

**ОБРАДА СЛИКЕ ПОМОЋУ TENSORFLOW И КОНВОЛУЦИЈСКИХ НЕУРОНСКИХ МРЕЖА****IMAGE PROCESSING USING TENSORFLOW AND CONVOLUTIONAL NETWORKS**Петар Цанић, Факултет техничких наука, *Нови Сад***Област – ЕЛЕКТРОТЕХНИЧКО И РАЧУНАРСКО ИНЖЕЊЕРСТВО**

**Кратак садржај:** – *Машинско учење доживљава значајан пораст и примену у широком спектру проблема различитих индустрија. Исправан рад техничко-технолошког система са камером који користи технологије машинског учења захтева прецизно препознавање слика. Тренутни проблем у индустрији се дефинише као класификациони проблем у машинском учењу који зависи од количине и обраде података, сложености система као и других параметара.*

**Кључне речи:** *Неуронске мреже, конволуционе мреже, модели неуронске мреже, препознавање слика*

**Abstract** – *Machine learning is experiencing significant growth and application across a broad spectrum of problems in various industries. The proper functioning of a technical-technological system with a camera that uses machine learning technologies requires accurate image recognition. The current issue in the industry is defined as a classification problem in machine learning, which depends on the amount and processing of data, the complexity of the system, and other parameters.*

**Keywords:** *Neural networks, Convolutional Neural Networks, neural network models, image recognition*

**1. УВОД**

У општој употреби, израз "вештачка интелигенција" означава програм који опонаша људско учење и размишљање. Неке ствари које повезујемо са другим стварима, као што су учење и решавање проблема, могу да ураде компјутери, али не на исти начин као људи - способност система да правилно тумачи податке, да учи из таквих података и да користи та учења за постизање специфичних циљева и задатака кроз флексибилно прилагођавање [1].

Приликом брзог развијања поља вештачких интелигенција (AI) и машинског учења, Tensorflow се појавио као практична библиотека. Развио га је Google Brain, Tensorflow је оквир за учење који је стекао распрострањену популарност. Обезбеђује флексибилну и променљиву платформу за изградњу, обуку и примену модела за учење машина, посебно неуронских мрежа. Једна од најважнијих примена Tensorflow-а јесте препознавање слика, где се модели могу обучити да разумеју и тумаче визуелни свет [1].

**Напомена:**

**Овај рад проистекао је из мастер рада чији ментор је био проф. др Александар Селаков**

**2. АРХИТЕКТУРА CNN-а**

Конволуцијск мрежа састоје се од више слојева, од којих сваки има одређену улогу у препознавању образаца. Кључни слојеви у типичној CNN архитектури укључују:

- **Улазни слој:** улазни слој прихвата вредности пиксела слике. Димензије овог слоја одговарају висини, ширини и каналима боја слике слике (нпр. црвена, зелена, плава за RGB слике).
- **Слојеви конволуције:** конволуционални слојеви су основни блокови CNN-а. Састоје се од скупа филтера који се могу учити (називају се и језгра) који скенирају преко слике уноса да би се издвојили локални обрасци и функције. Конволуциони слојеви могу да имају више филтера, производећи скуп мапа функција [2].
- **Слојеви за активацију:** након операције конволуције, примењује се функција за активацију (обично RELU) да би се у модел увела нелинеарност. Ово омогућава мрежи да научи сложене релације у подацима [2].
- **Слојеви за смањивање:** ови слојеви служе за смањивање просторне димензије (ширина и висина) док задржавају основне информације. Служи да се смањи комплетна сложеност мреже и чини је робуснијом за варијације у уносу.
- **Потпуно повезани слојеви:** потпуно повезани слојеви су традиционални неурални мрежни слојеви где је сваки неурон повезан са сваким неуроном у претходним и напредним слојевима [2].
- **Излазни слој:** излазни слој даје коначно предвиђање или резултат класификације. У препознавању слике, излазни слој често има неуроне који одговарају различитим класификацијама предмета на сликама (на пример, за класификацију објеката на сликама).

### 3. КЉУЧНИ КОНЦЕПТИ И ПРЕДНОСТИ

#### 3.1 Хијерархијско учење

CNN-ови уче хијерархијске приказе функција. Доњи слојеви откривају основне карактеристике попут ивица и текстура, док виши слојеви науче сложеније обрасце и делове објекта.

Овај хијерархијски приступ чини CNN-ове веома ефективним у хватању комплексних детаља у сликама.

У конволуционим слојевима исте тежине филтера примењују се на различите просторне позиције у уносу. Ово дељење тежине у великој броју смањује број параметара у поређењу са потпуно повезаним мрежама, нудећи CNN-ове компатибилно ефикасним.

#### 3.2 Инваријација

CNN су инхерентно преводилачки инваријантни, што значи да могу да препознају обрасце без обзира на њихову позицију на слици. Ово својство их чини погодне за задатке попут откривања објеката и класификације слика [3].

#### 3.3 Унапред обучени модели

За разне задатке препознавања слика доступни су CNN модели, као што су VGG, ResNet. Ови модели су обучени на великим скуповима података и могу се прецизно подесити за одређене апликације, уштедети значајно време обуке и ресурсе.

### 4. НЕКОЛИКО КЉУЧНИХ ТАЧАКА О ВИШЕКЛАСНОЈ КЛАСИФИКАЦИЈИ

У вишекласној класификацији, постоје три или више међусобно искључивих класа или категорија којима алгоритам мора доделити сваку тачку улазних података. Ове класе могу представљати различите исходе, ознаке или класе, у зависности од конкретног проблема који се решава. На пример, може се користити за класификацију слика животиња у категорије као што су "мачка", "пас", "коњ", "слон" итд.

Уобичајени примери проблема са класификацијом у више класа укључују категоризацију текста (додељивање докумената вишеструким темама или категоријама), препознавање слика (идентификовање објеката или објеката на сликама) и медицинску дијагнозу (класификовање болести у различите категорије)

Излаз вишекласног модела класификације је типично дистрибуција вероватноће на све могуће класе за дату тачку улазних података. Свакој класи се додељује оцена вероватноће, а класа са највећом вероватноћом сматра се предвиђеном класом за ту тачку података.


Функција губитка: у обуци модела класификације са више класа, функција губитка (често губитак унакрсне ентропије) се користи за мерење разлике између предвиђених вероватноћа и стварних ознака класе. Параметри модела се прилагођавају током тренинга како би се минимизирао овај губитак.

Метрике евалуације: уобичајене метрике евалуације за вишекласну класификацију укључују тачност

(пропорција исправно класификованих инстанци), прецизност, опозив, F1-скор и матрице конфузије. Ове метрике помажу у процени перформанси модела и његове способности да разликује различите класе.

Алгоритми: различити алгоритми машинског учења могу се користити за класификацију у више класа, укључујући логистичку регресију, стабла одлучивања, насумичне шуме, машине за подршку векторима, к-најближе суседе и технике дубоког учења као што су неуронске мреже.

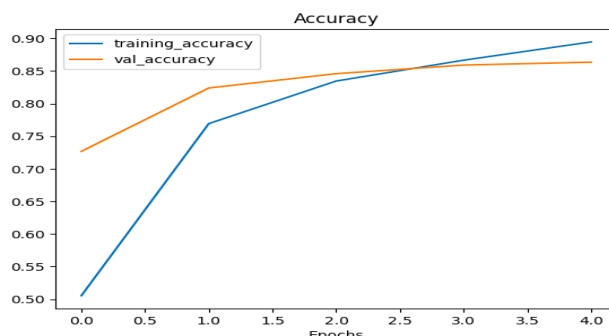
### 5. ПОНАШАЊЕ ДВА МОДЕЛА ПРЕУЗЕТА СА Tensorflow-Hub-a



СЛИКА 1 ГРАФИЧКИ ПРИКАЗ ПРЕДИКЦИЈЕ МОДЕЛА 1

```
Epoch 1/5 [=====] - 28s 680ms/step - loss: 1.7915 - accuracy: 0.3880 - val_loss: 1.1463 - val_accuracy: 0.6368
24/24 [=====] - 14s 620ms/step - loss: 0.8710 - accuracy: 0.7560 - val_loss: 0.8359 - val_accuracy: 0.7352
Epoch 2/5 [=====] - 14s 618ms/step - loss: 0.6160 - accuracy: 0.8373 - val_loss: 0.7385 - val_accuracy: 0.7676
Epoch 3/5 [=====] - 15s 624ms/step - loss: 0.4705 - accuracy: 0.8907 - val_loss: 0.7016 - val_accuracy: 0.7728
24/24 [=====] - 15s 606ms/step - loss: 0.3744 - accuracy: 0.9209 - val_loss: 0.6764 - val_accuracy: 0.7772
```

СЛИКА 2 ПРИКАЗ ПРОМЕНЕ ПАРАМЕТАРА ЗА МОДЕЛ 1 КРОЗ ЕПОХЕ



СЛИКА 3 ГРАФИЧКИ ПРИКАЗ ПРЕДИКЦИЈЕ МОДЕЛА 2

```
Epoch 1/5 [=====] - 26s 693ms/step - loss: 1.7622 - accuracy: 0.5053 - val_loss: 1.2434 - val_accuracy: 0.7268
24/24 [=====] - 15s 634ms/step - loss: 1.0120 - accuracy: 0.7693 - val_loss: 0.8459 - val_accuracy: 0.8240
Epoch 2/5 [=====] - 15s 642ms/step - loss: 0.7289 - accuracy: 0.8347 - val_loss: 0.6823 - val_accuracy: 0.8460
Epoch 3/5 [=====] - 15s 637ms/step - loss: 0.5871 - accuracy: 0.8667 - val_loss: 0.6004 - val_accuracy: 0.8592
24/24 [=====] - 14s 620ms/step - loss: 0.5813 - accuracy: 0.8947 - val_loss: 0.5504 - val_accuracy: 0.8636
```

СЛИКА 4 ПРИКАЗ ПРОМЕНЕ ПАРАМЕТАРА ЗА МОДЕЛ 2 КРОЗ ЕПОХЕ

Слике изнад прате како се перформансе модела мењају са сваком епохом обуке. Види се да се губитак модела смањује и његова прецизност расте и на скуповима података за обуку и валидацију, што је позитиван знак учења.

Скуп податак коришћен за обуку модела је прилагођен скуп ради бржег напретка и евалуације модела узете су све категорије али свака категорија садржи само 10% података (поступак је одрађен само

на тренинг подацима), јер је модел трениран на великом скупу података и тиме ћемо само мало променити његове параметре и биасе.

Овај код обучава модел на смањеном скупу података (10% података за обуку) и бележи напредак обуке.

Уобичајена је пракса да се у почетку обучи модел на мањем подскупу података ради бржег експериментисања пре обучавања на целом скупу података ако архитектура модела и хиперпараметри изгледају обећавајуће.

Укупно, оба параметра `accuarcy` и `val_accuarcy` расту кроз сваку епоху, што указује на то да се модел успешно прилагођава тренинг подацима и да има способност за генерализацију на новим подацима. Растући `val_accuarcy` у исто време са `accuarcy` представља позитиван знак и указује на добре перформансе модела.

Модел успешно предвиђа 85%, на мањем скупу података. Побољшање модела је могуће ако повећамо скуп података и тако да модел може да направи више шаблона за препознавање, одмрзавање последњих слојева тако да се поново израчунају на тренутни сет података за разлику од тренираног сета.

Поређењем ова два претходна лога могу се закључити, оба лога су са сличним вредностима `accuarcy` и `val_accuarcy` у првој епохи. У оба лога `accuarcy` на тренинг скупу се постепено повећава кроз сваку епоху, што указује на то да се модел успешно прилагођава тренинг подацима.

Што се тиче `val_accuarcy` на валидационом скупу, оба лога такође показују повећавање кроз епохе, што указује на способност модела да општује на новим подацима.

Први лог има ниже почетне вредности `accuarcy` и `val_accuarcy`, али успева да достигне сличне вредности као и други лог након неколико епоха обучавања. У оба случаја, модели се успешно прилагођавају и показују способност за опште предвиђање на валидационом скупу, што је пожељно својство.

## 6. ЗАКЉУЧАК

У закључку, `Tensorflow`, широко коришћена библиотека машинског учења коју је развио `Google`, вешта је у препознавању слика путем конволуционих неуронских мрежа (`CNN`). `CNN` су специјализована класа модела дубоког учења дизајнираних за задатке у вези са сликама, као што су класификација слика, детекција објеката и сегментација слике. `Tensorflow` пружа робустан оквир за имплементацију и обуку `CNN`-а за обављање задатака препознавања слика са изузетном тачношћу.

`CNN` користе хијерархијску архитектуру која се састоји од више слојева конволуционих и операција удруживања. Ови слојеви уче да аутоматски издвајају и идентификују значајне карактеристике из улазних слика, као што су ивице, текстуре и узорци. Дубљи слојеви постепено хватају апстрактније и сложеније репрезентације, омогућавајући мрежи да препозна

визуелне концепте високог нивоа као што су објекти, облици и структуре.

`Tensorflow` поједностављује креирање `CNN` модела нудећи `API` високог нивоа који апстрахује многе детаље имплементације ниског нивоа. Програмери могу са лакоћом да дефинишу мрежну архитектуру, конфигуришу хиперпараметре и користе различите технике оптимизације. Штавише, `Tensorflow` подржава оба модела обуке од нуле и коришћење унапред обучених модела путем трансферног учења, омогућавајући ефикасно препознавање широког спектра категорија слика.

У практичном смислу, процес препознавања слике помоћу `Tensorflow`-а и `CNN`-а обично укључује претходну обраду података, избор модела и прилагођавање, обуку о означеним скуповима података, валидацију и фино подешавање да би се постигле жељене перформансе. `Tensorflow` такође нуди алате за оптимизацију модела, њихово примену у реалним апликацијама и предвиђање нових, неозначених слика.

Укратко, `Tensorflow`, са својом подршком за `CNN`, представља моћан алат за задатке препознавања слика, омогућавајући програмерима да искористе могућности *deep-learning-a* како би аутоматски и прецизно идентификовали објекте и обрасце унутар слика, утирући пут широком спектру апликација. у областима као што су компјутерски вид, здравство, аутономна возила и још много тога.

## 7. ЛИТЕРАТУРА

[1] “TensorFlow” доступно:

<https://en.wikipedia.org/wiki/TensorFlow#Features> приступано: август-2023

[2] “Learn Convolutional Neural Network (CNN) in your browser!” доступно: <https://poloclub.github.io/cnn-explainer/>, приступано: октобар-2023

[3] “Deep learning” доступно:

[https://en.wikipedia.org/wiki/Deep\\_learning](https://en.wikipedia.org/wiki/Deep_learning), приступано: октобар-2023

### Кратка биографија:



**Петар Цанић** рођен је у Новом Саду 2000. године. Основне академске студије на Факултету техничких наука Универзитета у Новом Саду уписао је 2018. године. Дипломирао је 27.09.2022. године и исте године уписао је мастер академске студије . Контакт : [petar.canic55@gmail.com](mailto:petar.canic55@gmail.com)