

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

SEMINAR

**Raspoznavanje prometnih znakova korištenjem
modela konvolucijskih neuronskih mreža**

Pavo Matanović

Voditelj: *Siniša Šegvić*

Zagreb, travanj, 2019.

Sadržaj

1.	Uvod.....	1
2.	Osnove strojnog učenja.....	2
2.1	Prednosti konvolucijskog modela u klasifikaciji slika	2
3.	Unaprijedne neuronske mreže	3
3.1	Struktura konvolucijskih neuronskih mreža	3
3.1.1	Konvolucijski sloj.....	4
3.1.2	Sloj sažimanja	5
3.1.3	Klasifikator.....	5
4.	Primjeri arhitektura	6
4.1	MNIST	6
4.2	FER-MASTIF TS2010	7
4.3	GTSRB.....	8
5.	Treniranje CNNa	10
5.1	Povećanje skupa uzoraka	10
5.2	Normalizacija	10
5.3	Kombiniranje klasifikatora	10
6.	Zaključak	11
7.	Sažetak	12
8.	Literatura	13

1. Uvod

Ovaj seminarski rad bavi se problemom raspoznavanja prometnih znakova. U današnje vrijeme sve veću popularnost dobivaju autonomna vozila koja velika poduzeća automobilske industrije pokušavaju prilagoditi i omogućiti im širu upotrebu. Takva vozila se moraju oslanjati na kompjuterski vid, kako za lociranje bitnih objekata prilikom vožnje, tako i za raspoznavanje istih. Osim u autonomnim vozilima raspoznavanje prometnih znakova primjenjivo i u osobnim automobilima kao proširenje funkcionalnosti i poboljšanje sigurnosti u cestovnom prometu. Npr. Automobil može prepoznati znak za ograničenje brzine i limitirati vozaču maksimalnu brzinu vožnje ili prepoznati znak za oštri zavoj pa usporiti automobil ako vozač ulazi u zavoj s prevelikom brzinom.

Problemu raspoznavanja prometnih znakova u ovom radu pristupit ćemo korištenjem dubokih neuronskih mreža. Duboke neuronske mreže [vukotic14ms] postižu najbolje rezultate jer se značajke u potpunosti uče automatski nad skupom uzoraka i odlično su prilagođene određenom problemu za kojeg su trenirane.

Najčešće korišten model dubokih neuronskih mreža u području računalnogvida su konvolucijske neuronske mreže (engl. *Convolutional neural network – CNN*).

2. Osnove strojnog učenja

Strojno učenje je algoritam koji uči na osnovu podataka, odnosno prethodnog iskustva. U [Mitchell1997] daje se definicija: „Za računalni program kažemo da uči iz iskustva E u odnosu na klasu zadataka T i mjere učinkovitosti P, ako se njegova učinkovitost u zadacima iz T, mjerena s P, poboljšava s iskustvom E.“

Algoritam strojnog učenja definiran je:

- **Modelom:** postupak obrade podataka primijenjen na neki od zadataka iz T, npr. Klasifikacija slike, regresija, transkripcija ili translacija jezika
- **Gubitkom:** mjera učinka ili mjera pogreške (P), kriterij za optimizaciju slobodnih parametara
- **Metodom optimizacije**(načinom učenja): način pronalaženja parametara koji minimiziraju pogrešku(tj. maksimiziraju učinkovitost), npr. Metoda gradijentnog spusta

S obzirom na skup dostupnih podataka za učenje razlikujemo:

- **Nadzirano** učenje: svaki podatak ima dostupan željeni izlaz, analizira se u ovom seminaru, tipični primjeri: *klasifikacija, regresija*
- **Nenadzirano** učenje: dostupni samo podaci bez željenih izlaza, tipični primjeri: *grupiranje, smanjenje dimenzionalnosti*
- **Podržano** učenje: dostupna je povratna informacija o kvaliteti naučenog

Kapacitet modela je sposobnost prilagođavanja podatcima i obično je proporcionalan broju stupnjeva slobode modela. Modeli s malim kapacitetom mogu dovesti do podnaučenosti, dok modeli s prevelikim kapacitetom mogu dovesti do prenaučenosti. Optimalna vrijednost kapaciteta ovisi o složenosti zadatka za koji je model namijenjen i o količini podataka koji su dostupni za treniranje.

2.1 Prednosti konvolucijskog modela u klasifikaciji slika

Duboki modeli su korisni za prepoznavanje objekata koji su kompozicija značajki kroz više razina hijerarhije. (Osoba ima glavu, glava ima lice, lice ima nos)

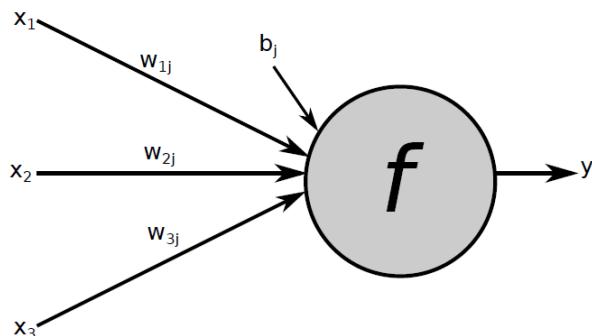
Potpuno povezani modeli prilikom prepoznavanja takvih objekata imaju sklonost da nauče šum jer svaki izlaz neurona ovisi o svim pikselima na ulazu. Korisne značajke su lokalnog karaktera pa će potpuno povezani sloj u tom slučaju imati beskorisne informacije o ostalim pikselima i uz oblik značajke naučiti će i poziciju objekta unutar slike. S obzirom na to da u konvolucijskom modelu izlaz neurona ovisi o manjem dijelu ulaza, značajke su lokalizirane i time se postiže ekvivariantnost na pomak. Model će percipirati lokalnu značajku dok god je cijela na ulazu. Ako translatiramo sliku, konvolucijski model neće imati problema u prepoznavanju značajke za razliku od potpuno povezanog modela.

Također, zbog razmatranja samo lokalnih interakcija i zbog raspršene povezanosti, konvolucijski modeli imaju manji broj parametara od potpuno povezanih modela. Potrebno je naučiti manje parametara, dok zadržavamo istu količinu informacije (označenih podataka). To rezultira jednostavnijim izračunom modela i smanjenjem vremena potrebnog za treniranje.

3. Unaprijedne neuronske mreže

Klasične unaprijedne neuronske mreže organizirane su kao slijed potpuno povezanih slojeva. Svaki sloj sastoji se od skalarnih aktivacija koje možemo zvati i umjetnim neuronima. Broj neurona u ulaznom sloju jednak je dimenzionalnosti uzorka, a broj neurona na izlazu jednak je broju klasa koje model raspoznaće. Broj skrivenih slojeva i neurona unutar njih je proizvoljan, međutim dobar odabir parametara može utjecati na postizanje boljih rezultata klasifikacije.

Neuron (Slika 3.1) se sastoji od aktivacijske funkcije, jednog ili više ulaza, jednog izlaza i, neobavezno, praga.



Slika 3.1 Model neurona [vukotic14ms]

Izlaz jednog neurona jednak je:

$$y_i = \sum_j f(w_{ij}x_j + b_j) \quad (1)$$

Radi lakšeg baratanja, često se ulaz predstavlja u obliku vektora \mathbf{x} , a težine u obliku matrice \mathbf{W} koja je proširena nultim retkom u kojem se nalazi vrijednost praga. Takvom reprezentacijom možemo jedan prolaz naprijed računati formulom (2) [vukotic14ms]. U višim programskim jezicima postoje funkcije za rad s matricama koje omogućuju paralelizaciju i time ubrzavaju računanje izlaza, a posljedično i vrijeme učenja CNN.

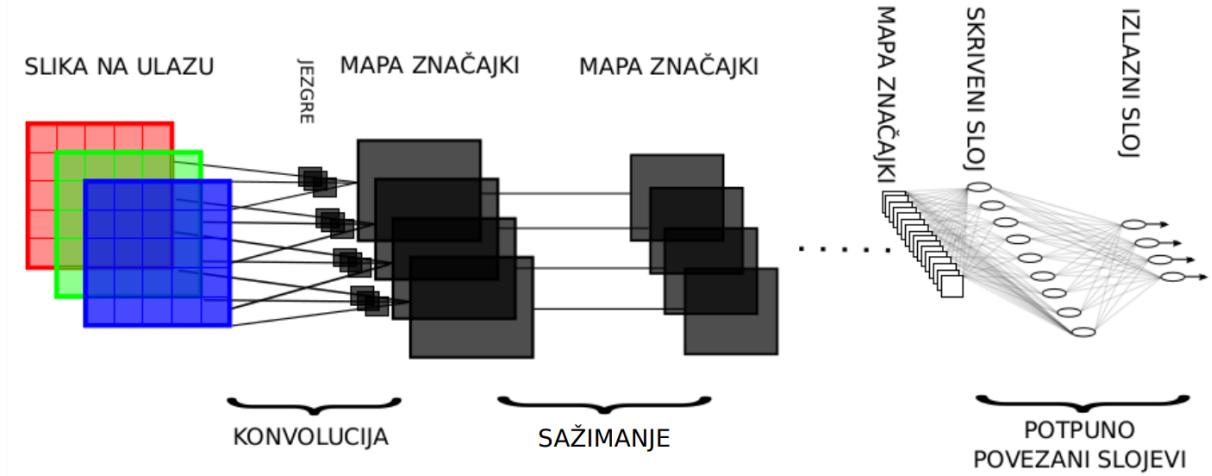
$$\vec{y} = f(\mathbf{W} \cdot \mathbf{x}) \quad (2)$$

3.1 Struktura konvolucijskih neuronskih mreža

Za razliku od potpuno povezanih slojeva, aktivacije u konvolucijskim slojevima su organizirane u obliku 3D tenzora koji su organizirani kao "snop" matrica koje nazivamo mapama značajki. Slika 3.2 prikazuje da konvolucijske aktivacije reagiraju samo na sitno lokalno susjedstvo u prethodnom sloju, za razliku od aktivacija u potpuno povezanim slojevima koje na ulazu primaju cijeli prethodni sloj.

Druga razlika u odnosu na potpuno povezane slojeve jest u tome da konvolucijske aktivacije iz iste mape značajki koriste isti skup težina. Na ulaz konvolucijskog

modela se dovodi monokromatska ili višekanalna slika u boji. Ulazna slika se dalje propušta kroz konvolucijske slojeve i slojeve sažimanja naizmjence. CNN tipično imaju po desetak slojeva [vukotic14ms]. Propuštanjem kroz konvolucijske slojeve i slojeve sažimanja smanjuje se dimenzionalnost slike (do veličine 1x1), te se izlazi dalje spajaju na klasifikator. Klasifikator se sastoji od potpuno povezanih slojeva. Konvolucijski slojevi „sposobni“ su za učenje dok slojevi sažimanja služe samo za smanjivanje dimenzija tenzora.



Slika 3.2 Opća struktura CNN-a [vukotic14ms]

3.1.1 Konvolucijski sloj

Konvolucijski sloj je definiran sljedećim hiperparametrima: brojem i veličinom mapa značajki, veličinom jezgre i korakom pomaka jezgre. Broj i veličina mapa značajki se postavlja validacijom, dok veličina jezgre ovisi o veličini ulaznog signala. Manja jezgra ima manje receptivno polje i bolje se fokusira na sitne detalje. To uzrokuje veću dubinu mreže i potrebu za velikom količinom memorije, ali je efikasnija za izračun. Za velike slike na ulazu uz manju jezgru mreži se jako sporo smanjuje dimenzionalnost i zahtjeva veliku količinu radne memorije, dok sitni detalji možda i nisu toliko relevantni za klasifikaciju. Tipično se veličina jezgre smanjuje s dubinom sloja, u prvom konvolucijskom sloju je veća nego u kasnijim. Pri tome treba paziti da se dimenzije jezgre ne smanje prenaglo kako ne bi izgubili neku bitnu informaciju. Korak pomaka se, radi jednostavnosti, najčešće postavlja na 1 [vukotic14ms].

Kako bi poboljšali učinkovitost klasifikacije, za izračun svake konvolucije jedne ulazne mape s izlaznom mapom koristi se ista jezgra. Bez dijeljenja težina postoji mogućnost prenaučenosti mreže na određeni detalj.

Najčešće korištene veličine jezgri su 3x3 ([vukotic14ms] za FER-MASTIF TS2010 i [ciresan2011] za GTSRB), 5x5 ([vukotic14ms] za MNIST), i 7x7 ([vukotic14ms] za FER-MASTIF TS2010). Ali [vukotic14ms] i [ciresan2011] koriste još i jezgru veličine 4x4 u srednjim slojevima.

3.1.2 Sloj sažimanja

Sloj sažimanja (engl. *pooling*) grupira značajke i smanjuje rezoluciju mapi značajki. Sloj sažimanja povećava prostornu invarijantnost, tj. neosjetljivost na male pomake značajki na slici.

Sažimanje se radi tako da se vrijednosti unutar pravokutnika veličine prozora sloja sažimanja predstavljaju jednom vrijednošću, pri čemu se pravokutnici ne preklapaju. Tipične veličine prozora sažimanja su 2×2 [vukotic14ccvw], [ciresan2011] i 4×4 [sermanet11].

Postoji nekoliko tehnika sažimanja: sažimanje usrednjavanjem, sažimanje maksimalnom vrijednošću (korišteno u [vukotic14ms] i [ciresan2011]) i nešto naprednije tehnike sažimanja Gaussovim usrednjavanjem te sažimanje metrikom Lp.

3.1.3 Klasifikator

Nakon što se slika reducira (prolaskom kroz konvolucijske slojeve i slojeve sažimanja) na veličinu 1×1 , taj sloj se dalje spaja na klasifikator. U krajnjim slojevima se obično koristi jedan ili više potpuno povezanih slojeva koji provode klasifikaciju [vukotic14ccvw] [ciresan2011]. U [sermanet11] se na ulaz klasifikatora, osim izlaza iz zadnjeg konvolucijskog sloja, dovodi i izlaz nakon prve konvolucije i sažimanja. Tako se postiže da klasifikator ne razmatra samo krupne (globalne) karakteristike, koje su invarijantne, nego i sitnije detalje.

4. Primjeri arhitektura

Ovisno o tipu problema, veličini ulaznih i izlaznih podataka neuronske mreže se konstruiraju s različitim hiperparametrima. Ne postoji univerzalna teorija koja određuje optimalnu vrijednost hiperparametara. Vrijednosti se određuju empirijski i prilagođene su problemu kojemu su modeli namijenjeni. Najčešće se hiperparametri određuju iscrpnom ili slučajnom pretragom na validacijskom skupu.

Ovdje se navode primjeri arhitektura izgrađene za skupove MNIST, FER-MASTIF TS2010 i GTSRB. Skup MNIST je skup rukom pisanih znamenki i nije direktno povezan s klasifikacijom prometnih znakova, ali se analizira kao standardni test arhitekture CNN za klasifikacijske probleme.

4.1 MNIST

U [vukotic14ms] za MNIST skup koristi se sljedeća arhitektura:

Tablica 4-1 Arhitektura [vukotic14ms] za skup MNIST

Sloj	Tip sloja	Broj mapa i neurona	Jezgra
0	Ulazni sloj	1 mapa veličine 32x32	
1	Konvolucijski sloj	6 mapi veličine 28x28	5x5
2	Sloj sažimanja	6 mapi veličine 14x14	2x2
3	Konvolucijski sloj	16 mapi veličine 10x10	5x5
4	Sloj sažimanja	16 mapi veličine 5x5	2x2
5	Konvolucijski sloj	100 mapi veličine 1x1	5x5
6	Skriveni sloj	80 neurona	
7	Izlazni sloj	10 neurona	

Arhitektura je trenirana u 10 epoha po 60 000 iteracija, a zatim ispitana na skupu od 10 000 uzoraka (10 klasa x 1000 uzoraka). Mreža postiže uspješnost od 98.67%. Detaljniji rezultati se mogu analizirati matricom zabune u tablici 4-2.

Tablica 4-2 Matrica zabune na ispitnom skupu MNIST [vukotic14ms]

		Predviđena klasa									
		0	1	2	3	4	5	6	7	8	9
Stvarna klasa	0	973	0	1	0	0	0	3	1	2	0
	1	0	1127	4	1	0	0	1	0	2	0
	2	3	0	1020	0	0	0	0	4	5	0
	3	0	0	2	992	0	6	0	3	5	2
	4	1	0	1	0	963	0	4	0	2	11
	5	1	0	0	3	0	884	1	1	0	2
	6	10	2	0	0	1	2	943	0	0	0
	7	0	1	7	2	0	0	0	1014	1	3
	8	2	0	1	0	1	1	1	3	962	3
	9	3	2	0	3	1	3	1	4	3	989

Iz tablice 4-2 vide se najčešće greške: broj 4 klasificiran kao broj 9 (11 puta), broj 6 klasificiran kao 0 (10 puta), broj 7 klasificiran kao broj 2 (7 puta).

Uzorci koji su pogrešno klasificirani su dosta slični predviđanjima mreže, ali ljudsko oko ih može ispravno klasificirati.

4.2 FER-MASTIF TS2010

U [vukotic14ms] za FER-MASTIF TS2010 skup koristi se sljedeća arhitektura:

Tablica 4-3 Arhitektura [vukotic14ms] za skup FER-MASTIF TS2010

Sloj	Tip sloja	Broj mapa i neurona	Jezgra
0	Ulazni sloj	3 mape veličine 48x48	
1	Konvolucijski sloj	10 mapi veličine 42x42	7x7
2	Sloj sažimanja	10 mapi veličine 21x21	2x2
3	Konvolucijski sloj	15 mapi veličine 18x18	4x4
4	Sloj sažimanja	15 mapi veličine 9x9	2x2
5	Konvolucijski sloj	20 mapi veličine 6x6	4x4
6	Sloj sažimanja	20 mapi veličine 3x3	2x2
7	Konvolucijski sloj	40 mapi veličine 1x1	3x3
8	Skriveni sloj	80 neurona	
9	Izlazni sloj	9 neurona	

Arhitektura je trenirana u 12 epoha po 4 500 iteracija, a zatim ispitana na skupu od 900 uzoraka (9 klasa x 100 uzoraka). Model postiže uspješnost od 98.22%. Detaljniji rezultati se mogu analizirati matricom zabune u tablici 4-4.

Iz tablice 4-4 vide se najčešće greške: znak A03 klasificiran kao A05 (7 puta), znak A03 klasificiran kao A04 (3 puta), znak B32 klasificiran kao A33 (3 puta).

Prve dvije greške se čine logične, dok je treća neočekivana. Međutim greške su nastale kod tamnih uzoraka s lošim kontrastom. [vukotic14ms]

Tablica 4-4 Matrica zabune na ispitnom skupu FER-MASTIF TS2010 [vukotic14ms]

		Predviđena klasa									
		Pre	Al	Re	Ro	Re	Ro	60	Re	Ro	Ro
Stvarna klasa	C02		100	0	0	0	0	0	0	0	0
	A04		0	99	0	0	0	0	1	0	0
	B32		0	0	97	3	0	0	0	0	0
	A33		0	0	0	100	0	0	0	0	0
	C11		0	0	0	0	100	0	0	0	0
	B31		0	0	0	0	0	100	0	0	0
	A05		0	0	0	0	0	0	98	0	2
	B46		0	0	0	0	0	0	0	100	0
	A03		0	3	0	0	0	0	7	0	90

4.3 GTSRB

U [ciresan2011] za GTSRB skup koristi se sljedeća arhitektura:

Tablica 4-5 Arhitektura [ciresan2011] za skup GTSRB

Layer	Type	# maps & neurons	kernel
0	input	1 or 3 maps of 48x48 neurons	
1	convolutional	100 maps of 46x46 neurons	3x3
2	max pooling	100 maps of 23x23 neurons	2x2
3	convolutional	150 maps of 20x20 neurons	4x4
4	max pooling	150 maps of 10x10 neurons	2x2
5	convolutional	250 maps of 8x8 neurons	3x3
6	max pooling	250 maps of 4x4 neurons	2x2
7	fully connected	200 neurons	
8	fully connected	43 neurons	

U tom radu autor je testirao kako utječu normalizacija kontrasta uzoraka u skupu za treniranje i slučajne ali ograničene transformacije na uspješnost klasifikacije.

Korištene su 3 normalizacije kontrasta: pikseli svih kanala slike su linearno skalirani na plus-minus 1 i 2 puta standardne devijacije prosječnog intenziteta piksela te korištenjem CLAHE normalizacije. To je testirano na crno-bijelim slikama i slikama u boji. Rezultati za crno-bijele slike su dani u tablici 4-6, a za slike u boji u tablici 4-7.

Tablica 4-6 Rezultati [ciresan2011] na GTSRB skupu za crno-bijele slike

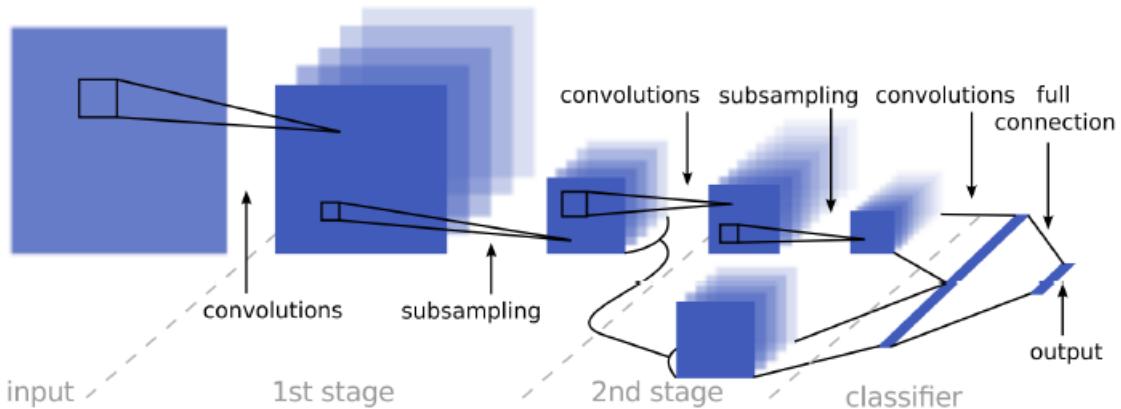
Deformation			Test error rate[%]				
T[%]	S[%]	R[°]	no	$\pm 1\sigma$	$\pm 2\sigma$	ClaHE	
0	0	0	3.43	3.65	3.18	2.73	
5	0	0	2.28	2.32	1.79	1.77	
5	10	10	2.10	2.42	1.82	1.53	
10	5	5	2.13	1.97	1.74	1.55	
10	10	10	1.79	2.02	1.42	1.36	

Tablica 4-7 Rezultati [ciresan2011] na GTSRB skupu za slike u boji

Deformation			Test error rate[%]				
T[%]	S[%]	R[°]	no	$\pm 1\sigma$	$\pm 2\sigma$	ClaHE	
0	0	0	2.83	2.98	2.78	2.32	
5	0	0	1.76	2.11	1.91	1.42	
5	10	10	1.41	1.99	1.61	1.86	
10	5	5	1.88	1.80	1.85	1.42	
10	10	10	1.66	1.88	1.58	1.27	

Najbolji rezultati se postižu CLAHE normalizacijom, uz najveću ogragu na slučajne transformacije. Usporedbom tablica 4-6 i 4-7 vidimo da veću uspješnost ima klasifikacija slika u boji.

U [sermanet11] koristi se arhitektura prikazana na slici 4.1:



Slika 4.1 Struktura [sermanet11] arhitekture za skup GTSRB

Ova arhitektura razlikuje se od gore navedenih jer osim zadnjeg konvolucijskog sloja, u klasifikator se ubacuje i izlaz konvolucije prvog sloja, ali s dodatnim sažimanjem. Ovakva arhitektura pokazala je rezultat klasifikacije od 98.97% na crno-bijelim slikama.

5. Treniranje CNN-a

Prije treniranja konvolucijskih neuronskih mreža potrebno je prikupiti podatke i obraditi ih. Podatke je zatim potrebno podijeliti na skup za učenje i skup za testiranje. Prilikom treniranja postoji opasnost da se mreža previše prilagodi skupu za učenje, tj. postane „prenaučena“. To uzrokuje lošu klasifikaciju do sad neviđenih objekata i kažemo da mreža loše generalizira.

Problem loše klasifikacije moguće je riješiti na više načina: normalizacijama, povećanjem skupa uzoraka, kombiniranjem više klasifikatora i drugih metoda.

5.1 Povećanje skupa uzoraka

Povećanje skupa uzoraka za učenje može se riješiti skupljanjem dodatnih uzoraka. Takav pristup može biti vremenski i novčano skup.

Bolji pristup, bez dodatnih troškova, temelji se na slučajnim transformacijama skupa uzoraka (najčešće translacija, rotacija i skaliranje).

Slučajne transformacije moguće je izvoditi na dva načina:

- **Tijekom svake iteracije** (engl. *online*) – na ulaz u mrežu postavi se predsloj koji transformira originalni uzorak te ga dalje proslijedi na prvi sloj CNN-a. Ovakav pristup može generirati proizvoljan broj transformiranih ulaza i neovisan je o skupu (dio je mreže). Mogući problemi su pojavljivanje istih uzoraka ako ih se generira puno više nego što je originalnih i potreba za spremanjem slika u većim dimenzijama nego što je ulaz u mrežu jer bi izrezivanjem nastali nedefinirani pikseli pozadine i loše utjecali na klasifikaciju.
- **Predobradom podataka** – Na svaki se uzorak apliciraju slučajne transformacije i spremaju se novi uzorci. Prednosti ovog pristupa su brže učenje (nema dodatnog procesiranja prije učenja) i lakše spremanje uzoraka. Kada se ovim postupkom znatno poveća broj uzoraka s obzirom na početni skup, mreža se ponaša skoro kao i „online“ pristupu.

5.2 Normalizacija

U [ciresan2011] i [sermanet11] koristi se normalizacija kontrasta na slikama. Normalizacija kontrasta može biti globalna ili lokalna. Globalna centririra sliku oko srednje vrijednosti, dok lokalna normalizacija naglašava rubove. U [ciresan2011] koristi se globalna normalizacija vrijednosti piksela tako da se oni linearno skaliraju prvo na granice ± 1 standardne devijacije oko srednje vrijednosti zatim na granice ± 2 standardne devijacije oko srednje vrijednosti. Također koristi se CLAHE (skr. engl. *Contrast-limited Adaptive Histogram Equalization*) normalizacija koja je lokalnog karaktera i koristi se radi naglašavanja rubova.

5.3 Kombiniranje klasifikatora

U [ciresan2011] kombiniraju se izlazi CNN i MLP tako da se uzme srednja vrijednost izlaza. Takva kombinacija klasifikatora postiže uspješnost od 99.15%.

6. Zaključak

Duboke neuronske mreže postižu dobre rezultate u klasifikacijskim problemima. Za klasifikaciju objekata koji su kompozicija sitnijih značajki, posebno se ističu konvolucijske neuronske mreže.

Rezultati klasifikacije prometnih znakova su 98 – 99%, dok je prema [sermanet11] ljudska uspješnost u klasifikaciji 98.81%. Ovdje vidimo da konvolucijske neuronske mreže mogu klasificirati prometne znakove jednako dobro kao i ljudi, dok se u [sermanet11] i [ciresan2011] postiže klasifikacija bolja od ljudske uspješnosti.

Najbolju uspješnost od 99.15% na skupu GTSRB doseže kombinacija CNN i MLP u [ciresan2011] zbog različitih priroda klasifikacije. CNN se trenira samo na vrijednostima intenziteta piksela dok se MLP trenira na opisima značajki i međusobno si pružaju komplementarne informacije čime postižu veću uspješnost u kombinaciji nego pojedinačno.

Na skupu FER-MASTIF TS2010 postiže se uspješnost od 98.22%. Treba imati u vidu da se radilo o jednostavnijem modelu bez puno naprednih metoda klasifikacije. Rezultati su u velikoj mjeri bili u skladu s očekivanjima, međutim javila jedna neobičnost prilikom klasifikacije. Uzrok tomu je dosta malen broj uzoraka i loš kontrast na krivo klasificiranim uzorcima.

7. Sažetak

U ovom radu ugrubo su objašnjeni osnovni pojmovi strojnog učenja. Diskutirane su prednosti konvolucijskih neuronskih mreža u klasifikaciji slika. Pokazana je struktura konvolucijskih neuronskih mreža. Kratko je opisana svaka sastavnica CNNa. Pokazani primjeri arhitektura iz literature. Analizirani rezultati klasifikacije na skupovima MNIST, FER-MASTIF TS2010 i GTSRB. Opisani načini poboljšanja klasifikacije slučajnim transformacijama skupova i normalizacijom ulaznih uzoraka.

8. Literatura

- [vukotic14ccvw] V. Vukotić, J. Krapac, S. Šegvić. Convolutional Neural Networks for Croatian Traffic Signs Recognition. *Proceedings of the Croatian Compter Vision Workshop 2014*, Zagreb, stranice 15-20, 2014.
- [vukotic14ms] V. Vukotić. Raspoznavanje objekata dubokim neuronskim mrežama. Diplomski rad. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 2014.
- [ciresan2011] D. Ciresan, U. Meier, J. Masci, J. Schmidhuber. A Committee of Neural Networks for Traffic Sign Classification. *International Joint Conference on Neural Networks*, California, USA, 2011.
- [sermanet11] P. Sermanet, Y. LeCun. Traffic Sign Recognition with Multi-Scale Convolutional Networks. *Proceedings of International Joint Conference on Neural Networks*, California, USA, 2011.
- [Mitchell1997] Mitchell, T. M. Machine Learning. McGraw-Hill, New York, 1997.