

# Performanse konvolucijskih neuronskih mreža na prometnim znakovima zemalja Europe

---

**Mažar, Krešimir**

**Master's thesis / Diplomski rad**

**2023**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Pula / Sveučilište Jurja Dobrile u Puli**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:137:735594>

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

*Download date / Datum preuzimanja:* **2024-11-27**



*Repository / Repozitorij:*

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli

Fakultet informatike u Puli

**KREŠIMIR MAŽAR**

**PERFORMANSE KONVOLUCIJSKIH NEURONSKIH MREŽA NA PROMETNIM  
ZNAKOVIMA ZEMALJA EUROPE**

Diplomski rad

Pula, rujan, 2023.

Sveučilište Jurja Dobrile u Puli

Fakultet informatike u Puli

**KREŠIMIR MAŽAR**

**PERFORMANSE KONVOLUCIJSKIH NEURONSKIH MREŽA NA PROMETNIM  
ZNAKOVIMA ZEMALJA EUROPE**

Diplomski rad

**JMBAG: 0016102024, redoviti student**

**Studijski smjer: Informatika**

**Predmet: Neuronske mreže i duboko učenje**

**Znanstveno područje: Društvene znanosti**

**Znanstveno polje: Informacijske i komunikacijske znanosti**

**Znanstvena grana: Informacijski sustavi i informatologija**

**Mentor: doc.dr.sc. Goran Oreški**

Pula, rujan, 2023.



## IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Krešimir Mažar, kandidat za magistra Informatike ovime izjavljujem da je ovaj Diplomski rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

Mažar

U Puli, rujan, 2023. godine



## **IZJAVA o korištenju autorskog djela**

Ja, Krešimir Mažar dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom „Performanse konvolucijskih neuronskih mreža na prometnim znakovima zemalja Europe“ koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, rujan, 2023. godine

Potpis

Mažar

# PERFORMANSE KONVOLUCIJSKIH NEURONSKIH MREŽA NA PROMETNIM ZNAKOVIMA ZEMALJA EUROPE

Krešimir Mažar

## Sažetak:

Ovaj rad se fokusira na analizu performansi konvolucijskih neuronskih mreža (CNN) na podacima prometnih znakova zemalja Europe. Specifično, istraživanje koristi trening skup podataka prometnih znakova jedne države i test skup podataka na drugim državama. Cilj istraživanja je procijeniti sposobnost generalizacije CNN modela pri klasifikaciji i prepoznavanju prometnih znakova različitih europskih zemalja. U radu se detaljno opisuje prikupljanje i pretprocesiranje podataka, izgradnja i treniranje CNN modela te evaluacija performansi modela kroz različite metrike. Rezultati ovog istraživanja pružaju uvid u transferabilnost CNN modela na različite zemlje prometnih znakova te ukazuju na mogućnosti primjene takvih modela u stvarnim uvjetima prometne signalizacije.

Ključne riječi: konvolucijske neuronske mreže, tensorflow, keras, klasifikacija znakova

# CONVOLUTIONAL NEURAL NETWORKS PERFORMANCE ON TRAFFIC SIGNS OF EUROPEAN COUNTRIES

Krešimir Mažar

## Abstract:

This study focuses on analyzing the performance of Convolutional Neural Networks (CNNs) on traffic sign data from European countries. Specifically, the research utilizes a training dataset consisting of traffic signs from one country and a separate test dataset containing traffic signs from other countries. The objective is to evaluate the generalization ability of CNN models in classifying and recognizing traffic signs from different European countries. The paper provides detailed descriptions of data collection, preprocessing, CNN model construction and training, and performance evaluation using various metrics. The results of this study offer insights into the transferability of CNN models across different traffic sign datasets and highlight the potential applications of such models in real-world traffic signaling scenarios.

Keywords: Convolutional Neural Networks, TensorFlow, Keras, traffic sign classification.

# Sadržaj

1. Uvod .....	2
2. Konvolucijske neuronske mreže .....	3
2.1. Konvolucijski sloj.....	3
2.2. Sloj grupiranja .....	4
2.3. Potpuno povezani sloj.....	5
2.4 Aktivacijske Funkcije.....	6
2.4.1 Sigmoid aktivacijska funkcija.....	6
2.4.2 Tanh aktivacijska funkcija .....	7
2.4.3 ReLU aktivacijska funkcija .....	8
2.4.4 Leaky ReLU aktivacijska funkcija .....	9
2.4.5 ELU aktivacijska funkcija.....	10
2.4.6 SELU aktivacijska funkcija .....	11
2.4.7 Softmax aktivacijska funkcija .....	12
2.5. Regularizacija .....	13
2.6 Funkcija gubitka .....	14
3. Dataset .....	15
4. Praktični rad .....	18
4.1. Opis problema .....	18
4.2. Prikupljanje i analiza podataka .....	18
4.3. Modeliranje i treniranje .....	23
4.4 Rezultati .....	26
4.4.1. Rezultati Njemačka .....	26
4.4.2. Rezultati Hrvatska .....	29
4.4.3. Rezultati Belgija.....	32
4.4.4. Rezultati Francuska.....	36
4.4.5. Rezultati Švedska.....	40
5. Analiza rezultata.....	44
5.1. Analiza rezultata Njemačka.....	45
5.2. Analiza rezultata Hrvatska .....	46
5.3. Analiza rezultata Belgija .....	47
5.4. Analiza rezultata Francuska.....	49
5.5. Analiza rezultata Švedska .....	50
6. Zaključak .....	52
7. Literatura .....	53
8. Popis slika .....	56
9. Popis tablica .....	57



# 1. Uvod

Autonomna vozila predstavljaju inovativnu tehnologiju koja obećava revoluciju u području prometa i mobilnosti. Jedan od ključnih izazova u razvoju autonomnih vozila je njihova sposobnost prepoznavanja i interpretiranja prometnih znakova kako bi sigurno i učinkovito navigirala cestama. Konvolucijske neuronske mreže (CNN) su se pokazale iznimno uspješnima u rješavanju problema prepoznavanja slika, uključujući prepoznavanje prometnih znakova.

Cilj ovog istraživanja je analizirati performanse konvolucijskih neuronskih mreža na prepoznavanju prometnih znakova zemalja Europe. U istraživanju se koristi Europski dataset koji se sastoji od znakova iz Hrvatske, Njemačke, Francuske, Švedske, Belgije i Nizozemske. Specifično, fokusiramo se na trening mreže na uzorku podataka iz jedne države, dok se testiranje provodi na prometnim znakovima iz drugih država Europe. Ideja je istražiti kako će se model generalizirati i kako će se ponašati na znakovima koji se razlikuju u obliku, boji, teksturi i drugim karakteristikama.

Ključni faktor koji će se evaluirati je točnost prepoznavanja prometnih znakova. Visoka točnost ukazuje na sposobnost modela da pravilno klasificira različite vrste znakova, čime se osigurava sigurnost i pouzdanost autonomnih vozila u interpretiranju cestovnih znakova.

Ovo istraživanje može pružiti uvid u performanse konvolucijskih neuronskih mreža na prometnim znakovima različitih zemalja Europe. Rezultati mogu pomoći u razumijevanju različitih izazova s kojima se autonomna vozila mogu suočiti u prepoznavanju prometnih znakova iz različitih kulturnih i geografskih konteksta.

## 2. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (CNN) su posebna vrsta neuronskih mreža s jednosmjernim prijenosom (eng. Feedforward). Slične su neuronskim mrežama u smislu da se sastoje od neurona s prilagodljivim težinama (eng. weights) i pristranostima (eng. bias) i pomacima (engl. stride). Osnovna razlika je što CNN arhitektura implicitno pretpostavlja da su ulazi slični slikama, što nam omogućuje kodiranje određenih svojstava u arhitekturi. Konvolucije posebno hvataju invarijantnost translacije (tj. filtri su neovisni o lokaciji). To pak čini funkciju prosljeđivanja učinkovitijom, znatno smanjuje broj parametara i olakšava optimizaciju mreže, s manjom ovisnošću o veličini podataka. Za razliku od redovitih neuronskih mreža, slojevi CNN-a imaju neurone raspoređene u nekoliko dimenzija: kanale, širinu, visinu i broj filtera u najjednostavnijem slučaju 2D-a. Konvolucijska neuronska mreža se sastoji, kao i MLP, od niza slojeva, gdje svaki sloj transformira aktivacije ili izlaze prethodnog sloja pomoću druge diferencijabilne funkcije. Postoji nekoliko takvih slojeva koji se koriste u CNN-ima, a bit će objašnjeni u kasnijim dijelovima, međutim, najčešći građevni blokovi s kojima ćete se susresti u većini arhitektura CNN-a su: konvolucijski sloj (eng. convolution layer), sloj grupiranja (pooling layer) i potpuno povezani slojevi (eng. fully connected layers). U osnovi, ovi slojevi djeluju kao ekstraktori značajki, slojevi za smanjenje dimenzionalnosti i klasifikaciju. Ti slojevi se slažu kako bi oblikovali potpuni konvolucijski sloj [1].

U nastavku slijede objašnjenja pojedine komponente cnn arhitekture.

### 2.1. Konvolucijski sloj

Konvolucijski sloj (eng. Convolutional layer) je osnovna građevna jedinica konvolucijskih neuronskih mreža (CNN). Ovaj sloj je posebno dizajniran za efikasnu obradu prostorno strukturiranih podataka poput slika. Glavna karakteristika konvolucijskog sloja je primjena konvolucije na ulazne podatke. Konvolucija je matematička operacija koja primjenjuje filter (jezgru) na ulazne podatke kako bi generirala značajke. Filter se sastoji od težina koje se uče tijekom treninga mreže. Konvolucijski sloj primjenjuje više filtera na ulazne podatke kako bi generirao više

značajki. Svaki filter provodi lokalnu prostornu konvoluciju preko ulaznih podataka, a rezultat konvolucije se kombinira kako bi se stvorila nova reprezentacija podataka. Kroz proces konvolucije, sloj može naučiti prepoznavati različite oblike, teksture i druge značajke prisutne u ulaznim slikovnim podacima. Nakon primjene konvolucije, može se primijeniti dodatna obrada poput aktivacijske funkcije (npr. ReLU) koja dodaje nelinearnost i poboljšava sposobnost modela da nauči kompleksne značajke. Konvolucijski slojevi također imaju mogućnost smanjenja dimenzionalnosti podataka primjenom operacija poput maksimalnog uzorkovanja (eng. max pooling) koje smanjuju prostornu rezoluciju i istovremeno očuvavaju značajke. Konvolucijski slojevi su ključni elementi u konvolucijskim neuronskim mrežama (CNN) i koriste se u raznim zadacima računalnog vida poput klasifikacije slika, detekcije objekata, segmentacije slika i drugih zadataka koji uključuju analizu i obradu prostorno strukturiranih podataka [2].

Formula konvolucijskoj sloja za izračun dimenzije outputa sadrži varijable „W“ koja predstavlja širinu ulaznog sloja, „F“ je veličina jezgre konvolucije, „P“ predstavlja broj dopunjavanja (eng. padding), te „S“ predstavlja korak (eng. stride). Formula omogućuje izračunavanje dimenzije izlaza nakon primjene konvolucije na ulazni sloj s određenim jezgrom konvolucije, uzimajući u obzir korak i eventualno dodano dopunjavanje [3].

$$W_{out} = \frac{W - F + 2P}{S} + 1$$

## 2.2. Sloj grupiranja

Sloj grupiranja (eng. Pooling layer) je sloj koji se često koristi u konvolucijskim neuronskim mrežama (CNN) kako bi se smanjila prostorna dimenzionalnost značajki generiranih konvolucijskim slojevima. Glavna svrha pooling sloja je izdvajanje najvažnijih informacija iz značajki i smanjenje računalnih zahtjeva. Najčešće korištena vrsta sloja grupiranja je maksimalno grupiranje. U tom slučaju, sloj grupiranja dijeli ulazne podatke na manje kvadratne ili pravokutne regije i zadržava samo najveće vrijednosti unutar svake regije. Ova operacija smanjuje dimenzije podataka, jer se informacija o najizraženijim značajkama zadržava, dok se manje

bitne detalje smanjuje. Primjerice, ako se primjeni maksimalno grupiranje s filterom veličine 2x2 i korakom (eng. Stride) 2, ulazni podaci će se podijeliti na 2x2 regije, a iz svake regije će se odabrati samo najveća vrijednost. Time se prostorna rezolucija podataka smanjuje za faktor 2, dok se važne značajke i dalje zadržavaju. Slojevi grupiranja također pomažu u sprječavanju preučivosti (eng. overfitting) tako što smanjuju broj parametara u mreži. Također, poboljšavaju invarijantnost modela na translaciju i male promjene u lokalnoj strukturi. Osim maksimalnog grupiranja, postoje i druge vrste slojeva kao što su srednje vrijednosti (eng. average pooling) i druge varijacije. Svaka od tih varijanti ima svoje prednosti i primjene ovisno o specifičnom zadatku. Pooling slojevi su važan dio konvolucijskih neuronskih mreža i igraju ključnu ulogu u smanjenju dimenzionalnosti podataka, očuvanju značajki i poboljšanju performansi modela [4].

Formula za sloj grupiranja za izračun dimenzije izlaznog volumena sadrži varijable „W“ koja predstavlja širinu ulaznog sloja, „F“ je veličina jezgre konvolucije, te „S“ predstavlja korak. Formula omogućuje izračunavanje dimenzije izlaznog volumena nakon primjene konvolucije na ulazni volumen s određenom veličinom jezgre konvolucije i korakom. Izračunom ovog izraza, dobiva se dimenzija izlaznog volumena konvolucijskog sloja [5].

$$W_{out} = \frac{W - F}{S} + 1$$

### 2.3. Potpuno povezani sloj

Potpuno povezani sloj (engl. Fully Connected Layer) u neuronskim mrežama je sloj u kojem su svi neuroni povezani s neuronima iz prethodnog sloja. Svaki neuron u ovom sloju prima ulazne vrijednosti iz svih neurona prethodnog sloja i zatim izračunava izlaznu vrijednost. Ovaj sloj se često koristi za klasifikaciju i obradu različitih vrsta podataka. Kada govorimo o potpuno povezanom sloju, obično se koriste matematičke operacije poput matričnog umnoška i dodavanja pristranosti kako bi se izračunala izlazna vrijednost svakog neurona. Ulazni podaci, predstavljeni vektorom, množe se sa matricom težina koja predstavlja parametre modela. Zatim

se dodaje pristranost kako bi se dobila konačna izlazna vrijednost neurona. Nakon toga, često se primjenjuje neka aktivacijska funkcija kako bi se uklonile negativne vrijednosti i stvorila nelinearnost u modelu. Potpuno povezani slojevi se često koriste kao posljednji sloj u neuronskim mrežama za klasifikaciju. Nakon što se podaci propagiraju kroz prethodne slojeve, izlazni vektor potpuno povezanog sloja predstavlja vjerojatnosti različitih klasa, a model donosi konačnu odluku o kategoriji kojoj pripada ulazni podatak. Ovi slojevi često imaju velik broj parametara i mogu doprinijeti kompleksnosti modela, što ih čini snažnim alatom za obradu različitih vrsta podataka i rješavanje različitih zadataka strojnog učenja[6].

## 2.4 Aktivacijske Funkcije

Aktivacijske funkcije u konvolucijskim neuronskim mrežama (CNN) igraju ključnu ulogu u procesu prijenosa i transformacije informacija kroz neuronske mreže. One se primjenjuju na izlaze pojedinih neurona kako bi se generirala konačna izlazna vrijednost neurona. Glavna svrha aktivacijskih funkcija je uvođenje nelinearnosti u neuronske mreže. Bez aktivacijskih funkcija, neuronske mreže bi bile ograničene na linearno kombiniranje ulaza, što bi ograničilo njihovu sposobnost modeliranja složenih i nestacionarnih podataka. Aktivacijske funkcije omogućuju neuronskim mrežama da nauče i reprezentiraju kompleksne odnose između ulaza i izlaza, čime se povećava njihova sposobnost učenja i generalizacije. Korištenje odgovarajuće aktivacijske funkcije ovisi o prirodi problema i specifičnostima arhitekture CNN-a. Odabir pravilne aktivacijske funkcije može biti ključan za postizanje optimalnih performansi modela i uspješnu obradu prometnih znakova u kontekstu autonomnih vozila[7].


Slijedi kratko objašnjenje najčešće korištenih aktivacijskih funkcija za klasifikacijski problem.

### 2.4.1 Sigmoid aktivacijska funkcija

Sigmoid funkcija uzima bilo koju realnu vrijednost kao ulaz i izlazne vrijednosti su u rasponu od 0 do 1. Što je ulaz veći (pozitivniji), to će izlazna vrijednost biti bliža 1.0,

dok će što je ulaz manji (negativniji), izlazna vrijednost biti bliža 0.0. Korištena je zbog mogućnosti dobre interpretacije.

Neki od problema su da zasićeni neuroni uništavaju gradijent, izlazne vrijednosti nisu centrirane oko nule, te Exp() je računalno skup proces [8]. Slika 1 prikazuje graf sigmoid funkcije i matematička formulu.



$$\sigma(x) = 1/(1 + e^{-x})$$


Slika 1: Graf sigmoid funkcija i matematička formula[9]

#### 2.4.2 Tanh aktivacijska funkcija

Tanh funkcija je vrlo slična sigmoidnoj/logističkoj aktivacijskoj funkciji i ima isti oblik slova S, s razlikom u rasponu izlaza od -1 do 1. U Tanh funkciji, što je ulaz veći (pozitivniji), to će izlazna vrijednost biti bliža 1.0, dok će što je ulaz manji (negativniji), izlazna vrijednost biti bliža -1.0.

Izlaz tanh aktivacijske funkcije je centriran oko nule, što nam omogućuje lako mapiranje izlaznih vrijednosti kao snažno negativne, neutralne ili snažno pozitivne.

Obično se koristi u skrivenim slojevima neuronskih mreža jer vrijednosti leže između -1 i 1. Zbog toga je srednja vrijednost za skriveni sloj blizu nule. To pomaže u centriranju podataka i olakšava učenje za sljedeći sloj [10]. Slika 2 prikazuje graf tanh(x) funkcije i matematičku formulu.



$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Slika 2: Graf Tanh(x) funkcija i matematička formula [9]


### 2.4.3 ReLU aktivacijska funkcija

Iako daje dojam linearne funkcije, ReLU ima derivativnu funkciju i omogućuje propagaciju unatrag (backpropagation), istovremeno čineći je računalno učinkovitom.

Glavna stvar ovdje je da ReLU funkcija ne aktivira sve neurone istovremeno.

Neuroni će biti deaktivirani samo ako je izlaz linearne transformacije manji od 0 [11].

Slika 3 prikazuje graf ReLU funkcije i matematičku formulu.




Slika 3: Graf ReLU funkcija i matematička formula [9]

#### 2.4.4 Leaky ReLU aktivacijska funkcija

Leaky ReLU je poboljšana verzija ReLU funkcije koja rješava problem „Dying ReLU“ jer ima malu pozitivnu nagibu u negativnom području. Prednost Leaky ReLU funkcije u odnosu na običnu ReLU funkciju je ta što omogućuje propagaciju unatrag čak i za negativne ulazne vrijednosti. Uvođenjem male pozitivne nagibe za negativne vrijednosti, derivacija u tom području postaje ne-nula, što sprječava problem „mrtvih neurona“ ili neurona koji ostaju neaktivni tijekom učenja. To pomaže poboljšati sposobnost učenja neuronske mreže i sprječava zasićenje neurona [12]. Slika 4 prikazuje graf Leaky ReLU funkcije i matematičku formulu.






$$f(x) = \max(0.01x, x)$$

Slika 4: Graf Leaky ReLU funkcija i matematička formula[9]

#### 2.4.5 ELU aktivacijska funkcija

ELU (eng. Exponential Linear Unit), je također varijanta ReLU funkcije koja modificira nagib negativnog dijela funkcije. ELU koristi logaritamsku krivulju za definiranje negativnih vrijednosti, za razliku od Leaky ReLU i Parametric ReLU funkcija koje koriste ravnu liniju.

ELU je snažna alternativa za ReLU zbog sljedećih prednosti: ELU se postupno izravnava sve do izlaza jednakog  $-\alpha$ , dok ReLU oštro izravnava. Izbjegava problem mrtvih ReLU funkcija uvođenjem logaritamske krivulje za negativne vrijednosti ulaza. To pomaže mreži da pomiče težine i pomake u pravom smjeru. Nedostaci ELU funkcije su povećavanje vremena računanja zbog uključene eksponencijalne operacije. Nema učenja vrijednosti  $\alpha$ . Problem eksplozije gradijenta [13]. Slika 5 prikazuje graf ELU funkcije i matematičku formulu.




$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha(\exp(x) - 1), & \text{if } x \leq 0 \end{cases}$$

Slika 5: Graf ELU funkcija i matematička formula[9]

#### 2.4.6 SELU aktivacijska funkcija

SELU je definiran u samo-normalizirajućim mrežama i brine se o unutarnjoj normalizaciji, što znači da svaki sloj čuva srednju vrijednost i varijancu iz prethodnih slojeva. SELU omogućuje ovu normalizaciju prilagođavanjem srednje vrijednosti i varijance. SELU ima i pozitivne i negativne vrijednosti kako bi pomicao srednju vrijednost, što nije bilo moguće s ReLU aktivacijskom funkcijom jer ne može izlaziti negativne vrijednosti. Gradijenti se mogu koristiti za prilagođavanje varijance. Funkcija aktivacije treba regiju s gradijentom većim od jedan kako bi ga povećala. SELU ima unaprijed definirane vrijednosti za alpha  $\alpha$  i lambda  $\lambda$ . Glavna prednost SELU funkcije u odnosu na ReLU je da je normalizacija brža od vanjske normalizacije, što znači da se mreža brže konvergira. SELU je relativno novija aktivacijska funkcija i potrebno je više istraživanja na arhitekturama poput CNN-a i RNN-a, gdje se uspoređuje njena primjena [14]. Slika 6 predstavlja SELU funkciju i matematičku formulu.



$$f(x) = \begin{cases} \lambda x, & \text{if } x > 0 \\ \lambda \alpha (e^x - 1), & \text{otherwise} \end{cases}$$

$$\alpha = 1.6733, \lambda = 1.0507$$

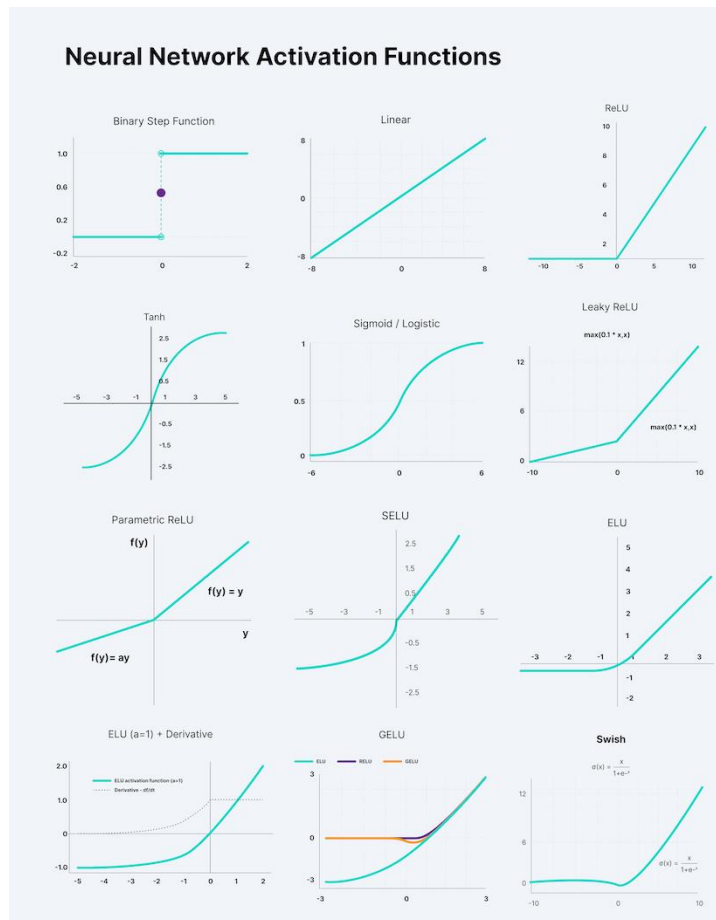
Slika 6: Graf SELU funkcija i matematička formula[9]

#### 2.4.7 Softmax aktivacijska funkcija

Softmax aktivacijska funkcija se često koristi u višeklasnoj klasifikaciji. Ona transformira ulazne vrijednosti u vjerojatnosti različitih klasa. Ova funkcija osigurava da izlazni vektor ima vrijednosti između 0 i 1, pri čemu je suma tih vrijednosti jednaka 1. Najveća vjerojatnost se pridružuje najizraženijoj klasi, dok manje izražene klase dobivaju manje vjerojatnosti. Softmax funkcija omogućuje modelu donošenje odluka o klasi kojoj pripada ulazni primjer na temelju relativnih vjerojatnosti. To je posebno korisno u problemima s više od dvije moguće klase [15]. Slijedi formula za softmax funkciju.

$$\text{softmax}(z_i) = \frac{\exp(z_i)}{\sum_j \exp(z_j)}$$

Slika 7 prikazuje grafovi većine aktivacijskih funkcija koje se koriste za neuronske mreže.



Slika 7: Prikaz grafova aktivacijskih funkcija[17]

## 2.5. Regularizacija

Regularizacija je tehnika koja se koristi u strojnom učenju kako bi se spriječilo preučenost modela. Cilj regularizacije je smanjiti kompleksnost modela i poboljšati njegovu sposobnost generalizacije na neviđene primjere.

Prekomjerna kompleksnost modela može rezultirati time da model „pamti“ ulazne podatke umjesto da nauči općenite zakonitosti. To može dovesti do loših performansi na novim podacima koje model nije vidio tijekom treninga. Regularizacija pomaže kontrolirati ovu kompleksnost i poboljšava generalizaciju modela [18].

Postoje različite tehnike regularizacije koje se koriste u strojnom učenju. Tehnike regularizacije mogu se koristiti samostalno ili u kombinaciji kako bi se poboljšala generalizacija modela i smanjilo preučenost. Važno je eksperimentirati s različitim

tehnikama i parametrima kako bi se pronašla optimalna kombinacija za konkretan problem.

Neke od najčešćih tehnika su [19]:

- L1 i L2 regularizacija: Ove tehnike dodaju regularizacijski gubitak u funkciju tijekom treninga. L1 regularizacija dodaje apsolutne vrijednosti težina u gubitak, dok L2 regularizacija dodaje kvadrate vrijednosti težina. Ovo potiče model da preferira manje vrijednosti težina, što može dovesti do rjeđe i bolje generalizirane reprezentacije.
- Dropout: Dropout je tehnika koja slučajno „ispušta“ (deaktivira) određeni postotak neurona tijekom treninga. To sprječava neurone da se previše specijaliziraju i ovisi o određenim ulazima, čime se poboljšava generalizacija modela. Dropout također pomaže u izgradnji više nezavisnih reprezentacija unutar modela.
- Early stopping: Early stopping je tehnika koja prekida trening kada se performanse modela na validacijskom skupu prestanu poboljšavati. To se postiže praćenjem metrika performansi (poput gubitka ili točnosti) na validacijskom skupu tijekom treninga. Early stopping pomaže u sprječavanju preučenosti modela i sprečava daljnje treniranje kada model dosegne optimalne performanse.
- Max norm regularizacija: Max norm regularizacija ograničava normu vektora težina unutar slojeva. To osigurava da težine ne prelaze određenu vrijednost, sprječavajući prekomjerno prilagođavanje modela na podatke.
- Augmentacija skupa za učenje (eng. Data Augmentation) je tehnika koja generira nove primjere podataka iz postojećih primjera primjenom transformacija poput rotacije, skaliranja, promjene osvjetljenja itd. Ovo proširuje skup podataka i pomaže modelu da nauči općenitije značajke.

## 2.6 Funkcija gubitka

Funkcija gubitka je mjera koja kvantificira koliko dobro model predviđa stvarne vrijednosti izlaza (ciljne vrijednosti) na temelju predikcija modela. Cilj je minimizirati vrijednost funkcije gubitka tijekom treninga kako bi se modelu omogućilo što bolje

prilagođavanje podacima. Postoji nekoliko razliĉitih vrsta loss funkcija, a odabir ovisi o vrsti zadatka i vrsti predikcije koju model obavlja. Neke od uobiĉajenih loss funkcija u strojnom uĉenju su [20]:

- Mean Squared Error (MSE): Ovo je jedna od najĉešće korištenih loss funkcija za regresijske probleme. Izraĉunava kvadratnu razliku između predikcija modela i stvarnih ciljnih vrijednosti te ih zbroji i podijeli s ukupnim brojem primjera. MSE daje veće težine većim razlikama između predikcija i ciljnih vrijednosti.
- Binary Crossentropy: Ova loss funkcija se koristi za binarnu klasifikaciju gdje je cilj predvidjeti dvije moguće klase. Raĉuna gubitak na temelju logaritamske razlike između predikcije modela i stvarnih ciljnih vrijednosti.
- Categorical Crossentropy: Ova loss funkcija se koristi za višeklasnu klasifikaciju gdje je cilj predvidjeti između više od dvije klase. Raĉuna gubitak na temelju logaritamske razlike između predikcije modela i stvarnih ciljnih vrijednosti, uzimajući u obzir sve moguće klase.
- Sparse Categorical Crossentropy: Sliĉno kao i Categorical Crossentropy, ova loss funkcija se koristi za višeklasnu klasifikaciju, ali oĉekuje indekse ciljnih vrijednosti umjesto vektora one-hot kodiranja.
- Hinge Loss: Ova loss funkcija se ĉesto koristi u algoritmima za strojno uĉenje potpomognuto podržanim vektorima (SVM). Ona procjenjuje gubitak na temelju udaljenosti između predikcija modela i stvarnih ciljnih vrijednosti.

### 3. Dataset

„European dataset“ se sastoji od prometnih znakova iz 6 europskih zemalja: Belgija, Hrvatska, Francuska, Njemaĉka, Nizozemska i Švedska. Sastoji se od 82 476 slika podjeljeno u 164 klase (znaka).

Slika 8 prikazuje nazive dataseta, broj klasa i broj znakova u svakoj zemlji.

Country	Dataset	Original classes	European classes	Training images	Testing images	Total images
Belgium	KUL	62	69	4561	2528	7089
Croatia	MASTIF-2009	97	88	4568	1843	6411
	MASTIF-2010	88	68	3694	1490	5184
	MASTIF-2011	53	41	1037	389	1426
France	Stereopolis	10	12	203	68	271
	UTBM	86	86	1878	753	2631
Germany	GTSRB	43	43	39209	12630	51839
	GTSDB	43	89	859	328	1187
Netherlands	RUG	3	12	58	17	75
Sweden	STS-Set1	19	52	2092	829	2921
	STS-Set2	19	52	2409	1033	3442

Slika 8: Prikaz klasa i broj znakova u datasetu [21]

Skup podataka European Traffic Sign (eng. ETSD) sadrži slike sadrže različite uvjete osvjetljenja, zamućenjima zbog pokreta, umjetnim artefaktima i perspektivama. Iako ne sadrži znakove snimljene noću ili u ekstremnim vremenskim uvjetima, data augmentacija je dobro poznata i primijenjena tehnika u literaturi za zadatke klasifikacije kako bi se generirali podaci i smanjio učinak pretreniranja. Obično se sintetičke slike generiraju primjenom različitih transformacija, simulirajući tamne ili svijetle scenarije, dodajući šum, zamućenje itd., kako bi se nadoknadio nedostatak informacija i izbjegla prikupljanje i označavanje podataka. Na taj način, skup podataka posjeduje potrebne karakteristike, kako bi se smatrao otpornijim za zadatke klasifikacije.


Kategorije prometnih znakova u datasetu su raspoređene na sljedeće kategorije[22]:

- Opasnost/upozorenje (Danger/Warning): Ova kategorija obuhvaća prometne znakove koji upozoravaju vozače na moguće opasnosti na cesti, kao što su zavoji, uski prolazi, neravne ceste, opasnosti od pada kamenja, opasnosti od životinja i slično. Ovi znakovi pružaju važne informacije vozačima kako bi bili svjesni opasnosti i prilagodili svoju vožnju.
- Regulativni (Regulatory): Regulativni prometni znakovi koriste se za upravljanje prometom i postavljeni su kako bi vozače upoznali s pravilima i ograničenjima na cesti. To uključuje znakove za ograničenje brzine,

obavezno zaustavljanje, obavezno skretanje, zabranu parkiranja ili vožnje u određenom smjeru, znakove za pješačke prijelaze i mnoge druge.

- Informativni (Informative): Informativni prometni znakovi pružaju korisne informacije vozačima o odredištima, smjerovima, udaljenostima, objektima od interesa, parkiralištima, benzinskim postajama, restoranima i slično. Oni pomažu vozačima da se orijentiraju i donesu informirane odluke o svom putovanju.
- Ostali (Others): Ova kategorija obuhvaća prometne znakove koji ne spadaju u gore navedene kategorije, kao što su znakovi koji označavaju radove na cesti, posebne uvjete vožnje, znakovi za bicikliste, znakovi za vozila hitne pomoći i druge posebne situacije.

Slika 9 predstavlja kategorije znakova u datasetu.



Slika 9: Kategorije znakova [23]



## 4. Praktični rad

### 4.1. Opis problema

Problem prepoznavanja znakova u kontekstu autonomnih vozila, gdje se koriste slike iz jedne zemlje za trening podatke, a slike iz drugih zemalja za testiranje, predstavlja izazov. Kada se koriste slike iz jedne zemlje za treniranje, autonomno vozilo će naučiti prepoznati znakove koji su karakteristični za tu zemlju, kao što su oblici, boje i simboli koji se koriste na tim znakovima. Međutim, kada se suoči s testnim slikama iz drugih zemalja, autonomno vozilo može se susresti s različitim oblicima, bojama ili simbolima, što može dovesti do smanjene uspješnosti prepoznavanja znakova.

Čak i male razlike u dizajnu znakova između različitih zemalja mogu predstavljati izazov za autonomno vozilo. Potrebno je osigurati da model za prepoznavanje znakova bude dovoljno fleksibilan i ima mogućnost generalizacijekako bi prepoznao znakove iz različitih zemalja, čak i ako su oblici, boje ili simboli drugačiji. Također je važno imati dovoljno raznovrsnih podataka iz različitih zemalja za trening modela kako bi se poboljšala sposobnost prepoznavanja znakova u različitim okruženjima.

Ovaj problem zahtijeva pažljivu pripremu trening podataka koji uključuje slike iz različitih zemalja kako bi se model naučio prepoznavati znakove iz različitih konteksta. Također, važno je provesti dobro testiranje i evaluaciju na slikama iz drugih zemalja kako bi se procijenila sposobnost modela da se prilagodi različitim uvjetima i uspješno prepozna znakove.

### 4.2. Prikupljanje i analiza podataka

Europski dataset za prepoznavanje prometnih znakova obuhvaća raznolike slike znakova iz više europskih zemalja. Dataset je inicijalno podjeljen na trening i test skup podataka, kasnije, unutar test podataka, izdvojeni su testni i validacijski skupovi u omjeru 70% za test skup podataka i 30% za validacijski skup podataka. Svaka slika započinje početnim slovom države iz koje dolazi. Njemačku predstavlja slovo „G“, Hrvatsku slovo „C“, Francusku slovo „F“, Belgiju slovo „B“, Švedsku slovo „S“. Uz pomoć skripte su spremljene slike za svaku državu. Iduća slika prikazuje primjer

spremanja trening podataka za Njemačku (slika 13), te su na takav način kreirani trening i skup podaci za ostale zemlje.

```
#Njemačka training
src = "/content/drive/MyDrive/ETSD/Training"
dst = "/content/drive/MyDrive/ETSD/TrainingGer"
import os, shutil
for item in os.listdir(src):
    s = os.path.join(src, item)
    d = os.path.join(dst, item)
    for name in os.listdir(s):
        if (name.startswith('G') and name.endswith('.ppm')):
            if not os.path.exists(d):
                os.makedirs(d)
            if os.path.isdir(s):
                shutil.copy(s + "/" + name, d + "/" + name)
```

Slika 10: Spremanje slika za trening skup Njemačke

Da bi se postigla bolja generalizacija, podaci su pažljivo podijeljeni na trening skupove za svaku zemlju pojedinačno. Tijekom analize klasa, identificirane su 8 zajedničkih klasa koje se pojavljuju u svim zemljama. Taj pristup omogućuje modelu da nauči prepoznavati ključne znakove, bez obzira na razlike u jeziku i kulturi.

Nadalje, kako bi se prevladalo preučenošću u slučajevima gdje je model pokazivao veći uspjeh na trening skupu nego na novim podacima, primijenjena je tehnika "data augmentation". To znači da su slike dodatno obogaćene varijacijama kao što su rotacija, promjena kontrasta i veličine, kako bi se stvorili novi podaci za trening. Ovo je osobito primijenjeno na zemlje gdje je primijećena preučenošću, osiguravajući da model nauči opće karakteristike znakova umjesto specifičnih pojedinosti iz trening skupa.

Jedna zanimljivost bila je Belgija, koja je imala jednu posebnu klasu za znak ograničenja brzine. Međutim, taj poseban slučaj nije značajno utjecao na cjelokupne rezultate modela, jer je bila slične svrhe kao i ostale klase za ograničenje brzine.

Odabir zajedničkih klasa i primjena tehnike data augmentation osigurava da model može učinkovito prepoznati ključne prometne znakove iz različitih europskih zemalja.

Znakovi su prikazani po zemljama u sljedećim tablicama. Trening skup Njemačke sadrži 10921 slika, te test 2928 slika. Trening skup Hrvatske sadrži 1512 slika, te test 634 slika. Trening skup Francuske sadrži 294 slika, te test 122 slika. Trening skup Belgije sadrži 869 slika, te test 474. Trening skup Švedske sadrži 1170 slika, te test 498 slika.

Tablica 1 prikazuje klasu 017 koja predstavlja znak „Djeca na cesti“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	017	017	017	017	017

Tablica 1: Znakovi u klasi 017

Tablica 2 prikazuje klasu 021 koja predstavlja znak „Radovi na cesti“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	021	021	021	021	021

Tablica 2: Znakovi u klasi 021

Tablica 3 prikazuje klasa 032 koja predstavlja znak „Opasnosti na cesti“ .

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	032	032	032	032	032

Tablica 3: znakovi u klasi 032

Tablica 4 prikazuje klasu 035 koji predstavlja znak „Raskrižje s cestom koja ima prednost prolaska“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	035	035	035	035	035

Tablica 4: znakovi u klasi 035

Tablica 5 prikazuje klasu 036 koja prestavlja znak „Obavezno zaustavljanje“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	036	036	036	036	036

Tablica 5: znakovi u klasi 036

Tablica 6 predstavlja klasu 037 koja predstavlja znak „Cesta s prednošću prolaska“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	037	037	037	037	037

Tablica 6: znakovi u klasi 037

Tablica 7 predstavlja klasu 050 koja predstavlja znak „Zabrana prometa za teretne automobile“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	050	050	050	050	050

Tablica 7: znakovi u klasi 050

Tablica 8 predstavlja klasu 059 koja predstavlja znak „Ograničenje brzine 30km/h“ , te klasa 058 kod Belgije „Ograničenje brzine 25km/h“.

Država	Francuska	Hrvatska	Belgija	Njemačka	Švedska
Znak					
Klasa	059	059	058	059	059

Tablica 8: znakovi u klasi 059

### 4.3. Modeliranje i treniranje

Modeliranje konvolucijske neuronske mreže (CNN) uključuje nekoliko koraka koji se mogu opisati na sljedeći način [24]:

- Kreiranje modela: Prvi korak je stvaranje arhitekture modela, odabir broja slojeva, rasporeda i pridruživanje odgovarajućih aktivacijskih funkcija. Ova faza obuhvaća definiranje strukture modela koji će se koristiti za klasifikaciju prometnih znakova.
- Konfiguriranje (eng. Compile) modela: Nakon stvaranja modela, slijedi korak konfiguriranja. To uključuje odabir prikladne funkcije gubitka (engl. loss function), optimizacijskog algoritma i dodatnih mjera koje će se koristiti za procjenu performansi modela.
- Treniranje modela: Treniranje modela je korak u kojem se model prilagođava trening skupu podataka. Ovaj korak obuhvaća iterativno prolazak kroz podatke, optimizaciju parametara modela i prilagođavanje modela trening podacima.
- Evaluacija modela: Nakon što je model treniran, dolazi do koraka evaluacije. U ovom koraku model se testira na neviđenim podacima, poput validacijskog ili testnog skupa. Točnost i druge relevantne mjere koriste se za procjenu performansi modela.
- Hiperparametarska optimizacija: Ovisno o rezultatima evaluacije, moguće je provesti hiperparametarsku optimizaciju kako bi se pronašle najbolje postavke modela. To uključuje eksperimentiranje s različitim vrijednostima hiperparametara kao što su stopa učenja, broj filtriranja, veličina kernela i slično, kako bi se postigle bolje performanse.
- Fine-tuning i iteracija: Ovisno o rezultatima evaluacije, može biti potrebno provesti fine-tuning modela ili iterirati kroz korake modeliranja kako bi se postigle bolje performanse. To može uključivati promjenu arhitekture, dodavanje ili uklanjanje slojeva, prilagođavanje hiperparametara ili promjenu pretprocesiranja podataka.

Neuronska mreža koja je korištena u radu je arhitektura koja se sastoji od nekoliko slojeva. Prvi sloj je konvolucijski sloj koji koristi 32 filtera veličine 3x3 za izdvajanje značajki slika. Nakon toga slijedi aktivacijska funkcija ReLU koja dodaje nelinearnost

u izlaz konvolucijskog sloja. Zatim slijedi još jedan konvolucijski sloj i aktivacijska funkcija. Nakon konvolucijskih slojeva, koristimo sloj za normalizaciju grupiranja (eng. Batch Normalization) kako bismo poboljšali stabilnost i brzinu učenja mreže. Slijedi sloj za maksimalno grupiranje (eng. MaxPooling) koji smanjuje dimenzionalnost izlaza. Postupak konvolucije, aktivacije, normalizacije i grupiranja ponavlja se još dva puta sa sve većim brojem filtera kako bi se izdvojile složenije značajke iz slike. Nakon toga, izlazni podaci se izravnavaju (eng. flatten) u jednodimenzionalni vektor kako bi se mogli proslijediti potpuno povezanim slojevima. Potpuno povezani sloj ima 256 čvorova i koristi aktivacijsku funkciju ReLU. Završni sloj je izlazni sloj koji koristi softmax aktivaciju za klasifikaciju slike u jednu od više klasa. Za optimizaciju koristimo Adam optimizator sa stopom učenja od 0.001. Mreža se kompajlira s gubitkom kategoričke unakrsne entropije (eng. categorical\_crossentropy) i metrikom točnosti (eng. accuracy).

Slika 11 prikazuje sažetak mreže koji prikazuje sve slojeve i parametre mreže.

```
# Layer 1
model.add(Conv2D(NUMB_FILTER_L1, (3, 3), input_shape=input_shape_val, padding='same'))
model.add(Activation('relu'))
model.add(Conv2D(NUMB_FILTER_L1, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(BatchNormalization())

# Layer 2
model.add(MaxPool2D((2, 2)))

# Layer 3
model.add(Conv2D(NUMB_FILTER_L2, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(Conv2D(NUMB_FILTER_L2, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(BatchNormalization())

# Layer 4
model.add(MaxPool2D((2, 2)))

# Layer 5
model.add(Conv2D(NUMB_FILTER_L3, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(Conv2D(NUMB_FILTER_L3, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(BatchNormalization())

# Layer 6
model.add(MaxPool2D((2, 2)))

# Flattening the model for fully connected layer
model.add(Flatten())

# Fully connected layer
model.add(Dense(NUMB_NODE_FC_LAYER))
model.add(Activation('relu'))

# Output layer
model.add(Dense(train_generator.num_classes, activation='softmax'))

# Define the optimizer
optimizer = Adam(learning_rate=1e-3)

# Compile the network
model.compile(loss='categorical_crossentropy', optimizer=optimizer, metrics=['accuracy'])

# Show the model summary
model.summary()
```

Slika 11: Neuronska mreža u pythonu

Slika 12 prikazuje da neuronska mreža ima ukupno 584,552 parametra, od kojih su 584,104 trenirajući parametri. Ostatak parametara se odnosi na nepromjenjive parametre koji ne sudjeluju u procesu treniranja.

Layer (type)	Output Shape	Param #
conv2d_36 (Conv2D)	(None, 28, 28, 32)	320
activation_42 (Activation)	(None, 28, 28, 32)	0
conv2d_37 (Conv2D)	(None, 28, 28, 32)	9248
activation_43 (Activation)	(None, 28, 28, 32)	0
batch_normalization_18 (Batch Normalization)	(None, 28, 28, 32)	128
max_pooling2d_18 (Max Pooling 2D)	(None, 14, 14, 32)	0
conv2d_38 (Conv2D)	(None, 14, 14, 64)	18496
activation_44 (Activation)	(None, 14, 14, 64)	0
conv2d_39 (Conv2D)	(None, 14, 14, 64)	36928
activation_45 (Activation)	(None, 14, 14, 64)	0
batch_normalization_19 (Batch Normalization)	(None, 14, 14, 64)	256
max_pooling2d_19 (Max Pooling 2D)	(None, 7, 7, 64)	0
conv2d_40 (Conv2D)	(None, 7, 7, 128)	73856
activation_46 (Activation)	(None, 7, 7, 128)	0
conv2d_41 (Conv2D)	(None, 7, 7, 128)	147584
activation_47 (Activation)	(None, 7, 7, 128)	0
batch_normalization_20 (Batch Normalization)	(None, 7, 7, 128)	512
max_pooling2d_20 (Max Pooling 2D)	(None, 3, 3, 128)	0
flatten_6 (Flatten)	(None, 1152)	0
dense_12 (Dense)	(None, 256)	295168
activation_48 (Activation)	(None, 256)	0
dense_13 (Dense)	(None, 8)	2056

=====  
Total params: 584,552  
Trainable params: 584,104  
Non-trainable params: 448

Slika 12: Parametri mreže



Slika 15 prikazuje `model.fit_generator`. `Model.fit_generator` funkcija je korištena za treniranje modela. Parametar „epochs“ određuje koliko puta će se iterirati kroz kompletan skup podataka prilikom treniranja modela. Parametar `validation_data` određuje validacijski skup podataka na kojem će se model evaluirati nakon svake epohe kako bi se pratila njegova uspješnost. Ovdje je korišten „`validation_generator`“ koji generira validacijske podatke. Parametar „`validation_steps`“ određuje broj koraka validacije koje će se izvršiti nakon svake epohe. U ovom slučaju, koristimo „`len(validation_generator)`“ kako bismo osigurali da se prolazi kroz sve podatke za validaciju. Tijekom izvršavanja ovog koda, model će biti treniran kroz zadani broj epoha. Nakon svake epohe, model će biti evaluiran na validacijskom skupu podataka. Na kraju, objekt će sadržavati informacije o toku treniranja, kao što su gubitak (eng. `loss`) i metrika točnosti (eng. `accuracy`) za svaku epohu.


```
GerGer = model.fit(  
    train_generator,  
    epochs=epochs,  
    validation_data=validation_generator,  
    steps_per_epoch=len(train_generator),  
    validation_steps=len(validation_generator)  
)
```

Slika 13: Fit generator

## 4.4 Rezultati


### 4.4.1. Rezultati Njemačka

Na slici 14 se nalazi graf koji prikazuje točnost na trening i test podacima iz Njemačke. Trening linija (plava linija) prikazuje kako se točnost modela mijenja tijekom treninga, dok test linija (crvena linija) prikazuje kako se testna točnost mijenja tijekom istog vremenskog razdoblja. Na početku treninga, obje linije pokazuju visoku točnost. Kako trening napreduje, trening linija postupno raste i približava se 100% točnosti. To sugerira da model uči iz trening podataka i postaje sve bolji u prepoznavanju znakova. Test linija se približava trening liniji, što je očekivano jer su test i trening podaci iz iste države.




Slika 14: Trening Njemačka i test Njemačka

Na slici 15 se nalazi graf koji prikazuje točnost na trening podacima Njemačke i test podacima Hrvatske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci se prilično približavaju trening podacima uz određene oscilacije tijekom epoha. Maksimalna test točnost iznosi 0,974, što je jako zadovoljavajuće s obzirom da su testni podaci iz druge države.




Slika 15: Trening Njemačka i test Hrvatska

Na slici 16 se nalazi graf koji prikazuje točnost na trening podacima Njemačke i test podacima Belgije. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci se prilično približavaju trening podacima uz određene oscilacije tijekom epoha. Maksimalna test točnost iznosi 0,955, što je jako zadovoljavajuće s obzirom da su testni podaci iz druge države.




Slika 16: Trening Njemačka i test Belgija

Na slici 17 se nalazi graf koji prikazuje točnost na trening podacima Njemačke i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci se vrlo brzo povećavaju, no ostaju blizu 90%. Maksimalna test točnost iznosi 0,89, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.



Slika 17: Trening Njemačka i test Francuska

Na slici 18 se nalazi graf koji prikazuje točnost na trening podacima Njemačke i test podacima Švedske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci se vrlo brzo povećavaju, no ostaju blizu 85%. Maksimalna test točnost iznosi 0,85, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.



Slika 18: Trening Njemačka i test Švedska


Tablica 9 prikazuje rezultate točnosti trening podataka Njemačke u odnosu na test podatke za ostale zemlje.

Model	Validacijska točnost	Test točnost
GerGer	0.996918	0.991120
GerCro	0.977778	0.974763
GerBel	0.985106	0.955696
GerFra	0.873469	0.853414
GerSwe	0.908333	0.893443

Tablica 9: Rezultati točnosti Njemačka (izvor: autor)


#### 4.4.2. Rezultati Hrvatska

Na slici 19 se nalazi graf koji prikazuje točnost na trening i test podacima Hrvatske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,996, što je jako zadovoljavajuća točnost.




Slika 19: Trening Hrvatska i test Hrvatska

Na slici 20 se nalazi graf koji prikazuje točnost na trening podacima Hrvatske i test podacima Njemačke. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,996, što je jako zadovoljavajuća točnost.




Slika 20: Trening Hrvatska i test Njemačka

Na slici 21 se nalazi graf koji prikazuje točnost na trening podacima Hrvatske i test podacima Belgije. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,95, što je jako zadovoljavajuća točnost.




Slika 21: Trening Hrvatska i test Belgija

Na slici 22 se nalazi graf koji prikazuje točnost na trening podacima Hrvatske i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju točnosti 85%, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.



Slika 22: Trening Hrvatska i test Francuska

Na slici 23 se nalazi graf koji prikazuje točnost na trening podacima Hrvatske i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju točnosti 80%, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.



Slika 23: Trening Hrvatska i test Švedska


Tablica 10 prikazuje rezultate točnosti trening podataka Hrvatske u odnosu na test podatke za ostale zemlje.

Model	Validacijska točnost	Test točnost
CroCro	0.996825	0.995268
CroGer	0.891096	0.889686
CroBel	0.959574	0.959916
CroFra	0.875000	0.852495
CroSwe	0.795918	0.794181

Tablica 10: Rezultati točnosti Hrvatska


#### 4.4.3. Rezultati Belgija

Na slici 24 se nalazi graf koji prikazuje točnost na trening i test podacima Belgije. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,994, što je jako zadovoljavajuća točnost.



Slika 24: Trening Belgija i test Belgija

Na slici 25 se nalazi graf koji prikazuje prikazuje točnost na trening podacima Belgije i test podacima Njemačke. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 80% točnosti, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.




Slika 25: Trening Belgija i test Njemačka

Na slici 26 se nalazi graf koji prikazuje prikazuje točnost na trening podacima Belgije i test podacima Hrvatske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 80%




točnosti, što je indikator da dolazi do prenaučivosti (eng. overffiting), gdje model slabo generalizira na test podacima.




Slika 26: Trening Belgija i test Hrvatska

Na slici 27 se nalazi graf koji prikazuje točnost na trening podacima Belgije i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 71% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 27: Trening Belgija i test Francuska

Na slici 28 se nalazi graf koji prikazuje točnost na trening podacima Belgije i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 73% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 28: Trening Belgija i test Švedska

Tablica 11 prikazuje rezultate točnosti trening podataka Belgije u odnosu na test podatke za ostale zemlje.

Model	Validacijska točnost	Test točnost
BelBel	0.995745	0.993671
BelGer	0.793836	0.793716
BelCro	0.806349	0.802839
BelFra	0.725000	0.713115
BelSwe	0.730612	0.732932

Tablica 11: Rezultati točnosti Belgija


Augmentacija podataka je tehnika koja se koristi u strojnom učenju, posebno u području konvolucijskih neuronskih mreža (CNN), kako bi se povećao trening skup podataka. Ova tehnika ima za cilj generirati nove primjere podataka iz postojećih primjera, koristeći različite transformacije i manipulacije, kako bi se obogatila raznolikost i raznolikost trening podataka. Tablica 12 pokazuje da se augmentacijom povećala validacijska točnost u odnosu na početni trening skup Belgije.

Model	Validacijska točnost	Test točnost
BelBel	0.995745	0.993671
BelGer	0.837671	0.815232
BelCro	0.876190	0.824921
BelFra	0.766667	0.704918
BelSwe	0.755102	0.740964

Tablica 12: Rezultati točnosti Belgija povećani trening podaci


#### 4.4.4. Rezultati Francuska

Na slici 29 se nalazi graf koji prikazuje točnost na trening podacima i test podacima Francuske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,99, što je jako zadovoljavajuća točnost.




Slika 29: Trening Francuska i test Francuska

Na slici 30 se nalazi graf koji prikazuje točnost na trening podacima Francuske i test podacima Njemačke. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 60% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.




Slika 30: Trening Francuska i test Njemačka

Na slici 31 se nalazi graf koji prikazuje točnost na trening podacima Francuske i test podacima Hrvatske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 76% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.




Slika 31: Trening Francuska i test Hrvatska

Na slici 32 se nalazi graf koji prikazuje točnost na trening podacima Francuske i test podacima Belgije. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 85% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 32: Trening Francuska i test Belgija

Na slici 33 se nalazi graf koji prikazuje točnost na trening podacima Francuske i test podacima Švedske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 76% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 33: Trening Francuska i test Švedska

Tablicom 13 su prikazani rezultati točnosti trening podataka Francuske u odnosu na test podatke za ostale zemlje.

Model	Validacijska točnost	Test točnost
FraFra	0.991667	0.991803
FraGer	0.601712	0.601434
FraCro	0.766667	0.763407
FraBel	0.857447	0.848101
FraSwe	0.763265	0.722892

Tablica 13: Rezultati točnosti Francuska


Tablica 14 pokazuje da se augmentacijom povećala točnost u odnosu na početni trening skup Francuske.

Model	Validacijska točnost	Test točnost
FraFra	0.991667	0.991803
FraGer	0.676370	0.676571
FraCro	0.780952	0.774448
FraBel	0.876596	0.873418
FraSwe	0.779592	0.765060

Tablica 14: Rezultati točnosti Francuska povećani trening podaci


#### 4.4.5. Rezultati Švedska

Na slici 34 se nalazi graf koji prikazuje točnost na trening i test podacima Švedske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu vrijednosti trening točnosti. Maksimalna test točnost iznosi 0,987, što je jako zadovoljavajuća točnost.



Slika 34: Trening Švedska i test Švedska

Na slici 35 se nalazi graf koji prikazuje točnost na trening podacima Švedske i test podacima Njemačke. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 70% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.




Slika 35: Trening Švedska i test Njemačka

Na slici 36 se nalazi graf koji prikazuje točnost na trening podacima Švedske i test podacima Hrvatske. Trening podaci vrlo brzo se približavaju 100% točnosti, a test




podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 65% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 36: Trening Švedska i test Hrvatska


Na slici 37 se nalazi graf koji prikazuje točnost na trening podacima Švedske i test podacima Belgija. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 70% točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 37: Trening Švedska i test Belgija

Na slici 38 se nalazi graf koji prikazuje točnost na trening podacima Švedske i test podacima Francuska. Trening podaci vrlo brzo se približavaju 100% točnosti, a test podaci na početku pokazuju nisku točnost, no vrlo brzo se približavaju blizu 80%

točnosti, što je indikator da dolazi do prenaučivosti, gdje model slabo generalizira na test podacima.



Slika 38: Trening Švedska i test Francuska

Tablicom 15 su prikazani rezultati točnosti trening podataka Švedske u odnosu na test podatke za ostale zemlje.

Model	Validacijska točnost	Test točnost
SweSwe	0.991837	0.987952
SweGer	0.690753	0.663934
SweCro	0.714286	0.640379
SweFra	0.725000	0.713115
SweBel	0.768085	0.753165

Tablica 15: Rezultati točnosti Švedska

Tablica 16 pokazuje da se augmentacijom povećala točnost u odnosu na početni trening skup Švedske.

Model	Validacijska točnost	Test točnost
SweSwe	0.991837	0.987952
SweGer	0.703425	0.701424
SweCro	0.741270	0.692429
SweFra	0.750000	0.715969
SweBel	0.831915	0.831224

Tablica 16: Rezultati točnosti Švedske povećani trening podaci

## 5. Analiza rezultata


Tablica 17 prikazuje usporedno podatke za sve zemlje.

Model	Validacijska točnost	Test točnost
GerGer	0.996918	0.991120
GerCro	0.977778	0.974763
GerBel	0.985106	0.955696
GerFra	0.873469	0.853414
GerSwe	0.908333	0.893443
CroCro	0.996825	0.995268
CroGer	0.891096	0.889686
CroBel	0.959574	0.959916
CroFra	0.875000	0.852495
CroSwe	0.795918	0.794181
BelBel	0.995745	0.993671
BelGer	0.837671	0.815232
BelCro	0.876190	0.824921
BelFra	0.766667	0.704918
BelSwe	0.755102	0.740964
FraFra	0.991667	0.991803
FraGer	0.676370	0.676571
FraCro	0.780952	0.774448
FraBel	0.876596	0.873418
FraSwe	0.779592	0.765060
SweSwe	0.991837	0.987952
SweGer	0.703425	0.701424

SweCro	0.741270	0.692429
SweFra	0.750000	0.715969
SweBel	0.831915	0.831224

Tablica 17: Usporedni prikaz svih rezultata po državama

Stupčasti graf na Slici 39 prikazuje usporedno sve rezultate po državama.



Slika 39: Usporedni graf rezultata točnosti po državama

### 5.1. Analiza rezultata Njemačka


Analiza podataka o točnosti modela na test skupovima za različite zemlje pokazuje da je model Njemačke općenito vrlo uspješan u klasifikaciji. Najviša postignuta točnost od 0.996918 na testu za Njemačku ukazuje na to da je model izuzetno dobro prilagođen Njemačkoj klasifikacijskoj domeni i vrlo precizno razlikuje između uzoraka različitih klasa, što je očekivano jer su trening i test podaci iz iste zemlje.

Slično tome, rezultat na testu za Belgiju s točnošću od 0.985106 također je vrlo impresivan i sugerira da model vrlo dobro opaža i klasificira belgijske uzorke.

Hrvatska i Švedska imaju nešto nižu, ali i dalje vrlo visoku točnost na testu, Hrvatska ima 0.977778, a Švedska 0.908333. Ovo ukazuje na dobru prilagodbu modela i sposobnost generalizacije na uzorke iz tih zemalja.

Najniži rezultat točnosti na testu je zabilježen za Francusku sa 0.873469. Iako je ovo najniža točnost među zemljama, i dalje je relativno visoka i ukazuje na prilično dobru klasifikaciju.

Slika 40 prikazuje graf koji sugerira da je model vrlo sposoban u razlikovanju uzoraka iz različitih zemalja te da postiže visoke performanse na testiranju.



Slika 40: Rezultati trening Njemačka i test ostale zemlje

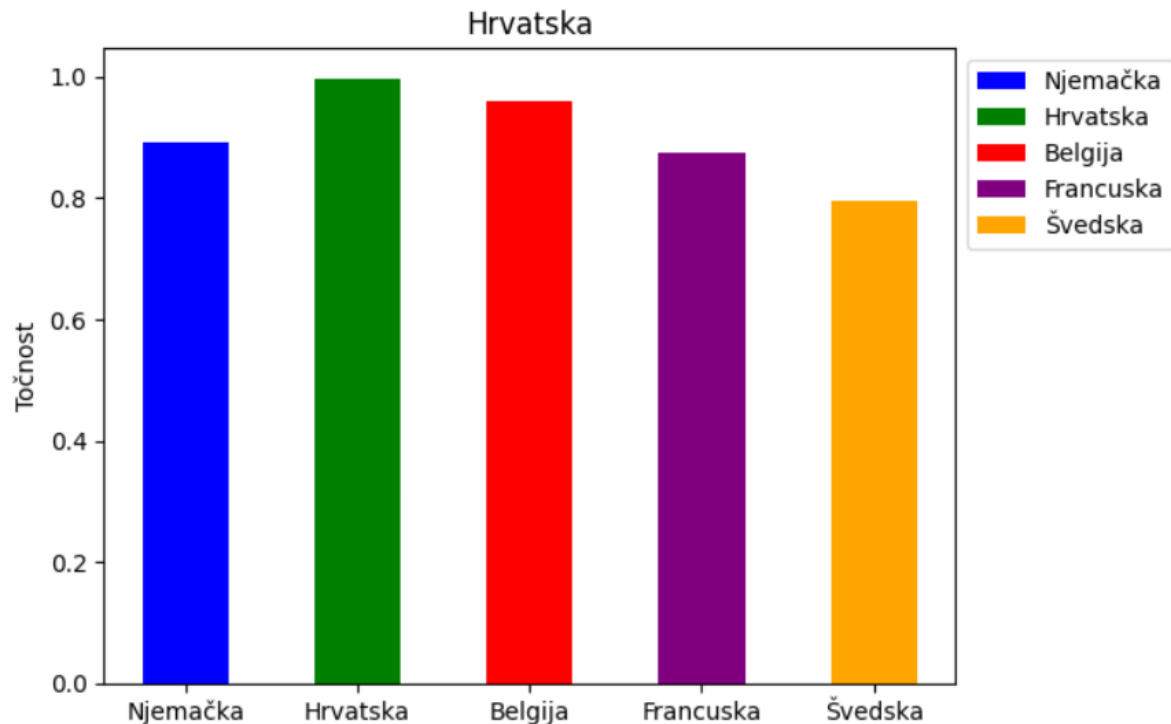
## 5.2. Analiza rezultata Hrvatska

Na temelju podataka o točnosti modela na test skupovima za različite zemlje, primjećujemo da model postiže izuzetno dobre rezultate u klasifikaciji. Točnost modela na test skupu za Hrvatsku iznosi 0.996825, što ukazuje na iznimno precizno razlikovanje i klasifikaciju uzoraka iz hrvatskog skupa podataka. Model se dobro prilagodio hrvatskom kontekstu i vjerojatno je dobro naučio razlikovati karakteristike uzoraka iz te zemlje.

Također, rezultati modela na test skupovima za ostale zemlje također su izuzetno dobri. Točnost za Njemačku iznosi 0.891096, za Belgiju 0.959574, za Francusku 0.875000 i za Švedsku 0.795918. Ovi rezultati sugeriraju da se model dobro

generalizira na različite klasifikacijske domene, jer je postigao visoku točnost na uzorcima iz svake zemlje.

Slika 41 prikazuje graf koji pokazuje da je model vrlo uspješan u razlikovanju uzoraka iz različitih država.



Slika 41: Rezultati trening Hrvatska i test ostale zemlje

### 5.3. Analiza rezultata Belgija

Na test podacima za Belgiju, model je postigao visoku točnost od 0.995745, što je očekivano jer su trening i test skup podataka iz iste zemlje. To ukazuje na dobru sposobnost modela da generalizira na belgijske znakove.


Međutim, na testiranju za Njemačku, model je postigao točnost od 0.793836, što je niže od belgijske točnosti. Razlika u znakovima i drugim značajkama između trening i test skupa podataka može objasniti smanjenje točnosti na testiranju za Njemačku.

Slično tome, na testiranju za Hrvatsku, model je postigao točnost od 0.806349, također niže u usporedbi s belgijskom točnosti. Razlike u znakovima između Belgije i Hrvatske mogu predstavljati izazov za model, što rezultira nešto nižom točnošću na testiranju za Hrvatsku.

Rezultati za Francusku i Švedsku također pokazuju niže točnosti na testiranju. Model je postigao točnost od 0.725000 na testiranju za Francusku i 0.730612 na testiranju za Švedsku. To sugerira poteškoće u prepoznavanju znakova iz tih zemalja koje model nije imao priliku dovoljno dobro naučiti tijekom treninga.

Nakon dodavanja slika u trening skup za svaku zemlju, točnost se poboljšala. Za Njemačku, točnost se povećala s 0.793836 na 0.837671. Za Hrvatsku, točnost se povećala s 0.806349 na 0.876190. Za Francusku, točnost se povećala s 0.725000 na 0.766667, dok se za Švedsku, točnost povećala s 0.730612 na 0.755102.

Slika 42 prikazuje graf koji pokazuje da su dodane slike u trening skup omogućile modelu bolje prepoznavanje znakova iz svake zemlje, što je dovelo do povećanja točnosti na testiranju za sve zemlje. Međutim, unatoč poboljšanju, model još uvijek ima poteškoća u generalizaciji na znakove iz drugih zemalja.



Slika 42: Rezultati trening Belgija i test ostale zemlje

#### 5.4. Analiza rezultata Francuska

Na test podacima za Francusku, model je postigao točnost od 0.991667. Ova visoka točnost sugerira da je model dobro generalizirao znakove iz Francuske, što je očekivano jer su trening i test skup podataka iz iste zemlje.

Kada se testira na znakovima iz Njemačke, model je postigao točnost od 0.676370, što je niže u usporedbi s francuskom točnosti. Razlike u znakovima i drugim značajkama između Njemačke i Francuske mogu objasniti smanjenje točnosti na testiranju za Njemačku.

Na testiranju za Hrvatsku, model je postigao točnost od 0.780952. Točnost je nešto niža od francuske točnosti, što sugerira da model ima određene poteškoće u prepoznavanju hrvatskih znakova.


S druge strane, na testiranju za Belgiju, model je postigao točnost od 0.857447, što je također visoka točnost. Ovo je očekivano s obzirom da je model treniran na belgijskim znakovima i ukazuje na dobru generalizaciju za belgijske znakove.

Na testiranju za Švedsku, model je postigao točnost od 0.763265. Točnost je nešto niža od francuske točnosti, što ukazuje na poteškoće u prepoznavanju švedskih znakova.

Slika 43 prikazuje graf koji dokazuje da nakon dodavanja slika u trening skup za svaku zemlju, točnosti su se poboljšale. Za Njemačku, točnost se povećala s 0.601712 na 0.676370. Za Hrvatsku, točnost se povećala s 0.766667 na 0.780952. Za Belgiju, točnost se povećala s 0.857447 na 0.876596, dok se za Švedsku, točnost povećala s 0.763265 na 0.779592.

Ovi rezultati pokazuju da su dodane slike u trening skup omogućile modelu bolje prepoznavanje znakova iz svake zemlje, što je dovelo do povećanja točnosti na testiranju za sve zemlje. Međutim, unatoč poboljšanju, model još uvijek ima poteškoća u generalizaciji na znakove iz drugih zemalja.





Slika 43: Rezultati trening Francuska i test ostale zemlje

### 5.5. Analiza rezultata Švedska

Na test podacima za Švedsku, model je postigao visoku točnost od 0.991837, što je očekivano jer su trening i test podaci iz iste zemlje. Međutim, kada se usporede rezultati za ostale zemlje, primjećujemo da model ima poteškoća u generalizaciji na znakove iz drugih zemalja.

Na testiranju za Njemačku, model je postigao točnost od 0.690753, što je značajno niže od točnosti na testiranju za Švedsku. To ukazuje na razlike u znakovima i drugim značajkama između trening i test skupa podataka za Njemačku, što rezultira smanjenjem točnosti na testiranju za tu zemlju.

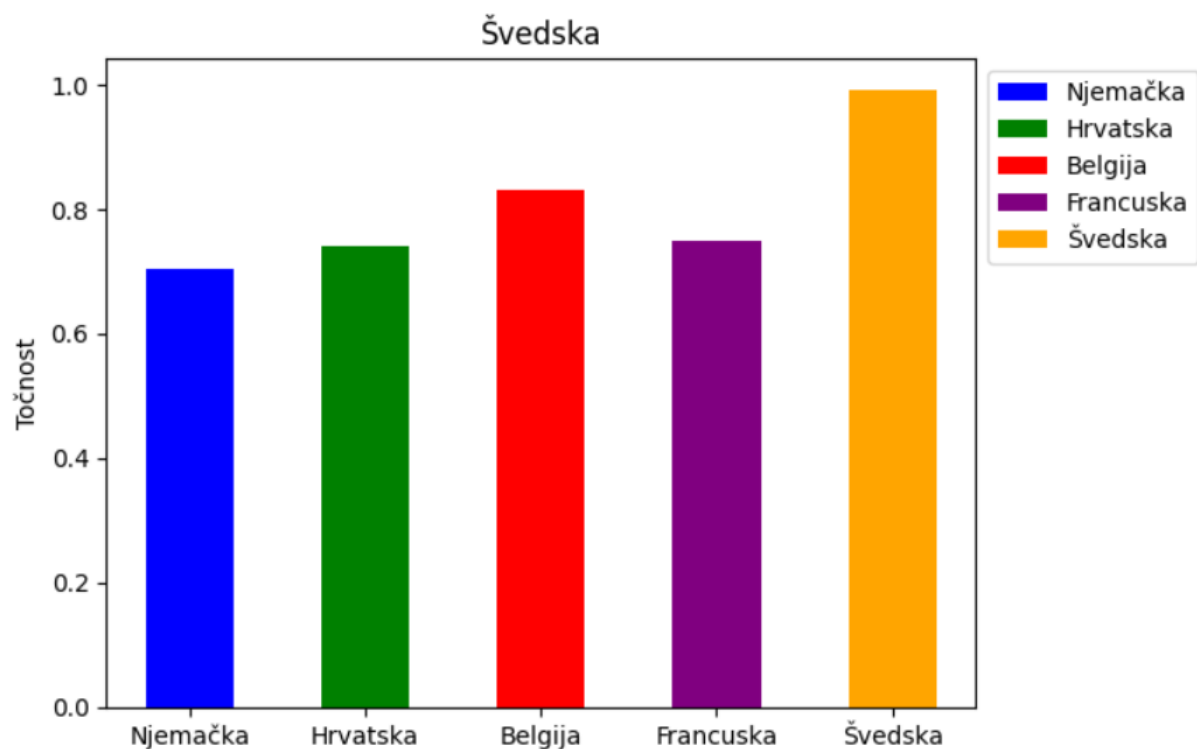
Slično tome, na testiranju za Hrvatsku, model je postigao točnost od 0.714286, također niže u usporedbi s točnosti za Švedsku. Razlike u znakovima između Švedske i Hrvatske mogu predstavljati izazov za model, što rezultira nešto nižom točnošću na testiranju za Hrvatsku.

Rezultati za Francusku i Belgiju također pokazuju niže točnosti na testiranju u odnosu na Švedsku. Model je postigao točnost od 0.725000 na testiranju za

Francusku i 0.768085 na testiranju za Belgiju. To sugerise da model ima poteškoća u prepoznavanju znakova iz tih zemalja, što rezultira nižom točnošću na testiranju.

Slika 44 prikazuje graf koji dokazuje da nakon dodavanja slika u trening skup za svaku zemlju dolazi do poboljšanje u točnosti na testiranju za Njemačku, Hrvatsku, Francusku i Belgiju. Za Njemačku, točnost se povećala s 0.690753 na 0.703425. Za Hrvatsku, točnost se povećala s 0.714286 na 0.741270. Za Francusku, točnost se povećala s 0.725000 na 0.750000, dok se za Belgiju, točnost povećala s 0.768085 na 0.831915.

Ovi rezultati pokazuju da su dodane slike u trening skup omogućile modelu bolje prepoznavanje znakova iz svake zemlje, što je dovelo do povećanja točnosti na testiranju za sve zemlje. Međutim, unatoč poboljšanju, model još uvijek ima poteškoća u generalizaciji na znakove iz drugih zemalja.



Slika 44: Rezultati trening Švedska i test ostale zemlje

## 6. Zaključak

U ovom istraživanju analizirane su performanse konvolucijskih neuronskih mreža (CNN) na prometnim znakovima zemalja Europe. Glavni cilj bio je istražiti mogućnost generalizacije CNN modela pri klasifikaciji i prepoznavanju prometnih znakova različitih europskih zemalja. Kroz eksperimente korištenjem trening skupa podataka prometnih znakova jedne zemlje i testiranje na podacima drugih zemalja, utvrđeno je da se točnost modela može značajno smanjiti kada se model trenira na jednoj zemlji, a testira na drugim zemljama. Razlog za to je prisutnost razlika u znakovima između zemalja, poput različitih oblika, boja, tekstura ili znakovnih poruka. Ove razlike u znakovima između zemalja predstavljaju izazov za modeliranje prometnih znakova na širem europskom skupu podataka. Model koji je treniran na podacima jedne zemlje može se specijalizirati za prepoznavanje specifičnih značajki tih znakova, ali može imati poteškoća u prepoznavanju znakova iz drugih zemalja s različitim karakteristikama.

U našem slučaju trening podaci Njemačke su imale najbolje rezultate na test podacima ostalih zemalja, sve zemlje na test podacima prelaze 90% točnosti, osim Švedske kod koje dolazi do 87%. Kod trening podataka Hrvatske 90% točnosti ima na test podacima Belgije i Njemačke. Kod ostalih trening podataka zemalja dobivamo lošiju točnost, stoga, za postizanje boljih performansi na prometnim znakovima zemalja Europe, preporučuje se korištenje šireg skupa trening podataka koji obuhvaća znakove iz različitih zemalja. Ovo omogućuje modelu da nauči općenitije značajke koje se primjenjuju na različite znakove iz različitih zemalja.

Uz to, daljnja istraživanja mogu se usmjeriti na razvoj tehnika prilagodbe ili transfernog učenja koje omogućuju bolju generalizaciju modela na različite zemlje prometnih znakova. Također se može istražiti primjena dodatnih tehnika augmentacije podataka kako bi se modelu pružila veća robusnost i sposobnost prepoznavanja raznolikih znakova. U konačnici, razumijevanje izazova i ograničenja pri klasifikaciji prometnih znakova zemalja Europe pomoći će u razvoju boljih i pouzdanijih sustava za analizu prometne signalizacije, s ciljem poboljšanja sigurnosti i učinkovitosti prometa na cestama.

Github: <https://github.com/kremazar/Diplomski>

## 7. Literatura

1. Teuwen, J., & Moriakova, N. (2020). Convolutional neural networks, Convolutional neural networks (str. 487), [https://www2.cs.uh.edu/~ceick/ai/CNN\\_Reading\\_Material.pdf](https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf) (pristupljeno 19.7.2023.)
2. Teuwen, J., & Moriakova, N. (2020). Convolutional neural networks, Convolutions (str. 488), [https://www2.cs.uh.edu/~ceick/ai/CNN\\_Reading\\_Material.pdf](https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf) (pristupljeno 19.7.2023.)
3. Medium [online fotografija], [https://miro.medium.com/v2/resize:fit:750/format:webp/1\\*gRWLLPaarbD3sR-OFeh4mg.png](https://miro.medium.com/v2/resize:fit:750/format:webp/1*gRWLLPaarbD3sR-OFeh4mg.png) (pristupljeno: 19.7.2023)
4. Teuwen, J., & Moriakova, N. (2020). Convolutional neural networks, Pooling layers (str. 491), [https://www2.cs.uh.edu/~ceick/ai/CNN\\_Reading\\_Material.pdf](https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf) (pristupljeno 19.7.2023.)
5. Medium [online fotografija], [https://miro.medium.com/v2/resize:fit:750/format:webp/1\\*gRWLLPaarbD3sR-OFeh4mg.png](https://miro.medium.com/v2/resize:fit:750/format:webp/1*gRWLLPaarbD3sR-OFeh4mg.png) (pristupljeno: 19.7.2023)
6. Teuwen, J., & Moriakova, N. (2020). Convolutional neural networks, Fully connected layers (str. 492), [https://www2.cs.uh.edu/~ceick/ai/CNN\\_Reading\\_Material.pdf](https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf) (pristupljeno 19.7.2023.)
7. V7, Activation Functions in Neural Networks, [website], 2021., <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
8. Baheti Pragati. "Sigmoid function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
9. Medium [online fotografija], [https://miro.medium.com/v2/resize:fit:828/format:webp/1\\*ZafDv3VUm60Eh10OeJu1vw.png](https://miro.medium.com/v2/resize:fit:828/format:webp/1*ZafDv3VUm60Eh10OeJu1vw.png) (pristupljeno: 19.7.2023)
10. Baheti Pragati. "Tanh function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)

11. Baheti Pragati. "ReLU function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> . (pristupljeno 19.7.2023.)
12. Baheti Pragati. "Leaky function" funkcija": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
13. Baheti Pragati. "ELU function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
14. Baheti Pragati. "SELU function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
15. Baheti Pragati. "Softmax function": Activation Functions in Neural Networks. V7 Labs. [Website]. 2021. <https://www.v7labs.com/blog/neural-networks-activation-functions> (pristupljeno 19.7.2023.)
16. Medium [online fotografija], [https://encrypted-tbn2.gstatic.com/images?q=tbn:ANd9GcT6hCYYUF3WqWhTMihJEJZDD8GfNAUDcIP\\_m85KYnp085C6Fx9D](https://encrypted-tbn2.gstatic.com/images?q=tbn:ANd9GcT6hCYYUF3WqWhTMihJEJZDD8GfNAUDcIP_m85KYnp085C6Fx9D) (pristupljeno: 19.7.2023)
17. V7 [online fotografija], [https://encrypted-tbn3.gstatic.com/images?q=tbn:ANd9GcRYk-Lc49PCjPW3Is4WYu\\_UB9vZihSssK8Ejr1P05Fbv7LGlUqY](https://encrypted-tbn3.gstatic.com/images?q=tbn:ANd9GcRYk-Lc49PCjPW3Is4WYu_UB9vZihSssK8Ejr1P05Fbv7LGlUqY) (pristupljeno: 19.7.2023)
18. Goodfellow, Ian, Yoshua Bengio, i Aaron Courville. "Regularization for Deep Learning" U: Deep Learning, 224. stranica. MIT Press, 2016.
19. Goodfellow, Ian, Yoshua Bengio, i Aaron Courville. "Parameter Regularization" U: Deep Learning, 227-268. stranica. MIT Press, 2016.
20. Analytics Vidhya, Understanding Loss Function in Deep Learning, [website], 2022, <https://www.analyticsvidhya.com/blog/2022/06/understanding-loss-function-in-deep-learning> (pristupljeno 19.7.2023.)
21. Citalli Gamez Serna, Yassine Ruichek (218), Relation of classes and total number of traffic signs by country, ). Clasification of Traffic Sign: The European Dataset, <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8558481> (Pristupljeno 17. srpnja 2023).
22. Citalli Gamez Serna, Yassine Ruichek (218). Clasification of Traffic Sign: The European Dataset, 6.str [PDF]

<https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8558481> (Pristupljeno 17. srpnja 2023).

23. Jonas Teuwena, Nikita Moriakova (2020). Convolutional neural networks, 2.str [PDF] [https://www2.cs.uh.edu/~ceick/ai/CNN\\_Reading\\_Material.pdf](https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf) (Pristupljeno 17. srpnja 2023).

24. Datacamp, Convolutional Neural Networks in Python with Keras, [website], 2017., <https://www.datacamp.com/tutorial/convolutional-neural-networks-python> (pristupljeno 19.7.2023.)

## 8. Popis slika

- Slika 1: Graf sigmoid funkcija i matematička formula
- Slika 2: Graf Tanh(x) funkcija i matematička formula
- Slika 3: Graf ReLU funkcija i matematička formula
- Slika 4: Graf Leaky ReLU funkcija i matematička formula
- Slika 5: Graf ELU funkcija i matematička formula
- Slika 6: Graf SELU funkcija i matematička formula
- Slika 7: Prikaz grafova aktivacijskih funkcija
- Slika 8: Prikaz klasa i broj znakova u datasetu
- Slika 9: Kategorije znakova
- Slika 10: Spremanje slika za trening skup Njemačke
- Slika 11: Neuronska mreža u pythonu
- Slika 12: Parametri mreže
- Slika 13: Fit generator
- Slika 14: Trening Njemačka i test Njemačka
- Slika 15: Trening Njemačka i test Hrvatska
- Slika 16: Trening Njemačka i test Belgija
- Slika 17: Trening Njemačka i test Francuska
- Slika 18: Trening Njemačka i test Švedska
- Slika 19: Trening Hrvatska i test Hrvatska
- Slika 20: Trening Hrvatska i test Njemačka
- Slika 21: Trening Hrvatska i test Belgija
- Slika 22: Trening Hrvatska i test Francuska
- Slika 23: Trening Hrvatska i test Švedska
- Slika 24: Trening Belgija i test Belgija
- Slika 25: Trening Belgija i test Njemačka
- Slika 26: Trening Belgija i test Hrvatska
- Slika 27: Trening Belgija i test Francuska
- Slika 28: Trening Belgija i test Švedska
- Slika 29: Trening Francuska i test Francuska
- Slika 30: Trening Francuska i test Njemačka
- Slika 31: Trening Francuska i test Hrvatska
- Slika 32: Trening Francuska i test Belgija
- Slika 33: Trening Francuska i test Švedska
- Slika 34: Trening Švedska i test Švedska
- Slika 35: Trening Švedska i test Njemačka
- Slika 36: Trening Švedska i test Hrvatska
- Slika 37: Trening Švedska i test Belgija
- Slika 38: Trening Švedska i test Francuska
- Slika 39: Usporedni graf rezultata točnosti po državama
- Slika 40: Rezultati trening Njemačka i test ostale zemlje
- Slika 41: Rezultati trening Hrvatska i test ostale zemlje
- Slika 42: Rezultati trening Belgija i test ostale zemlje
- Slika 43: Rezultati trening Francuska i test ostale zemlje
- Slika 44: Rezultati trening Švedska i test ostale zemlje

## 9. Popis tablica

Tablica 1: Znakovi u klasi 017

Tablica 2: Znakovi u klasi 021

Tablica 3: Znakovi u klasi 032

Tablica 4: Znakovi u klasi 035

Tablica 5: Znakovi u klasi 036

Tablica 6: Znakovi u klasi 037

Tablica 7: Znakovi u klasi 050

Tablica 8: Znakovi u klasi 059

Tablica 9: Rezultati točnosti Njemačka

Tablica 10: Rezultati točnosti Hrvatska

Tablica 11: Rezultati točnosti Belgija

Tablica 12: Rezultati točnosti Belgija povećani trening podaci

Tablica 13: Rezultati točnosti Francuska

Tablica 14: Rezultati točnosti Francuska povećani trening podaci

Tablica 15: Rezultati točnosti Švedska

Tablica 16: Rezultati točnosti Švedske povećani trening podaci

Tablica 17: Usporedni prikaz svih rezultata po državama