

**PRIMENA KONVOLUCIONIH NEURONSKIH MREŽA ZA DETEKCIJU BOLESTI PNEUMONIJE NAD PACIJENTIMA****APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS FOR DETECTION OF PNEUMONIA DISEASE IN PATIENTS**

Dimitrije Stojanov, *Fakultet tehničkih nauka, Novi Sad*

**Oblast – RAČUNARSTVO I AUTOMATIKA**

**Kratak sadržaj** – U radu je prikazana primena konvolucionih neuronskih mreža u detekciji bolesti pneumonije kod pacijenata. Objasnjene su osnove neuronskih mreža i kako one funkcionišu. Detaljno je prikazan proces i tehnologije koje se koriste u obradi i analizi slika. Skup podataka, javno dostupan, sastoji se od rendgen snimaka grudnog koša i korišćen je u istraživanju. U radu su prikazane dve arhitekture konvolucionih neuronskih mreža i njihovi rezultati klasifikacije upoređeni su sa rezultatima drugih radova.

**Ključne reči:** Konvolucione neuronske mreže, veštačka inteligencija, obrada i analiza slika, klasifikacija slika.

**Abstract** – This paper shows the application of convolutional neural networks in detection of pneumonia in patients. Basics of neural networks and how they work are explained. The process and technologies used in image processing and analysis are shown in detail in this paper. The dataset, publicly available, consists of chest x-rays and was used in the research. The paper presents two architectures of convolutional neural networks and their classification results are compared with the results of other research.

**Keywords:** Convolutional neural networks, artificial intelligence, image processing and analysis, image classification.

**1. UVOD**

Pneumonija je zapaljenje tkiva u plućima uzrokovanom bakterijskom infekcijom. Svake godine milioni ljudi širom sveta završe u bolnici zbog pneumonije. Srećom, ova bolest može biti izlečena upotrebom antibiotika i antivirusnih lekova. Važno je da se pneumonija rano dijagnostikuje i leči kako bi se izbegle komplikacije koje mogu dovesti do smrti pacijenta. Rendgenski snimci pluća su najčešći način dijagnostikovanja pneumonije, ali čak i stručni radiolozi često imaju izazove u identifikaciji bolesti na tim snimcima. To je zbog toga što slika pneumonije može biti nejasna, lako se može pomešati s drugim bolestima i može izgledati kao benigna abnormalnost. Zbog ovih nedoslednosti, dijagnoza pneumonije varira među radiolozima.

Zato je potrebno razviti sistem podrške koji bi pomogao radiolozima u dijagnostikovanju pneumonije na osnovu rendgenskih snimaka pluća. Razvoj dubokog učenja,

posebno konvolucionih neuronskih mreža (CNN), pokazao je veliki uspeh u klasifikaciji slika. Glavna ideja iza CNN mreža je stvaranje veštačkog modela sličnog ljudskom mozgu. CNN mreže imaju sposobnost da izdvoje značajne karakteristike iz celokupne slike. One su se pokazale korisnim ne samo u rešavanju problema kompjuterskog vida, već i u medicini. Na primer, CNN mreže su uspešno korišćene za prepoznavanje raka dojke, detekciju tumora mozga, dijagnostikovanje Alchajmerove bolesti, klasifikaciju kožnih lezija i drugo. Implementacija ovakvog sistema mogla bi pomoći lekarima u dijagnostikovanju pneumonije. Trenutno, ovi modeli ne mogu zameniti ljudski faktor u dijagnozi, ali imaju potencijal da to jednog dana učine.

U ovom radu je prikazana primena konvolucionih neuronskih mreža za detekciju bolesti pneumonije kod rendgen snimaka pacijenata. Objasnjene su teorijske osnove neuronskih mreža i kako one funkcionišu. Detaljno su prikazane tehnologije i proces obrade i analize slika. U radu su prikazane dve arhitekture konvolucionih neuronskih mreža. Krenirani modeli su klasifikatori koji bi na osnovu priuštenih rendgen snimaka davali odgovor da li je pacijent oboleo od bolesti pneumonije ili je zdrav. Rezultati klasifikacije poređeni su sa rezultatima iz radova koji se bave istom ovom temom.

**2. TEORIJSKI POJMOVI I DEFINICIJE****2.1. Veštačke neuronske mreže**

Neuronske mreže (NN) su efikasni sistemi za informaciono procesiranje koji se koriste za rešavanje problema poput aproksimacija funkcija, klasifikacije oblika, optimizacije i klasterizacije. Veštačke neuronske mreže (ANN) se neprestano razvijaju i poboljšavaju kako bi povećale tačnost i efikasnost u raznim primenama. Bez obzira na oblik, ulaz u ANN predstavlja niz vrednosti koje se obrađuju, a u daljem tekstu će biti objašnjeni osnovni koncepti dubokog učenja i arhitekture ANN [3].

**2.2. Osnovne komponente veštačkih neuronskih mreža**

Osnovni elementi neuronskih mreža su neuroni, veze, težine i funkcija propagacije.

Veštačke neuronske mreže simuliraju biološke neurone u mozgu i sastoje se od neurona koji primaju ulaze i prenose informacije drugim neuronima. Ulazi mogu biti podaci poput slika ili teksta, a izlaz poslednjeg neurona predstavlja krajnji rezultat kao klasifikacija ili prepoznavanje. Ulazni signali se množe sa težinama veza i obrađuju aktivacionom funkcijom kako bi se dobio izlaz.

**NAPOMENA:**

Ovaj rad proistekao je iz master rada čiji mentor je bila prof. dr Jelena Slivka.


### 2.3. Vrste neuronskih mreža

Veštačke neuronske mreže koriste različite organizacije neurona kako bi se rešavali različiti zadaci. To uključuje različite strukture konekcija između neurona, poput veza sa svim neuronima u sledećem sloju ili samo sa određenim neuronima. Postoji više popularnih arhitektura, kao što su višeslojni perceptron, konvolutivne neuronske mreže, rekurentne neuronske mreže, LSTM, GRU.

### 2.4. Konvolucione neuronske mreže


Arhitekture neuronskih mreža mogu biti potpuno povezane, gde su svi neuroni jednog sloja povezani sa svim neuronima sledećeg sloja, ili lokalno povezane, gde se koristi princip lokalne povezanosti neurona. Konvolucione neuronske mreže (CNN) su specifična vrsta mreže koja se često koristi u obradi i analizi slika. Ona omogućava efikasno prepoznavanje karakteristika i šablona u podacima, jer koristi organizaciju slojeva za tu svrhu. Kroz proces treniranja, težine konekcija se prilagođavaju kako bi mreža mogla da prepozna slike ili šablone koje joj se prezentuju.

Konvolucione neuronske mreže (CNN) se sastoje od nekoliko slojeva koji uključuju konvolucione slojeve, slojeve za udruživanje, potpuno povezane slojeve i izlazni sloj, slika 1. Ova arhitektura može se razlikovati u rasporedu i kombinaciji ovih slojeva, a to je ključna razlika u odnosu na višeslojne perceptrone [4].



Slika 1. Prikaz modela konvolucione neuronske mreže [8]

Konvolucioni sloj u neuronskoj mreži koristi lokalnu obradu podataka u dvo-dimenzionalnom formatu. Skriveni neuroni u ovom sloju koriste konvolucione kernele (filtre) koji se primenjuju na mali deo podataka iz prethodnog sloja. Ovo omogućava stvaranje mapa karakteristika za različite filtere u konvolucionom sloju.




Slika 2. Prikaz konvolucionog sloja CNN mreže

Slojevi za udruživanje (pooling) koriste se za smanjenje dimenzionalnosti tako što grupišu susedne ćelije mape karakteristika [5]. Uobičajene operacije udruživanja uključuju maksimalno ili prosečno uzimanje vrednosti. Efekti pooling operacija prikazani su na slici 3.

## 3. METODOLOGIJA


### 3.1. Skup podataka

Skup podataka sastoji se od 5856 slika raspoređenih u grupe za obuku, testiranje i validaciju.



Slika 3. Prikaz operacije pooling sloja CNN

Skup za obuku sadrži 5216 slika od kojih 3834 su renden snimci pluća pacijenata koji boluju od pneumonije a 1300 snimaka zdravih pacijenata. Skup podataka preuzet je sa sajta kaggle.com pod nazivom Chest X-Ray Images (Pneumonia). Podaci u obliku slika su različitih dimenzija. Slike su tipa JPEG fajla. Veličina fajlova varira od 50 KB do 2350 KB. Primer slika korišćenik za obuku i testiranje može se videti na slici 4.



Slika 4. Zdrava pluća pacijenta naspram pluća pacijenta obolelog od pneumonije

Primećuje se neuravnoteženost podataka između dve navedene klase tako da će se augmentacijom podataka, kasnije navedenom u radu, skup podataka za obuku izbalansirati. Navedene slike su različitih rezolucija i predprocesiranjem dovedene su sve na istu rezoluciju. Ulaz sistema predstavljaju trodimenzionalne matrice  $224 \times 224 \times 3$ . Za implementaciju sistema korišćena je konvoluciona neuronska mreža. Sistem je obučen za binarnu klasifikaciju slika, odnosno klasifikuje da li je pacijent čiji je rendgen snimak stigao na obradu oboleo od bolesti pneumonije ili nije.

### 3.2. Augmentacija podataka

Augmentacija podataka je moćan alat koji se koristi za povećanje robustnosti modela, posebno kada su skupovi podataka neuravnoteženi. Ona uključuje primenu različitih transformacija nad originalnim slikama, kao što su rotacija, pomeranje, flipovanje, promena svetlosti i zumiranje. Klasa ImageDataGenerator u okviru Keras biblioteke omogućava jednostavno i brzo generisanje augmentiranih slika, čime se obezbeđuje veća varijabilnost u skupu podataka i bolja generalizacija modela. Glavna prednost ove klase je što pruža augmentaciju podataka u realnom vremenu tokom faze obuke, obezbeđujući da model dobije nove varijacije slika u svakoj epohi, a istovremeno štedeći memoriju učitavanjem slika u grupama.

### 3.3. Arhitektura neuronske mreže

Za implementaciju rešenja korišćena je konvoluciona neuronske mreže. Konvolucione neuronske mreže (CNN-ovi) postale su najnaprednija tehnologija za prepoznavanje slika i uspešno se primenjuju u širokom spektru zadataka kompjuterske vizije. Ključne prednosti upotrebe CNN-ova koje su dovele do odabira ove

arhitekture su: prostorna invarijantnost, hijerarhijsko predstavljanje, smanjenje parametrizacije, transfer učenje i visoka tačnost [7].

### 3.4. Funkcija gubitka

Funkcija gubitka koja je korišćena u istraživanju je Binary Cross-Entropy Loss. U mašinskom učenju, funkcija gubitka je matematička funkcija koja meri razliku između predviđenog izlaza modela i stvarnog izlaza. Cilj funkcije gubitka je da minimizuje ovu razliku tokom procesa obuke. Binary Cross-Entropy Loss je funkcija gubitka koja se koristi u problemima binarne klasifikacije.

### 3.5. Model

Konvolucione neuronske mreže se ističu kod obrade podataka koji imaju prostornu strukturu. Zato se najčešće koriste kod obrade i analize slika. U istraživanju korišćene su dve arhitekture konvolucione neuronske mreže. Obe arhitekture sačinjene su od ulaznih slojeva, konvolucionih slojeva (Conv2D), pooling sloja (MaxPooling2D), Flatten, Dense i Dropout sloja. Dve arhitekture se razlikuju u svojoj kompleksnosti.

## 4. PREGLED STANJA U OBLASTI

U rešenju [1] korišćen je isti skup podataka koji će se upotrebiti za izradu rešenja u ovom radu. Korišćene su već istrenirane konvolucione neuronske mreže, Xception i Vgg16 koje su obučavane na poznatom skupu podataka ImageNet. Kao metrike za evaluaciju korišćeni su tačnost, osetljivost, specifičnost, povrat, preciznost i F1 mera. Rezultati ove dve mreže prikazani su u tabeli 1.

Tabela 1. Rezultati istraživanja rada [1]

	Accuracy	Sensitivity	Specificity	Precision	Recall	F1 score
Xception	0.82	0.85	0.76	0.83	0.86	0.83
VGG16	0.87	0.82	0.91	0.89	0.88	0.88

U radu [2] takođe je korišćen isti skup podataka koji je korišćen za izradu rešenja u ovom radu. Karakteristike iz slike se izdvajaju korišćenjem modela neuronskih mreža unapred obučanih pomoću ImageNet. Pripremljeno je pet različitih modela i analizirane su njihove performanse, gde je peti model kombinacija rezultata svih prethodno obučanih modela. Obučeni modeli su dali sledeće rezultate, AlexNet je postigao tačnost od 92.86%, dok je ResNet18 pokazao najveće performanse od 94.23%. DenseNet121 (tačnost 92.62%), InceptionV3 (tačnost 92.01%) i GoogLeNet (tačnost 93.12%) takođe su pokazale odlične rezultate. Kombinovanjem ovih modela postignuta je najveća tačnost od 96.39%.

## 5. EKSPERIMENTI

### 5.1. Eksperiment 1

Prvi model CNN1 sačinjen je od ulaznog sloja, praćenim sa kombinacijom dva konvoluciona sloja i jednim pooling slojem. Konvolucioni slojevi sadrže po 64 filtera dimenzija 3x3 i aktivacionu funkciju relu.

Hiper-parametri u pooling sloju su postavljeni na 2, 2. Veličina 2x2 pomaže u smanjenju prostornih dimenzija ulaznih mapa obeležja za faktor 2, dok se i dalje zadržavaju najvažnije informacije. Na ova četiri sloja nadovezana su još dva konvoluciona sloja praćena sa još jednim pooling slojem. Konvolucioni slojevi ovog puta sadrže po 128 filtera takođe dimenzija 3x3 i aktivacionom

funkcijom relu. Pooling sloj ima veličinu 2x2. Sledeći korišćeni sloj je Flatten a potom kombinacija Dense i Dropout slojeva. Prvi Dense sloj sadrži 512 neurona sa aktivacionom funkcijom relu. Sledi Dropout sloj sa stopom opadanja od 0.7, što zači da postoji 70% šanse da neuron bude ispušten tokom obuke. Drugi Dense sloj se sastoji od 256 neurona sa takođe relu aktivacionom funkcijom. Dropout sloj koji sledi ima stopu padanja od 0.5 i nadovezuje se na poslednji Dense sloj sa 2 neurona i aktivacionom funkcijom softmax.

```
input_img = Input(shape=train_batch.image_shape, name='ImageInput')
x = Conv2D(64, (3, 3), activation='relu', padding='same')(input_img)
x = Conv2D(64, (3, 3), activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = Conv2D(128, (3, 3), activation='relu', padding='same')(x)
x = Conv2D(128, (3, 3), activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = Flatten(name='Flatten')(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.7)(x)
x = Dense(256, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(2, activation='softmax')(x)
model = Model(inputs=input_img, outputs=x)
```

Slika 5. Arhitektura prvog modela CNN

### 5.2. Eksperiment 2

Drugi model CNN2 ima jednostavniju strukturu. Ulazni sloj praćen kombinacijama konvolucionih slojeva i pooling slojeva. Prvi konvolucioni sloj sastoji se od 32 filtera, veličinim kernel od 3x3 i aktivacionom funkcijom relu. Sledi MaxPooling2D sloj veličine 2x2. Drugi konvolucioni sloj sadrži 64 filtera i ima istu veličinu i aktivacionu funkciju kao i prvi sloj. Drugi pooling sloj identičan je prvom. Poslednji Conv2D sloj takođe sadrži 64 filtera veličinu kernela od 3x3 i relu aktivacionu funkciju. Sledi Flatten sloj i dva Dense sloja. Prvi Dense sloj sadrži 64 neurona sa relu aktivacionom funkcijom. Drugi Dense sloj se sastoji od dva neurona i softmax kao aktivacionu funkciju. Primer druge arhitekture konvolucione neuronske mreže prikazan je na slici 6.

```
input_img = Input(shape=train_batch.image_shape, name='ImageInput')
x = Conv2D(32, (3, 3), activation='relu', padding='same')(input_img)
x = MaxPooling2D((2, 2))(x)
x = Conv2D(64, (3, 3), activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = Conv2D(64, (3, 3), activation='relu', padding='same')(x)
x = Flatten(name='flatten')(x)
x = Dense(64, activation='relu')(x)
x = Dense(2, activation='softmax')(x)
model = Model(inputs=input_img, outputs=x)
```

Slika 6. Arhitektura drugog modela CNN

### 5.3. Evaluacija

Korišćene su metrike koje rade evaluaciju rezultata tačnosti klasifikatora. Da bi pravilno izvršili evaluaciju modela uvode se četiri pojma koji karakterišu rezultate klasifikacije: stvarni pozitiv, stvarni negativ, lažni pozitiv, lažni negativ. Pomoću navedenih izračunatih vrednosti dobijamo neke od metrika koji se koriste za evaluaciju modela za klasifikaciju. Korišćeni metrice u ovom radu su: tačnost, preciznost, povrat i F1 mera [6].

## 6. REZULTATI I DISKUSIJA

Rezultati metrika evaluacije binarnog klasifikatora prikazani su u tabelama ispod. U tabeli 2 izdvojena je tačnost dva modela nad podacima iz skupa za obuku i nad podacima skupa za evaluaciju. Tabela 3 predstavlja rezultate metrika poput preciznosti, povrata i F1 mere.



Tabela 2. Tačnost dva modela obučavana u radu

	Test data		Validation data	
	Accuracy	Loss	Accuracy	Loss
Model 1	0.80	<b>0.12</b>	0.87	<b>0.03</b>
Model 2	<b>0.82</b>	0.22	<b>0.92</b>	0.08

Tabela 3. Vrednosti preciznosti, povrata i F1 mere

	Precision	Recall	F1 score
Model 1	0.73	0.98	0.83
Model 2	<b>0.80</b>	<b>0.97</b>	<b>0.87</b>

Model sa jednostavnijom arhitekturom pokazao je veću tačnost na skupu podataka za testiranje i nad validacionim podacima. Kompleksniji CNN modeli obično pokazuju bolje performanse u klasifikaciji. Složeniji modeli mogu naučiti složenije šablone u podacima. Oni imaju veći kapacitet da detektuju suptilnije karakteristike i varijacije među različitim podacima ali su skloniji natprilagođenju što pretpostavljamo da je dovelo do lošijih rezultata kod prvog modela. Jednostavnije arhitekture CNN-a obično imaju manje parametara i manju sposobnost za učenje složenih šablona. Manje parametara pomaže oko sprečavanja prenaučivosti i tako poboljšava performanse sistema.

Tačnost klasifikacije test podataka i validacionih podataka pokazala se kao veoma uspešna. Loss vrednost se pokazala niskom za ova dva modela, ispod 0.1 validacione podatke i oko 0.2 za test podatke. Ove vrednosti pokazuju da istrenirani modeli nisu prilagođeni ili pretrenirani. U radu [1] za model Xception vrednost preciznosti iznosi 0.83, povrata 0.86 i F1 mere 0.83. Za model Vgg16 vrednost za preciznost iznosi 0.89, povrata 0.88 i F1 mere iznosi 0.88. Tačnost Xception modela iznosi 0.82 a Vgg16 modela 0.87. Poredeći navedene rezultate sa rezultatima dobijenim u ovom radu vidimo dosta sličnosti. Vgg16 model je pokazao uspešnijim od dva trenirana modela dok je Xception pokazao slične performanse. Rezultati u radu [2] pokazali su mnogo bolje performanse nego dva modela korišćena u ovom radu.

Svih 5 navedenih modela postigli su tačnost od preko 90%. Najveću tačnost je imao ResNet18 od 94.23% dok je GoogleNet imao preko 93% a AlexNet, DenseNet121 i InceptionV3 imali su oko 92%. Visoka tačnost u klasifikaciji može se objasniti korišćenjem već obučanih neuronskih mreža pomoću ImageNet skupa podataka. Kombinacija ovih pet pređa koja je takođe objašnjena u radu [2] dala je tačnost od preko 96%.

Rezultati klasifikacije dobijeni iz modela koji prelaze 90% mogu se smatrati veoma upešnim i kao takve mogu se koristiti i u polju medicine. Modeli obučeni u ovom radu ne pokazuju dovoljno dobre performanse klasifikacije ovakvih slika da bi potpuno zamenili ljudski faktor ali mogli bi se smatrati podrškom lekarima tokom dijagnostikovanja. Bolje obučeni modelima treniranim na najsavremenijem hardveru mogu se postići bolji rezultati i smanjiti ljudska greška prilikom pregleda pacijenata i dijagnostikovanja raznih bolesti. Modeli obučavani u ovom radu pokazali su određeni stepen greške u klasifikaciji.

Analizirajući skup podataka može se primetiti dosta abnormalnosti kod pacijenata koji su oboleli od pneumonije. Ove razlike među podacima iste klase

klasifikator može tretirati kao šum i da to dovede do pogrešne klasifikacije. Naš cilj je da se što više smanji broj lažno negativnih primera klasifikacije jer su oni najveća pretnja za zdravlje pacijenta.

## 7. ZAKLJUČAK

U ovom radu predstavljen je sistem za klasifikaciju rendgen snimaka grudnog koša pacijenata. Klasifikator je na osnovu snimka davao rezultat, da li je pacijent oboleo od bolesti pneumonije. Ovakvi modeli pokazuju veliki potencijal u medicini kao način dijagnostikovanja ne samo bolesti pneumonije već i mnogih drugih bolesti. Sistemi predstavljeni u ovom radu oslanjaju se na modele konvolucionih neuronskih mreža.

U budućnosti, sa boljim hardverom i bogatijim skupovima podataka, rezultati klasifikacije mogu se još više unaprediti. Daljim napretkom veštačke inteligencije i medicinske tehnologije, očekuje se da će neuronske mreže postati još snažniji alat za podršku zdravstvenim stručnjacima u dijagnostikovanju različitih bolesti.

## 8. LITERATURA

- [1] Ayan, Enes, and Halil Murat Ünver. "Diagnosis of pneumonia from chest X-ray images using deep learning." *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*. IEEE, 2019.
- [2] Chouhan, Vikash, et al. "A novel transfer learning based approach for pneumonia detection in chest X-ray images." *Applied Sciences* 10.2 (2020): 559.
- [3] Sze, Vivienne, et al. "Efficient processing of deep neural networks: A tutorial and survey." *Proceedings of the IEEE* 105.12 (2017): 2295-2329.
- [4] Sang, Jonghee, Soomyung Park, and Junwoo Lee. "Convolutional recurrent neural networks for urban sound classification using raw waveforms." *2018 26th European Signal Processing Conference (EUSIPCO)*. IEEE, 2018.
- [5] Hijazi, Samer, Rishi Kumar, and Chris Rowen. "Using convolutional neural networks for image recognition." *Cadence Design Systems Inc.: San Jose, CA, USA* (2015): 1-12.
- [6] Goutte, Cyril, and Eric Gaussier. "A probabilistic interpretation of precision, recall and F-score, with implication for evaluation." *European conference on information retrieval*. Springer, Berlin, Heidelberg, 2005.
- [7] Alzubaidi, Laith, et al. "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions." *Journal of big Data* 8 (2021): 1-74
- [8] <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

### Kratka biografija:



**Dimitrije Stojanov** rođen je 23.02.1998. godine u Novom Sadu. Osnovne akademske studije završio je 2020 godine na Fakultetu tehničkih nauka nakon kojih upisuje master akademske studije na usmerenju Inteligentni isistemi, studijski program Primjenjene računarske nauke. kontakt: [mitadima@gmail.com](mailto:mitadima@gmail.com)