathbf{c}_1 žele se modelovati diskontinualne promjene u ulaznim podacima. Neprekidnim latentnim kodovima \mathbf{c}_2 i \mathbf{c}_3 žele se modelovati kontinualne promjene u ulaznim podacima.

Latentni kod \mathbf{c}_1 je, kao i kod uslovnih GAN-ova, zadat kodom 1–od–10, odnosno $\mathbf{c}_1 = [a_1, a_2, a_3, a_4, a_5, a_6, a_7, a_8, a_9, a_{10}]$, pri čemu je u svakom trenutku samo jedna od komponenata vektora $a_i = 1$, dok su sve ostale $a_{j \neq i} = 0$. Latentni kod \mathbf{c}_1 je takođe slučajna promjenljiva, zadata gustinom vjerovatnoće $f(\mathbf{c}_1 | \mathbf{p}) = \prod_{i=1}^{10} p_i^{a_i}$, gdje $p_i = 1/10$ predstavlja vjerovatnoću da i -ta komponenta vektora \mathbf{c}_1 uzme vrijednost $a_i = 1$. Neprekidni latentni kodovi \mathbf{c}_2 i \mathbf{c}_3 su zadati neprekidnom uniformnom funkcijom gustine vjerovatnoće, definisanom sa:

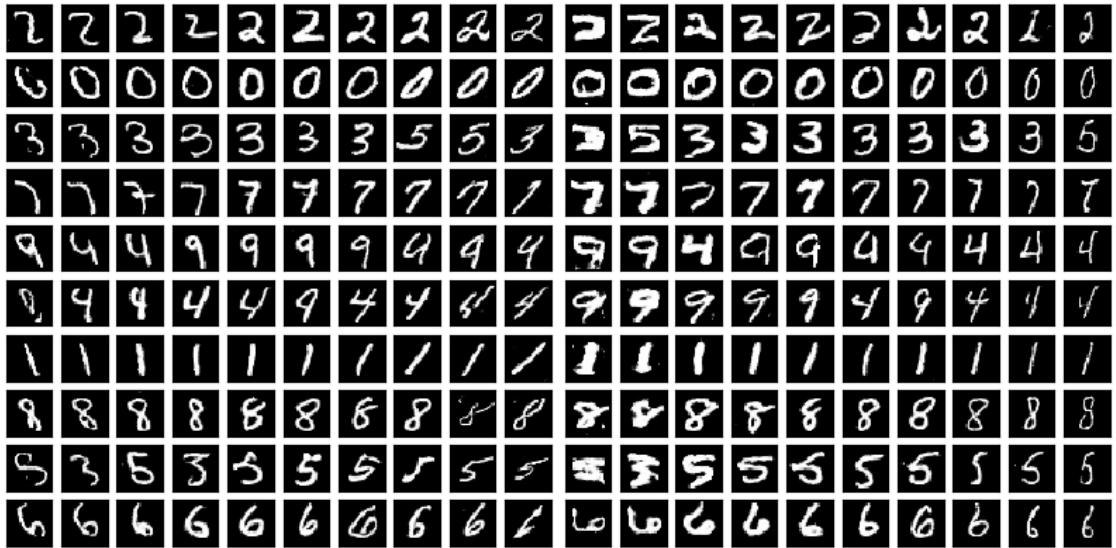
$$f(x) = \begin{cases} \frac{1}{2} & -1 \leq x \leq 1, \\ 0 & \text{inače.} \end{cases} \quad (6.28)$$

Potrebno je primijetiti da ovakav izbor latentnih kodova oslikava intuiciju da takvi latenti kodovi u podacima stvarno i postoje. Rezultati obučavanja Info-GAN modela, prikazani na slikama 6.2 i 6.3, tu intuiciju i potvrđuju.

Na prikazanim slikama može se primijetiti da se promjenom diskretnog latentnog koda mijenja i vrijednost generisane cifre. Cifre nisu sortirane, jer se, za razliku od uslovnih GAN-ova, u toku obučavanja ne može uspostaviti veza između latentnog koda i generisane cifre. Sa druge strane, promjenom neprekidnog latentnog koda \mathbf{c}_2 mijenja se ugao rotacije generisane cifre, dok se promjenom \mathbf{c}_3 može uticati na širinu generisane cifre.

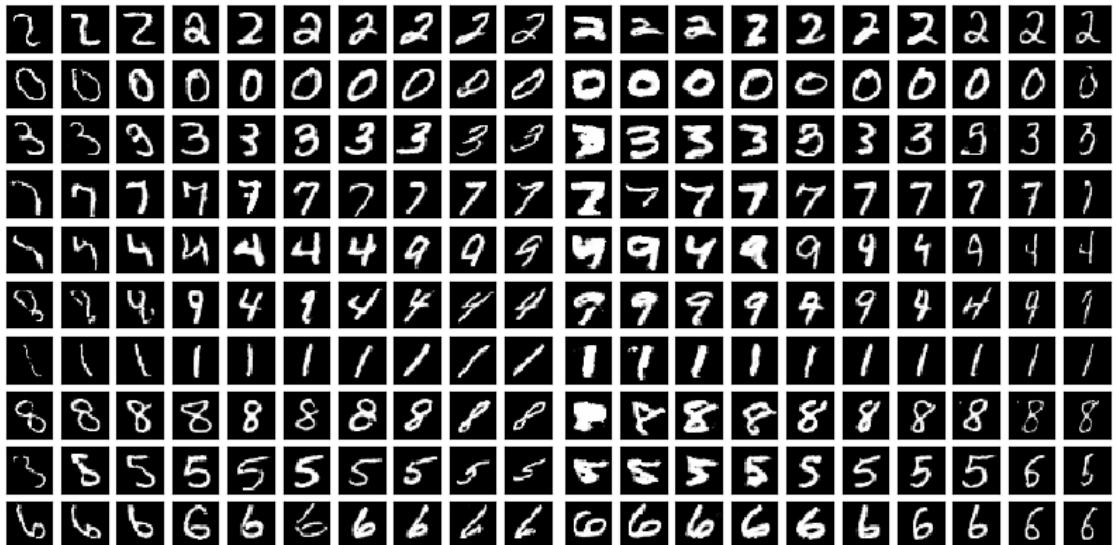
Neprekidni latentni kodovi u ovom eksperimentu su u toku obučavanja aproksimirani veoma jednostavnom uniformnom distribucijom. Treba primijetiti da se uloga latentnih kodova u generisanju cifara može utvrditi tak nakon obučavanja i eksperimentalne analize. Za generisanje slika koje imaju mnogo složeniju distribuciju,

6.4. Eksperimentalni rezultati i diskusija



(a) Kod \mathbf{c}_2 uzima vrijednosti iz intervala $[-1,1]$. (b) Kod \mathbf{c}_3 uzima vrijednosti iz intervala $[-1,1]$.

Slika 6.2: Primjeri generisanih slika rukom pisanih cifara korišćenjem Info-GAN modela sa tri latentna koda nakon 50 epoha obučavanja. Na prikazanim slikama diskretni kod \mathbf{c}_1 mijenja se po redovima, dok se promjene neprekidnih kodova \mathbf{c}_2 i \mathbf{c}_3 vrše po kolonama.



(a) Kod \mathbf{c}_2 uzima vrijednosti iz intervala $[-1,1]$. (b) Kod \mathbf{c}_3 uzima vrijednosti iz intervala $[-1,1]$.

Slika 6.3: Primjeri generisanih slika rukom pisanih cifara korišćenjem Info-GAN modela sa tri latentna koda nakon 80 epoha obučavanja. Na prikazanim slikama diskretni kod \mathbf{c}_1 se mijenja po redovima, dok se promjene neprekidnih kodova \mathbf{c}_2 i \mathbf{c}_3 vrše po kolonama.

6.4. Eksperimentalni rezultati i diskusija

izbor odgovarajuće aproksimativne distribucije nije tako jednostavan. Takođe, nemogućnost upravljanja generisanjem odgovarajućih cifara predstavlja problem ukoliko se ovakav model želi koristiti u svrhe fuzije sa mjerenjima drugih modaliteta. U sljedećoj Glavi 7 predstavljen je model generativnih suparničkih mreža koji, kao kod uslovnih GAN-ova, nudi mogućnost upravljanja nad generisanim podacima, istovremeno maksimizujući uzajamnu informaciju generatora i diskriminadora.

Glava 7

Uslovne generativne suparničke mreže sa više generatora

Pojavom GAN-ova obučavanje generativnih probabilističkih modela postao je veoma rasprostranjen pristup rješavanju problema nenadgledanog mašinskog učenja. Razlog tome vjerovatno leži u nadi istraživača da će generativni modeli, uz dovoljno velike skupove podataka za obučavanje, biti u stanju da nauče razlučenu reprezentaciju (eng. *disentangled representation*) svijeta. Učenje razlučene reprezentacije podrazumijeva da model nauči razumijevati strukturu i uzajamnu povezanost obilježja sadržanih u podacima za obučavanje. Na primjer, veoma abstraktно, za skup slika saobraćajnih scena, naučena razlučena reprezentacija značila bi da model svako obilježje scene (pješake, položaj pješaka u odnosu na kolovoznu traku, druga vozila u saobraćaju i njihov položaj u odnosu na druge učesnike u saobraćaju, mostove, pješačke prelaze i slično) vidi kao zaseban skup dimenzija, nekog hipotetičkog visoko-dimenzionalnog prostora. Zaseban skup dimenzija za svako obilježje ulaznih podataka se u probabilističkom kontekstu može shvatiti i kao zasebna višedimenzionalna funkcija gustine vjerovatnoće za svaki od tih atributa. I bez uloženja u problematiku međusobne zavisnosti pojedinih gustina (da su mostovi uvijek iznad kolovoza, da su pješački prelazi iscrtani uvijek na kolovozu i slično), jasno je da je ukupna distribucija vjerovatnoće veoma kompleksna i multimodalna^a.

Zbog problema kolapsa modova, GAN mreže, predstavljene u glavama 4, 5 i 6, favorizuju učenje samo jednog moda multimodalne distribucije vjerovatnoće ulaznih podataka. Na primjer, neka važi pretpostavka da ulazne slike mogu da sadrže samo dva objekta: čovjeka i automobil. Jasno je da slike na kojima se pojavljuje samo čovjek ili samo automobil takođe predstavljaju uzorke distribucije ulaznih podataka. Ukoliko generator nauči da generiše uvijek identičnu sliku, samo jednog od objekata, u stanju je da „prevari“ diskriminator. Time se proces optimizacije,

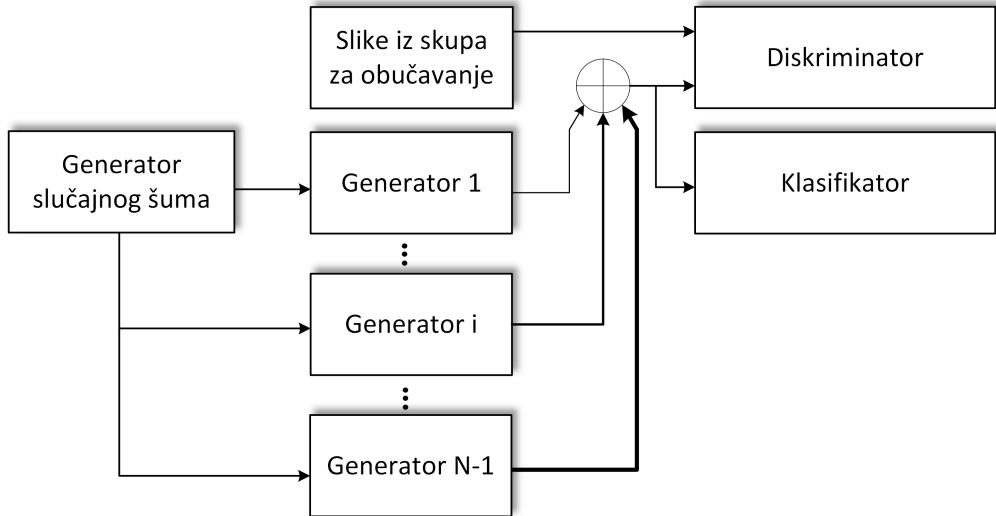
^aU matematičkoj statistici, mod se definiše kao vrijednost slučajne promjenljive koja se realizuje najčešće. Na primjer, kod Gausove raspodjele mod je jednak njenoj srednjoj vrijednosti.

7.1. Mješavina GAN-ova

u skladu sa analizom datom u odjeljku 4.3, i završava. U nastavku će biti predstavljena metoda kojom se kod generativnih suparničkih mreža umanjuje uticaj fenomena kolapsa modova i samim tim omogućava generisanje reprezentativnijih i smislenijih slika.

7.1 Mješavina GAN-ova

Model mješavine GAN-ova ili MGAN-ova [89] (eng. *Mixture GANs*) zasniva se upravo na pretpostavci da raspodjela ulaznih podataka ima prirodnu dekompoziciju na jednostavnije raspodjele. Ideja autora je da umjesto jednog generatora, koji aproksimira složenu raspodjelu ulaznih podataka, koriste više generatora koji aproksimiraju komponente mješavine jednostavnijih raspodjela. Ukoliko se u toku obučavanja maksimizuje KL-divergencija svih parova pojedinačnih raspodjela, pretpostavka je da će onda svaki od generatora aproksimirati različite modove ulazne raspodjele. Arhitektura MGAN mreže prikazana je na Slici 7.1



Slika 7.1: Arhitektura MGAN mreže.

Autori predlažu sljedeću minimax strategiju za obučavanje MGAN-ova:

$$\min_{\theta_{G_{1:N}}, \theta_C} \max_{\theta_D} V_{MGAN} (\theta_D, \theta_{G_{1:N}}, \theta_C), \quad (7.1)$$

gdje je V_{MGAN} data sa:

$$\begin{aligned}
 V_{MGAN} (\theta_D, \theta_{G_{1:N}}, \theta_C) &= V (\theta_D, \theta_{G_{1:N}}) - \beta \sum_{i=1}^N \pi_i \mathbb{E}_{\mathbf{x} \sim p_{G_i}} [\log C_i(\mathbf{x}, \theta_C)] \\
 &= \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] + \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}} [\log (1 - D(G_{1:N}(\mathbf{z}, \theta_{G_{1:N}}), \theta_D))] \\
 &\quad - \beta \sum_{i=1}^N \pi_i \mathbb{E}_{\mathbf{x} \sim p_{G_i}} [\log C_i(\mathbf{x}, \theta_C)]. \quad (7.2)
 \end{aligned}$$

U prethodnoj jednačini parametrizacije generatora G_i , $1 \leq i \leq N$, predstavljene su vektorima θ_{G_i} , dok su parametrizacije diskriminadora D i višeklasnog klasifikatora C predstavljene vektorima θ_D i θ_C , respektivno. Generatori G_i zajedno indukuju složenu raspodjelu ulaznih podataka $p_G = p_{G_1 \oplus G_2 \oplus \dots \oplus G_N}$. Slučajni vektor raspodjeljen prema takvoj, miješanoj, raspodjeli predstavljen je u prethodnoj jednačini sa $G_{1:N}(\cdot)$. Koeficijenti mješavine dati su sa π_j . Kao i težinski koeficijent $\beta > 0$, autori tretiraju koeficijente mješavine kao fiksne hiper-parametre zadate na početku treninga. Vrijednosti izlaza klasifikatora $C_i(\mathbf{x}, \theta_C) = C_i$ predstavljaju vjerovatnoću da je \mathbf{x} generisao generator G_i . Takodeže važi i sljedeća jednakost:

$$\sum_{i=1}^N C_i = 1. \quad (7.3)$$

Kao i kod klasičnih GAN-ova koji su predstavljeni u Glavi 4, potrebno je pokazati da je u stanju ravnoteže JS divergencija između mješavine p_G i raspodjele ulaznih podataka p_X minimalna. Međutim, kako se želi postići da generatori aproksimiraju različite modove ulazne raspodjele, dodatni uslov koji mora biti zadovoljen u stanju ravnoteže je da JS-divergencija raspodjele bilo koja dva generatora p_{G_i} i p_{G_j} , $i \neq j$, bude maksimalna.

I zaista, ako se prepostavi da su generatori G_1, G_2, \dots, G_N i koeficijenti mješavine $\pi_1, \pi_2, \dots, \pi_n$ zadati, optimalni diskriminator se može izvesti analogno proceduri dатој у одјељку 4.3, односно:

$$\hat{D}(\mathbf{x}, \hat{\theta}_D) = \frac{p_X(\mathbf{x})}{p_X(\mathbf{x}) + p_G(\mathbf{x})}. \quad (7.4)$$

Određivanje optimalnog klasifikatora sastoji se u određivanju nule parcijalnog izvoda jednačine (7.2). Prema jednačini (7.3), vjerovatnoća C_1 da slučajni vektor komponente mješavine $\mathbf{x} \sim p_{G_1}$ potiče od generatora G_1 može se odrediti sa $C_1 = 1 - \sum_{j=2}^N C_j$, pa se ima:

$$\begin{aligned} 0 &= \frac{\partial V_{MGAN}}{\partial C_k} = -\beta \frac{\partial}{\partial C_k} \left(\sum_{i=1}^N \pi_i \mathbb{E}_{\mathbf{x} \sim p_{G_i}} [\log C_i(\mathbf{x}, \theta_C)] \right) \\ &= -\beta \frac{\partial}{\partial C_k} \left(\pi_1 \mathbb{E}_{\mathbf{x} \sim p_{G_1}} \left[\log \left(1 - \sum_{j=2}^N C_j \right) \right] + \pi_k \mathbb{E}_{\mathbf{x} \sim p_{G_k}} [\log C_k(\mathbf{x}, \theta_C)] \right) \quad (7.5) \\ &= -\beta \left(\frac{\pi_k p_{G_k}}{C_k} - \frac{\pi_1 p_{G_1}}{C_1} \right). \end{aligned}$$

Iz prethodne jednačine proizilazi:

$$\frac{\pi_1 p_{G_1}}{C_1} = \frac{\pi_2 p_{G_2}}{C_2} = \dots = \frac{\pi_N p_{G_N}}{C_N}, \quad (7.6)$$

Uvrštavanjem (7.6) u (7.3), dobija se optimalna vrijednost izlaza klasifikatora \hat{C}_k :

$$\hat{C}_k(\mathbf{x}, \hat{\theta}_C) = \frac{\pi_k p_{\mathcal{G}_k}}{\sum_{i=1}^N \pi_i p_{\mathcal{G}_i}}. \quad (7.7)$$

U odjeljku 4.3 pokazano je da se optimalna vrijednost parametara generatora dobija kada je JS divergencija raspodjela $p_{\mathcal{X}}$ i $p_{\mathcal{G}}$ minimalna, odnosno:

$$\hat{\theta}_G^{GAN} = \min_{\theta_G} \left(2 D_{JS}(p_{\mathcal{X}} \| p_{\mathcal{G}}) - 2 \log 2 \right). \quad (7.8)$$

Međutim, kod MGAN-ova, pored uslova minimalne JS divergencije stvarne $p_{\mathcal{X}}$ i aproksimativne distribucije $p_{\mathcal{G}}$, potrebno je da optimum funkcije greške ispunjava uslov da pojedinačne komponente mješavine imaju nosače^b koji se ne preklapaju, odnosno, $p_{\mathcal{G}_j}(\mathbf{x}) > 0 \Rightarrow p_{\mathcal{G}_k}(\mathbf{x}) = 0, \forall j \neq k$. Uvrštavanjem izraza (7.4), (7.7) i (7.8) u (7.2) to se i pokazuje. Ima se:

$$\begin{aligned} \hat{\theta}_G &= \hat{\theta}_G^{GAN} - \min_{\theta_G} \left(\beta \sum_{i=1}^N \pi_i \mathbb{E}_{\mathbf{x}_i \sim p_{\mathcal{G}_i}} \left[\log \frac{\pi_i \mathbf{x}_i}{\sum_{j=1}^N \pi_j \mathbf{x}_j} \right] \right) \\ &= \hat{\theta}_G^{GAN} + \min_{\theta_G} \left(\beta \sum_{i=1}^N \pi_i H(\mathbf{x}_i) - \beta H \left(\sum_{i=1}^N \pi_i \mathbf{x}_i \right) - \beta \sum_{i=1}^N \pi_i \log \pi_i \right). \end{aligned} \quad (7.9)$$

Zajednička entropija slučajnih promjenljivih manja je ili jednaka od sume entropija pojedinačnih slučajnih promjenljivih. Jednakost važi samo u slučaju ako su slučajne promjenljive nezavisne. Tako se i u jednačini (7.9) optimizacijom generatora minimizuje suma entropija pojedinačnih komponenata $\sum_{i=1}^N \pi_i H(p_{\mathcal{G}_i})$, a maksimizuje entropija mješavine $H\left(\sum_{i=1}^N \pi_i p_{\mathcal{G}_i}\right)$. Optimalna vrijednost postiže se kada su komponente mješavine statističke nezavisne.

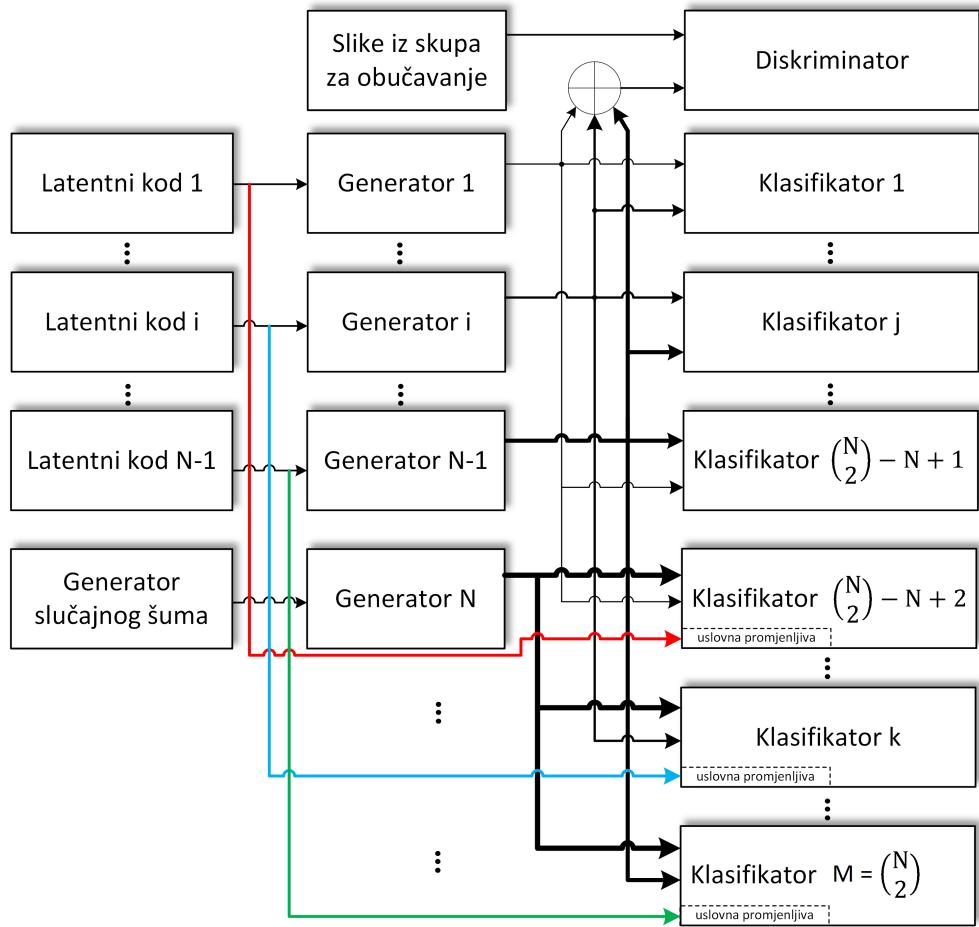
7.2 Uslovne generativne suparničke mreže sa više generatora

Predstavljene MGAN mreže koriste veoma interesantan pristup rješavanju problema kolapsa modova, međutim, kao ni klasični GAN-ovi ne nude mogućnost upravljanja generisanjem modova zajedničke distribucije. U glavama 5 i 6 prikazana su dva pristupa upravljanja generatorima. Kod uslovnih GAN-ova, dodatni upravljački ulazni vektor koristi se kako bi se generator usmjerio da generiše slike željenih klasa. Pri tome su upravljački vektori obično anotacije iz skupa za obučavanje. Za razliku od njih, InfoGAN-ovi su imaju mogućnost da sami nauče latentne kodove. Nakon obučavanja InfoGAN-ova, moguće je uspostaviti vezu između latentnog koda i generisane slike, ali za složenije slike prirodno je očekivati da su i latentni kodovi složeniji, a samim tim usložnjava se i njihova interpretacija.

^bNosač funkcije f definisane na Ω je skup $\{x \in \Omega \mid f(x) \neq 0\}$.

7.2. Uslovne generativne suparničke mreže sa više generatora

Uslovne generativne suparničke mreže sa više generatora - CMGGAN (eng. *Conditional Multi-Generator GAN*) [32], slično MGAN-ovima, takođe nude mogućnost aproksimacije složene distribucije ulaznih podataka mješavinom jednostavnijih raspodjela. Međutim, za razliku od MGAN-ova, CMGGAN-ovi posjeduju i upravljačke ulaze kojima je moguće usmjeriti generatore da generišu željena obilježja ulaznih podataka. Ova osobina čini CMGGAN mreže ključnim doprinosom ove disertacije, jer se na taj način omogućava fuzija obilježja mjerena senzora različitih modaliteta. Kombinovanjem ili miješanjem generisanih obilježja dobija se signal koji, idealno, predstavlja reprezentativan primjerak podataka iz skupa za obučavanje.



Slika 7.2: Arhitektura CMGGAN mreže sa jednim diskriminatorm, N generatora i $M = \binom{N}{2} = N(N - 1)/2$ klasifikatora.

Minimax strategija za obučavanje CMGGAN-ova data je sa:

$$\min_{\theta_{G_{1:N}}, \theta_{C_{1:M}}} \max_{\theta_D} V_{CMGGAN} (\theta_D, \theta_{G_{1:N}}, \theta_{C_{1:M}}), \quad (7.10)$$

pri čemu je

$$\begin{aligned}
 V_{CMGGAN}(\theta_D, \theta_{G_{1:N}}, \theta_{C_{1:M}}) &= \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{X}}} [\log D(\mathbf{x}, \theta_D)] \\
 &+ \mathbb{E}_{\mathbf{z} \sim p_{\mathcal{Z}}, \mathbf{y} \sim p_{\mathcal{Y}}} [\log (1 - D(G(\mathbf{z}, \theta_{G_{1:N}} \mid \mathbf{y}), \theta_D))] \\
 &- \beta_1 \sum_{(i,j)_k \wedge i,j \neq N} \pi_k \left(\mathbb{E}_{\mathbf{x} \sim p_{\mathcal{G}_i}} [\log C_k(\mathbf{x}, \theta_{C_k})] + \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{G}_j}} [\log (1 - C_k(\mathbf{x}, \theta_{C_k}))] \right) \\
 &- \beta_2 \sum_{(l,N)} \pi_l \left(\mathbb{E}_{\mathbf{x} \sim p_{\mathcal{G}_l}} [\log C_l(\mathbf{x}, \theta_{C_l} \mid \mathbf{y}_l)] + \mathbb{E}_{\mathbf{x} \sim p_{\mathcal{G}_N}} [\log (1 - C_l(\mathbf{x}, \theta_{C_l} \mid \mathbf{y}_l))] \right).
 \end{aligned} \tag{7.11}$$

U prethodnoj jednačini sa $(i,j)_k$ označen je element skupa svih kombinacija (bez ponavljanja) druge klase od N elemenata, odnosno $(i,j)_k \in S_N^2 = \{a \in 2^{\{1,2,\dots,N\}} \mid |a| = 2\}$ i $1 \leq k \leq |S_N^2| - N + 1$. Broj klasifikatora C_k jednak je ukupnom broju kombinacija, odnosno $M = |S_N^2| = \binom{N}{2}$. Arhitektura CMGGAN mreže prikazana je na Slici 7.2.

Svakom paru generatora (G_i, G_j) , pri čemu je $i \neq j$, dodijeljuje se jedan binarni klasifikator C_k . Generatori i klasifikatori uslovljeni su latentim kodom \mathbf{y}_k . Zadatak binarnog klasifikatora je da optimizuje generatore tako da otkrivaju različite modove stvarne distribucije ulaznih podataka. Istovremeno, diskriminatom D osigurava se da mješavina pojedinačnih komponenata $p_{\mathcal{G}} = p_{\mathcal{G}_1 \oplus \mathcal{G}_2 \oplus \dots \oplus \mathcal{G}_N}$ dobro aproksimira distribuciju ulaznih podataka.

Teoretska analiza CMGGAN-ova analogna je onoj datoj za MGAN-ove. Osnovna razlika, koja omogućava da svaki par generatora uči različite modove distribucije, ogleda se u primjeni više binarnih umjesto jednog višeklasnog klasifikatora.

7.3 Diskusija

Binarne klasifikatore i generatore moguće je usloviti latentnim kodovima, što otvara mogućnost upravljanja modelom da generiše željene slike na izlazu, slično kao kod uslovnih GAN-ova i InfoGAN-ova. Međutim, za razliku od njih, prednost CMGGAN-ova je što latentni kodovi mogu biti proizvoljno kompleksni i ne moraju se učiti. Ako se latentni kodovi ne moraju učiti, izbjegava se veoma kompleksna procedura eksperimentalne analize njihovog značenja za generisanje slika. To predstavlja veliku prednost u odnosu na već postojeće modele uslovljenih generativnih suparničkih mreža.

Latentni kodovi ne moraju biti anotacije slika iz skupa za obučavanje. Međutim, za uspješno obučavanje CMGGAN mreža neophodno je da slike iz skupa za obučavanje i latentni kodovi budu „upareni“, odnosno, moraju da budu vremenski sinhronizovani i da na neki način opisuju istu scenu ili dijelove iste scene. Kvalitet generisanih slika zavisi, dakle, od korišćenih podataka za obučavanje (kako slika, tako i latentnih kodova), korišćenih arhitektura neuronskih mreža, metoda obučavanja i svih drugih preporučenih metoda neophodnih za uspješno obučavanje vještačkih ne-

7.3. Diskusija

uronskih mreža. Nakon obučavanja, CMGGAN mreža izvršava se koristeći samo generatore.

U narednoj Glavi 8 biće izvršena detaljna eksperimentalna analiza CMGGAN mreže na primjeru transformacije obilježja.

Glava 8

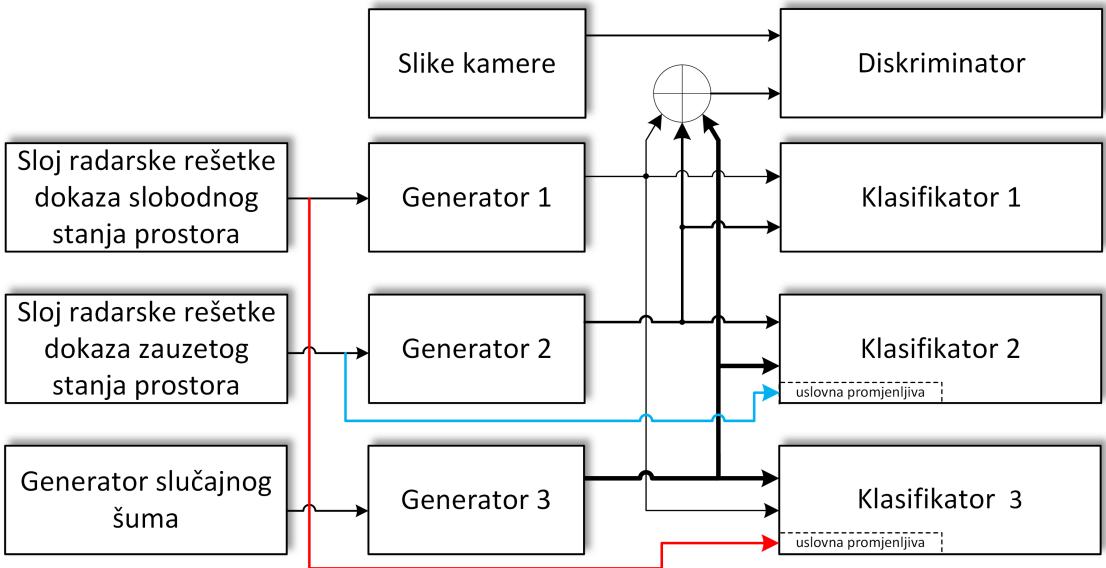
Transformacija obilježja i semantička fuzija senzorskih mjerena različitih modaliteta

U fazi planiranja projekta razvoja visoko automatizovanog vozila neophodno je izvršiti analizu stvarnih saobraćajnih situacija kojima vozilo mora da ovlada. Jedan od rezultata te analize je i senzorska konfiguracija vozila. Senzorska konfiguracija predstavlja skup senzora kojima vozilo (ili sistem) može da izračuna svoj položaj u prostoru, prepozna, odredi položaj i prati ostale učesnike u saobraćaju, prepozna važne informacije i uputstva za pravilno odvijanje saobraćaja i slično. Kako je saobraćajna infrastruktura prije svega prilagođena čovjekovom vizuelnom sistemu, nezaobilazni članovi senzorske konfiguracije su sistemi mono i stereo kamera. U prilog tome ide i činjenica da su slike dobijene kamerom, u poređenju sa mjerenjima drugih tipova senzora, jednostavnije za semantičku anotaciju. Anotirani skupovi podataka pružaju mogućnost korišćenja algoritama mašinskog učenja visokog kapaciteta, koji nerijetko postižu rezultate klasifikacije i regresije iznad prosječnih ljudskih mogućnosti. Kamere su, međutim, osjetljive na otežane radne uslove, kao što su na primjer loše ili prekomjerno osvjetljenje, pa je samo njihovo korišćenje za percepciju voznog okruženja neadekvatno u sistemima visoko-automatizovane vožnje. U nastavku, predstavljen je metod transformacije obilježja senzorskih mjerena jednog modaliteta u obilježja senzorskih mjerena drugog modaliteta. Takođe, eksperimentalnom analizom pokazano je, da se vještački generisana mjerena mogu koristiti za semantičku fuziju sa mjerenjima stvarnih senzora.

8.1 Transformacija obilježja

Kao što je u uvodnoj Glavi 1 istaknuto, visok nivo pouzdane percepcije okruženja vozila moguće je postići tek fuzijom senzorskih mjerena različitih modaliteta. Oslanjajući se na CMGGAN modele date u Glavi 7, u ovoj glavi predstavljen

8.1. Transformacija obilježja



Slika 8.1: Transformacija obilježja sadržanih u radarskim mjerjenjima i slikama dobijenih kamerom korišćenjem CMGGAN mreže.

je potpuno novi pristup obradi i fuziji mjernih podataka radara i kamere. Predloženi CMGGAN-ovi omogućavaju transformaciju radarskih mjerjenja u slike kamere. Ovaj proces naziva se transformacija obilježja, i u opštem slučaju definiše se kao proces transformacije mjerjenja jednog modaliteta u mjerjenje drugog modaliteta. Na primjer, neka je $\Omega = \{X_1 = \text{udaljenost}, X_2 = \text{boja}\}$ skup obilježja i neka je senzor S_1 u mogućnosti da detektuje obilježje X_1 , a senzor S_2 obilježje X_2 . Ako je za potpunu karakterizaciju nekog objekta potreban vektor obilježja $[X_1, X_2]$, transformacija obilježja bi se mogla vršiti sabiranjem vektora obilježja pojedinačnih senzora, odnosno $[X_1, X_2] = [X_1, \emptyset] + [\emptyset, X_2]$. Obilježja generisanih slika i obilježja slika snimljenih stvarnom kamerom moguće je dalje zajedno obrađivati u istom semantičkom prostoru. Ovaj proces naziva se semantička fuzija. U opštem slučaju, preduslov za semantičku fuziju je, dakle, uspješna transformacija mjernih podataka različitih modaliteta na mjerne podatke istog modaliteta.

Arhitektura CMGGAN mreže koja omogućava transformaciju obilježja sadržanih u radarskim mjerjenjima i slikama dobijenih kamerom prikazana je na Slici 8.1. Analogno analizi datoј u Glavi 7, cilj obučavanje diskriminatora je da prepozna da li slika na njegovom ulazu potiče od kamere ili je generisana od strane niza generatora. Odnosno, ako je na ulaz diskriminatora dovedena slika dobijena kamerom, cilj je da se na izlazu diskriminatora dobije vrijednost koja teži jedinici. Obrnuto, ukoliko je na ulaz diskriminatora dovedena slika koja potiče od generatora, cilj je da se na izlazu diskriminatora dobije vrijednost koja teži nuli. U oba slučaja, veličina odstupanja dobijene vrijednosti od ciljne vrijednosti koristi se kao signal greške kojim se nekom od optimizacionih metoda (na primjer metodom stohastičkog gradijentnog spusta) prilagođavaju parametri modela.

Tri klasifikatora u prikazanom modelu imaju različite zadatke. Zadatak klasifika-

8.1. Transformacija obilježja

tora 1 je da prepozna da li signal na njegovom ulazu potiče od generatora 1 ili generatora 2. Klasifikator 1 tako ima mogućnost da upravlja procesom njihovog obučavanja i obezbjedi da nauče različita obilježja. Istovremeno, klasifikatori 2 i 3 imaju zadatak da maksimizuju zajedničku količinu informacija u pripadajućim slojevima rešetki dokaza i izlaznim signalima generatora 2 i 3, respektivno. Kako se mješanjem izlaznih signala generatora želi dobiti slika kojom bi se „prevario“ diskriminatory, jasno je i da izlazni signali svakog od generatora sadrže naučena obilježja u prostoru slika dobijenih kamerom.

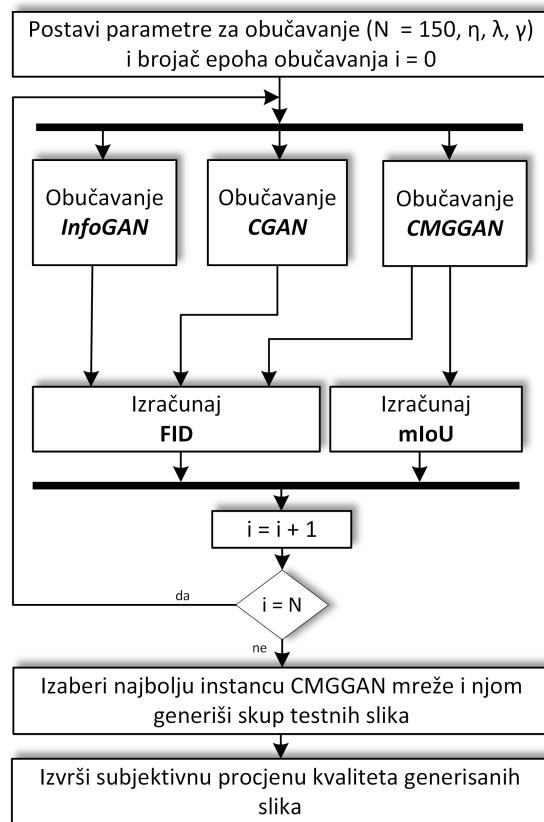
Generatori, klasifikatori i diskriminatory se mogu modelovati dubokom neuronskom mrežom. Arhitektura samih mreža se bira u zavisnosti od rezolucije slika dobijenih kamerom i veličine rešetke dokaza. Međutim, prirodno je očekivati da sve neuronske mreže generatora imaju istu arhitekturu, te da su arhitekture diskriminatora i klasifikatora veoma slične. Iako je za obučavanje modela potrebno prilagođavati parametre 7 dubokih neuronskih mreža, u fazi testiranja i eksploracije potrebne su samo neuronske mreže generatora.

Važno je istaknuti da prikazana arhitektura za transformaciju obilježja omogućava da se izabrani modeli mreža obučavaju nenadgledano, odnosno nije potrebno vršiti semantičku anotaciju slika dobijenih kamerom niti rešetki dokaza^a. Prikazani model je, u skladu sa teorijskom analizom iz Glave 7, moguće proširiti tako da za generisanje vještačkih slika koristi i mjerjenja senzora drugih modaliteta.

^aPonekad se ovdje prikazani metod obučavanja naziva samonadgledani metod obučavanja (eng. *self-supervised*).

8.2 Eksperimentalni pristup i postavka eksperimenta

Kao što je u prethodnom odjeljku naglašeno, osnovu algoritama za transformaciju obilježja i semantičku fuziju predstavlja CMGGAN mreža. Za obučavanje modela koristi se skup podataka predstavljen u odjeljku 3.4. Ocjena kvaliteta i raznovrsnosti generisanih slika izvršena je subjektivnom i objektivnom analizom istih. Objektivna mjera kvaliteta FID, koja je predstavljena u odjeljku 3.6, iskorišćena je za poređenje CMGGAN mreže sa referentnim CGAN i InfoGAN mrežama. Pregled koraka evaluacije algoritma dat je na Slici 8.2, dok je detaljna arhitektura korišćenih neuronskih mreža prikazana na Slici 8.3.



Slika 8.2: Pregled koraka evaluacije CMGGAN mreže za transformaciju obilježja i semantičku fuziju slika dobijenih kamerom i mjerena radara.

Maksimalni broj epoha obučavanja iznosi $N = 150$. U toku jedne epohe obučavanja na ulaz svake od korišćenih mreža dovodi se par (slika dobijena kamerom, rešetke dokaza) iz skupa za obučavanje. Pri tome se ti parovi biraju slučajnim odabirom. Neuronske mreže optimizuju se metodom stohastičkog gradijentnog spusta. Dužina koraka gradijentnog spusta η bira se iz skupa $\{0,0001, 0,00001\}$. Hiper-parametar λ iz jednačine (6.26) predstavlja težinski koeficijent regularizacionog dijela funkcije gubitka InfoGAN mreže i bira se iz skupa $\{0,5, 1,0\}$. InfoGAN i CGAN mreža

8.2. Eksperimentalni pristup i postavka eksperimenta

se obučavaju, takozvanom, Vaserštajnovom funkcijom gubitka [77] za koju je potrebno u proces obučavanja uvesti dodatni hiper-parametar γ . Parametar γ uzima vrijednosti iz skupa $\{0,5,1,0\}$.

Izbor arhitekture neuronskih mreža je ključan za uspješno obučavanje. Na Slici 8.3 duboke konvolucione neuronske mreže kojima se modeluje funkcije generatorka, klasifikatora i diskriminatorka CMGAN mreže veoma su slične. Nazivi aktivacijskih funkcija i primjenjenih tehniki regularizacije dati su na spojevima slojeva mreža. Pod operacijom „transformacija“ podrazumijeva se promjena oblika prethodnih slojeva, na primjer iz matrice u vektor svih vrsta te matrice. Aktivaciona funkcija ReLU [90] (eng. *Rectified Linear Unit*) zadata je sa:

$$\text{relu}(x) = \begin{cases} 0 & \text{za } x < 0, \\ x & \text{za } x \geq 0. \end{cases} \quad (8.1)$$

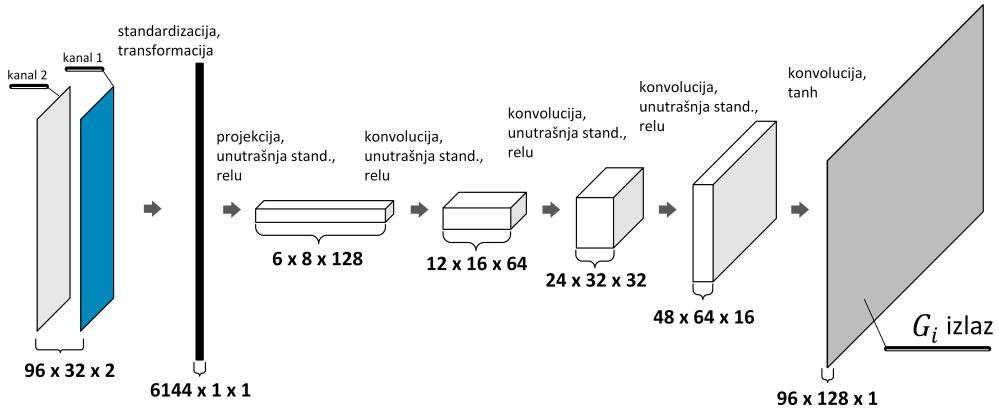
Za razliku od ReLU, LeakyReLU [91] (eng. *Leaky Rectified Linear Unit*) aktivacije dozvoljavaju mali pozitivan gradijent kada neuron nije aktivan:

$$\text{leaky_relu}(x) = \begin{cases} ax & \text{za } x < 0, \\ x & \text{za } x \geq 0. \end{cases} \quad (8.2)$$

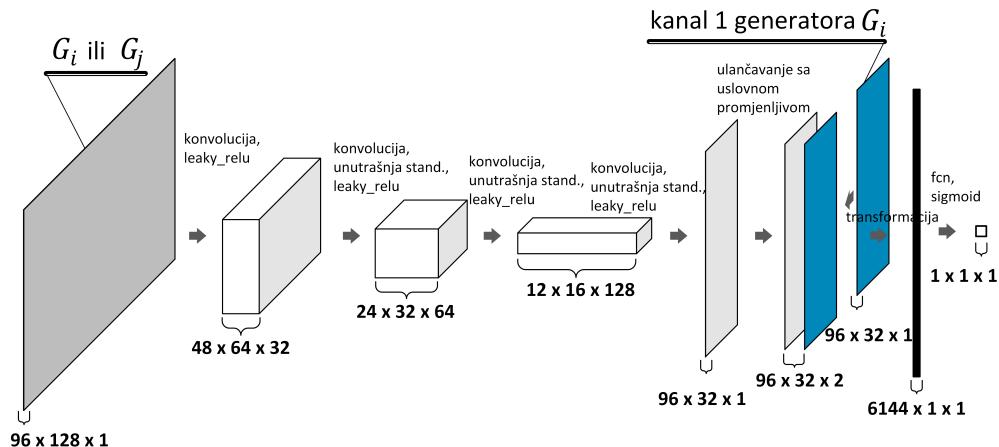
Parametar a LeakyReLU aktivacione funkcije je konstantan^b, reda 10^{-2} . Kako se disriminatorm i klasifikatorom procjenjuje vjerovatnoća, aktivaciona funkcija na izlaznom sloju tih mreža je sigmoidna funkcija $\sigma(x) = 1/(1 + \exp(-x))$. Za razliku od njih, generatori na izlazu koriste tangens hiperbolički $\tanh = (\exp(2x) - 1)/(\exp(2x) + 1)$. Opseg vrijednosti $[-1, 1]$ izlaza generatora, osim što ima veći dinamički opseg od sigmoidne funkcije, je pogodan ulazni sloj za mreže diskriminatorka i klasifikatora.

^bKod ParametricReLU - PReLU, koje imaju istu definiciju kao LeakyReLU ovaj parametar može da se obučava.

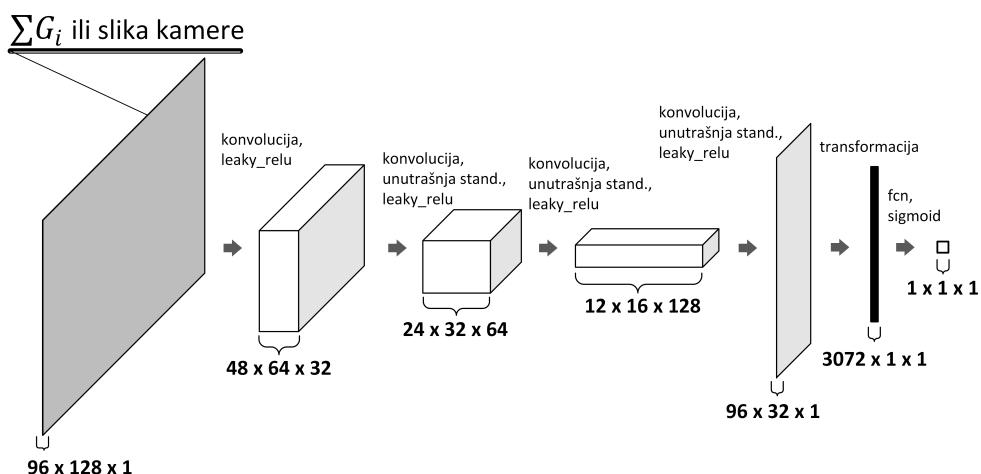
8.2. Eksperimentalni pristup i postavka eksperimenta



(a) Arhitektura generatora



(b) Arhitektura klasifikatora



(c) Arhitektura diskriminatora

Slika 8.3: Detaljna arhitektura dubokih neuronskih mreža kojima se modeluju funkcije generatora, klasifikatora i diskriminatora CMGGAN mreže.

8.3 Validacija transformacije obilježja

Predložena arhitektura za transformaciju obilježja, prikazana na Slici 8.3, implementirana je u programskom jeziku Python^c korišćenjem programske biblioteke za razvoj i obučavanje modela mašinskog učenja Tensorflow^d. Programska biblioteka Tensorflow podržava obučavanje i izvršavanje modela na računarskim grafičkim kartama. U toku obučavanja i izvršavanja predloženog modela korišćena je računarska grafička karta tipa „Nvidia Geforce GTX 1080 Ti“. Zbog relativno malih dimenzija ulaznih podataka, i velike procesorske moći korišćene grafičke kartice brzine obučavanja i izvršavanja modela nisu predstavljale značajnu prepreku u procesu validacije.

8.3.1 Objektivna ocjena kvaliteta generisanih slika

Nakon svake epohe obučavanja, za generisane slike svih mreža korišćenih u eksperimentu računa se FID mjera. Ideja FID mjere zasnovana je na pretpostavci da neka mreža za klasifikaciju slika, koja je prethodno obučena na velikom skupu anotiranih slika, na nekom od svojih skrivenih slojeva sadrži vektor obilježja ulazne slike. U disertaciji je za tu svrhu iskorišćena Inception-V3 [92] mreža, obučena na Imagenet skupu podataka. Pretpostavljeno je, pri tome, da 2048-dimenzionalna aktivacija pool3 sloja te mreže sadrži sva relevantna obilježja ulazne slike. Informacije sadržane u tom vektoru obilježja sažimaju se dalje u jednu skalarnu veličinu - FID mjeru, koja se smatra objektivnom mjerom za ocjenu kvaliteta generisanih slika. Za računanje FID mjere iskorišćena je javno dostupna programska biblioteka^e napisana u programskom jeziku Python.

Na Slici 8.4 prikazane su vrijednosti FID mjere u toku obučavanja CMGGAN, InfoGAN i CGAN mreža. InfoGAN i CGAN mreže postižu najbolje rezultate izborom hiper-parametara $\lambda = 1,0$ i $\gamma = 0,5$. U gotovo svim epohama obučavanja CMGGAN postižu nižu vrijednost FID mjere. Potrebno je primijetiti da izborom građijentnog koraka $\eta = 0,00001$ FID mjera CMGGAN mreže opada sa rastom broja epoha obučavanja, što ukazuje na svrshishodnost upotrebe FID mjere za objektivnu analizu kvaliteta generisanih slika.

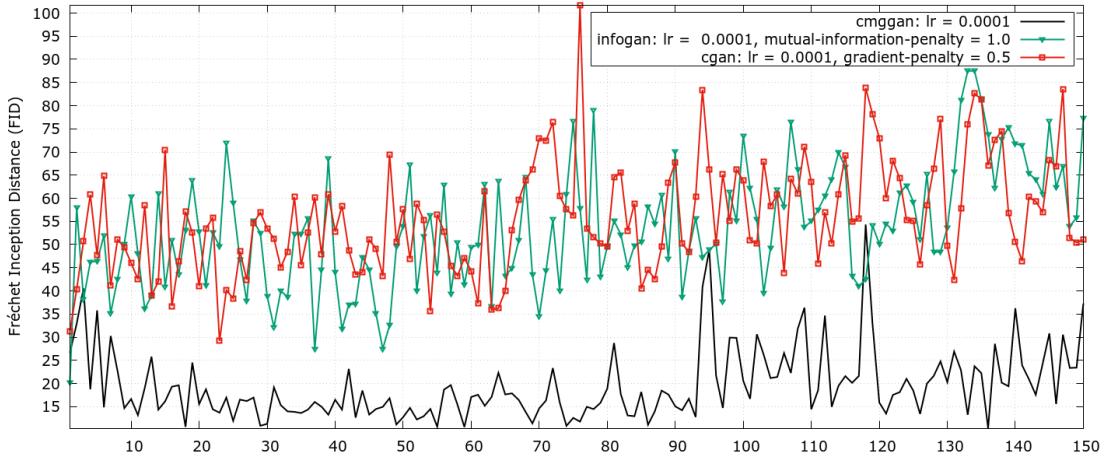
Nakon svake epohe obučavanja, pored FID mjere, CMGGAN mreža je iskorišćena za generisanje slika korišćenjem radarskih rešetki dokaza i skupa za validaciju. Skup za validaciju, kao što je opisano u odjeljku 3.4 pored parova (slika dobijena kamerom, rešetke dokaza), sadrži i 100 anotiranih slika. Anotirani slobodni prostor ispred sistemskog vozila iskorišćen je za računanje Žakardovog indeksa ($J = TP / (TP + FP + FN)$). Kako se Žakardov indeks u literaturi još naziva i količnik presjeka i unije - IoU, srednja vrijednost IoU nad svim slikama skupa naziva se srednji količnik presjeka i unije ili mIoU (eng. *mean IoU*). Anotacije generisanih slika računaju se automatski korišćenjem FCN [93] (eng. *Fully Convolutional*

^c<https://www.python.org/>

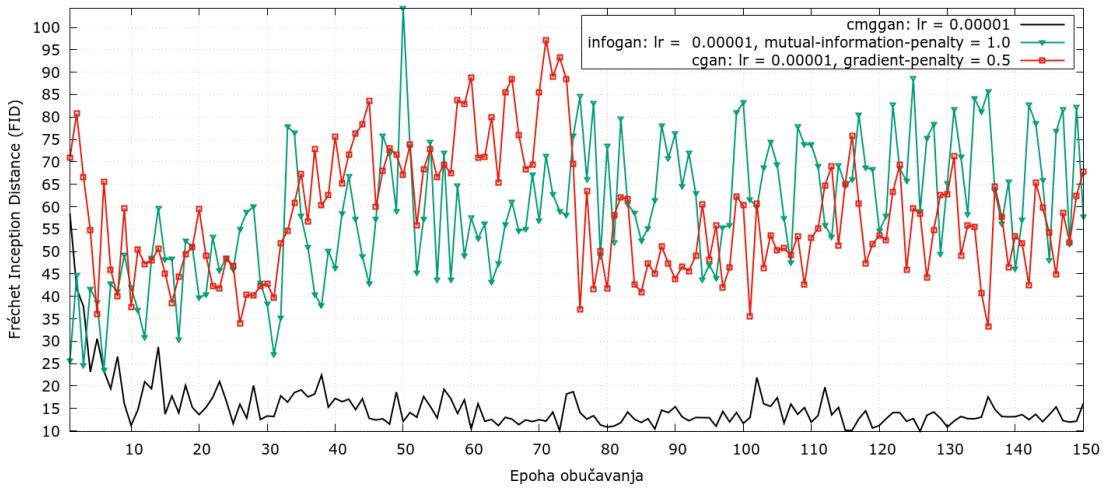
^d<https://www.tensorflow.org/>

^e<https://github.com/tsc2017/Frechet-Inception-Distance>

8.3. Validacija transformacije obilježja



(a) Gradijentni korak 0,0001



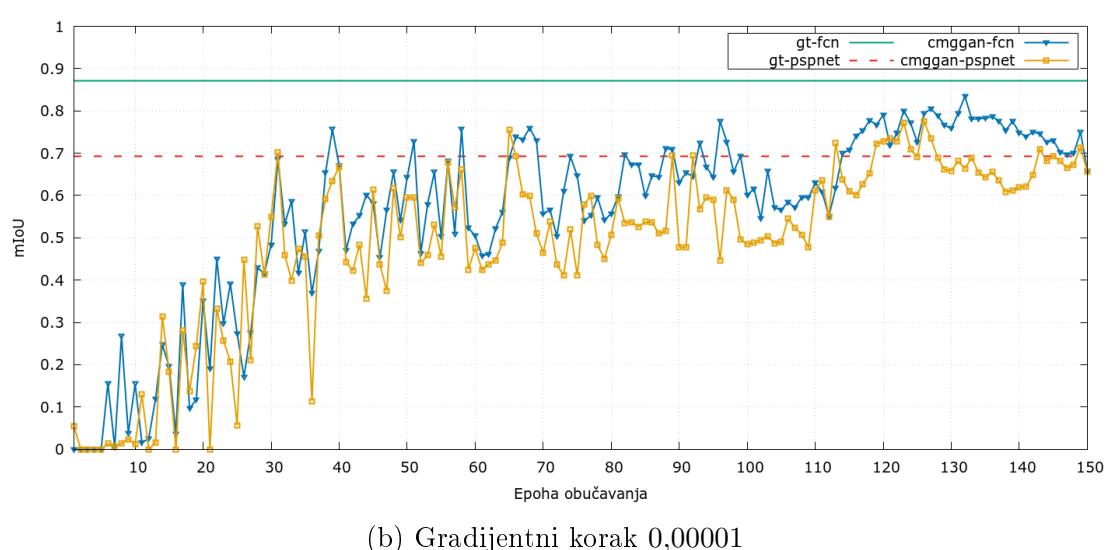
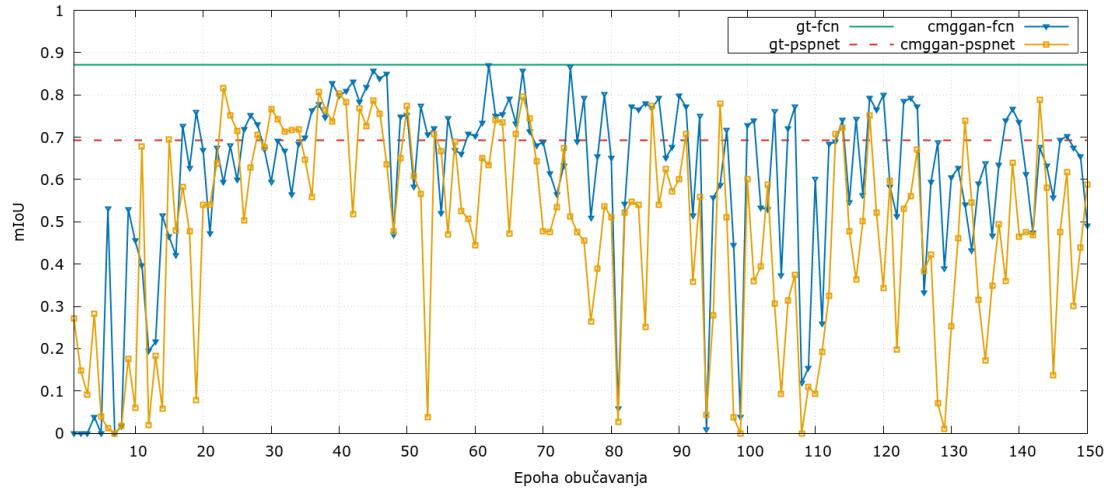
(b) Gradijentni korak 0,00001

Slika 8.4: FID mjera u toku obučavanja CMGGAN, InfoGAN i CGAN mreža, za dvije vrijednosti gradijentnog koraka i najoptimalnije vrijednosti hiper-parametra λ i γ . Što je vrijednost FID mjere niža smatra se da je mreža bolja.

*Network for Semantic Segmentation) i PSPNET [94] (eng. *Pyramid Scene Parsing Network*) mreža za semantičku segmentaciju piksela. Za semantičku segmentaciju iskorišćene su javno dostupne implementacije^f FCN i PSPNET mreža napisana u programskom jeziku Python. FCN i PSPNET mreže su prethodno obučene na ADE20k skupu podataka koji je predstavljen u odjeljku 3.5.1. Kao što je već pomenuto, FCN i PSPNET mreže obučene su RGB slikama iz ADE20k skupa podataka. Da bi se sive slike iz skupa za validaciju prilagodile ulazima FCN i PSPNET mreža, uzeto je da su R, G i B kanal jednaki sivoj slici iz skupa za validaciju ako se vrši semantička segmentacija stvarne slike dobijene kamerom ili generisanoj slici ako se*

^f<https://github.com/hellochick/semantic-segmentation-tensorflow>

8.3. Validacija transformacije obilježja



Slika 8.5: Srednja Žakardova ili mIoU mjera nakon svake epohe obučavanja CMGAN mreže. Punom zelenom i isprekidanom crvenom linijom prikazana je vrijednost mIoU FCN i PSPNET anotacija stvarnih slika iz skupa za validaciju, respektivno.

vrši semantička segmentacija generisane slike. Prikazani rezultati dobro oslikavaju graf mIoU mjere u toku obučavanja. Vizuelno, rezultati semantičke segmentacije PSPNET mrežom bolji su nego rezultati dobijeni FCN mrežom, kako za stvarne tako i za generisane slike. Korišćenjem „ručnih“ anotacija slika, te FCN i PSPNET anotacija slika generisanih CMGGAN mrežom računa se mIoU nakon svake epohe obučavanja. Rezultati su prikazani na Slici 8.5.

Interesantno je primijetiti da se graf mIoU mjere, koja je zasnovana na potpuno drugačijem mernom principu od FID mjere ponaša veoma slično. Obučavanje

8.3. Validacija transformacije obilježja

manjim gradijentnim korakom i ovdje daje bolje rezultate, i kao kod FID grafa postoji trend povećanja mIoU sa povećanjem broja epoha obučavanja. Iako se najveći mIoU postiže nakon 74 epoha korišćenjem gradijentnog koraka $\eta = 0,0001$, mnogo stabilniji rezultati se postižu gradijentnim korakom $\eta = 0,00001$, gdje se najveći mIoU dostiže tek nakon 132 epohe obučavanja. Takođe, može se primijetiti da FCN anotacije generisanih slika u toku većeg dijela obučavanja imaju veću vrijednost mIoU od PSPNET anotacija stvarnih slika (crvena isprekidana linija). Na skupu korišćenih slika FCN mreža imaju bolje rezultate semantičke segmentacije od PSPNET mreža.

8.3.2 Subjektivna ocjena generisanih slika

Za subjektivnu ocjenu transformacije obilježja koriste se generisane slike dobijene CMGGAN mrežom, obučenom gradijentnim korakom $\eta = 0,00001$ nakon 132 epohe obučavanja. Slike su generisane korišćenjem radarskih rešetki dokaza iz testnog skupa podataka. Zadatak izvršene eksperimentalne analize je da se poređenjem generisanih sa stvarnim slikama dobijenih kamerom dobije jedna ili više subjektivnih ocjena kvaliteta generisanih slika. U tu svrhu, učesnicima eksperimenta predstavljeno je 50 parova stvarnih i generisanih slika. Pri tome se 50 parova bira slučajnim odabirom iz cijelog testnog skupa podataka. Vrijeme potrebno za izvršavanje eksperimenta nije bilo ograničeno, međutim, učesnici su morali odgovoriti na sva postavljena pitanja.

Na početku svakog eksperimenta učesnicima je dato sljedeće objašnjenje eksperimenta: „*Svaka od sljedećih 50 grupa pitanja sastoji se od slučajno odabranog para slika, jednog opštег i niza od 10 detaljnih pitanja. Gornja slika u prikazanom paru je referentna slika. Cilj eksperimenta je da se poredeći donju, vještački generisani sliki sa referentnom slikom da odgovor na postavljena pitanja. Opšte pitanje odnosi se na kvalitet prikaza stvarne scene vještački generisanom slikom. Odgovor na opšte pitanje sastoji se u odabiru jednog od ponuđenih odgovora: 1 - postoje neprihvatljive razlike, 2 - postoje značajne razlike, 3 - postoje prihvatljive razlike, 4 - postoje neznatne razlike, 5 - nema uočljivih razlika. Na niz od 10 detaljnih pitanja potrebno je odgovoriti sa „da“ ili „ne“. Prilikom odgovaranja na detaljna pitanja potrebno je uzeti u obzir da se pokretni objekti ne smatraju elementima puta. Isto tako, u obzir ne treba uzimati oblik i tip zaštitne ograde na bočnim djelovima puta, niti bilo koje elemente slike koje se ne odnose na sam put (na primjer planine u pozadini).“.*

Primjeri parova stvarnih i generisanih slika dati su na Slici 8.6. Svaka grupa pitanja počinje opštim pitanjem: „*Koliko dobro generisana slika (donja slika prikazanog para) prikazuje sve elemente puta prikazane na referentnoj slici (gornja slika)?*“. Zatim je slijedila lista sljedećih detaljnih pitanja:

1. „*Da li generisana slika ispravno prikazuje lateralnu poziciju vozila na putu?*“,
2. „*Da li generisana slika ispravno prikazuje krivinu puta?*“,

8.3. Validacija transformacije obilježja



(a) Ljeva krivina

(b) Širina kolovoza



(c) Saobraćajna signalizacija

(d) Slobodne kolovozne trake

Slika 8.6: Primjeri parova stvarnih i generisanih slika korišćenih za subjektivnu ocjenu kvaliteta generisanih slika. Kod svakog od četiri para slika gornja slika predstavlja stvarnu sliku kamere, a donja sliku generisanu CMGGAN mrežom na osnovu radarskih rešetki dokaza.

3. „Da li generisana slika ispravno prikazuje širinu puta (sve vozne i zaustavne

8.3. Validacija transformacije obilježja

trake zajedno)?“,

4. „*Da li se na generisanoj slici sistemsko vozilo nalazi u tunelu?“,*
5. „*Da li se na referentnoj slici sistemsko vozilo nalazi u tunelu?“,*
6. „*Da li se na generisanoj slici na putu ispred sistemskog vozila nalazi most, nadvožnjak ili neka druga stacionarna konstrukcija iznad vozila?“,*
7. „*Da li se na referentnoj slici na putu ispred sistemskog vozila nalazi most, nadvožnjak ili neka druga stacionarna konstrukcija iznad vozila?“,*
8. „*Da li se na generisanoj slici na putu ispred vozila nalazi druga stacionarna prepreka (ne uključujući mostove, znakove i tunele iz pitanja 4 i 6)?“,*
9. „*Da li se na referentnoj slici na putu ispred vozila nalazi druga stacionarna prepreka (ne uključujući mostove, znakove i tunele iz pitanja 5 i 7)?“,*
10. „*Da li generisana slika ispravno prikazuje pokretne objekte na putu?“.*

U eksperimentu je učestvovalo dvanaest osoba. Odgovori na opšte pitanje iskorisćeni su za računanje prosječne ocjene kvaliteta predstavljenih generisanih slika. Odgovori na opšta pitanja sažeti su u Tabeli 8.1. Samo 16% ispitanika ocijenilo je

Tabela 8.1: Odgovori na opšta pitanja.

	Ocjena				
	1	2	3	4	5
Broj odgovora	96	157	177	86	84

da generisane slike sadrže neprihvatljive razlike u poređenju sa referentnom slikom. Prema prikazanoj tabeli, prosječna, subjektivna ocjena kvaliteta generisanih slika prema tabeli iznosi 2,84.

Odgovori na detaljna pitanja iskorisćeni su da bi se utvrdilo da li generisane slike sadrže obilježja koja su prisutna i na slikama scena snimljenih stvarnom kamerom. Odgovori na detaljna pitanja analizirani su korišćenjem dvije različite metodologije. Bilo je očekivano da će pitanja 4, 5, 6, 7, 8 i 9, vezana za kvalitet reprezentacije stacionarnih konstrukcija na putu izazvati nedoumice kod učesnika. Zbog toga su odgovori na ta pitanja sažeta u dvije statističke mjere: specifičnost i osjetljivost. Specifičnost S se definiše kao udio tačnih negativnih odgovora TN u ukupnom broju negativnih odgovora $TN + FP$, odnosno $S = TN / (TN + FP)$. Osjetljivost ili opoziv O izražava udio tačnih pozitivnih odgovora TP^g u ukupnom broju pozitivnih odgovora $TP + FN$, odnosno $O = TP / (TP + FN)$. Intuitivnije, specifičnost karakteriše sposobnost sistema da ne generiše lažno pozitivne objekte, dok osjetljivost

^gOznake TN (eng. *True Negative*), FP (eng. *False Positive*), TP (eng. *True Positive*) i FN (eng. *False Negative*) uobičajene su u statističkoj analizi, te su zbog toga i ovdje zadržane u izvornom obliku.

8.3. Validacija transformacije obilježja

čini isto za lažno negativne objekte. Obje mjere su od velike važnosti za sisteme visoko automatizovane vožnje. Na primjer, lažno pozitivna detekcija (takođe poznata kao greška prve vrste ili α -greška) može da izazove neželjenu aktivaciju funkcije automatskog kočenja vozila. Sa druge strane, lažno negativna detekcija (takođe poznata kao greška druge vrste ili β -greška) može da spriječi aktivaciju funkcije automatskog kočenja u prisustvu stvarne prepreke na putu. Odgovori na ovaj podskup detaljnih pitanja predstavljeni su u Tabeli 8.2. Na osnovu rezultata prikazanih

Tabela 8.2: Rezultati statističke analize odgovora na detaljna pitanja 4-9.

	Statističke mjere kvaliteta					
	Broj TP	Broj FP	Broj TN	Broj FN	Specifičnost $\frac{TN}{TN+FP}$	Osjetljivost $\frac{TP}{TP+FN}$
Detekcija tunela	0	5	595	0	0,9917	0,0000
Detekcija stacionarnih konstrukcija iznad vozila	5	0	455	140	1,0000	0,0345
Detekcija drugih stacionarnih objekata	0	123	474	3	0,7940	0,0000

u tabeli, CMGGAN mreža postiže veliku specifičnost prilikom detekcije tunela i uzvišenih stacionarnih konstrukcija. Za preostale stacionarne objekte uočava se veći broj lažno pozitivnih, što utiče na nepovoljnu vrijednost specifičnosti $S = 0,7940$. Pretpostavlja se da ovaj problem djelimično potiče od lažnih detekcija (nekada se za takve objekte kažu da su „ghost“ objekti) koje nastaju uslijed efekta mnogostruke propagacije emitovanog elektromagnetskog talasa ili uslijed interferencije sa talasima drugih radara.

Mala osjetljivost algoritma na stacionarne konstrukcije iznad vozila je očekivana i poželjna, jer korišćeni radar ima veoma nisku rezoluciju mjerena po vertikalnoj osi i ograničeno vidno polje po visini. Zbog toga radar uzvišene objekte detektuje samo na većim udaljenostima od sistemskog vozila. Radarska rešetka dokaza, kao što je pokazano u odjelu 3.1, modeluje sva radarska mjerena jednako, ne uzimajući u obzir mogućnost da prepreka od koje se elektromagnetski talas reflektovao ima visinu ili da je moguće da sistemsko vozilo prođe ispod iste (ukoliko se radi o uzvišenoj konstrukciji). Pretpostavlja se međutim, da je ta informacija ipak sadržana u radarskoj rešetki dokaza. Kako uzvišeni objekti ne predstavljaju prepreke kretanju sistemskog vozila, celije rešetke koje pripadaju takvim preprekama potrebno je pouzdano detektovati i ukloniti. Uobičajen i vrlo nepouzdan inženjerski pristup detekcije mostova na osnovu radarske rešetke dokaza sastoji se u pomjeranju graničnog okvira duž pretpostavljene putanje sistemskog vozila. U svakom koraku pomjeranja graničnog okvira pored se raspodjela mjerena unutar okvira sa nekom referentnom veličinom. Problemi na koje se ovdje nailazi su pouzdano određivanje putanje vozila, određivanje referentne veličine i slično.

Odgovori na preostala detaljna pitanja sažeti su u Tabeli 8.3 korišćenjem jednostavne metode brojanja potvrđnih i negativnih odgovora na detaljna pitanja o položaju vozila, krivini i širini puta, te o postojanju pokretnih objekata na putu. Predstavljeni metod za transformaciju obilježja postiže dobre rezultate prilikom generisanja obilježja u prostoru slika, a koja su sadržana u radarskim mjeranjima. Niži procenat ispravno generisanih pokretnih objekata je očekivan i poželjan, jer radarske rešetke dokaza ne sadrže informaciju o pokretnim objekatima.

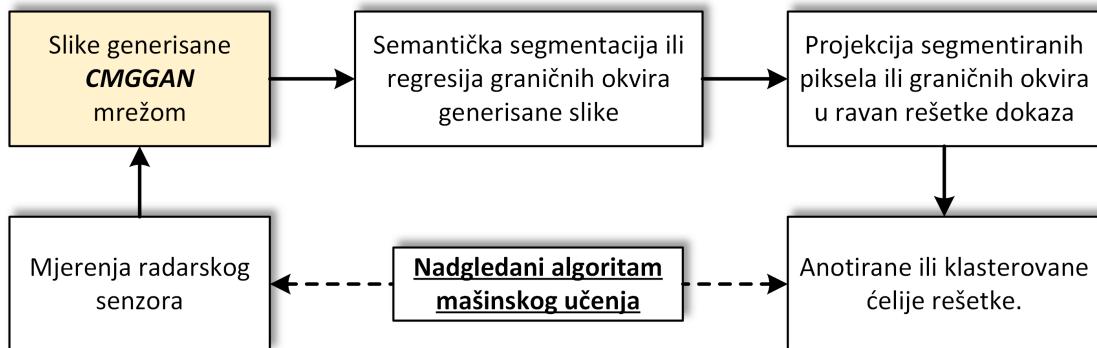
8.4. Principi semantičke fuzije senzorskih mjerena različitih modaliteta

Tabela 8.3: Odgovori na pitanja o položaju vozila i kvalitetu generisanih obilježja scene.

Odgovori	Detaljna pitanja			
	Položaj sistemskog vozila	Krivina puta	Širina puta	Pokretni objekti
Broj potvrđnih odgovora	529	544	516	217
Broj negativnih odgovora	71	56	84	383
Procenat potvrđnih odgovora [%]	88,2	90,6	86,0	36,2

8.4 Principi semantičke fuzije senzorskih mjerena različitih modaliteta

U praksi, generisanje vještačkih slika na osnovu radarskih mjerena otvara razne mogućnosti njihove semantičke fuzije sa slikama stvarne kamere. Na Slici 8.7 prikazan je princip automatske anotacije radarskih podataka. Korišćenjem nekog od obučenih algoritama za semantičku segmentaciju ili regresiju graničnih okvira, vrši se procjena semantičke klase piksela ili graničnih okvira objekata sadržanih u generisanoj slici. Ako se pretpostavi da su kamera i korišćeni radar ispravno kalibrисани^h, u odnosu na isti koordinatni početak (uobičajeno je to sredina prednje osovine vozila) moguće je projektovati semantičke elemente slike u ravan rešetke dokaza. Na



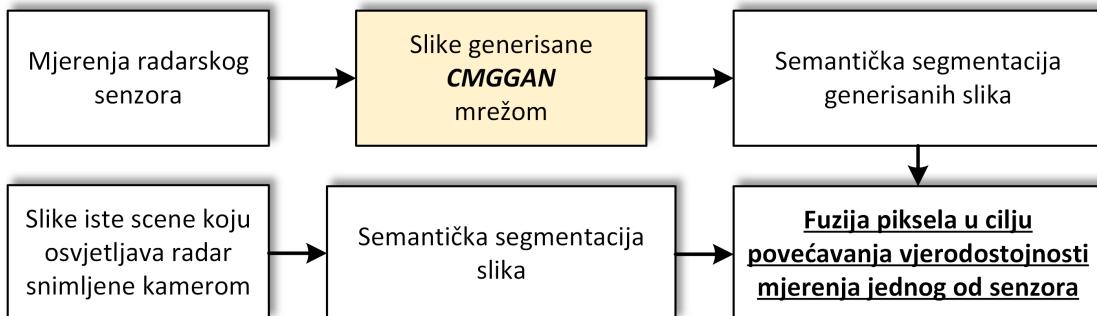
Slika 8.7: Princip automatske anotacije radarske rešetke dokaza korišćenjem CMGGAN-ova.

taj način dobijaju se automatski anotirane celije rešetke kojima se može obučavati neki od nadgledanih algoritama mašinskog učenja za segmentaciju rešetki dokaza. Nakon uspješno obučenog algoritma za segmentaciju radarskih podataka otvara se mogućnost optimizacije senzorske konfiguracije vozila (na primjer eliminacijom jedne ili više kamera). Mogućnost automatske anotacije radarskih rešetki dokaza korišćenjem relativno jeftinih anotacija slika takođe predstavlja veoma veliki doprinos ove disertacije.

^hPretpostavka o ispravnoj kalibraciji vozila nije stroga. Da bi testno vozilo uopšte moglo da se koristi na javnim saobraćajnicama, obično je potrebno obezbjediti dozvolu neke od nadležnih institucija zaduženih za tehnički nadzor. Kako je ispravna kalibracija senzora neophodna za bezbjedan rad sistema, jedna od stavki koja se provjerava prilikom pribavljanja takve dozvole je i ispravna kalibracija senzora.

8.5. Diskusija rezultata

Na Slici 8.8 prikazan je još jedan princip semantičke fuzije generisanih i stvarnih slika čiji je cilj povećanje vjerodostojnosti mjerenja stvarnog senzora. Kamere su



Slika 8.8: Princip fuzije piksela generisane i stvarne slike dobijene kamerom u cilju povećanja vjerodostojnosti mjerenja.

veoma osjetljive na promjene vanjskog osvjetljenja i loše vremenske i radne uslove. Na primjer, nečistoće na površini sočiva često uzrokuju zamućene oblasti na dobijenim slikama. Radari sa druge strane nisu osjetljivi na pomenute fenomene, pa je u cilju postizanja određenog stepena funkcionalne bezbjednosti sistema, hipotezu o nekom obilježju prostora, izračunatu obradom slike dobijene stvarnom kamerom, moguće provjeriti koristeći generisanu sliku.

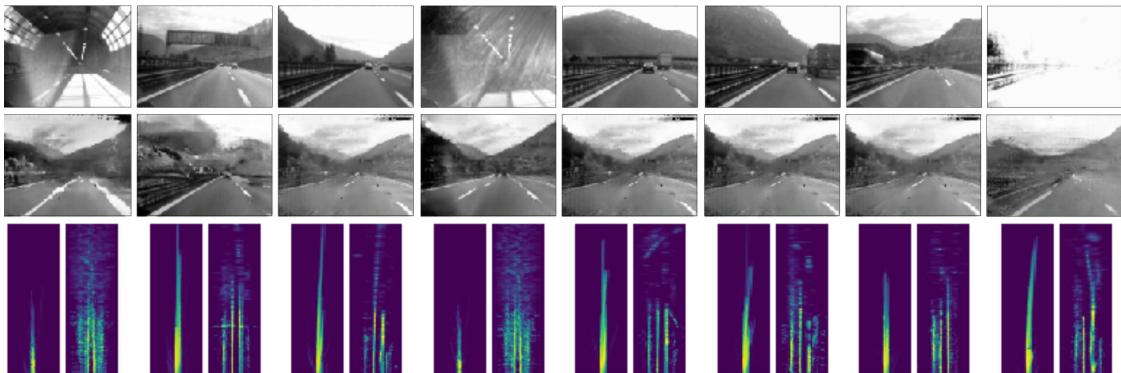
8.5 Diskusija rezultata

Eksperimentalna analiza transformacije obilježja izvršena je na relativno malom skupu parova slika i radarskih rešetki dokaza. Mjerenja radara i slike scene snimljene kamerom prikupljene su u toku eksperimentalne vožnje auto-putem. Izvršeno je 9850 uzastopnih i sinhronizovanih mjerenja, a mjerni podaci su nakon obrade podijeljeni na skupove za obučavanje, validaciju i testiranje. Ovi podaci iskorišćeni su za obučavanje i validaciju predložene metode transformacije obilježja. Prikazano je da je uz pomoć radarskih rešetki dokaza CMGGAN mrežom moguće generisati slike koje sadrže sva relevantna obilježja vidljiva i na stvarnim slikama. Pri tome je potrebno napomenuti da je, uvezvi u obzir dimenzije korišćenih sivih slika 96×32 piksela, broj mogućih slika koje je moguće generisati CMGGAN mrežom jednak¹ $256^{3072} \approx 10^{7372}$.

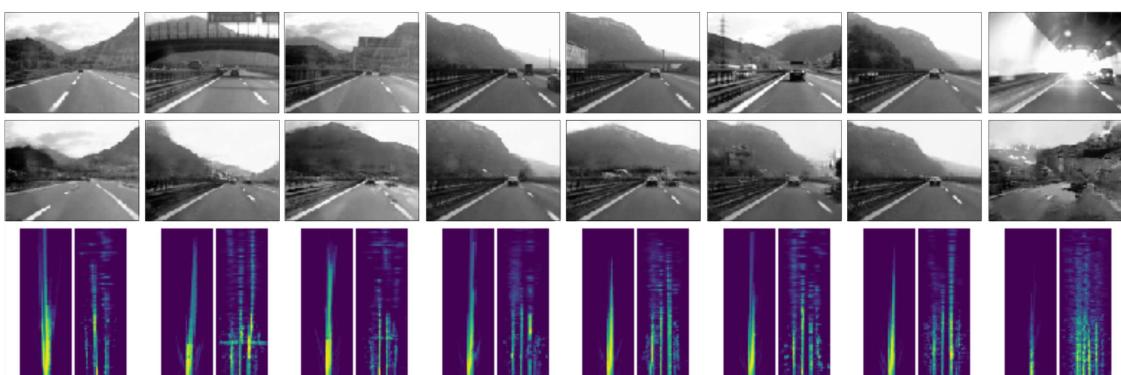
Važno je razmotriti mogućnost korišćenja vještački generisanih slika za semantičku fuziju sa stvarnim slikama scene. Za semantičku fuziju nije od primarnog značaja da generisane slike sadrže sva obilježja kao i stvarne slike dobijene kamerom. Ovdje je prevashodno važno da su važna obilježja sadržana u radarskim mjeranjima vjerodostojno prikazana i na generisanim slikama. Kako mjerena radara nisu osjetljiva na efekte koji mogu da degradiraju slike dobijene kamerom, dodatni izvor pouzdanih informacija, kao što su generisane slike, može se iskoristiti za povećanje pouzdanosti kompletognog sistema visoko automatizovane vožnje.

¹Interesantan je podatak da je broj atoma u vidljivom svemiru procijenjen na $10^{78} - 10^{80}$ [95].

8.5. Diskusija rezultata



(a) Gradijetni korak $\eta = 0.0001$, epoha obučavanja $n = 74$



(b) Gradijentni korak $\eta = 0.00001$, epoha obučavanja $n = 132$

Slika 8.9: Slike generisaneinstancama CMGGAN mreže koje su ostvarile najveći mIoU. Odozgo prema dole, na objema slikama vrste predstavljaju: stvarne slike, generisane slike i radarske rešetke dokaza. Posmatrano slike po kolonama, generisane slike su generisane CMGGAN mrežom na osnovu radarskih rešetki. Radarske rešetke dokaza su, u toku faze obučavanja mreže, sa stvarnim slikama činile par za obučavanje.

Eksperimentalni rezultati pokazuju da se CMGGAN mreže mogu koristiti za transformaciju obilježja sadržanih u radarskim rešetkama dokaza u sliku kamere. Na primjeru semantičke segmentacije piksela generisanih slika biće pokazano da CMGGAN mreže omogućavaju i semantičku fuziju informacija. Semantička segmentacija generisanih slika već je izvršena u koraku određivanja mIoU mjeru kako bi se izabrao najbolji model za generisanje slika. Izabrani model je zatim iskorišćen za validaciju transformacije obilježja. Kako bi se upotpunila slika o prikladnosti predloženog algoritma za semantičku fuziju mjerena različitim modalitetima na Slici 8.9 prikazano je 8 generisanih slika, zajedno sa parovima iz skupa za testiranje. Kako su radari neosjetljivi na svjetlosne efekte koji su vidljivi na slikama dobijenih kamerom, ni slike koje su generisane na osnovu radarskih mjerena ne prikazuju takve efekte. Kvalitet slika dobijenih kamerom, kao što se vidi na nekim od slika jako je degradiran. Ako se sistem visoko automatizovane vožnje oslanja samo na slike dobijene kamerom, na primjer za određivanje slobodnog prostora ispred sistemskog vozila,

8.5. Diskusija rezultata

njegove performanse će takođe biti degradirane. Korišćenjem generisanih slika dobijaju se vjerodostojnije informacije o okruženju vozila.



(a) Ručno anotirane slike iz skupa za obučavanje.



(b) Automatski anotirane slike iz skupa za obučavanje korišćenjem FCN mreže.



(c) Automatski anotirane slike iz skupa za obučavanje korišćenjem PSPNET mreže.



(d) Automatski anotirane generisane slike korišćenjem FCN mreže.



(e) Automatski anotirane generisane slike korišćenjem PSPNET mreže.

Slika 8.10: Uporedni prikaz ručno i automatski anotiranih slika iz skupa za obučavanje i slika generisana korišćenjem CMGGAN mreže.

Sa druge strane, ako se posmatraju slike tunela i mostova, jasno je da je tumačenje informacija sadržanih u pripadajućim radarskim rešetkama dokaza veoma teško. Višestruke refleksije elektromagnetskih talasa unutar tunela mogu prouzrokovati, već pomenute, lažno pozitivne detekcije radara. Obučena mreža veoma dobro diskriminiše lažno pozitivne detekcije, i gdje postoji slobodan prostor ispred vozila isti se pronalazi i na generisanim slikama. Slobodan prostor na slikama veoma pouzdano može se odrediti nekom od dubokih konvolucionih mreža za semantičku segmentaciju. Rezultati semantičke segmentacije stvarnih i generisanih slika korišćenjem FCN i PSPNET mreža prikazani su na Slici 8.10.

Korišćenje CMGGAN mreža za transformaciju obilježja nije ograničeno samo na

8.5. Diskusija rezultata

dva korišćena modaliteta senzora. Broj generatora CMGGAN mreže teoretski je neograničen, a zavisi samo od računarske moći korišćenog hardvera za obučavanje. Na primjer, veoma interesantno bi bilo umjesto rešetki radara koristiti mjerena lidara ili mikrofona. Pri tome ne treba zaboraviti, da se mreža obučava bez nadgledanja, odnosno za njeno obučavanje potrebno je testnim vozilom prikupiti dovoljno senzorskih mjerena jednog ili drugog modaliteta i odgovarajućih slika scene.

Glava 9

Zaključak

U ovoj disertaciji dat je novi metod transformacije obilježja sadržanih u senzorskim mjerjenjima jednog modaliteta u senzorska mjerena drugog modaliteta. Predloženi metod zasnovan je na novoj arhitekturi generativnih suparničkih mreža, takozvanim CMGGAN-ovima. Predložene CMGGAN mreže ključni su doprinos ove disertacije. Korišćenjem pogodnih senzorskih mjerena jednog modaliteta, koji se posmatraju kao latentne promjenljive, CMGGAN-ovima moguće je generisati vještačka mjerena drugog modaliteta. Validacija predloženog metoda transformacije obilježja izvršena je na konkretnom primjeru fuzije radarskih mjerena i slika dobijenih kamerom. Objektivnom i subjektivnom analizom generisanih slika pokazano je da se predloženi metod transformacije obilježja može koristiti za generisanje vještačkih slika, koje kvalitativno i kvantitativno sadrže obilježja sadržana u radarskim mjerjenjima. Pored toga, za semantičku fuziju obilježja sadržanih u slikama dobijenih kamerom i mjerjenjima radara nije potrebno definisati vektor obilježja. Takav način fuzije mjerena, kako je pokazano, vodi gubitku obilježja sadržanih u mjernim podacima. Ovo predstavlja veliku prednost predložene metode transformacije obilježja u odnosu na poznate metode fuzije. Takođe, veoma važna karakteristika predloženih CMGGAN mreža je da se obučavaju potpuno nenadgledano. To znači da je granica kvaliteta signala generisanih CMGGAN mrežom određena samo kapacitetom korišćenih neuronskih mreža.

Pored transformacije obilježja, u disertaciji su predloženi različiti principi semantičke fuzije senzorskih mjerena različitih modaliteta. Jedan od navedenih principa je i princip automatske anotacije radarske rešetke dokaza korišćenjem slika generisanih CMGGAN-ovima. Mogućnost automatske anotacije radarskih rešetki dokaza korišćenjem relativno jeftinih anotacija slika takođe predstavlja veoma veliki doprinos ove disertacije.

Iz kratke diskusije o funkcionalnoj bezbjednosti u Glavi 2 jasno je da iza složenih koraka koji su potrebni za ispunjavanje bezbjednosnih normi u stvari leži potreba proizvođača i zakonodavca da se problem u potpunosti razumije konceptualno, odnosno, da se razumije i detaljno opiše priroda problema. Tek tada moguće je

definisati bezbjednosne ciljeve, bezbjednosne zahtjeve, a potom iz njih izvedene softverske i hardverske zahtjeve neophodne za razvoj funkcionalnih komponenata sistema. Ako je funkcionalnost komponente zasnovana na vještačkim neuronskim mrežama, bezbjednosne norme na nivou same komponente, na trenutnom nivou nauke i tehnologije, nije moguće ispuniti. Naime, vještačke neuronske mreže imaju veoma visoke performanse u zadacima kao što su detekcija i prepoznavanje objekata ili planiranje trajektorije, ali se ne uklapaju u paradigmu razvoja i sertifikacije softvera u automobilskoj industriji.

Jedan od problema je i izbor samog vektora obilježja ili vektora stanja prostora. Odnosno, u toku validacije sistemske arhitekture visoko automatizovanog vozila potrebno je utvrditi koja mjerljiva obilježja prostora su potrebna i dovoljna za postizanje odgovarajućeg stepena automatizacije vozila. Problem je što se za najviši stepen automatizacije vožnje, odnosno sistema čije su performanse jednake čovjekovim, vjerovatno mora definisati i visokodimenzionalni vektor stanja prostora, a to validaciju sistema čini veoma složenom. Na primjer, neka se u vidnom polju vozača nalaze dva pješaka A i B. Analizirajući njihovu signalizaciju rukama ili analizirajući njihov razgovor ili kako se gledaju, vozač je u stanju da odredi i prirodu njihovog odnosa. Neka vozač ima dobro razvijene kognitivne sposobnosti (kognitivne sposobnosti, važne za uspješno upravljanje motornim vozilom, razvijaju se u najranijem životnom dobu [96]). Ako pješak A doziva pješaka B, dobar vozač je, na neki način, u stanju pouzdano odrediti da pješaci imaju određeni priateljski ili porodični odnos, te da će se pješak B kretati prema pješaku A. Na osnovu pretpostavke o kretanju pješaka, vozač će prilikom upravljanja vozilom donijeti bezbjedniju odluku nego kada mu je odnos između pješaka nepoznat ili skriven. Način na koji je pretpostavka o prijateljskom odnosu donesena teško se može objasniti i nije direktno mjerljiva vizuelnim sistemom čovjeka, pa se ovdje govori o latentnim ili skrivenim obilježjima ili kodovima. Korist latentnih kodova pri odlučivanju naravno nije strana ni teoriji odlučivanja. U disertaciji je njihov značaj posebno istaknut u Glavi 6 na primjeru algoritma maksimizacije očekivanja. Latentni kodovi iskorišćeni su takođe u konstrukciji CMGGAN mreža. Naime, korišćenjem latentnih kodova kao uslovnih promjenljivih, CMGGAN mreže su, u procesu nenadgledanog mašinskog učenja, u mogućnosti naučiti uslovnu raspodjelu vjerovatnoće ulaznih podataka.

Svi navedeni problemi bezbjednog korišćenja vještačkih neuronskih mreža u obradi signala senzora visoko automatizovanih vozila: pravilan izbor podataka za obučavanje, pravilan izbor modela, „borba“ protiv suparničkih primjera, validacija i verifikacija izabranog modela, neriješeni su, i predmet su daljeg istraživanja.

Bibliografija

- [1] Jens Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE transactions on systems, man, and cybernetics*, pages 257–266, 1983.
- [2] Markus Maurer, J Christian Gerdes, Barbara Lenz, and Hermann Winner. *Autonomes Fahren: technische, rechtliche und gesellschaftliche Aspekte*. Springer, 2015.
- [3] Tom M Gasser, Clemens Arzt, Mihiar Ayoubi, Arne Bartels, Lutz Bürkle, Jana Eier, Frank Flemisch, Dirk Häcker, Tobias Hesse, Werner Huber, et al. Rechtsfolgen zunehmender fahrzeugautomatisierung. *Berichte der Bundesanstalt für Straßenwesen. Unterreihe Fahrzeugtechnik*, (83), 2012.
- [4] National Highway Traffic Safety Administration et al. Preliminary statement of policy concerning automated vehicles. washington, dc. *Verfügbar unter www.nhtsa.gov/staticfiles/rulemaking/pdf/Automated_Vehicles_Policy.pdf*, 2013.
- [5] SAE International. Automated driving: levels of driving automation are defined in new sae international standard j3016. 2014.
- [6] Benjamin Lussier, Raja Chatila, Felix Ingrand, Marc-Olivier Killijian, and David Powell. On fault tolerance and robustness in autonomous systems. In *Proceedings of the 3rd IARP-IEEE/RAS-EURON joint workshop on technical challenges for dependable robots in human environments*, pages 351–358, 2004.
- [7] ISO Vim. International vocabulary of basic and general terms in metrology (vim). *International Organization*, 2004:09–14, 2004.
- [8] Ljubiša Golubović. *Električna mjerjenja*. Tehnički fakultet Čačak, Elektrotehnički fakultet Banja Luka, 1996.
- [9] Ramon Pallas-Areny and John G Webster. *Sensors and signal conditioning*. John Wiley & Sons, 2012.
- [10] Katedra za merenja. *Metrologija električnih veličina - predavanja*. Univerzitet u Nišu, Elektronski fakultet, 2014.

BIBLIOGRAFIJA

- [11] Bernd Jähne. Emva 1288 standard for machine vision: Objective specification of vital camera data. *Optik & Photonik*, 5(1):53–54, 2010.
- [12] Peter Pinggera, Sebastian Ramos, Stefan Gehrig, Uwe Franke, Carsten Rother, and Rudolf Mester. Lost and found: detecting small road hazards for self-driving vehicles. In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1099–1106. IEEE, 2016.
- [13] Hirokatsu Kataoka, Yoshimitsu Aoki, Yutaka Satoh, Shoko Oikawa, and Yasuhiro Matsui. Fine-grained walking activity recognition via driving recorder dataset. In *2015 IEEE 18th International Conference on Intelligent Transportation Systems*, pages 620–625. IEEE, 2015.
- [14] Faraz M Mirzaei. *Extrinsic and intrinsic sensor calibration*. 2013.
- [15] Merrill Ivan Skolnik. Introduction to radar systems. *New York, McGraw Hill Book Co., 1980. 590 p.*, 1980.
- [16] Hongming Chen, Ola Engkvist, Yinhai Wang, Marcus Olivecrona, and Thomas Blaschke. The rise of deep learning in drug discovery. *Drug discovery today*, 23(6):1241–1250, 2018.
- [17] Dan Guest, Kyle Cranmer, and Daniel Whiteson. Deep learning and its application to lhc physics. *Annual Review of Nuclear and Particle Science*, 68:161–181, 2018.
- [18] Maciej A Mazurowski, Mateusz Buda, Ashirbani Saha, and Mustafa R Bashir. Deep learning in radiology: an overview of the concepts and a survey of the state of the art. *arXiv preprint arXiv:1802.08717*, 2018.
- [19] Sebastian Thrun, Wolfram Burgard, and Dieter Fox. *Probabilistic robotics*. MIT press, 2005.
- [20] Ivan Klajn and Milan Šipka. *Veliki rečnik stranih reči i izraza*. Prometej, 2006.
- [21] Jae Pil Hwang, Seung Eun Cho, Kyung Jin Ryu, Seungkeun Park, and Euntai Kim. Multi-classifier based lidar and camera fusion. In *2007 IEEE Intelligent Transportation Systems Conference*, pages 467–472. IEEE, 2007.
- [22] Feihu Zhang, Daniel Clarke, and Alois Knoll. Vehicle detection based on lidar and camera fusion. In *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pages 1620–1625. IEEE, 2014.
- [23] Zhexiang Yu, Jie Bai, Sihan Chen, Libo Huang, and Xin Bi. Camera-radar data fusion for target detection via kalman filter and bayesian estimation. Technical report, SAE Technical Paper, 2018.

BIBLIOGRAFIJA

- [24] Xian Wu, Jing Ren, Yujun Wu, and Jianwang Shao. Study on target tracking based on vision and radar sensor fusion. Technical report, SAE Technical Paper, 2018.
- [25] Alireza Asvadi, Luis Garrote, Cristiano Premebida, Paulo Peixoto, and Urbano J Nunes. Multimodal vehicle detection: fusing 3d-lidar and color camera data. *Pattern Recognition Letters*, 115:20–29, 2018.
- [26] Xiao Wang, Linhai Xu, Hongbin Sun, Jingmin Xin, and Nanning Zheng. On-road vehicle detection and tracking using mmw radar and monovision fusion. *IEEE Transactions on Intelligent Transportation Systems*, 17(7):2075–2084, 2016.
- [27] Ziguo Zhong, Stanley Liu, Manu Mathew, and Aish Dubey. Camera radar fusion for increased reliability in adas applications. *Electronic Imaging*, 2018(17):258–1, 2018.
- [28] Luca Caltagirone, Mauro Bellone, Lennart Svensson, and Mattias Wahde. Lidar-camera fusion for road detection using fully convolutional neural networks. *Robotics and Autonomous Systems*, 111:125–131, 2019.
- [29] Liang Xiao, Ruili Wang, Bin Dai, Yuqiang Fang, Daxue Liu, and Tao Wu. Hybrid conditional random field based camera-lidar fusion for road detection. *Information Sciences*, 432:543–558, 2018.
- [30] Jakob Lombacher, Markus Hahn, Jürgen Dickmann, and Christian Wöhler. Potential of radar for static object classification using deep learning methods. In *Microwaves for Intelligent Mobility (ICMIM), 2016 IEEE MTT-S International Conference on*, pages 1–4. IEEE, 2016.
- [31] Christian Wöhler, Ole Schumann, Markus Hahn, and Jürgen Dickmann. Comparison of random forest and long short-term memory network performances in classification tasks using radar. In *Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, 2017, pages 1–6. IEEE, 2017.
- [32] Vladimir Lekic and Zdenka Babic. Automotive radar and camera fusion using generative adversarial networks. *Computer vision and image understanding*, 2019.
- [33] Marius Cordts, Mohamed Omran, Sebastian Ramos, Timo Rehfeld, Markus Enzweiler, Rodrigo Benenson, Uwe Franke, Stefan Roth, and Bernt Schiele. The cityscapes dataset for semantic urban scene understanding. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3213–3223, 2016.
- [34] Gerhard Neuhold, Tobias Ollmann, Samuel Rota Bulo, and Peter Kontschieder. The mapillary vistas dataset for semantic understanding of street scenes. In *ICCV*, pages 5000–5009, 2017.

BIBLIOGRAFIJA

- [35] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 248–255. Ieee, 2009.
- [36] Vladimir Lekić and Zdenka Babić. Multiphase tensor level-set method for segmentation of natural images. In *Image Processing and Communications Challenges 3*, pages 77–84. Springer, 2011.
- [37] Vladimir Lekić and Zdenka Babić. Neneta: Heterogeneous computing complex-valued neural network framework. In *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pages 192–196. IEEE, 2017.
- [38] Vladimir Lekić and Zdenka Babić. Using gans to enable semantic segmentation of ranging sensor data. In *2018 Zooming Innovation in Consumer Technologies Conference (ZINC)*, pages 96–99. IEEE, 2018.
- [39] Alexandru Constantin Serban, Erik Poll, and Joost Visser. A standard driven software architecture for fully autonomous vehicles. 2018.
- [40] Filip Ejodus. Međunarodna bezbednost: Teorije, sektori i nivoi. *Beograd: Službeni glasnik*, 2012.
- [41] G Fine Kinney and AD Wiruth. Practical risk analysis for safety management. Technical report, Naval Weapons Center China Lake Ca, 1976.
- [42] EN IEC. 61508 1-6: Funktionale sicherheit sicherheitsbezogenerelektrischer/elektronischer/programmierbarer elektronischer systeme, 2002.
- [43] ISO26262 ISO. 26262: Road vehicles-functional safety. *International Standard ISO/FDIS*, 26262, 2011.
- [44] Sébastien Christiaens, Juergen Ogrzewalla, and Stefan Pischinger. Functional safety for hybrid and electric vehicles. Technical report, SAE Technical Paper, 2012.
- [45] Markus Müller, Klaus Hörmann, Lars Dittmann, and Jörg Zimmer. *Automotive SPICE in der Praxis: Interpretationshilfe für Anwender und Assessoren*. dpunkt. verlag, 2012.
- [46] Rick Salay, Rodrigo Queiroz, and Krzysztof Czarnecki. An analysis of iso 26262: Using machine learning safely in automotive software. *arXiv preprint arXiv:1709.02435*, 2017.
- [47] Jens Henriksson, Markus Borg, and Cristofer Englund. Automotive safety and machine learning: Initial results from a study on how to adapt the iso 26262 safety standard. In *2018 IEEE/ACM 1st International Workshop on Software*

BIBLIOGRAFIJA

- Engineering for AI in Autonomous Systems (SEFAIAS)*, pages 47–49. IEEE, 2018.
- [48] Sina Shafaei, Stefan Kugele, Mohd Hafeez Osman, and Alois Knoll. Uncertainty in machine learning: A safety perspective on autonomous driving. In *International Conference on Computer Safety, Reliability, and Security*, pages 458–464. Springer, 2018.
 - [49] Rick Salay, Rodrigo Queiroz, and Krzysztof Czarnecki. An analysis of iso 26262: Machine learning and safety in automotive software. Technical report, SAE Technical Paper, 2018.
 - [50] Avrim Blum and Ronald L Rivest. Training a 3-node neural network is np-complete. In *Advances in neural information processing systems*, pages 494–501, 1989.
 - [51] Vladimir Vapnik. *The nature of statistical learning theory*. Springer science & business media, 2013.
 - [52] Ian Osband. Risk versus uncertainty in deep learning: Bayes, bootstrap and the dangers of dropout. In *NIPS Workshop on Bayesian Deep Learning*, 2016.
 - [53] Ian Osband, Charles Blundell, Alexander Pritzel, and Benjamin Van Roy. Deep exploration via bootstrapped dqn. In *Advances in neural information processing systems*, pages 4026–4034, 2016.
 - [54] Bryan C Russell, Antonio Torralba, Kevin P Murphy, and William T Freeman. Labelme: a database and web-based tool for image annotation. *International journal of computer vision*, 77(1-3):157–173, 2008.
 - [55] Alberto Elfes. Using occupancy grids for mobile robot perception and navigation. *Computer*, 22(6):46–57, 1989.
 - [56] Florian Homm, Nico Kaempchen, Jeff Ota, and Darius Burschka. Efficient occupancy grid computation on the gpu with lidar and radar for road boundary detection. In *Intelligent Vehicles Symposium (IV), 2010 IEEE*, pages 1006–1013. IEEE, 2010.
 - [57] W Xiao, B Vallet, Y Xiao, J Mills, and N Paparoditis. Occupancy modelling for moving object detection from lidar point clouds: A comparative study. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4, 2017.
 - [58] Daniel Pagac, Eduardo Mario Nebot, and Hugh Durrant-Whyte. An evidential approach to probabilistic map-building. In *Robotics and Automation, 1996. Proceedings., 1996 IEEE International Conference on*, volume 1, pages 745–750. IEEE, 1996.

BIBLIOGRAFIJA

- [59] Huadong Wu, Mel Siegel, Rainer Stiefelhagen, and Jie Yang. Sensor fusion using dempster-shafer theory [for context-aware hci]. In *Instrumentation and Measurement Technology Conference, 2002. IMTC/2002. Proceedings of the 19th IEEE*, volume 1, pages 7–12. IEEE, 2002.
- [60] Chunlei Yu, Véronique Cherfaoui, and Philippe Bonnifait. An evidential sensor model for velodyne scan grids. In *Control Automation Robotics & Vision (ICARCV), 2014 13th International Conference on*, pages 583–588. IEEE, 2014.
- [61] Mehdi Mirza and Simon Osindero. Conditional generative adversarial nets. *CoRR*, abs/1411.1784, 2014.
- [62] Vesna Marinkovic. *Racunarska grafika Uvod.* 2019.
- [63] Bernd Pfsmmer, Nitin Sanket, Kostas Daniilidis, and Jonas Cleveland. Penn-cosyvio: A challenging visual inertial odometry benchmark. In *2017 IEEE International Conference on Robotics and Automation, ICRA 2017, Singapore, Singapore, May 29 - June 3, 2017*, pages 3847–3854, 2017.
- [64] Davide Scaramuzza. *Omnidirectional Vision: From calibration to root motion estimation.* PhD thesis, ETH Zurich, 2007.
- [65] Davide Scaramuzza. Ocamcalib: Omnidirectional camera calibration toolbox for matlab. *Retrieved from the World Wide Web: http://robotics.ethz.ch/scaramuzza/Davide Scaramuzza files/Research/OcamCalib Tutorial.htm*, 2013.
- [66] Bolei Zhou, Hang Zhao, Xavier Puig, Sanja Fidler, Adela Barriuso, and Antonio Torralba. Scene parsing through ade20k dataset. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [67] Yann LeCun, Léon Bottou, Yoshua Bengio, Patrick Haffner, et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, 1998.
- [68] Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C Lawrence Zitnick. Microsoft coco: Common objects in context. In *European conference on computer vision*, pages 740–755. Springer, 2014.
- [69] Tim Salimans, Ian Goodfellow, Wojciech Zaremba, Vicki Cheung, Alec Radford, and Xi Chen. Improved techniques for training gans. In *Advances in Neural Information Processing Systems*, pages 2234–2242, 2016.
- [70] Martin Heusel, Hubert Ramsauer, Thomas Unterthiner, Bernhard Nessler, and Sepp Hochreiter. Gans trained by a two time-scale update rule converge to a local nash equilibrium. In *Advances in Neural Information Processing Systems*, pages 6626–6637, 2017.

BIBLIOGRAFIJA

- [71] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826, 2016.
- [72] Raimundo Real and Juan M Vargas. The probabilistic basis of jaccard’s index of similarity. *Systematic biology*, 45(3):380–385, 1996.
- [73] Mladen Nikolić and Andđelka Zečević. Mašinsko učenje. *Skripta, Univerzitet u Beogradu, Matematički fakultet*, 2019.
- [74] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In *Advances in neural information processing systems*, pages 2672–2680, 2014.
- [75] Ian J. Goodfellow. NIPS 2016 tutorial: Generative adversarial networks. *CoRR*, abs/1701.00160, 2017.
- [76] Roger B Myerson. *Game theory*. Harvard university press, 2013.
- [77] Martin Arjovsky, Soumith Chintala, and Léon Bottou. Wasserstein gan. *arXiv preprint arXiv:1701.07875*, 2017.
- [78] Alec Radford, Luke Metz, and Soumith Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. *CoRR*, abs/1511.06434, 2015.
- [79] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, 2015.
- [80] Bing Xu, Naiyan Wang, Tianqi Chen, and Mu Li. Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*, 2015.
- [81] Minhyeok Lee and Junhee Seok. Controllable generative adversarial network. *IEEE Access*, 7:28158–28169, 2019.
- [82] Grigorios G. Chrysos, Jean Kossaifi, and Stefanos Zafeiriou. Robust conditional generative adversarial networks. In *International Conference on Learning Representations (ICLR)*, 2019.
- [83] Michael Z Bell. Why expert systems fail. *Journal of the Operational Research Society*, 36(7):613–619, 1985.
- [84] Christopher M Bishop. *Pattern recognition and machine learning*. Springer, 2006.

BIBLIOGRAFIJA

- [85] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- [86] Claude E Shannon and Warren Weaver. The mathematical theory of communication (urbana, il, 1949).
- [87] Liam Paninski. Estimation of entropy and mutual information. *Neural computation*, 15(6):1191–1253, 2003.
- [88] Xi Chen, Yan Duan, Rein Houthooft, John Schulman, Ilya Sutskever, and Pieter Abbeel. Infogan: Interpretable representation learning by information maximizing generative adversarial nets. In *Advances in Neural Information Processing Systems*, pages 2172–2180, 2016.
- [89] Quan Hoang, Tu Dinh Nguyen, Trung Le, and Dinh Q. Phung. Multi-generator generative adversarial nets. *CoRR*, abs/1708.02556, 2017.
- [90] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, pages 807–814, 2010.
- [91] Andrew L Maas, Awni Y Hannun, and Andrew Y Ng. Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml*, volume 30, page 3, 2013.
- [92] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9, 2015.
- [93] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3431–3440, 2015.
- [94] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, and Jiaya Jia. Pyramid scene parsing network. In *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pages 2881–2890, 2017.
- [95] David J Triggle. The chemist as astronaut: searching for biologically useful space in the chemical universe. *Biochemical pharmacology*, 78(3):217–223, 2009.
- [96] Sabine Kubesch and Laura Walk. Körperliches und kognitives training exekutiver funktionen in kindergarten und schule. *Sportwissenschaft*, 39(4):309, 2009.

Biografija autora

Vladimir Lekić rođen je u Rijeci 3.12.1978. godine. Oženjen je i otac dvoje djece. Osnovne studio završio je 2003. godine na Elektrotehničkom fakultetu, Univerzitet u Banjoj Luci, na studijskom programu Elektronika i komunikacije. Tema njegovog diplomskog rada glasila je „Analiza i simulacija MPLS protokola“.

Po završetku osnovnih studija, Vladimir se zaposlio na radno mjestu „Viši stručni saradnik“ u IT odjelu *Nove banjalučke banke a.d.*. Na radnom mjestu „Tehnička podrška“ firme *Comverse Ltd.* proveo je od 2005. do 2007. godine te od 2008. do 2013. godine. Na radnom mjestu „Inženjer za razvoj“ firme *RLE International GmbH* proveo je 7 mjeseci 2008. godine.

Vladimir je magistrirao na temi „Nivo-skup metode za segmentaciju slika u boji“ 2012. godine na Elektrotehničkom fakultetu univerziteta u Banjoj Luci.

Na radnom mjestu „Expert“ u firmi *Elektrobit Automotive GmbH* Vladimir je zaposlen od 2013. do 2017. godine. Od 2017. do 2019. zaposlen je kao „Inženjer za istraživanje i razvoj“ u firmi *Mercedes-Benz Cars & Vans AG*. Od kraja 2019. godine do danas Vladimir je kao „Senior Data Scientist“ zaposlen u firmi *Boehringer Ingelheim GmbH*.

Vladimir je u toku naučno–istraživačkog rada na magistarskim i doktorskim studijim objavio nekoliko naučnih radova na međunarodnim naučnim konferencijama i časopisima.

Vladimir pored maternjeg srpskog, tečno govori njemački i engleski jezik.

Izjava 1

Izjava o autorstvu

Izjavljujem da je doktorska disertacija pod naslovom „Obrada signala senzora autonomnih vozila korišćenjem vještačkih neuronskih mreža“, naslov rada na engleskom jeziku „Highly-Automated-Vehicle Sensors Signal Processing Using Artificial Neural Networks“,

- rezultat sopstvenog istraživačkog rada,
- da doktorska disertacija, u cijelini ili u dijelovima, nije bila predložena za dobitanje bilo koje diplome prema studijskim programima drugih visokoškolskih ustanova,
- da su rezultati korektno navedeni i
- da nisam kršio autorska prava i koristio intelektualnu svojinu drugih lica.

U Banjoj Luci, 23. januara 2020.

Potpis doktoranta



Izjava 2

Izjava kojom se ovlašćuje Univerzitet u Banjoj Luci da doktorsku disertaciju učini javno dostupnom

Ovlašćujem Univerzitet u Banjoj Luci da moju doktorsku disertaciju pod naslovom „Obrada signala senzora autonomnih vozila korišćenjem vještačkih neuronskih mreža“, koja je moje autorsko djelo, učini javno dostupnom.

Doktorsku disertaciju sa svim prilozima predao sam u elektronskom formatu pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju pohranjenu u digitalni repozitorijum Univerziteta u Banjoj Luci mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (*Creative Commons*) za koju sam se odlučio.

- Autorstvo
- Autorstvo - nekomercijalno
- Autorstvo - nekomercijalno - bez prerade
- Autorstvo - nekomercijalno - dijeliti pod istim uslovima
- Autorstvo - bez prerade
- Autorstvo - dijeliti pod istim uslovima

U Banjoj Luci, 23. januara 2020.

Potpis doktoranta



Izjava 3

Izjava o identičnosti štampane i elektronske verzije doktorske disertacije

Ime i prezime autora **Vladimir Lekić**

Naslov rada **Obrada signala senzora autonomnih vozila
korišćenjem vještačkih neuronskih mreža**

Mentor **prof. dr. Zdenka Babić**

Izjavljujem da je štampana verzija moje doktorske disertacije identična elektronskoj verziji koju sam predao za digitalni repozitorijum Univerziteta u Banjoj Luci.

U Banjoj Luci, 23. januara 2020.

Potpis doktoranta

