

Duboko učenje za detekciju upale pluća iz X-ray slika prsnog koša

Ribičić, Ivana

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:609131>

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

Download date / Datum preuzimanja: **2025-01-15**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

Sveučilišni studij

**DUBOKO UČENJE ZA DETEKCIJU UPALE PLUĆA IZ
X-RAY SLIKA PRSNOG KOŠA**

Završni rad

Ivana Ribičić

Osijek, 2023.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju**

Osijek, 06.09.2023.

Odboru za završne i diplomske ispite

Prijedlog ocjene završnog rada na preddiplomskom sveučilišnom studiju

Ime i prezime Pristupnika:	Ivana Ribičić
Studij, smjer:	Računalno inženjerstvo
Mat. br. Pristupnika, godina upisa:	R4561, 27.07.2020.
OIB Pristupnika:	42068874056
Mentor:	prof. dr. sc. Irena Galić
Sumentor:	dr. sc. Marija Habijan
Sumentor iz tvrtke:	
Naslov završnog rada:	Duboko učenje za detekciju upale pluća iz X-ray slika prsnog koša
Znanstvena grana rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak završnog rad:	Istražiti i opisati teorijske osnove obrade slika s naglaskom na problematiku obrade medicinskih slika metodama dubokog učenja kao i formate zapisa medicinskih slika. Istražiti i dati kratak pregled područja prethodnih istraživanja detekcije upale pluća iz X-ray slika prsnog koša i kliničku pozadinu. Opisati teorijske osnove konvolucijskih neuronskih mreža. Razviti sustav za klasifikaciju X-ray
Prijedlog ocjene završnog rada:	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene od strane mentora:	06.09.2023.
Datum potvrde ocjene od strane Odbora:	24.09.2023.
Potvrda mentora o predaji konačne verzije rada:	<i>Mentor elektronički potpisao predaju konačne verzije.</i>
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 25.09.2023.

Ime i prezime studenta:

Ivana Ribičić

Studij:

Računalno inženjerstvo

Mat. br. studenta, godina upisa:

R4561, 27.07.2020.

Turnitin podudaranje [%]:

10

Ovom izjavom izjavljujem da je rad pod nazivom: **Duboko učenje za detekciju upale pluća iz X-ray slika prsnog koša**

izrađen pod vodstvom mentora prof. dr. sc. Irena Galić

i sumentora dr. sc. Marija Habijan

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1. UVOD	1
1.1 Zadatak završnog rada	1
2. TRENUTNE METODE ZA KLASIFIKACIJU X-RAY SLIKA PRSNOG KOŠA ..	3
3. MEDICINSKA I TEHNOLOŠKA POZADINA	4
3.1. Pluća i prsni koš	4
3.2. Način dobivanja X-ray slika medicinskim uređajima	4
3.3. Opis X-ray slika prsnog koša	6
3.4. Formati zapisa medicinskih slika	7
3.5. Konvolucijske neuronske mreže	10
3.6. Osnovna svojstva konvolucijskih neuronskih mreža	12
3.7. Stvaranje neuronske mreže	13
4. RAZVIJENI SUSTAV ZA KLASIFIKACIJU X-RAY SLIKA	15
4.1. Opis korištenog skupa podataka	15
4.2. Arhitektura neuronske mreže	16
5. DOBIVENI REZULTATI	20
6. ZAKLJUČAK	23
LITERATURA	24
SAŽETAK	26
ABSTRACT	27
PRILOZI	28
pneumonia_detection.py	28

1. UVOD

Obrada medicinskih slika odnosi se na proces izdvajanja značajnih informacija iz medicinskih slika ljudskog tijela kako bi se dijagnosticirala, pratila ili liječila određena zdravstvena stanja pacijenta. Dobivanje i obrada slika postiže se korištenjem uređaja za radiografiju, magnetsku rezonancu (MR), računalnu tomografiju, ultrazvuk i druge [1].

Upala pluća (pneumonija) je infekcija koja zahvaća plućne mjehuriće (alveole) u jednom ili oba plućna krila. Plućni mjehurići se mogu napuniti tekućinom ili gnojnim materijalom što može uzrokovati neke od najpoznatijih simptoma upale kao što su kašalj, groznica, zimica i otežano disanje. U slučaju sumnje na upalu pluća, krvnim pretragama potvrđuje se prisustvo infekcije, dok se sama upala pluća najčešće potvrđuje rendgenskom snimkom [2].

Klasifikaciju X-ray slika prsnog koša obično obavlja radiolog, međutim s napretkom u tehnologiji, posebice na području dubokog učenja, razvijaju se mnogobrojni sustavi čija je svrha ispravna klasifikacija X-ray slika. Neki od tih sustava te njihove performanse bit će spomenuti i u ovom radu.

Sam cilj ovog rada bio je razviti sustav koristeći metode dubokog učenja koji će detektirati upalu pluća iz X-ray slika prsnog koša te je moći razlikovati od zdravih pluća. Da bi se ostvario željeni cilj, za razvoj modela korištena je konvolucijska neuronska mreža i binarni klasifikator s obzirom na to da se radi o dvije kategorije slika: slike zdravih pluća i slike s upalom pluća.

Na samom početku opisan je zadatak završnog rada. U nastavku je dan pregled par dosadašnjih istraživanja na ovom području. Poglavlja i potpoglavlja koja slijede opisuju medicinsku i tehnološku pozadinu, odnosno načine dobivanja X-ray slika prsnog koša, opis dobivenih slika, formate zapisa medicinskih slika kao i konvolucijske neuronske mreže, način njihova stvaranja i osnovna svojstva. Dan je i opis razvijenog sustava koji je korišten za klasifikaciju slika u ovom radu i opisani su dobiveni rezultati. Na kraju rada dan je zaključak.

1.1 Zadatak završnog rada

Istražiti i opisati teorijske osnove obrade slika s naglaskom na problematiku obrade medicinskih slika metodama dubokog učenja kao i formate zapisa medicinskih slika. Istražiti i dati kratak pregled područja prethodnih istraživanja detekcije upale pluća iz X-ray slika prsnog koša i

kliničku pozadinu. Opisati teorijske osnove konvolucijskih neuronskih mreža. Razviti sustav za klasifikaciju X-ray slika prsnog koša koji će ulazne slike klasificirati u dvije skupine: (1) slike sa zdravim plućima i (2) slike s upalom pluća. Za razvoj sustava koristiti konvolucijsku neuronsku mrežu i binarni klasifikator. Prikazati rezultate i provjeriti točnost rada sustava.

2. TRENUTNE METODE ZA KLASIFIKACIJU X-RAY SLIKA PRSNOG KOŠA

Tijekom prošlih desetljeća duboko učenje korišteno je za detekciju bolesti pluća kao i drugih bolesti iz X-ray slika prsnog koša. Istraživanja računalnog vida i prepoznavanja uzoraka istaknula su sposobnosti konvolucijskih neuronskih mreža (KNM) kod rješavanja problema klasifikacije, segmentacije te detekcije objekata postižući vrhunske rezultate [3]. S obzirom na to, KNM su poslužile kao alat u različitim istraživanjima temeljenim na klasifikaciji X-ray slika prsnog koša.

Primjerice, CheXNet je konvolucijska neuronska mreža izgrađena od 121 sloja. Model je treniran koristeći 112 120 X-ray slika prsnog koša na kojima je 14 različitih bolesti. Za učenje mreže izdvojene su X-ray slike pluća s upalom te je stvoren testni skup u kojem se nalazilo 420 slika. Dobiveni rezultati performansi modela uspoređeni su s rezultatima radiologa. Zaključak je bio da su rezultati dobiveni CheXNet mrežom bolji u odnosu na rezultate klasifikacije radiologa [4].

Sljedeći pristup koristi ansambl učenje (engl. *ensemble learning*) pri detekciji upale pluća iz X-ray slika prsnog koša. Ideja je zasnovana na korištenju unaprijed istreniranih konvolucijskih neuronskih mreža. Korištene mreže DenseNet169, MobileNetV2 i Vision Transformer (ViT) unaprijed su trenirane na *ImageNet* skupu podataka korištenjem X-ray slika za detekciju upale pluća. Performanse svakog pojedinačnog modela uspoređene su s performansama ansambla dobivenih na skupu podataka sastavljenog od 5856 X-ray slika. Performanse kreiranog ansambla pokazale su se boljima u odnosu na performanse pojedinačnih modela [5].

U [6] kreiran je model KNM-a zasnovan na VGG arhitekturi koji je treniran na skupu podataka u kojem se nalazi 5786 X-ray slika prsnog koša. U koraku predobrade podataka povećan je kontrast slika *Dynamic Histogram Equalization (DHE)* tehnikom. Model je kreiran od samo šest slojeva uključujući ReLu aktivacijsku funkciju, nasumično izbacivanje neurona te slojeve sažimanja. Rezultati dobiveni ovim modelom pokazali su se dobrim u usporedbi s rezultatima prijašnjih modela.

3. MEDICINSKA I TEHNOLOŠKA POZADINA

3.1. Pluća i prsni koš

Kostur prsnog koša sastavljen je od prsne kosti i prsnih kralježaka te rebara i rebrene hrskavice koji zajedno tvore stijenku prsnog koša i okružuju prostor u kojem su smješteni organi prsne šupljine. Rebra su plosnate, izdužene kosti koje su straga spojena s odgovarajućim prsnim kralješčima, a sprijeda su rebrenom hrskavicom spojena s prsnom kosti te tako oblikuju kostur prsnog koša. U srednjem dijelu prsnog koša smješteni su srce, dušnik i jednjak, a u pokrajnjim dijelovima nalaze se pluća.

Pluća su glavni organ dišnog sustava koja se sastoje od lijevog i desnog plućnog krila. Serozna opna obavija svako plućno krilo zbog čega je površina pluća glatka i sjajna. Svako plućno krilo ima oblik uzdužno presječeneg stošca. Lijevo plućno krilo je uže i dulje te ima dva režnja, a desno koje ima tri režnja je kraće i šire, ali veće i teže od lijevoga. Poznavanje normalne anatomije bronhopulmonalnih segmenata važno je za pravilno tumačenje rendgenskih slika i kirurške zahvate na oboljelim dijelovima pluća [7].

Upala pluća (pneumonija) je infekcija koja zahvaća plućne mjehuriće (alveole) u jednom ili oba plućna krila. Plućni mjehurići se mogu napuniti tekućinom ili gnojnim materijalom što može uzrokovati neke od najpoznatijih simptoma upale kao što su kašalj, groznica, zimica i otežano disanje, bol u prsima pri disanju ili kašljanju, umor te mučnina. Najugroženiji dio populacije kada je upala pluća u pitanju su dojenčad u dobi od dvije godine ili mlađi te osobe starije od 65 godina. U slučaju sumnje na upalu pluća, krvnim pretragama potvrđuje se prisustvo infekcije, dok se sama upala pluća najčešće potvrđuje rendgenskim snimkom [2].

3.2. Način dobivanja X-ray slika medicinskim uređajima

Slikovne pretrage su nezamjenjiv alat u medicini jer slike organa unutar tijela koji su nevidljivi našem oku daju vrijedne informacije o zdravstvenom stanju organa. Medicinske slike dobivaju se bojnim uređajima koji koriste različite metode dobivanja slika poput ultrazvuka, računalne tomografije, magnetske rezonance, konvencionalnih rendgenskih uređaja i drugih.

Ultrazvuk radi tako da računalni program aktivira pulsni generator. Uz pomoć upravljačke jedinice elektronski impulsi se prenose na piezoelektrične kristale sonde. Ultrazvučni valovi se odašilju prema tijelu zbog električne deformacije kristala. Zatim ovi reflektirani ultrazvučni

valovi izazivaju deformaciju piezoelektričnih kristala i stvaranje mikrovalnih struja. Iznos mikrovoltažnih struja povećava se uporabom kompenzacijskog pojačala, a uz to se vrši i pohrana signala u memoriji računala. Na kraju digitalni procesor stvara slikovni prikaz na osnovu intenziteta mikrovoltažnih struja [1].

Otkriće računalne tomografije (CT) najznačajniji je napredak u radiologiji nakon otkrića rendgenskih zraka. CT kombinira niz rendgenskih slika snimljenih iz različitih kutova oko tijela pacijenta i koristi računalnu obradu za stvaranje slika poprečnog presjeka kostiju, krvnih žila i mekih tkiva unutar tijela. CT slike pružaju detaljnije informacije od običnih rendgenskih snimaka. Za razliku od konvencionalnog rendgenskog zračenja koje koristi fiksnu rendgensku cijev, CT skener koristi motorizirani rendgenski izvor koji se okreće oko kružnog otvora strukture u obliku cilindra koja se naziva portal. Tijekom CT skeniranja, pacijent leži na krevetu koji se polako pomiče kroz portal dok se rendgenska cijev okreće oko pacijenta, ispuštajući uske snopove rendgenskih zraka kroz tijelo. Umjesto filma, CT skeneri koriste posebne digitalne rendgenske detektore koji se nalaze točno nasuprot izvora rendgenskih zraka. Kako rendgenske zrake napuštaju tijelo pacijenta, detektori ih primaju i šalju u računalo. Svaki put kada izvor rendgenskih zraka izvrši jednu punu rotaciju, CT računalo koristi sofisticirane matematičke tehnike za konstruiranje dvodimenzionalne slike isječka. Kada je cijeli rez dovršen, slika se pohranjuje, a proces skeniranja se ponavlja kako bi se proizveo drugi isječak slike. Cijela procedura se ponavlja dok se ne prikupi željeni broj isječaka. Isječci se mogu prikazati pojedinačno ili ih se računalom može povezati kako bi se dobila trodimenzionalna slika tijela [2, 8].

Magnetska rezonanca je neinvazivna tehnologija snimanja ljudskog tijela kojom se dobivaju trodimenzionalne slike. Za rad koristi magnete koji proizvode snažno magnetsko polje čija jačina djeluje na protone u ljudskom tijelu tako da se poravnavaju s poljem u kojem se nalaze. Kako radiofrekventna struja pulsira kroz pacijenta, tako se protoni stimuliraju i izlaze iz vlastitog ekvilibrijuma opirući se magnetskom polju. Kada je radiofrekvencijsko polje isključeno, senzori uređaja detektiraju energiju koja se oslobađa dok se protoni ponovno usklađuju s magnetskim poljem. Na osnovu ovih magnetskih svojstava, liječnici mogu razlikovati tkiva koja izgrađuju ljudski organizam. Kako bi se dobila slika magnetskom rezonancom, pacijent se smješta unutar velikog magneta za vrijeme trajanja procesa snimanja [8].

Rendgenske ili X-zrake nastaju bombardiranjem mete elektronima visoke energije. U konvencionalnoj radiografiji X-zrake koje prolaze kroz ljudsko tijelo se apsorbiraju što

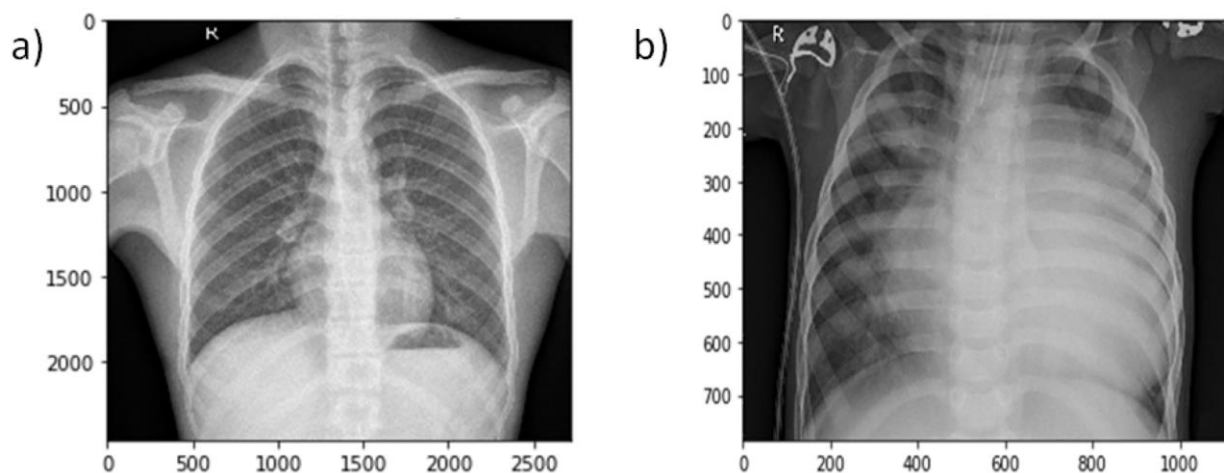
uzrokuje slabljenje upadne zrake. Ujednačena X-zraka emitirana iz izvora modulira se dok prolazi kroz ljudsko tijelo i te se promjene bilježe na filmu. Kontrast u rendgenskoj slici ovisi o različitoj atenuaciji rendgenskih zraka dok prolaze kroz različita tjelesna tkiva. Rendgenska oprema mora biti kalibrirana za točnu proizvodnju željenog napona, struje i vremena ekspozicije zbog čega se mora često provjeravati kako bi se osigurala ispravna doza zračenja. Kod konvencionalnih rendgenskih snimki kao medij za pohranu i prikaz slika koristi se metalni film. Zbog svoje jednostavnosti i dostupnosti konvencionalna snimka pluća danas je jedna od najučestalijih slikovnih pretraga koja pruža dijagnostičke informacije o plućima, srcu i susjednim strukturama [9, 10].

3.3. Opis X-ray slika prsnog koša

X-ray slike dobivene korištenjem različitih medicinskih uređaja mogu se gledati na računalu ili na filmu. Uređaji za dobivanje rendgenskih snimaka emitiraju snažna zračenja koja putuju zrakom, stupaju u kontakt s tijelom i njegovim tkivima i stvaraju sliku na metalnom filmu. Za stvaranje kontrasta na slikama tkiva na filmu ključna je atenuacija – slabljenje X zračenja u tkivu. Mali intenzitet zračenja daje svijetli kontrast na slici nakon prolaska kroz tkivo, dok visoki intenzitet zračenja daje tamni kontrast. Boje vidljive na X-ray slikama idu od potpuno crne kada nema nikakve apsorpcije, do potpuno bijele kada se rendgensko zračenje atenuira u potpunosti.

Atenuacija fotona X zraka ovisi o gustoći tkiva. Naime, što je tkivo gušće, rendgenski je vidljivije (bjelje) na slici. Različitom gustoćom prikazuju se, redom od najgušćeg do najrjeđeg: metal (intenzivno bijelo), kortikalna kost (manje bijelo), mišić i tekućina (sivo), mast (tamno sivo) i zrak ili plin (crno). Zdravo plućno tkivo je meko tkivo koje je ispunjeno zrakom koji ima oko 800 puta manju gustoću. Zbog zraka koji se nalazi u zdravom plućnom tkivu njegova gustoća je znatno snižena što rezultira tamnijom slikom. Na tamnijoj podlozi, koju predstavljaju zdrava pluća, mogu se vidjeti promjene koje daju svjetliju sliku. Te promjene mogu biti upalni procesi koji putem sluzi istiskuju zrak i popunjavaju ga sa znatno gušćom tvari pa zahvaćeni dijelovi pluća daju znatno svjetliju sliku [11].

Na slici 3.1 prikazana je rendgenska snimka prsnog koša. Na lijevom dijelu slike prikazana su zdrava pluća na kojima je sve jasno vidljivo, bez ikakvih zamućenja na slici. Desni dio slike prikazuje pluća zahvaćena upalom, vidljivo je kako je rendgenska slika „zamućena“, kao da se na njoj nalazi sjena. Po toj „sjeni“ jasno je da se radi o upali.



Slika 3.1. a) X-ray slika zdravih pluća, b) pluća s upalom (desno) [12]

3.4. Formati zapisa medicinskih slika

Medicinske slike se pohranjuju u točno određenim formatima koje različita računala koja sudjeluju u komunikaciji moraju moći prepoznati. Iz tog razloga razvijeni su međunarodni standardi za obradu i pohranjivanje medicinskih slika [13].

U okviru globalnog fenomena koji predstavlja informacijsko društvo javila se potreba za standardizacijom u komunikaciji koja podržava medicinske informacije. Još se ranije pokazalo da dijeljenje zajedničke opreme, kao što je zajednička kamera između uređaja koji koriste različite metode skeniranja (CT i MR skeneri), i aktivna primjena računala u dijagnostičke svrhe donosi niz prednosti što je dovelo do standardiziranog pristupa i razvoja PACS-a (engl. *Picture Archiving and Communication System*).

Korištenje standardiziranih pristupa treba olakšati proces „dijeljenja“ medicinskih slika. Takvu sliku potrebno je analizirati, procesirati, pohraniti i proslijediti s jednog odredišta na drugo, što je dovelo do pitanja kompatibilnosti uređaja i/ili odgovarajućih aplikacija i potrebe za standardom za digitalnu sliku i komunikacije u medicini.

Danas, takav standard postoji i naziva se DICOM (engl. *Digital Imaging and Communications in Medicine*) standard, koji je definiran u okviru dokumentacije koja je postala neizostavno sredstvo za omogućavanje i optimiziranje kompatibilnosti uređaja i razmjene podataka u okviru zdravstvenih ustanova.

Pojava DICOM standarda i razvoj PACS-a zahtjeva sažimanje slika velikih formata kako bi njihova pohrana bila moguća. Na primjer, DICOM slika najčešće se pretvara u JPEG (engl. *Joint Photographic Experts Group*) ili u TIFF format (engl. *Tagged Image File Format*) za potrebe razmjene putem interneta. Prisutan je PNG format (engl. *Portable Network Graphics*) koji omogućava ponovno otvaranje te pohranjivanje datoteke čije se sažimanje obavlja bez gubitka i uz mogućnost korekcije boje i svjetline.

Medicinske slike koje se dobiju uporabom različitih radioloških uređaja sadrže ogromnu količinu podataka koju je potrebno sistematizirati. Uporaba softverskog programa, za čiji razvoj su zaslužne brojne informatičke tvrtke i prilagodba postojećem radiološkom informacijskom sustavu za pohranu slika unutar pojedine zdravstvene ustanove omogućavaju sistematizaciju medicinskih podataka. Ovaj softverski program omogućava pohranu slika pacijenta koje postaju dostupne liječnicima za usporedbu kao i za praćenje razvoja uočenih promjena [14].

Razlika između DICOM-a i drugih formata očituje se u načinu grupiranja podataka. Tako se kod DICOM formata zapisa informacije grupiraju u setove podataka. Na primjer, snimka nečijeg prsnog koša sadrži i identifikacijske podatke osobe unutar samog snimka kako bi se izbjegla mogućnost zamjene dvaju snimaka. DICOM podatkovni objekt čini veći broj atributa: ime i prezime pacijenta te njegov identifikacijski broj, datum snimke kao i podaci o razmaku i broju piksela. Pojedinačni DICOM prikaz može imati samo jedan atribut za opis razmaka i broja piksela, što omogućava velik broj primjena. DICOM format u jednom podatkovnom paketu može sadržavati veći broj slojeva što omogućava da se više prikaza spremi u jedan podatkovni objekt. Iako se rijetko koristi, zip kompresija omogućava sažimanje cijelog DICOM podatkovnog objekta. Isti princip formatiranja koristi se u svim aplikacijama što uključuje i mrežno korištenje [15].

PACS je računalni sustav razvijen kao rješenje problema pohrane, razmjene i prikaza digitalnih medicinskih slika dobivenih korištenjem različitih dijagnostičkih uređaja od kojih su neki: digitalna radiografija, digitalni rendgen, računalna tomografija, ultrazvuk, magnetska rezonanca. U kombinaciji s postojećim računalnim tehnologijama i telekomunikacijskim infrastrukturama ovaj sustav pruža učinkovit pristup medicinskim slikama u stvarnom vremenu, njihovu interpretaciju, obradu, arhiviranje i prikaz.

Primarni cilj PACS sustava je arhiviranje slika. S obzirom na golemu količinu podataka koji se generiraju u neprestanom radu bolnica i drugih ustanova potrebno je osigurati veliki memorijski kapacitet te brz i učinkovit pristup podacima. PACS arhiv organiziran je hijerarhijski te se

sastoji od dvije glavne skupine podataka: trenutno aktivni podaci pohranjeni u sustavima s brzom dostupnošću koji se još nazivaju i kratkotrajnim arhivom, to su zapravo online sustavi. Druga grupa su pasivni podaci koji namijenjeni dugotrajnoj pohrani (engl. *long-term archive*). Novi i aktualni snimci spremaju se u kratkotrajni arhiv, na disku lokalnog računala ili poslužitelja (engl. *server*), a stariji snimci se čuvaju u udaljenom dugotrajnom arhivu [14].

Pored DICOM standarda postoje i drugi formati zapisa medicinskih slika primjerice: Analyze, Nifti i Minc.

Analyze format nastao je krajem 1980-ih te se više od desetljeća smatrao standardom za naknadnu obradu medicinskih slika. Glavna karakteristika Analyze formata je ta što je dizajniran za pohranu višedimenzionalnih podataka s obzirom na to da je u jednu datoteku moguće pohraniti trodimenzionalne ili četverodimenzionalne podatke (kao četvrta dimenzija koristi se vrijeme). Podatak pohranjen u Analyze formatu sastoji se od dvije binarne datoteke: slikovne datoteke s ekstenzijom „.img“ koja sadrži neobrađene podatke vokseli i datoteke zaglavlja s ekstenzijom „.hdr“ koja sadrži metapodatke, na primjer broj pikseli u x, y i z osi, veličina vokseli i tip podataka. Zaglavlje ima fiksnu veličinu od 348 bajtova i opisuje se kao struktura u C programskom jeziku. Za čitanje i uređivanje zaglavlja potreban je pomoćni softverski program. Analyze format se danas smatra zastarjelim, ali je i dalje u upotrebi.

Nifti format nastao je s ciljem iskorištavanja prednosti Analyze formata te uklanjanja njegovih nedostataka. Nifti uključuje podršku za tip podataka koji nije predviđen u formatu Analyze kao što je 16-bitni podatak bez predznaka (engl. *unsigned 16-bit*). Ovaj format također dopušta pohranjivanje zaglavlja i podataka o pikselima u zasebnim datotekama, međutim slike se najčešće spremaju kao jedna „.nii“ datoteka u kojoj su zaglavlje i podaci o pikselima spojeni. Zaglavlje ima veličinu od 348 bajtova u slučaju pohrane podataka kao „.hdr“ i „.img“ datoteka ili veličinu od 352 bajta u slučaju jedne „.nii“ datoteke. Uporabom Nifti formata moguća je pohrana zapisa na dva načina. Prvi način se koristi rotacijom i translacijom pri mapiranju koordinata vokseli. Drugi se način koristi za spremanje 12 parametara linearne transformacije kojom je definirano poravnanje volumena slike prema standardnom koordinatnom sustavu. Nifti format je u kratkom vremenu zamijenio Analyze u oslikavanju mozga (engl. *neuroimaging*) i danas je jedan od najčešće korištenih formata zapisa na tom području [16].

Minc format zapisa je razvijen kao sustav za fleksibilan, samodokumentirajući prikaz neuroznanstvenih slikovnih podataka proizvoljne orijentacije i dimenzionalnosti. Ovaj sustav uključuje tri komponente: specifikaciju i format datoteke, programsku biblioteku i velik broj

alata. Novije verzije ovog sustava podržavaju 64-bitnu veličinu datoteka, internu kompresiju te niz drugih značajki. Minc sustav je idealan za rad s bazama podataka zbog svog proširivog dizajna koji omogućuje uključivanje različitih pojedinosti u metapodatke zaglavlja [17].

Tablica 3.1 prikazuje sažeti opis navedenih formata koji se koriste za zapis medicinskih slika.

Tablica 3.1. Opis formata zapisa medicinskih slika [16]

FORMAT	ZAGLAVLJE	EKSTENZIJA	TIP PODATKA
Analyze	Fiksna duljina: 348 bajtova binarnog formata	.img, .hdr	Integer, float, complex
Nifti	Fiksna duljina: 352 bajta binarnog formata (348 bajtova kada se podaci spremaju kao .img i .hdr)	.nii	Integer, float, complex
Minc	Proširivi binarni format	.mnc	Integer, float, complex
Dicom	Binarni format promjenjive duljine	.dcm	Integer

3.5. Konvolucijske neuronske mreže

Među različitim arhitekturama dubokog učenja posebna vrsta višeslojne neuronske mreže za prostorne podatke je konvolucijska neuronska mreža (KNM). Arhitektura KNM-a inspirirana je vizualnom percepcijom živih bića. Iako se prvi put pojavljuju 1980-ih, razvoj konvolucijskih neuronskih mreža doživljava procvat tek 2012. godine zbog dotadašnjih ograničenja u pogledu računalne snage te nedostatka označenih skupova podataka i efikasnih algoritama. Uklanjanjem tih ograničenja KNM postale su jedan od najkorištenijih alata u području računalnog vida, obrade govora i drugih.

Konvolucijske neuronske mreže su vrsta umjetnih neuronskih mreža (engl. *artificial neural networks*) koje imaju duboku unaprijednu (engl. *feedforward*) arhitekturu te veliku sposobnost generaliziranja u usporedbi s drugim potpuno povezanim mrežama. KNM može naučiti visoko apstrahirana svojstva objekata ili prostorne podatke te ih može učinkovitije identificirati. Model duboke konvolucijske neuronske mreže (engl. *deep convolutional neural network*) sastoji se od skupa koji mogu naučiti različite značajke ulaznih podataka (npr. slike) s višestrukim razinama

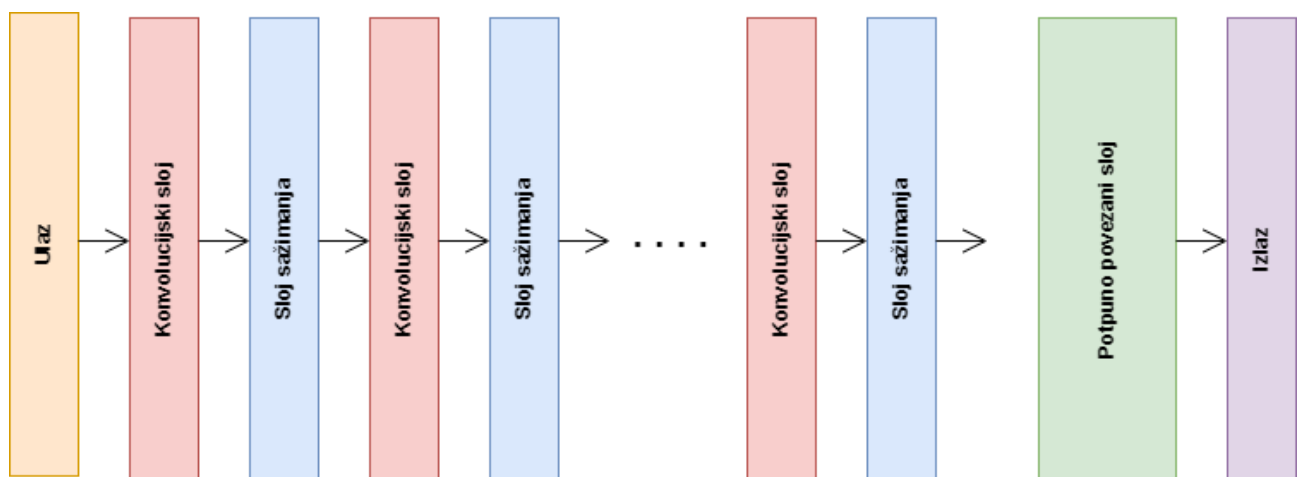
apstrakcije. Početni slojevi uče i izdvajaju značajke visoke razine (s nižom apstrakcijom), a dublji slojevi uče i izdvajaju značajke niske razine (s višom apstrakcijom).

Tradicionalna konvolucijska neuronska mreža izgrađena je od jednog ili više blokova konvolucijskih slojeva i slojeva sažimanja (engl. *pooling layers*), nakon kojih slijedi jedan ili više potpuno povezanih (engl. *fully connected*) slojeva i izlazni sloj.

Konvolucijski sloj temeljni je građevni blok KNM-a. Ovaj sloj ima za cilj naučiti značajke ulaza. Konvolucijski sloj sastoji se od nekoliko konvolucijskih jezgri (engl. *kernel*), koje imaju sposobnost učenja ili filtra koji se koriste za izračunavanje različitih mapa značajki. Svaki dio mape značajki povezan je s receptivnim poljem u prethodnom sloju. Nova mapa značajki stvara se konvoluiranjem ulaza s jezgrama i primjenom nelinearne aktivacijske funkcije po elementima na konvoluirani rezultat. Svojstvo dijeljenja parametara konvolucijskog sloja smanjuje složenost modela. Sloj sažimanja ili poduzorkovanja uzima mali dio konvolucijskog izlaza kao ulaz i smanjuje ga uzorkovanjem kako bi proizveo jedan izlaz.

Posljednji dio KNM-a u osnovi se sastoji od jednog ili više potpuno povezanih slojeva koji se obično nalaze u unaprijednim neuronskim mrežama (engl. *feedforward neural networks*). Potpuno povezani sloj uzima ulaz od konačnog sloja sažimanja ili konvolucijskog sloja i generira konačni izlaz KNM -a.

Slika 3.2. prikazuje slojeve KNM-a.



Slika 3.2. Slojevi konvolucijske neuronske mreže

Glavni zadatak bilo koje aktivacijske funkcije u bilo kojem modelu temeljenom na neuronskoj mreži je preslikati ulaz u izlaz, gdje se ulazna vrijednost dobiva izračunavanjem ponderirane

sume ulaza neurona i daljnjim dodavanjem pomaka (engl. *bias*), ako pomak postoji. Drugim riječima, aktivacijska funkcija odlučuje hoće li se neuron aktivirati ili ne za dani ulaz proizvodeći odgovarajući izlaz. U KNM arhitekturi, nakon svakog sloja koji se može naučiti (slojeva s težinama, tj. konvolucijski i potpuno povezani slojevi) koriste se nelinearni aktivacijski slojevi. Nelinearno ponašanje tih slojeva omogućuje KNM modelu da nauči složenije stvari i uspije nelinearno preslikati ulaze u izlaze. Važna značajka aktivacijske funkcije je da ona treba biti diferencijabilna kako bi se omogućila unazadna propagacija (engl. *backpropagation*) pogreške za treniranje modela.

Najčešće korištene aktivacijske funkcije su: sigmodna (logistička) funkcija, *ReLU* (engl. *rectified linear unit*), *Leaky ReLU*, *Tanh* (tangens hiperbolni).

U slučaju klasifikacije slika KNM se može promatrati kao kombinacija dvaju dijelova: dijela za izdvajanje značajki i dijela za klasifikaciju. Pri tome i konvolucijski sloj i sloj sažimanja izvode ekstrakciju značajki.

Kao primjer možemo uzeti sliku psa. Različiti konvolucijski slojevi, od niže razine prema višoj, detektiraju različite značajke kao što su dva oka, duge uši ili četiri noge za daljnje prepoznavanje. Povrh ovih značajki, dodaju se potpuno povezani slojevi kao klasifikatori i dodjeljuje se vjerojatnost da je ulazna slika pas.

Osim dizajna slojeva, poboljšanje rada KNM-a ovisi o nekoliko različitih aspekata kao što su aktivacijska funkcija, normalizacijska metoda, funkcija gubitaka, regularizacija, optimizacija i brzina obrade i drugi [18].

3.6. Osnovna svojstva konvolucijskih neuronskih mreža

Revolucija umjetne inteligencije i dubokog učenja temelji se na nekoliko svojstava koja posjeduje. Kao dio dubokog učenja, konvolucijske neuronske mreže nasljeđuju ta svojstva, a to su:

Jednostavnost – duboko učenje ne zahtjeva složeni inženjering i kompleksna inženjerska rješenja čime se uvode jednostavniji modeli koji se mogu trenirati, a sastoje se od pet do šest različitih tenzorskih operacija.

Skalabilnost – duboko učenje omogućava iskorištavanje *Mooreov* zakon u potpunosti s obzirom na to da je podložno paralelizaciji procesa na GPU ili TPU. Osim toga, modele dubokog učenja

moгуće je trenirati na bazama podataka proizvoljne veličine jer se ovi modeli uče iteracijom na manjim skupovima podataka. Jedino ograničenje kada se radi s modelima dubokog učenja je dostupna količina paralelnih operacija.

Svestranost i mogućnost ponovnog korištenja – modele dubokog učenja moguće je trenirati na dodatnim podacima bez ponovnog kretanja od samog početka, što nije slučaj s različitim prijašnjim pristupima strojnog učenja. Nadalje, modele dubokog učenja karakterizira mogućnost prenamjene što znači da se mogu koristiti za rješavanje novih problema. Primjerice, sustav koji je prvobitno dizajniran za klasifikaciju slika može se iskoristiti za obradu videozapisa [19].

Pored navedenih svojstava, konvolucijske neuronske mreže karakteriziraju i zajedničke težine i pomaci koji imaju istu vrijednost za svaki skriveni neuron u pojedinom sloju. To znači da svi skriveni neuroni detektiraju istu značajku (na primjer rub) na različitim dijelovima slike. Ovo svojstvo mrežu čini tolerantnom na translaciju objekata na slici. Na primjer mreža koja je naučena da prepozna automobil na slici učinit će to neovisno o mjestu na kojem se automobil nalazi na slici [20].

3.7. Stvaranje neuronske mreže

Dvije osnovne faze rada neuronskih mreža su faza učenja i faza testiranja. Pored ovih glavnih faza imamo još i fazu validacije te fazu opoziva (primjene) neuronske mreže.

Prije samog procesa učenja nužno je definirati arhitekturu modela (ulazne i izlazne varijable) i pristupiti prikupljanju podataka na kojima će se odvijati proces treniranja mreže. Odgovarajuće podatke potrebno je podijeliti u dva skupa: skup podataka za učenje (treniranje) i skup podataka za testiranje. Ne postoji strogo definirano pravilo za podjelu prikupljenih podataka, ali najčešća praksa je da se za učenje uzme 80% podataka, a preostalih 20% za testiranje. Ako će se za vrijeme učenja provoditi optimizacija kako bi se smanjila duljina učenja i pojednostavila struktura mreže, prikupljeni podaci moraju se podijeliti u tri skupa: skup za učenje, testiranje i skup za validaciju. Podaci u skupu za validaciju uzimaju se iz skupa za učenje.

Nakon što je model izgrađen i nakon što su definirani ulazni i izlazni podaci te pravilo učenja, pristupa se procesu učenja mreže s ciljem uočavanja veze među podacima i procjene izlaznih vrijednosti na temelju ulaznih veličina. Faza učenja je u osnovi proces podešavanja težina u mreži koji se odvija kroz veći broj ponavljanja (prolaza kroz mrežu, epoha). Mreža se najčešće

trenira kroz nekoliko tisuća epoha. Broj prolazaka kroz mrežu, kao ni način podjele početnog skupa podataka, nije strogo definiran.

U fazi validacije cilj je odrediti optimalan broj epoha pri kojem će rezultat treniranja biti što bolji, a samim time pogreška što manja. U ovoj fazi nastoji se optimizirati duljina trajanja procesa učenja i broj neurona u skrivenim slojevima, nakon čega se dobivena mreža sprema i započinje se njeno testiranje.

Testiranje mreže je najvažnija faza u radu s neuronskim mrežama i ona je ključna za vrednovanje performansi. Ono po čemu se ova faza razlikuje od prethodne je činjenica da sada mreža više ne uči, što znači da su vrijednosti težina fiksirane na one dobivene kao rezultat ranije faze. Takva mreža dobiva nove ulazne podatke koji nisu bili dio skupa korištenog za proces učenja te se od mreže očekuje da za dosad neviđeni ulaz proizvede izlaz.

Vrednovanje performansi mreže provodi se izračunavanjem pogreške ili drugog odabranog pokazatelja točnosti na način da se procijenjeni izlaz uspoređuje sa stvarnima.

Pogreška mreže dobivena na validacijskom skupu je rezultat kojim se tumači točnost rada neuronske mreže i učinkovitost pri predviđanju na budućim podacima.

Faza opoziva ili operativna faza odnosi se na korištenje kreirane neuronske mreže u radu s novim skupovima podataka s nepoznatim rezultatima i fiksiranim težinama [21, 22].

4. RAZVIJENI SUSTAV ZA KLASIFIKACIJU X-RAY SLIKA

Razvijeni sustav koristi konvolucijsku neuronsku mrežu za klasifikaciju ulaznih podataka, odnosno rendgenskih slika prsnog koša, u dvije skupine: slike sa zdravim plućima i slike s upalom pluća. S obzirom na to da izlaz sustava može biti jedna od dvije klase, riječ je o problemu binarne klasifikacije. Prije samog procesa treniranja mreže bilo je potrebno prilagoditi podatke za učenje kao i parametre korištenog modela.

4.1. Opis korištenog skupa podataka

Skup podataka za treniranje kreiranog modela preuzet je s web sjedišta *kaggle.com*. Podatkovni skup sastoji se od 5856 rendgenskih slika prsnog koša i dvije kategorije: kategorija „Normal“ u kojoj se nalaze rendgenske slike zdravih pluća te kategorija „Pneumonia“ u kojoj se nalaze rendgenske slike pluća s upalom. Skup podataka je organiziran u tri mape: train, val i test gdje su u svakoj podaci podijeljeni u dvije podmape koje predstavljaju dvije navedene kategorije slika. Mape su redom korištene za učenje mreže, validaciju te testiranje mreže.

Tablica 4.1. prikazuje broj podataka za svaku kategoriju („Normal“ i „Pneumonia“) u svakom od tri navedena skupa.

Tablica 4.1. Broj podataka u skupovima za učenje, validaciju i testiranje

	NORMAL	PNEUMONIA	UKUPNO
Train	1341	3875	5216
Val	8	8	16
Test	234	390	624

Na slici 4.1. prikazani su grafikoni na kojima su vidljivi broj i omjer podataka u skupovima za učenje, validaciju i testiranje.



Slika 4.1. Omjer X-ray slika zdravih i pluća s upalom

X-ray slike prsnog koša prikupljene su kao dio retrospektivne kohortne studije pedijatrijskih pacijenata od jedne do pet godina starosti iz medicinskog centra za žene i djecu u Guangzhou (engl. *Guangzhou Women and Children's Medical Center*). Sve X-ray slike nastale su kao dio rutinske brige za pacijente [23].

4.2. Arhitektura neuronske mreže

Kao što je prije spomenuto, za rješenje danog problema korištena je konvolucijska neuronska mreža čiji su glavni dijelovi konvolucijski sloj, sloj sažimanja te potpuno povezani slojevi.

```

model = Sequential([
    Conv2D(32, (3,3), activation='relu', input_shape=(width, height, 1)),
    MaxPooling2D(pool_size=(2,2)),
    Conv2D(64, (3,3), activation='relu'),
    MaxPooling2D(pool_size=(2,2)),
    Conv2D(128, (3,3), activation='relu'),
    MaxPooling2D(pool_size=(2,2)),
    Conv2D(128, (3,3), activation='relu'),
    MaxPooling2D(pool_size=(2,2)),
    Flatten(),
    Dropout(0.5),
    Dense(512, activation='relu'),
    Dropout(0.5),
    Dense(512, activation='relu'),
    Dense(1, activation='sigmoid')
])

```

Slika 4.2 Izgled modela


Kako je prikazano i u kodu na slici 4.2 , model se sastoji od konvolucijskih slojeva i slojeva sažimanja koji se izmjenjuju, a svakih ima po četiri. Nakon toga slijedi izlazni sloj koji koristi sigmoidnu aktivacijsku funkciju. Također su korištena i dva *Dropout* sloja za nasumično izostavljanje neurona kako bi se spriječilo pretjerano usklađivanje na podatke za učenje (engl. *overfitting*).

Model je kompiliran pomoću *Adam* optimizacijskog algoritma. Korištena funkcija gubitka je *binary_crossentropy* s obzirom da se radi o samo dvije mogućnosti izlaza - ili se radi o zdravim plućima ili se radi o upali pluća. Proces učenja modela odvija se kroz 30 epoha s veličinom serije (engl. *batch size*) koja je jednaka 16. Kroz svaku epohu prati se vrijednost F1 mjere na skupu za učenje i validacijskom skupu.

Tablica 4.2. Hiperparametri modela

PARAMETAR	VRIJEDNOST
Optimizacijski algoritam	Adam
Broj epoha	30
Veličina serije	16
Aktivacijska funkcija skrivenih slojeva	ReLU
Aktivacijska funkcija izlaznog sloja	Sigmoid
Funkcija gubitka	<i>binary_crossentropy</i>

Tablica 4.2. prikazuje hiperparametre kreiranog modela dok slika 4.3. prikazuje dijagram kreiranog modela dobivenog korištenjem funkcije *plot_model*.



Slika 4.3. Dijagram prikaz kreiranog modela

Tablica 4.1. i slika 4.1. iz prethodnog poglavlja pokazuju da je broj podataka u validacijskom skupu puno manji od broja podataka u ostala dva skupu. Iz tog razloga dobivena vrijednost parametara preciznosti i odziva dobivenih na tom skupu ne može jamčiti dobar ili loš rezultat na testnim podacima. Uzimajući to u obzir, metrike izvedbe modela procijenjene su na podacima iz skupa za učenje i testnog skupa.

Kako bi se povećao broj podataka na skupu za učenje, provedena je augmentacija podataka. To je postupak umjetnog povećavanja broja podataka skupa za učenje tako da se novi podaci kreiraju od postojećih podataka. To se može ostvariti rotacijom, skaliranjem, izrezivanjem dijela postojeće slike, zrcaljenjem, promjenom osvjetljenja i slično.

Augmentacija podataka postignuta je korištenjem *ImageDataGenerator* API-ja kako je prikazano na slici 4.4. *ImageDataGenerator* provodi augmentaciju podataka u stvarnom vremenu (engl. *real-time data augmentation*) [24].

```
train_data_generator = ImageDataGenerator(rescale = 1./255,
rotation_range = 9,
zoom_range = 0.2,
width_shift_range = 0.2,
height_shift_range = 0.2)
validation_data_generator = ImageDataGenerator(rescale = 1./255,
rotation_range = 9,
zoom_range = 0.2,
width_shift_range = 0.2,
height_shift_range = 0.2)
```

Slika 4.4. Prikaz korištenja *ImageDataGenerator* u kodu


S obzirom da se augmentacija provodi u stvarnom vremenu, za vrijeme trajanja procesa učenja, augmentirani podaci se ne spremaju automatski te se time broj podataka u skupovima za učenje i validaciju nakon procesa učenja ne mijenja. Međutim *ImageDataGenerator* tijekom svake epohe generira točno određen broj augmentiranih podataka na kojima se mreža uči. Broj generiranih podataka za svaku epohu dobije se kao količnik broja skupa podataka i ukupnog broja prolazaka kroz podatke (epoha).

To bi značilo da se u svakoj epohi na skupu za učenje generira 326 augmentiranih podataka, dok broj generiranih podataka na skupu za validaciju iznosi 39.

5. DOBIVENI REZULTATI

Tijekom treniranja mreže prate se određene metrike koje služe za procjenu rada kreiranog modela. Učenje modela provedeno je na jednom skupu, a njegova sposobnost ispravne klasifikacije X-ray slika zdravih pluća i pluća s upalom mjerena je na drugom skupu.

Kao parametar koji je korišten za ocjenjivanje rada kreiranog modela uzeta je F1 mjera koja se može protumačiti kao harmonička sredina preciznosti i odziva. Ova mjera uzeta je s obzirom na nepravilan omjer podataka u skupu za učenje (znatno veći broj slika pluća s upalom u odnosu na slike zdravih pluća).




Slika 5.1. Prikaz promjene gubitka i F1 mjere na skupu za učenje i testnom skupu kroz epohe

Slika 5.1. prikazuje promjenu gubitka te F1 mjere kroz epohe. Na lijevom grafu je vidljivo da gubitak na skupu za učenje opada kako se broj epohe povećava, što je i poželjno. Međutim na testnom skupu gubitak ne postiže „stalnu“ vrijednost nego naizmjenično raste i opada kroz epohe.

Desni graf na slici prikazuje promjenu F1 mjere kroz epohe. U teoriji najbolja vrijednost F1 mjere je 1, odnosno što bliže 1, dok je najlošija vrijednost 0. Na skupu za učenje vidljiv je jako dobar rezultat s obzirom na to da je vrijednost F1 mjere jako blizu 1. Na testnom skupu imamo lošiji rezultat što je i očekivano.

Slika 5.2. prikazuje matricu zabune koja prikazuje sposobnost klasifikacije mreže. Na glavnoj dijagonali su ispravno klasificirani podatci, a izvan dijagonale nalaze se pogrešno klasificirani podatci.




Slika 5.2. Matrica zabune

Na slici je vidljivo sljedeće:

- istinito pozitivnih (engl. *true positive* – TP) rezultata je 179 (slike zdravih pluća klasificirane kao slike zdravih pluća),
- lažno pozitivnih (engl. *false positive* – FP) rezultata je 55 (slike zdravih pluća koje su klasificirane kao slike s upalom pluća),
- istinito negativnih (engl. *true negative* – TN) rezultata je 381 (slike pluća s upalom koje su ispravno klasificirane),
- lažno negativnih (engl. *false negative* – FN) rezultata je 9 (slike pluća s upalom koje su klasificirane kao slike s zdravim plućima).

Cilj je smanjiti broj FP i FN rezultata, prvenstveno broj FN rezultata. S obzirom da se u FP zdrava pluća promatraju kao da se radi o upali pluća, veći broj takvih slučajeva je prihvatljiviji u odnosu na veći broj FN rezultata gdje bi se upala pluća promatrala kao zdrava pluća.

ROC krivulja, odnosno krivulja operativne karakteristike prijemnika (engl. *Receiver Operating Curve*), je graf koji prikazuje izvedbu klasifikacijskog modela u odnosu na pragove (engl.



Slika 5.3. ROC krivulja

thresholds) klasifikacije. ROC krivulja prikazuje omjer metrika koje predstavljaju stopu istinito pozitivnih rezultata (engl. *true positive rate* – TPR) i stopu lažno pozitivnih rezultata (engl. *false positive rate* – FPR) [25].

Medicinski gledano, što je veće područje ispod ROC krivulje (engl. AUC – *area under the ROC curve*), klasifikator (test) bolje razlikuje pacijente s ili bez bolesti.

Na slici 5.3. površina ispod ROC krivulje je značajna što znači da model dosta dobro razlikuje X-ray slike zdravih pluća od slika s upalom pluća.

Tablica 5.1. Metrike modela

PRECIZNOST	ODZIV	F1 MJERA
76.5%	95.21%	84.84%

U tablici 4.2. je prikaz konačne vrijednosti preciznosti, odziva i F1 mjere kreiranog modela. Vidljivo je kako je 76.5% točno klasificiranih primjera u skupu koje je model klasificirao kao pozitivne. Točno klasificiranih primjera u skupu pozitivnih primjera je 95.21%. Vrijednost F1 mjere iznosi 0.8484 što je puno bliže 1 nego 0, iz čega se može zaključiti da model radi prilično dobro.

6. ZAKLJUČAK

Cilj ovoga rada bio je kreirati sustav koji detektira upalu pluća iz X-ray slika prsnog koša, opisati metode dobivanja X-ray slika različitim medicinskim uređajima, opisati dobivene slike prsnog koša te opisati konvolucijske neuronske mreže koje su bile osnova za razvoj sustava s obzirom na njihove dosadašnje rezultate u radu s problemima klasifikacije i detekcije objekata.

Opisane su glavne karakteristike razvijenog sustava, korišteni skup podataka i na kraju su prikazani dobiveni rezultati. Zbog nejednakog omjera slika sa zdravim plućima i slika s upalom, mjera točnosti ne bi bila vjerodostojan pokazatelj rada kreiranog modela te je stoga kao pokazatelj performansi modela korištena F1 mjera. Dobivena vrijednost F1 mjere je nešto manja od poželjne. Međutim prilikom prilagođavanja parametara modela ideja je bila dobiti što je manji mogući broj lažno negativnih rezultata na što je na kraju i postignuto.

LITERATURA

- 1 Skripta radiološkijska aparatura, Sveučilište u Mostaru, Visoka zdravstvena škola. Dostupno na:
<https://fzs.sum.ba/sites/default/files/SKRIPTA%20RADIOLOGIJSKA%20APARATURA.pdf>. [Citirano: 6.6.2023.]
- 2 Mayo Clinic. Dostupno na: <https://www.mayoclinic.org/> [Posjećeno: 28.8.2023.]
- 3 M. D. Zeiler, R. Fergus, Visualizing and understanding convolutional networks. In: Computer vision–ECCV 2014
- 4 P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. Langlotz, K. Shpanskaya, et al. Chexnet, Radiologist-level pneumonia detection on chest x-rays with deep learning. arXiv 2017, arXiv:1711.05225
- 5 A. Mabrouk, R. P. Díaz Redondo, A. Dahou, M. Abd Elaziz, M. Kayed, Pneumonia Detection on Chest X-ray Images Using Ensemble of Deep Convolutional Neural Networks. Appl. Sci. 2022, 12, 6448. <https://doi.org/10.3390/app12136448>
- 6 D. Zhang, F. Ren., Y. Li, L. Na, Y. Ma, Pneumonia Detection from Chest X-ray Images Based on Convolutional Neural Network. Electronics 2021, 10, 1512. <https://doi.org/10.3390/electronics10131512>
- 7 J. Krmpotić- Nemanić, A. Marušić, Anatomija čovjeka
- 8 National Institute of Biomedical Imaging and Bioengineering. Dostupno na: <https://www.nibib.nih.gov/> [Posjećeno: 28.8.2023]
- 9 G. J. Bansal, Digital radiography. A comparison with modern conventional imaging. Dostupno na: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2563775/> [Posjećeno: 28.8.2023]
- 10 R. Joarder, N. Crundwell, Chest X-Ray in Clinical Practice. Springer; 2009.
- 11 S. Pašić, A. Klojučar, "Koje karakteristike tkiva vidimo na rendgenskoj slici?", Veterinarska stanica, vol.54, br. 4, str. 467-476, 2023. Dostupno na: <https://doi.org/10.46419/vs.54.4.10> [Citirano: 6.6.2023.]
- 12 M. F. Hashmi, S. Katiyar, A. G. Keskar, N. D. Bokde, Z. W. Geem, Efficient Pneumonia Detection in Chest Xray Images Using Deep Transfer Learning. Diagnostics 2020, 10, 417. <https://doi.org/10.3390/diagnostics10060417>
- 13 G. Hofmann, H. Stančić, "ARHIVIRANJE MEDICINSKIH SLIKA U DIGITALNOME OBLIKU", Physiotherapia Croatica, vol.14(Suppl), br. 1., str. 94-98, 2017. [Online]. Dostupno na: <https://hrcak.srce.hr/174044>. [Citirano: 7.6.2023.]
- 14 I. Reljin, A. Gavrovska, Telemedicina. Akademski misao, Beograd 2013.
- 15 D. Miletić, Slikovne dijagnostičke pretrage. Medicinski fakultet, Sveučilište u Rijeci, Rijeka, 2009. Dostupno na: <https://www.yumpu.com/hr/document/view/14297322/1-miletic-d-digitalni-zapis-u-radiologiji-rijeka-2010-medicinski> [Citirano: 7.6.2023.]

- 16 M. Larobina, L. Murino, Medical Image File Formats.
- 17 R. D. Vincent, P. Neelin, N. Khalili-Mahani, A. L. Janke, V. S. Fonov, S. M. Robbins, L. Baghdadi, J. Lerch, J. G. Sled, R. Adalat, D. MacDonald, A. P. Zijdenbos, D. L. Collins, A. C. Evans, MINC 2.0: A Flexible Format for Multi-Modal Images.
- 18 A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti, D. De, Fundamental Concepts of Convolutional Neural Network. 10.1007/978-3-030-32644-9_36.
- 19 F. Chollet, Deep Learning with Python, Manning, Shelter Island
- 20 <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html> [Citirano: 8.6.2023.]
- 21 <https://eris.foi.hr/11neuronske/nn-predavanje4.html> [Citirano: 9.6.2023.]
- 22 S. Dumančić, Neuronske mreže, Diplomski rad. Dostupno na: <http://www.mathos.unios.hr/~mdjumic/uploads/diplomski/DUM05.pdf>. [Citirano: 9.6.2023.]
- 23 <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
- 24 <https://medium.com/@shubhamkabre/step-by-step-solution-of-deep-learning-for-pneumonia-detection-from-chest-x-ray-images-5bb272eb8548>
- 25 <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>

SAŽETAK

X-ray slike prsnog koša dobivaju se medicinskim uređajima za radiografiju, računalnu tomografiju (CT), ultrazvuk te magnetsku rezonancu (MR). Na osnovu medicinskih slika otkrivaju se i potvrđuje različite bolesti. Jedna od tih bolesti je upala pluća (pneumonija), česta akutna upalna bolest plućnog parenhima. S razvojem tehnologije sve su češći sustavi koji se koriste za detekciju upale pluća iz X-ray slika prsnog koša. Takvi sustavi temeljeni su na metodama dubokog učenja, od kojih su najčešće konvolucijske neuronske mreže koje daju jako dobre rezultate i kada se radi s manjim skupovima podataka. Za potrebe ovog rada kreiran je sustav dubokog učenja koji koristi konvolucijsku neuronsku mrežu kako bi detektirao upalu pluća na skupu podataka sastavljenom od X-ray slika prsnog koša. Za klasifikaciju podataka korišten je binarni klasifikator te su prikazani rezultati dobiveni klasifikacijom.

Ključne riječi: duboko učenje, konvolucijske neuronske mreže, upala pluća, X-ray slike prsnog koša

ABSTRACT

Chest X-ray images are obtained using devices for radiography, computerized tomography (CT), ultrasound and magnetic resonance imaging (MRI). Medical images are used for detection and confirmation of various diseases. One of these diseases is pneumonia which is an inflammation of the lungs, usually caused by an infection. Systems that are used to detect pneumonia from X-ray images are becoming more and more common since thanks to the constant development of technology. Such systems are based on deep learning methods and the most common methods are convolutional neural networks that can be used even on smaller datasets and still achieve good results. For the purposes of this paper, a deep learning system based on a convolutional neural network was created with a goal to detect pneumonia from a data set composed of a chest X-ray images. A binary classifier was used to classify the data, and the results obtained by the classification were presented.

Key words: deep learning, convolutional neural networks, pneumonia, chest X-ray images

PRILOZI

pneumonia_detection.py

```
1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import seaborn as sns
4 import os
5 import keras
6 from keras import backend as K
7 from keras.utils.vis_utils import plot_model
8 from keras.models import Sequential
9 from keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout
10 from keras.preprocessing.image import ImageDataGenerator
11 from sklearn.metrics import confusion_matrix, roc_curve
12
13 # Podaci
14 train = 'archive\\chest_xray\\train'
15 val = 'archive\\chest_xray\\val'
16 test = 'archive\\chest_xray\\test'
17
18 def data_plot(dir, title):
19     x=len(os.listdir(dir+'/NORMAL'))
20     y=len(os.listdir(dir+'/PNEUMONIA'))
21     category = ['Zdrava pluća', 'Upala pluća']
22     count = [x, y]
23     plot = plt.bar(category,count)
24     plot[0].set_color('orange')
25     plt.title(title)
26     plt.show()
27
28 print('Skup za učenje:\n')
29 print('Zdrava pluća:', len(os.listdir(train+'/NORMAL')), '\nUpala pluća:', len(os.listdir(train+'/PNEUMONIA')))
30 print('Ukupan broj slika skupa za učenje:', len(os.listdir(train+'/NORMAL')) + len(os.listdir(train+'/PNEUMONIA')))
31 data_plot(train, title='Prikaz broja slika skupa za učenje')
32
33 print('\nValidacijski skup:\n')
34 print('NORMAL:', len(os.listdir(val+'/NORMAL')), '\nPNEUMONIA:', len(os.listdir(val+'/PNEUMONIA')))
35 print('Ukupan broj slika validacijskog skupa:', len(os.listdir(val+'/NORMAL')) + len(os.listdir(val+'/PNEUMONIA')))
36 data_plot(val, title='Prikaz broja slika validacijskog skupa')
37
38 print('\nTestni skup:\n')
39 print('NORMAL:', len(os.listdir(test+'/NORMAL')), '\nPNEUMONIA:', len(os.listdir(test+'/PNEUMONIA')))
40 print('Ukupan broj slika testnog skupa:', len(os.listdir(test+'/NORMAL')) + len(os.listdir(test+'/PNEUMONIA')))
41 data_plot(test, title='Prikaz broja slika testnog skupa')
42
43 # Metrike
44 def plot_metrics(model):
45     train_loss = model.history['loss']
46     val_loss = model.history['val_loss']
47     train_f1_score = model.history['f1']
48     val_f1_score = model.history['val_f1']
49
50     fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(15,5))
51     plt.subplots_adjust(wspace=0.40)
52 # Gubitak
53     ax1.plot(train_loss)
54     ax1.plot(val_loss)
55     ax1.grid()
56     ax1.set_xlabel('Epohe')
57     ax1.set_ylabel('Gubitak')
58     ax1.legend(['Gubitak skupa za učenje', 'Gubitak testnog skupa'], loc='upper left')
59     ax1.set_title('Prikaz gubitka na skupu za učenje i testnom skupu u odnosu na broj epoha')
```

```

60 # F1 mjera
61 ax2.plot(train_f1_score)
62 ax2.plot(val_f1_score)
63 ax2.grid()
64 ax2.set_xlabel('Epohe')
65 ax2.set_ylabel('F1 mjera')
66 ax2.legend(['F1 mjera skupa za učenje', 'F1 mjera testnog skupa'], loc='upper left')
67 ax2.set_title('Prikaz F1 mjere na skupu za učenje i testnom skupu u odnosu na broj epoha')
68
69 plt.show()
70
71 # Funkcija predikcije
72 def predict_class(predictions):
73     valResult = predictions.copy()
74     valResult[valResult <= 0.5] = 0
75     valResult[valResult > 0.5] = 1
76     return valResult
77
78 # Matrica zabune
79 def plot_cm(predictions, labels):
80     valResult = predict_class(predictions)
81     cm = pd.DataFrame(confusion_matrix(labels, valResult),
82                       index=["Zdrava pluća", "Upala pluća"],
83                       columns=["Zdrava pluća", "Upala pluća"])
84     plt.title("Matrica zabune")
85     sns.heatmap(cm,
86                annot=True,
87                annot_kws={"size": "25"},
88                fmt='.3g')
89     plt.xlabel('\nProcjena')
90     plt.ylabel('Stvarno')
91     plt.show()
92
93 # ROC krivulja
94 def plot_roc(predictions, labels):
95     fpr, tpr, thresholds = roc_curve(labels, predictions)
96     plt.plot(fpr, tpr, 'g')
97
98     plt.plot([0, 1], [0, 1], 'r--')
99     plt.title('Receiver Operating Characteristic (ROC) krivulja', fontsize=12)
100    plt.ylabel('\nStopa istinito npozitivnih rezultata (TPR)', fontsize=10)
101    plt.xlabel('\nStopa lažno pozitivnih rezultata (FPR)', fontsize=10)
102    plt.grid()
103    plt.show()
104
105 def f1(actual_class, prediction):
106     def recall_score(actual_class, prediction):
107         true_positives = K.sum(K.round(
108             K.clip(actual_class * prediction, 0, 1)))
109         possible_positives = K.sum(K.round(K.clip(actual_class, 0, 1)))
110         recall = true_positives / (possible_positives + K.epsilon())
111         return recall
112     def precision_score(actual_class, prediction):
113         true_positives = K.sum(K.round(
114             K.clip(actual_class * prediction, 0, 1)))
115         predicted_positives = K.sum(K.round(K.clip(actual_class, 0, 1)))
116         precision = true_positives / (predicted_positives + K.epsilon())
117         return precision
118     precision = precision_score(actual_class, prediction)

```

```

178 | | | | | | | | | | | | | | | shuffle = False)
179
180 validation_steps = validation_generator.samples // batch_size
181 # (624/16 = 39)
182 training_steps = train_generator.samples // batch_size
183 # (5216/16= 326)
184
185 model_1 = model.fit_generator(
186 | | | | | | | | generator = train_generator,
187 | | | | | | | | steps_per_epoch = training_steps,
188 | | | | | | | | epochs = 30,
189 | | | | | | | | validation_data = validation_generator,
190 | | | | | | | | validation_steps = validation_steps)
191
192 plot_metrics(model_1)
193
194 # Predikcija modela
195 prediction = model.predict_generator(validation_generator,
196 | | | | | | | | | | | | | | validation_steps)
197 actual_class = validation_generator.classes
198
199 # Matrica zabune
200 plot_cm(prediction, actual_class)
201
202 # ROC krivulja
203 plot_roc(prediction, actual_class)
204
205 # Spremanje modela na disk
206 KERAS_MODEL_NAME = "PneumoniaModel/keras.hdf5"
207 keras.models.save_model(model, KERAS_MODEL_NAME)
208 del model
209
152 batch_size = 16
153
154 train_data_generator = ImageDataGenerator(rescale = 1./255,
155 | | | | | | | | | | | | | | | | rotation_range = 9,
156 | | | | | | | | | | | | | | | | | | | | zoom_range = 0.2,
157 | | | | | | | | | | | | | | | | | | | | width_shift_range = 0.2,
158 | | | | | | | | | | | | | | | | | | | | height_shift_range = 0.2)
159 validation_data_generator = ImageDataGenerator(rescale = 1./255,
160 | | | | | | | | | | | | | | | | | | | | rotation_range = 9,
161 | | | | | | | | | | | | | | | | | | | | zoom_range = 0.2,
162 | | | | | | | | | | | | | | | | | | | | width_shift_range = 0.2,
163 | | | | | | | | | | | | | | | | | | | | height_shift_range = 0.2)
164 # Train
165 train_generator = train_data_generator.flow_from_directory(
166 | | | | | | | | | | | | | | | | | | | | train,
167 | | | | | | | | | | | | | | | | | | | | target_size = (width, height),
168 | | | | | | | | | | | | | | | | | | | | batch_size = batch_size,
169 | | | | | | | | | | | | | | | | | | | | class_mode = 'binary',
170 | | | | | | | | | | | | | | | | | | | | color_mode = 'grayscale')
171 # Test
172 validation_generator = validation_data_generator.flow_from_directory(
173 | | | | | | | | | | | | | | | | | | | | test,
174 | | | | | | | | | | | | | | | | | | | | target_size = (width, height),
175 | | | | | | | | | | | | | | | | | | | | batch_size = batch_size,
176 | | | | | | | | | | | | | | | | | | | | class_mode = 'binary',
177 | | | | | | | | | | | | | | | | | | | | color_mode = 'grayscale',

```

```

178 | | | | | | | | | | | | | | | | | | | | shuffle = False)
179
180 validation_steps = validation_generator.samples // batch_size
181 # (624/16 = 39)
182 training_steps = train_generator.samples // batch_size
183 # (5216/16= 326)
184
185 model_1 = model.fit_generator(
186 | | | | | | | | | | | | | | | | | | | | generator = train_generator,
187 | | | | | | | | | | | | | | | | | | | | steps_per_epoch = training_steps,
188 | | | | | | | | | | | | | | | | | | | | epochs = 30,
189 | | | | | | | | | | | | | | | | | | | | validation_data = validation_generator,
190 | | | | | | | | | | | | | | | | | | | | validation_steps = validation_steps)
191
192 plot_metrics(model_1)
193
194 # Predikcija modela
195 prediction = model.predict_generator(validation_generator,
196 | | | | | | | | | | | | | | | | | | | | validation_steps)
197 actual_class = validation_generator.classes
198
199 # Matrica zabune
200 plot_cm(prediction, actual_class)
201
202 # ROC krivulja
203 plot_roc(prediction, actual_class)
204
205 # Spremanje modela na disk
206 KERAS_MODEL_NAME = "PneumoniaModel/keras.hdf5"
207 keras.models.save_model(model, KERAS_MODEL_NAME)
208 del model
209

```