

Unaprijeđivanje kvalitete CT snimaka primjenom neuronskih mreža

Pavlović, Kristijan

Master's thesis / Diplomski rad

2019

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:200:848536>

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

Download date / Datum preuzimanja: **2025-04-01**

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

**UNAPRIJEĐIVANJE KVALITETE CT SNIMAKA
PRIMJENOM NEURONSKIH MREŽA**

Diplomski rad

Kristijan Pavlović

Osijek, 2019.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 21.09.2019.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Kristijan Pavlović
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D-923R, 24.09.2018.
OIB studenta:	87350576984
Mentor:	Izv. prof. dr. sc. Irena Galić
Sumentor:	Dr. sc. Hrvoje Leventić
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	Doc.dr.sc. Časlav Livada
Član Povjerenstva:	Dr. sc. Krešimir Romić
Naslov diplomskog rada:	Unaprijeđivanje kvalitete CT snimaka primjenom neuronskih mreža
Znanstvena grana rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak diplomskog rada:	Istražiti i opisati state of the art metode unaprijeđivanja kvalitete CT snimaka primjenom neuronskih mreža. Praktični dio: razviti sustav za generiranje podataka za učenje te razviti arhitekturu neuronske mreže koja će omogućiti unaprijeđivanje kvalitete CT snimaka. Tehnologija: Python, Ruby, Tensorflow Sumentor: Hrvoje Leventić. Tema rezervirana za: Kristijan Pavlović
Prijedlog ocjene pismenog dijela ispita (diplomskog 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: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	21.09.2019.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

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

Osijek, 23.09.2019.

Ime i prezime studenta:

Kristijan Pavlović

Studij:

Diplomski sveučilišni studij Računarstvo

Mat. br. studenta, godina upisa:

D-923R, 24.09.2018.

Ephorus podudaranje [%]:

6%

Ovom izjavom izjavljujem da je rad pod nazivom: **Unaprijeđivanje kvalitete CT snimaka primjenom neuronskih mreža**

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

i sumentora Dr. sc. Hrvoje Leventić

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 diplomskog rada	1
2. UMJETNE NEURONSKE MREŽE	2
2.1. Duboke neuronske mreže	4
2.2. Konvolucijske neuronske mreže	5
2.2.1. Konvolucijski sloj	5
2.2.2. Sloj sažimanja	6
2.2.3. Potpuno povezani sloj	7
2.3. Učenje neuronskih mreža	7
3. METODE UNAPRJEĐIVANJA KVALITETE CT SNIMKI PRIMJENOM NEURONSKIH MREŽA	10
3.1. Jednostavna konvolucijska neuronska mreža	10
3.1.1. Korišteni skupovi podataka	10
3.1.2. Rezultati	11
3.2. Konvolucijska neuronska mreža temeljena na usmjerenim valovima	12
3.2.1. Korišteni skupovi podataka	12
3.2.2. Rezultati	13
3.3. Rezidualna enkoder-dekoder konvolucijska neuronska mreža	13
3.3.1. Korišteni skupovi podataka	13
3.3.2. Rezultati	14
3.4. Rezidualna konvolucijska neuronska mreža	15
3.4.1. Korišteni skupovi podataka	16
3.4.2. Rezultati	16
3.5. Perceptivna konvolucijska neuronska mreža	17
3.5.1. Korišteni skupovi podataka	17
3.5.2. Rezultati	17
3.6. Konvolucijska neuronska mreža temeljena na U-net arhitekturi	17
4. KONVOLUCIJSKA NEURONSKA MREŽA ZA UNAPRJEĐIVANJE KVALITETE CT SNIMKI	20
4.1. Programski jezik Python	20
4.2. Programska biblioteka TensorFlow i Keras API	20

4.3. Metode evaluacije unaprjeđivanja kvalitete CT snimki	21
4.4. Opis skupa podataka	21
4.5. Jednostavna konvolucijska neuronska mreža	22
4.5.1. Predobrada skupa podataka	22
4.5.2. Učenje predložene konvolucijske neuronske mreže	24
4.5.3. Evaluacija predložene konvolucijske neuronske mreže	26
4.6. Konvolucijska neuronska mreža temeljena na U-net arhitekturi	27
4.6.1. Predobrada skupa podataka	27
4.6.2. Učenje predložene konvolucijske neuronske mreže	28
4.6.3. Evaluacija predložene konvolucijske neuronske mreže	29
4.6.4. Optimizacija parametara predložene konvolucijske neuronske mreže	30
5. ZAKLJUČAK	33
LITERATURA	34
SAŽETAK	37
SUMMARY	38
ŽIVOTOPIS	39
PRILOZI	40

1. UVOD

Računalna tomografija (*engl. Computerized Tomography - CT*) je slikovna radiološka metoda koja podrazumijeva korištenje ionizirajuće-rendgenskog zračenja [1] u svrhu kreiranja slojevitog prikaza određenog dijela tijela. CT je pogodan za prikaz koštanih struktura, slobodnih zglobnih tijela te topografskog odnosa koštanih i mekotkivnih struktura. Prema [2], rastući broj CT snimki povećava potencijalni rizik od zračenja i postaje razlog zabrinutosti javnosti. Da bi se smanjio potencijalni rizik, CT s niskom dozom zračenja privlači sve veću pozornost, ali smanjivanje količine zračenja znatno pogoršava kvalitetu CT snimke.

Cilj ovog diplomskog rada je dati teorijsku podlogu vezanu za konvolucijske neuronske mreže, opisati *state of the art* metode unaprjeđivanja kvalitete CT snimki primjenom neuronskih mreža te za praktični dio implementirati neuronsku mrežu koja unaprjeđuje kvalitetu CT snimki iz prikupljenog skupa podataka. Glavna motivacija rada je razvoj neuronske mreže koja radiolozima omogućuje korištenje niže količine zračenja za snimke jednake kvalitete kao kod onih snimljenih s višom dozom.

U drugom će se poglavlju opisati teorijska podloga vezana za umjetne neuronske mreže, duboke neuronske mreže i konvolucijske neuronske mreže. Navest će se različiti slojevi konvolucijske neuronske mreže te opisati kako neuronske mreže uče. U trećem će se poglavlju opisati *state of the art* metode unaprjeđivanja kvalitete CT snimki primjenom neuronskih mreža. U četvrtom će se poglavlju opisati dvije predložene neuronske mreže kreirane u svrhu unaprjeđivanja kvalitete CT snimki. Navest će se njihova arhitektura, korišteni skup podataka, opisati proces učenja te će se prikazati rezultati evaluacije predloženih mreža.

1.1. Zadatak diplomskog rada

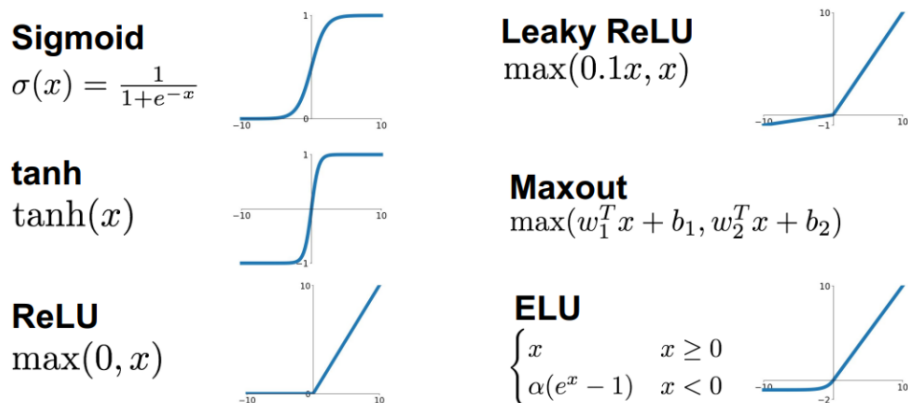
Zadatak diplomskog rada je istražiti i opisati *state of the art* metode unaprjeđivanja kvalitete CT snimki primjenom neuronskih mreža. Za praktični dio rada potrebno je razviti sustav za generiranje podataka za učenje te razviti arhitekturu neuronske mreže koja će omogućiti unaprjeđivanje kvalitete CT snimki.

2. UMJETNE NEURONSKE MREŽE

Umjetne neuronske mreže (*engl. artificial neural networks*) ili skraćeno neuronske mreže (*engl. neural networks*) prvotno su bile inspirirane načinom rada ljudskog mozga [3], ali se vremenom udaljilo od pokušaja emulacije rada mozga i počelo koristiti prikladnija rješenja za specifične probleme. Neki od tih problema su: računalni vid, obrada prirodnog jezika (*engl. natural language processing*) i prepoznavanje govora.

Neuronske mreže postoje već dugo godina, ali su se tek u zadnje vrijeme postavile kao bolji izbor u odnosu na konkurentne metode strojnog učenja. Prema [3], primarni razlog toga je brzi razvoj računalne tehnologije i činjenica da neuronske mreže omogućuju korištenje GPU-a (*engl. Graphics Processing Unit* - jedinica za obradu grafike) koji su znatno brži od CPU-a (*engl. Central Processing Unit* - središnja jedinica za obradu), koje koriste tradicionalne metode, prilikom obrade podataka. Također, neuronske mreže omogućuju kreiranje kompleksnijih i boljih algoritama te obradu većeg skupa podataka (*engl. dataset*) u odnosu na konkurentne metode.

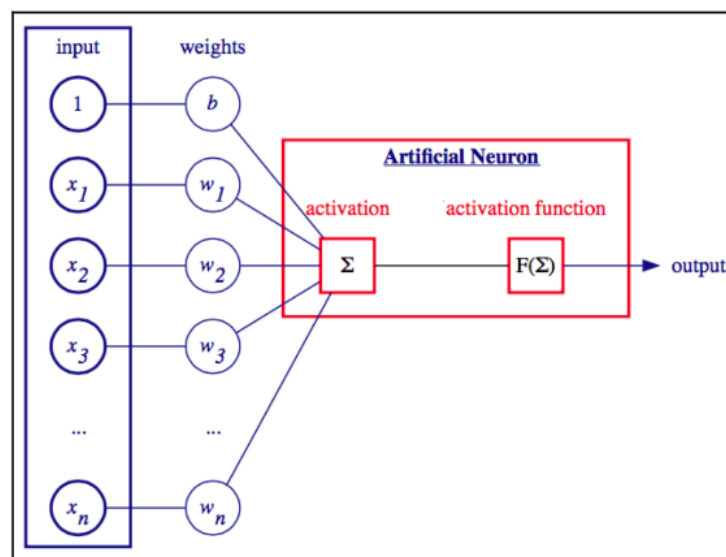
Kao i sve ostale metode strojnog učenja, neuronska mreža se može opisati kao matematički model za obradu informacija. U neuronskim se mrežama obrada informacija odvija kroz niz jednostavnih, povezanih elemenata koji se nazivaju neuroni i koji izmjenjuju informacije putem veza koje ih povezuju. Neuroni su matematičke funkcije koje na temelju jednog ili više ulaza daju izlaz. Veze između neurona su opisane težinama koje određuju njihovu važnost te kako se obrađuju informacije. Svaki neuron ima unutarnje stanje koje je određeno na temelju izlaza svih neurona koji su s njime povezani. Izlaz neurona se određuje korištenjem aktivacijske funkcije koja omogućuje kreiranje nelinearnih neuronskih mreža i koja je izračunata na temelju unutarnjeg stanja neurona. Na slici Sl. 2.1. nalazi se prikaz najčešće korištenih aktivacijskih funkcija.



Sl. 2.1.: Najčešće korištene aktivacijske funkcije [4]

Neuronska mreža može imati neograničen broj neurona koji su organizirani u međusobno povezane slojeve (*engl. layers*). Ulazni sloj predstavlja skup podataka i početne uvjete te se inače ne broji kod opisa mreže i utvrđivanja broja slojeva, a izlazni sloj predstavlja izlaz iz mreže. Izlazni sloj može imati više od jednog neurona, a to je izuzetno korisno kod klasifikacije gdje svaki izlazni neuron predstavlja jednu od klasa.

Na slici Sl. 2.2. nalazi se prikaz neuronske mreže koja se sastoji od više ulaza koji su povezani s jednim neuronom. Prvi iznosi 1 i on ima težinu koja je predstavljena slovom b , što označava *bias*.



Sl. 2.2.: Neuronska mreža [3]


Neuron je definiran kao:

$$y = f\left(\sum_i x_i w_i + b\right) \quad (2-1)$$

gdje y predstavlja izlaz, $f()$ aktivacijsku funkciju, x_i ulaze, w_i težine, a b *bias*. Izlaz, ulazi, težine i *bias* su numeričke vrijednosti.

Između ulaznog i izlaznog sloja neuronske mreže se može nalaziti još slojeva koji se nazivaju skrivenim slojevima. Na slici Sl. 2.3. nalazi se prikaz neuronske mreže s 3 potpuno povezana sloja. Uobičajeno je da svi neuroni u istom sloju imaju jednaku aktivacijsku funkciju, ali za različite slojevi ona ne mora biti jednaka.

Svaka neuronska mreža mora proći kroz postupak učenja (*engl. training*) da bi se suvislo podesili parametri mreže, tj. težine veza između neurona. Budući da je neuronska mreža aproksimacija kriterijske funkcije, niti jedna mreža neće biti jednaka kriterijskoj funkciji koju aproksimira nego će se od nje razlikovati za pogrešku (*engl. error*). Prilikom učenja koristi se *backpropagation* algoritam koji, nakon svakog prolaska podataka kroz mrežu, ponovno podešava parametre mreže s ciljem minimizacije pogreške.



Sl. 2.3.: Neuronska mreža s 3 sloja [3]

2.1. Duboke neuronske mreže

Neuronske mreže koje imaju više od jednog skrivenog sloja nazivaju se duboke neuronske mreže (*engl. deep neural networks*). Glavni razlog korištenja dubokih neuronskih mreža je razina učenja. One ne uče samo kako predvidjeti izlaz na temelju ulaznih podataka nego imaju sposobnost razumijevanja osnovnih značajki i karakteristika ulaza. Ta se sposobnost naziva duboko učenje (*engl. deep learning*).

Njihova upotreba je najčešća pri rješavanju problema predikcije, detekcije značajki i klasifikacije. Najpoznatije primjene dubokog učenja u praksi:


- Googleov Vision API [5] i Amazonov Rekognition [6] omogućuju korištenje dubokog učenja u svrhu raznih primjena računalnog vida kao što su: prepoznavanje i detekcija objekata i scena na slikama, prepoznavanje teksta, prepoznavanje lica,
- obrada MR (*engl. Magnetic Resonance* - magnetna rezonanca) [7] i CT [2] snimki u medicini,
- Googleov Neural Machine Translation API [8] omogućuje korištenje dubokih neuronskih mreža za računalno prevođenje,
- Googleov Assistant [9], Appleova Siri [10] i Amazonova Alexa [11] se oslanjaju na duboke neuronske mreže za prepoznavanje govora,
- Googleov AlphaGo [12], koji je baziran na dubokom učenju, je 2016. godine pobijedio svjetskog prvaka Lee Sedola u poznatoj japanskoj strateškoj igri Go.

Najpopularnije biblioteke otvorenog koda (*engl. open-source libraries*) koje se koriste za duboko učenje u programskom jeziku Python su TensorFlow, Keras i PyTorch.

2.2. Konvolucijske neuronske mreže

Konvolucijska neuronska mreža (*engl. convolutional neural network*) ili jednostavno konvolucijska mreža je vrsta dubokih neuronskih mreža koja, prema [3], trenutno daje bolje rezultate od svih ostalih metoda strojnog učenja u području računalnog vida i obrade prirodnog jezika. Vid je jedan od najbitnijih ljudskih osjetila te se na njega oslanjamo gotovo pri svakoj radnji. Unatoč tome, računalni vid i prepoznavanje slika je do sada bio jedan od najtežih problema računalnih znanosti. Vrlo je teško objasniti računalu koje sve značajke čine koji objekt i kako ih prepoznati, ali dubokim učenjem neuronske mreže mogu samostalno naučiti te značajke.

Konvolucijske neuronske mreže se sastoje od niza slojeva: konvolucijski slojevi (*engl. convolutional layers*), slojevi sažimanja (*engl. pooling layers*) i potpuno povezani slojevi (*engl. fully connected layers*). Na slici Sl. 2.4. nalazi se prikaz jedne arhitekture konvolucijske neuronske mreže koja služi za klasifikaciju slika.




Sl. 2.4.: Arhitektura konvolucijske neuronske mreže [3]


2.2.1. Konvolucijski sloj

Konvolucijski sloj je najbitniji sloj u konvolucijskim neuronskim mrežama i služi za ekstrakciju značajki iz ulaznih podataka. Sastoji se od niza *kernela* koji predstavljaju filtere koji se primjenjuju na svim dijelovima ulaznih podataka. *Kernel* je definiran nizom težina koje imaju sposobnost učenja. Budući da su ulazni podaci dvodimenzionalni u slučaju crno-bijele slike te trodimenzionalni u slučaju slike u boji (RGB), svaki piksel slike predstavljen je s jednim (crno-bijela slika) ili tri neurona (slika u boji). Svaki neuron sadrži intenzitet boje piksela na tom mjestu te su samo susjedni neuroni povezani, što smanjuje broj težina. Na slici Sl. 2.5. nalazi se ilustracija primjene *kernela* dimenzije 3x3 na dvodimenzionalne ulazne podatke.

Kernel se prvo postavlja u gornji lijevi kut slike te se za određivanje izlaznog neurona utvrđuje ponderirana suma (*engl. weighted sum*) ulaza s ciljem da se istakne specifična značajka ulaza, primjerice rub ili crta. Skup neurona koji sudjeluju u ulazu *kernela* nazivaju se receptivno polje (*engl. receptive field*). U kontekstu mreže, izlaz dobiven primjenom *kernela* predstavlja aktivacijsku vrijednost neurona u sljedećem sloju. *Kernel* se tako pomiče po slici s korakom (*engl. stride*) određene veličine dok ne obiđe cijelu površinu ulaznih podataka, a tijekom obilaska mu težine ostaju



Sl. 2.5.: Primjena *kernela* na dvodimenzionalne ulazne podatke [3]




Sl. 2.6.: Konvolucija s *kernelom* veličine 2x2 [3]

nepromijenjene. Na slici Sl. 2.6. nalazi se prikaz konvolucije gdje se na temelju ulaza dimenzije 4x4 i *kernela* dimenzije 2x2 dobije izlaz dimenzije 3x3.


Izlazni podatci dobiveni konvolucijom se nazivaju mapama značajki (*engl. feature maps*) i svaki konvolucijski sloj ih može imati više, ali je svaka mapa dobivena *kernelom* različitih težina. Mape značajki se koriste kao ulazi u sljedeći sloj konvolucijske mreže.

2.2.2. Sloj sažimanja

Sloj sažimanja dijeli ulazne podatke na matricu gdje svaka podmatrica predstavlja receptivno polje nekoliko neurona. Nakon toga se na svaku podmatricu primjenjuje operaciju sažimanja. Sloj sažimanja ne mijenja dubinu ulaznih podataka nego samo služi da se reprezentacija slike drži što manjom. Najčešći oblik sažimanja je po maksimalnoj vrijednosti (Sl. 2.7.), a postoji i oblik sažimanja po srednjoj vrijednosti (Sl. 2.8.). Slojevi sažimanja su definirani korakom i veličinom receptivnog polja. Na slikama je za izračun izlaza korišten korak od 2, a veličina perceptivnog polja je bila 2x2.



Sl. 2.7.: Sažimanje po maksimalnoj vrijednosti [3]



Sl. 2.8.: Sažimanje po srednjoj vrijednosti [3]

2.2.3. Potpuno povezani sloj

Potpuno povezani slojevi predstavljaju nekoliko potpuno povezanih slojeva neurona i oni, korištenjem aktivacijske funkcije, estimiraju izlaze konvolucijske neuronske mreže. Ako je namjena mreže višeklasna klasifikacija onda se koristi softmax aktivacijska funkcija, a broj izlaznih neurona je jednak broju klasa iz skupa za klasifikaciju. Softmax aktivacijska funkcija određuje vjerojatnosti da objekt koji se klasificira pripada pojedinoj klasi, a ukupan zbroj vjerojatnosti uvijek iznosi 1.

2.3. Učenje neuronskih mreža

Nakon definiranja arhitekture neuronske mreže koja sadrži informacije o mreži kao što su vrsta ulaza, broj skrivenih slojeva, broj neurona u skrivenom sloju, aktivacijska funkcija i vrsta izlaza, moraju se postaviti težine koje će definirati interna stanja svakog neurona.

Prema [3], svaka neuronska mreža je aproksimacija kriterijske funkcije te ne može nikada biti jednaka funkciji koju aproksimira. Tijekom učenja neuronske mreže, cilj je minimizirati pogrešku aproksimacije. Pogreška ovisi o težinama, kojih je mnogo u neuronskim mrežama, tako da se za pogrešku može reći da je ona funkcija s mnogo varijabli. Minimizacija aproksimacije tada označava traženje minimuma hiperravnine.

Kriterijske funkcije koje se koriste u ovom diplomskom radu su:

- MSE (*engl. mean squared error*) - srednja kvadratna pogreška,
- MAE (*engl. mean absolute error*) - srednja apsolutna pogreška i
- L0 - proizvoljno implementirana funkcija.

Srednja kvadratna pogreška je prema [13] definirana kao:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (2-2)$$

a srednja apsolutna pogreška kao:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (2-3)$$

gdje y_i predstavlja referentni izlaz, a \hat{y}_i izlaz modela.

Implementacija L0 kriterijske funkcije prema [14] može se definirati kao:

$$\text{L0} = \sum_{i=1}^N (|y_i - \hat{y}_i| + 10^{-8})^{\text{gamma}}, \quad (2-4)$$

gdje y_i predstavlja referentni izlaz, \hat{y}_i izlaz modela, a gamma potenciju čija je inicijalna vrijednost 2 i koja se smanjuje pri svakoj sljedećoj epohi.

Učenje neuronske mreže za sebe veže nekoliko pojmova koje treba definirati. Prema [3], stopa učenja predstavlja vrijednost koja označava kolika će biti promjena trenutnih težina mreže kada se pojave novi podaci. Ona se može odrediti tako da ostane nepromijenjena tijekom cijelog procesa učenja, ali se može i dinamički mijenjati ovisno o točnosti mreže ili o proteklom vremenu od početka učenja. Stopa učenja se najčešće predaje kao parametar metodi optimizacije kojoj je cilj minimizirati kriterijsku funkciju i koja se primjenjuje tijekom učenja mreže.

Metode optimizacije koje se koriste u ovom diplomskom radu su:

- SGD (*engl. stochastic gradient descent*) - stohastički gradijent spusta,
- Adam (*engl. adaptive moment estimation*) - adaptivna estimacija momenta i
- RMSprop.

Trajanje učenja neuronske mreže određuje se brojem epoha, a jedna epoha predstavlja jedan obilazak skupa podataka za učenje. Da bi se ubrzalo učenje mreže, u memoriju se može učitati više podataka od jednom, a broj istovremeno učitanih podataka naziva se veličina *batcha* (*engl. batch size*).

Prije procesa učenja neuronske mreže, skup podataka je potrebno podijeliti na 3 dijela:

- skup za učenje - skup podataka na temelju kojih neuronska mreža uči,

- skup za validiranje naučenog - skup podataka na temelju kojih se provjerava točnost mreže tijekom učenja, često nakon svake epohe,
- skup za testiranje - skup podataka koje mreža nije "vidjela" tijekom učenja, na temelju njega se testira finalna točnost mreže nakon učenja.

3. METODE UNAPRJEĐIVANJA KVALITETE CT SNIMKI PRIMJENOM NEURONSKIH MREŽA


Zbog lakšeg odabira arhitekture neuronske mreže za rješavanje zadanog problema, proučene su i opisane *state of the art* metode unaprjeđivanja kvalitete CT snimki primjenom neuronskih mreža.

3.1. Jednostavna konvolucijska neuronska mreža

Chen i ostali u svom prvom radu na temu unaprjeđivanja kvalitete CT snimki [2] predlažu korištenje konvolucijske neuronske mreže koja se sastoji od tri sloja. Prvi i drugi sloj se sastoje od konvolucijskog dijela s ReLU (*engl. Rectified Linear Unit*) aktivacijskom funkcijom, a treći sloj od konvolucijskog dijela bez aktivacijske funkcije. Ulaz i izlaz su slike, ali se svaka ulazna slika dijeli na preklapajuće segmente slike fiksne veličine (*engl. patches*) s određenim korakom koji je manji od veličine segmenta. Mreža uči koristeći navedene *patcheve* te se, na temelju naučenog, slika rekonstruira netom prije izlaza.

3.1.1. Korišteni skupovi podataka

Skup podataka preuzet je s mrežne stranice The Cancer Imaging Archive (TCIA). On se sastoji od 165 CT snimki raznih dijelova tijela pacijenata koje su snimljene pri uobičajenoj količini zračenja. Snimke ukupno sadrže 7015 slika (*engl. slices*) rezolucije 256x256 piksela. Na slici Sl. 3.1. nalazi se prikaz tipičnih slika iz skupa podataka.



Sl. 3.1.: Slike iz skupa podataka [2]

Dodavanjem Poissonovog šuma na preuzete slike dobiveni su parovi slika, referentne i zašumljene.

Za dodatno testiranje mreže nad realnim podacima, korištene su dvije CT snimke ovce koje je pružio doktor Eric Hoffman iz sveučilišta američke savezne države Iowa. Jedna CT snimka je snimljena pri uobičajenoj količini zračenja, a druga pri niskoj količini zračenja.

3.1.2. Rezultati

Predložena mreža je implementirana koristeći programski jezik MATLAB, učena je koristeći 200, a testirana koristeći 100 parova slika. Od 200 slika iz skupa za učenje kreirano je ukupno 10^6 *patcheva*. Kao metoda optimizacije korištena je SGD metoda, kriterijska funkcija je temeljena je na srednjoj kvadratnoj pogrešci, a učenje je ukupno trajalo 17 sati koristeći NVIDIA GTX 980 Ti grafičku karticu.

Rezultati predložene konvolucijske mreže nad podacima preuzetim s mrežne stranice TCIA uspoređeni su s 3 konkurentne metode za uklanjanje šuma: ASD-POCS [15], K-SVD [16] i BM3D [17], čiji su parametri postavljeni prema izvornim člancima.

Kvantitativna evaluacija mreže predložene u [2] izvršena je uspoređujući njene rezultate unaprjeđivanja kvalitete slika s rezultatima prethodno navedenih konkurentnih metoda. Usporedba rezultata je izvršena korištenjem nekoliko metoda: omjer signala i šuma (*engl. peak signal to noise ratio - PSNR*), korijen srednje kvadratne pogreške (*engl. root mean square error - RMSE*) i indeks strukturne sličnosti (*engl. structural similarity - SSIM*). PSNR i SSIM metode su dodatno opisane u potpoglavlju 4.3.. Na slici Sl. 3.2. nalaze se rezultati kvantitativne evaluacije.

	Low-dose	ASD-POCS	KSVD	BM3D	CNN200
PSNR	36.3975	41.5021	40.8445	41.5358	42.1514
RMSE	0.0158	0.0087	0.0096	0.0088	0.0080
SSIM	0.8644	0.9447	0.9509	0.9610	0.9707

Sl. 3.2.: Kvantitativna evaluacija mreže [2]

Kvalitativnu evaluaciju su izvršila tri radiologa s više od 8 godina kliničkog iskustva na temelju parova zašumljenih i izvornih slika iz skupa podataka za testiranje te pripadajućih slika unaprjeđene kvalitete dobivenih svakom od metoda. Utvrđeno da je predložena mreža ostvarila najbolje rezultate.

Dodatnim testiranjem nad realnim podacima, rezultati predložene mreže kvalitativno su evaluirani usporedbom s rezultatima konkurentnih metoda te je utvrđeno da je predložena mreža ostvarila najbolje rezultate.

Povećanjem skupa slika za učenje s 200 na 2000 ostvareni su neznatno bolji rezultati. Učenje mreže se odvijalo na temelju 10^7 *patcheva* te je trajalo 56 sati.

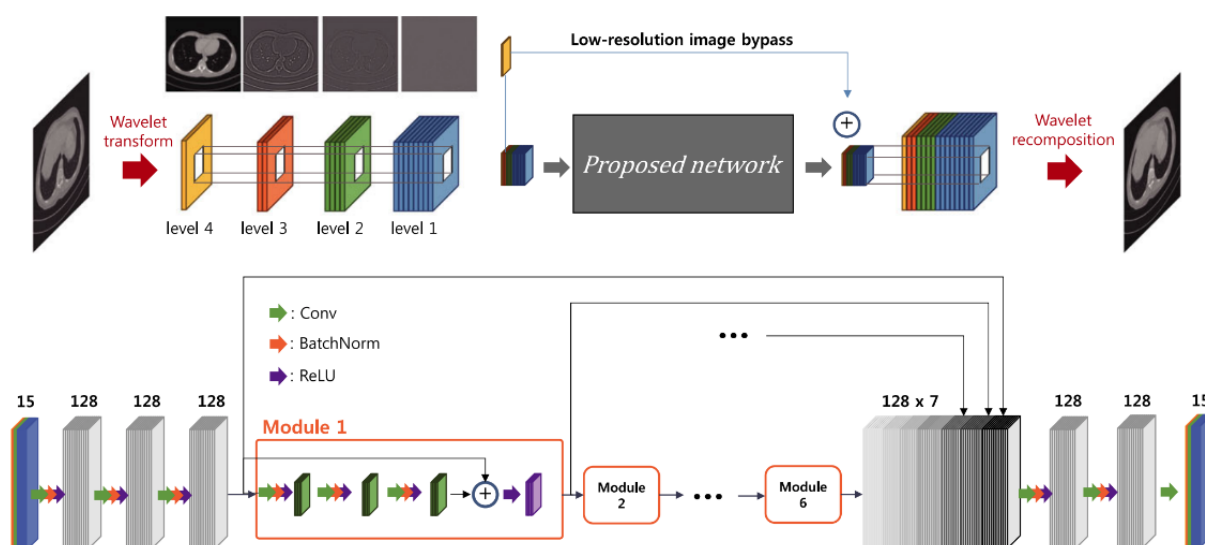
Autori navode kako bi korištenje trodimenzionalnih ulaznih podataka bio efektivan način poboljšanja performansi preložene neuronske mreže, ali da je implementacija znatno teža te da traži znatno više računalnih resursa.

3.2. Konvolucijska neuronska mreža temeljena na usmjerenim valovima

Kang i ostali u svom radu na temu unaprjeđivanja kvalitete CT snimki [18] predlažu korištenje konvolucijske neuronske mreže temeljene na usmjeravanju valova (KAIST-Net). Usmjerenom valnom transformacijom (*engl. directional wavelet transform*) se iz ulaznih podataka izdvajaju usmjerene komponente artefakta i njihove korelacije te ih mreža efektivno uklanja. U svrhu bržeg učenja i ostvarivanja boljih performansi, mreži je dodan rezidualni dio. Na slici Sl. 3.3. prikazana je arhitektura predložene neuronske mreže.

3.2.1. Korišteni skupovi podataka

Skup podataka za učenje pružila je Mayo klinika pri svom tzv. “velikom izazovu” gdje je cilj bio unaprjeđivanje kvalitete CT snimki koje su snimljene pri niskoj količini zračenja (*engl. the 2016 NIH-AAPM-Mayo Clinic Low Dose CT Grand Challenge*). Skup podataka se sastojao od 10 snimki pacijenata, ukupno 3642 slika rezolucije 512x512 piksela, koje su prethodno uparene tako da svaka snimka snimljena pri niskoj dozi zračenja (četvrtina uobičajene količine) ima svoj par koja predstavlja snimku koja je snimljena pri uobičajenoj količini zračenja.



Sl. 3.3.: Arhitektura predložene mreže [18]

Mayo klinika je također pružila i skup podataka za testiranje mreže. On se sastojao od 20 CT snimki pacijenata, ukupno 2101 slika rezolucije 512x512, koje su snimljene koristeći četvrtinu uobičajene količine zračenja.


3.2.2. Rezultati

Predložena mreža je implementirana koristeći programski jezik MATLAB. Umjesto slika pune veličine, mreža koristi *patcheve* koje ekstraktira sa slika.


Kvalitativnu evaluaciju mreže izvršili su stručnjaci na temelju rezultata koje je mreža dobila koristeći skup podataka za testiranje. Predložena mreža osvojila drugo mjesto na navedenom "velikom izazovu".

3.3. Rezidualna enkoder-dekoder konvolucijska neuronska mreža

U svom drugom radu na temu unaprjeđivanja kvalitete CT snimki [19], Chen i ostali predlažu korištenje rezidualne konvolucijske neuronske mreže (RED-CNN). Na slici Sl. 3.4. prikazana je arhitektura predložene neuronske mreže koja se sastoji od deset slojeva. Prvih se pet slojeva sastoje od konvolucijskog dijela s ReLU aktivacijskom funkcijom, a drugih pet dijelova od dekonvolucijskog dijela, također s ReLU aktivacijskom funkcijom. Na slici Sl. 3.5. prikazan je krajnji oblik neuronske mreže gdje je na arhitekturu predložene mreže dodan rezidualni dio.




Sl. 3.4.: Arhitektura predložene mreže [19]



Sl. 3.5.: Predložena mreža s dodanim rezidualnim dijelom [19]

3.3.1. Korišteni skupovi podataka

Skup podataka za učenje i testiranje predložene mreže preuzet je s mrežne stranice National Biomedical Imaging Archive te se sastoji od 165 CT snimki koje su snimljene pri uobičajenoj količini zračenja. Preuzete snimke se sastoje od 7015 slika rezolucije 256x256 piksela. Kao i u potpoglavlju 3.1., snimkama je pogoršana kvaliteta koristeći Poissonov šum te su dobiveni parovi snimki, referentne i zašumljene. Autori te podatke nazivaju simuliranim podacima. Na slici Sl. 3.6. nalazi se prikaz tipičnih slika iz skupa podataka.



Sl. 3.6.: Slike iz skupa podataka [19]

Skup podataka za krajnje testiranje mreže nad kliničkim podacima pružila je Mayo klinika u obliku snimki koji su korištene pri tzv. “velikom izazovu” klinike gdje je cilj bio unaprjeđivanje kvalitete CT snimki koje su snimljene pri niskoj količini zračenja (*engl. the 2016 NIH-AAPM-Mayo Clinic Low Dose CT Grand Challenge*). Preuzeto je 10 snimki pacijenata, ukupno 2378 slika rezolucije 512x512 piksela. One su prethodno uparene tako da svaka snimka snimljena pri niskoj dozi zračenja (četvrtina uobičajene količine) ima svoj par koja predstavlja snimku koja je snimljena pri uobičajenoj količini zračenja.

3.3.2. Rezultati

Predložena mreža je implementirana koristeći programski jezik MATLAB, a učena je koristeći NVIDIA GTX 1080 Ti grafičku karticu. Umjesto slika pune veličine, mreža koristi *patcheve* koje ekstraktira sa slika.

Da bi se kvantitativno utvrdila točnost dobivenih rezultata, korišteni su: korijen srednje kvadratne pogreške (RMSE), omjer signala i šuma (PSNR) i indeks strukturne sličnosti (SSIM).

Rezultati predložene mreže nad simuliranim podacima uspoređeni su s 5 konkurentnih metoda za unaprjeđivanje kvalitete CT snimki: TV-POCS [15], K-SVD [16], BM3D [17], CNN10 [2] i KAIST-Net [18], čiji su parametri postavljeni prema izvornim člancima. CNN10 je konvolucijska neuronska mreža opisana u potpoglavlju 3.1., a KAIST-Net je konvolucijska neuronska mreža opisana u potpoglavlju 3.2.

Na slici Sl. 3.7. nalaze se rezultati kvantitativne evaluacije predložene mreže i konkurentnih metoda nad simuliranim podacima, a na slici Sl. 3.8. se nalaze rezultati nad kliničkim podacima. Prvi broj u rezultatima predstavlja srednju vrijednost, a drugi broj standardnu devijaciju.

	PNSR	RMSE	SSIM
LDCT	36.3975±5.24	0.0158±0.0062	0.8644±0.0754
TV-POCS	41.5021±2.11	0.0087±0.0010	0.9498±0.0126
K-SVD	40.8445±2.54	0.0096±0.0013	0.9447±0.0168
BM3D	41.5358±2.09	0.0088±0.0010	0.9509±0.0127
CNN10	41.9892±2.10	0.0082±0.0011	0.9658±0.0129
KAIST-Net	42.2746±2.05	0.0078±0.0009	0.9688±0.0098
RED-CNN	43.7871±2.01	0.0069±0.0007	0.9754±0.0086

Sl. 3.7.: Kvantitativna evaluacija nad simuliranim podacima [19]

	PNSR	RMSE	SSIM
LDCT	39.4314±1.5206	0.0109±0.0021	0.9122±0.0280
TV-POCS	41.7496±1.1522	0.0083±0.0012	0.9535±0.0143
K-SVD	42.7203±1.4260	0.0074±0.0014	0.9531±0.0167
BM3D	42.7661±1.0471	0.0073±0.0009	0.9563±0.0125
CNN10	43.6561±1.1323	0.0066±0.0009	0.9664±0.0100
KAIST-Net	43.9668±1.2169	0.0064±0.0009	0.9688±0.0110
RED-CNN	44.4187±1.2118	0.0060±0.0009	0.9705±0.0087


Sl. 3.8.: Kvantitativna evaluacija nad kliničkim podacima [19]

Kvalitativnu evaluaciju su nad kliničkim podacima izvršila dva radiologa s 6 i 8 godina kliničkog iskustva na temelju 10 slika iz snimki koje su snimljene pri niskoj količini zračenja te pripadajućih poboljšanih slika dobivenih svakom od navedenih metoda. Predložena mreža je i kvalitativno pokazala najbolje rezultate.


3.4. Rezidualna konvolucijska neuronska mreža

Yang i ostali u svom radu na temu unaprjeđivanja kvalitete CT snimki [20] predlažu korištenje rezidualne konvolucijske neuronske mreže (ResNet). Predložena mreža unaprjeđuje kvalitetu CT snimki uklanjanjem šuma i artefakta predviđanjem rezidualne komponente između CT snimki koje su snimljene pri niskoj količini zračenja i CT snimki koje su snimljene pri uobičajenoj količini zračenja. Budući da dvodimenzionalna verzija predložene mreže ne uzima u obzir prostornu neprekidnost tkiva i organa, kreirana je trodimenzionalna verzija predložene mreže te su mreže uspoređene evaluacijom rezultata nad kliničkim podacima.

Na slici Sl. 3.9. se nalazi prikaz uobičajene konvolucijske neuronske mreže (a) i konvolucijske neuronske mreže s dodanim rezidualnim dijelom (b), a na slici Sl. 3.10. se nalazi prikaz arhitekture predložene mreže.



Sl. 3.9.: Konvolucijska neuronska mreža (a) i konvolucijska neuronska mreža s dodanim rezidualnim dijelom (b) [20]



Sl. 3.10.: Arhitektura predložene mreže [20]

3.4.1. Korišteni skupovi podataka

Kliničke podatke za učenje i testiranje predložene mreže je pružila Mayo klinika. To su CT snimke koje su korištene na tzv. "velikom izazovu" klinike gdje je cilj bio unaprjeđivanje kvalitete CT snimki koje su snimljene s niskom dozom zračenja (*engl. the 2016 NIH-AAPM-Mayo Clinic Low Dose CT Grand Challenge*). Podatci se sastoje od snimki koje su snimljene pri niskoj količini zračenja i pripadajućih snimki koje su snimljene pri uobičajenoj količini zračenja. Preuzeto je 10 snimki pacijenata rezolucije 512x512 piksela.

3.4.2. Rezultati

Predložena mreža je implementirana koristeći programski jezik MATLAB, a učena je koristeći NVIDIA GTX 1080 grafičku karticu. Umjesto slika pune veličine, mreža koristi *patcheve* koje ekstrahira sa slika.


Rezultati predložene rezidualne konvolucijske mreže uspoređeni su s 3 konkurentne metode za uklanjanje šuma: BM3D [17], NLM [21] i DFR [22], čiji su parametri optimizirani za dobivanje što boljih rezultata nad kliničkim podacima.

Kvantitativna evaluacija predložene mreže izvršena je uspoređujući njene rezultate unaprjeđivanja kvalitete slika s rezultatima prethodno navedenih konkurentnih metoda. Usporedba rezultata je izvršena korištenjem nekoliko metoda: omjer signala i šuma (PSNR), indeks strukturne sličnosti (SSIM), korijen srednje kvadratne pogreške (RMSE) i srednja apsolutna pogreška (MAE).

Obje predložene mreže su po svim aspektima ostvarile bolje rezultate od konkurentnih metoda, a trodimenzionalna mreža je ostvarila bolje rezultate od dvodimenzionalne.

3.5. Perceptivna konvolucijska neuronska mreža

Yang i ostali u svom radu na temu unaprjeđivanja kvalitete CT snimki [23] predlažu korištenje perceptivne konvolucijske neuronske mreže. Arhitektura predložene mreže je prikazana na slici Sl. 3.11. i sastoji se od konvolucijske neuronske mreže sačinjene od 8 slojeva i kalkulatora perceptivnog gubitka. Svaki od 8 slojeva se sastoji od konvolucijskog i ReLu dijela.



Sl. 3.11.: Arhitektura predložene mreže [23]

3.5.1. Korišteni skupovi podataka


Skup za učenje mreže sastoji se od 2600 CT slika, a skup za testiranje mreže od 500 CT slika koje je pružila bolnica Massachusetts General. Umjesto slika pune veličine, mreža koristi *patcheve* koje ekstrahira sa slika. Za učenje, korišteno je 100 tisuća *patcheva* koji su nasumično ekstrahirani sa slika iz skupa za učenje.

3.5.2. Rezultati

Kvantitativna evaluacija predložene mreže uspoređena je s 2 konkurentne metode za uklanjanje šuma: BM3D [17] i CNN-MSE [2]. Usporedba rezultata je izvršena korištenjem omjera signala i šuma (PSNR) i indeksa strukturne sličnosti (*engl. structural similarity - SSIM*). Prema dobivenim rezultatima, utvrđeno je da perceptivna regularizacija mreže sprječava pretjerano izgladivanje i gubitak strukturnih detalja.


3.6. Konvolucijska neuronska mreža temeljena na U-net arhitekturi

Iako do sada primjenu nije našla u unaprjeđivanju kvalitete CT snimki, U-net je mreža [24], koja inače služi za segmentaciju biomedicinskih snimki, uz blage izmjene [7] donijela izvrsne rezultate pri unaprjeđivanju kvalitete slika. Mreža je uspjela naučiti kako na temelju slika kojima je kvaliteta znatno pogoršana, koristeći referentne slike kojima je kvaliteta blago pogoršana, za izlaz dobiti rekonstruirane slike jednake, a ponekad čak i bolje kvalitete nego kad je mreža učena s referentnim




Sl. 3.12.: Arhitektura U-net mreže [24]

slikama kojima kvaliteta nije pogoršana. Na slici Sl. 3.12. nalazi se prikaz arhitekture U-net mreže iz izvornog članka, a na slici Sl. 3.13. prikaz rezultata unaprjeđivanja kvalitete slike za nasumični impulsni šum. Može se primijetiti kako su pri testiranju, za istu sliku na ulazu, obje mreže ostvarile gotovo identične rezultate iako su pri učenju imale različitu kvalitetu referentnih slika. Mreža iz članka [7] je pri učenju koristila Adam optimizacijsku metodu, stopu učenja od 0.001, a veličinu *batcha* od 4.



(a) Rezultati mreže koja je pri učenju imala referentne slike kojima kvaliteta nije bila pogoršana



(b) Rezultati mreže koja je pri učenju imala referentne slike pogoršane kvalitete

Sl. 3.13.: Rezultati mreže za nasumični impulsni šum [14], gdje je lijevo referentna slika (ulaz pri testiranju), na sredini slika pogoršane kvalitete, a desno rekonstruirana slika, tj. rezultat neuronske mreže

4. KONVOLUCIJSKA NEURONSKA MREŽA ZA UNAPRJEĐIVANJE KVALITETE CT SNIMKI

U ovom će se poglavlju opisati dvije predložene konvolucijske neuronske mreže za unaprjeđivanje kvalitete CT snimki. Prvo će se dati teorijska pozadina vezana za tehnologije korištene pri implementaciji predloženih mreža te teorijska pozadina vezana za metode evaluacije unaprjeđivanja kvalitete CT snimki, a zatim će se opisati skup podataka te detaljno opisati način implementacije svake od predloženih mreža. Opis implementacije svake mreže će se sastojati od opisa poboljšanja skupa podataka, opisa učenja i prikaza rezultata evaluacije predložene mreže.

4.1. Programski jezik Python

Python je programski jezik otvorenog tipa kojeg je 1989. godine kreirao Guido van Rossum [25]. Uz programski jezik dolazi i standardna biblioteka koja zadovoljava zahtjeve većine korisnika: regularni izrazi, obrada teksta, korištenje internetskih protokola, razvoj programske podrške i kreiranje sučelja za operacijske sustave. Dolazi u dvije verzije: Python 2.x i Python 3.x.

Budući da ga je lako koristiti te sadrži alate i biblioteke za rješavanje raznih problema, široko je korišten u znanstvenim i istraživačkim krugovima [26]. Rezultati istraživanja iz 2018. je godine pokazuju da 66% znanstvenika koji se bave podatkovnim znanostima svakodnevno koriste Python.

4.2. Programska biblioteka TensorFlow i Keras API

TensorFlow je programska biblioteka otvorenog tipa kreirana 2015. godine od strane GoogleBrain tima [27] i najčešće je korištena za strojno učenje. Može se koristiti na nekoliko CPU-a ili GPU-a te je dostupan na raznim platformama: Linux, MacOS, Windows, Android i iOS.

Keras je API (*engl. Application Programming Interface*) visoke razine koji se koristi za rad s neuronskim mrežama [28]. Napisan je u programskom jeziku Python i koristi se putem programske biblioteke TensorFlow. Kreiran je s fokusom na brzinu s ciljem da se od ideje može brzo doći do implementacije.

Prema [28], glavne osobine Kerasa su:

- podržava konvolucijske i povratne neuronske mreže, ali i njihovu kombinaciju,
- radi besprijekorno s CPU-om, ali i s GPU-om,
- nudi izvrsno korisničko iskustvo te smanjuje količinu programskog koda kojeg korisnik mora pisati,

- kriterijska funkcija, metode optimizacije, aktivacijske funkcije i ostali dijelovi su svi odvojeni u posebne module,
- može ga se lako proširiti dodatnim klasama, funkcijama i dodatnim modulima,
- radi s Pythonom i ne zahtjeva posebne datoteke za konfiguraciju,
- greške u programskom kodu su detaljno i jasno opisane.

4.3. Metode evaluacije unaprjeđivanja kvalitete CT snimki

U ovom se diplomskom radu koriste dvije vrlo poznate metode za objektivnu evaluaciju kvalitete slika: omjer signala i šuma (*engl. peak signal to noise ratio - PSNR*) i indeks strukturne sličnosti (*engl. structural similarity - SSIM*).

Prema članku [29], PSNR metoda se definira kao:

$$\text{PSNR}(f, g) = 10 \log_{10}(255^2 / \text{MSE}(f, g)) \quad (4-1)$$

$$\text{MSE}(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f_{ij} - g_{ij})^2 \quad (4-2)$$

gdje je f referentna slika veličine $M \times N$ piksela, g testna slika veličine $M \times N$ piksela, a $\text{MSE}(f, g)$ srednja kvadratna pogreška između slike f i g . Vrijednost PSNR metode približava se beskonačnosti kako se vrijednost MSE metode približava nuli. To pokazuje da veća vrijednost PSNR metode označava veću kvalitetu slike.

SSIM metoda se definira kao:


$$\text{SSIM}(f, g) = l(f, g) c(f, g) s(f, g) \quad (4-3)$$

gdje f predstavlja referentnu sliku veličine $M \times N$ piksela, g testnu sliku veličine $M \times N$ piksela, $l(f, g)$ metodu koja računa blizinu srednjeg osvjetljenja između slika, $c(f, g)$ metodu koja računa blizinu kontrasta između slika, a $s(f, g)$ metodu koja računa korelacijske koeficijente između slika. Vrijednosti SSIM metode su unutar intervala $[0, 1]$, gdje 0 označava da slike ni malo ne nalikuju jedna na drugu, a 1 označava da su slike jednake.

4.4. Opis skupa podataka

Skup podataka koji se koristi u ovom diplomskom radu sastoji se od 20 CT snimki. Svaka od njih se sastoji od niza slika (*engl. slice*) rezolucije 512×512 piksela. One zajedno čine trodimenzionalni prikaz snimanog dijela tijela. Na slici Sl. 4.1. nalaze se slike iz skupa podataka.

Ovisno o arhitekturi neuronske mreže, skup podataka je potrebno prikladno obraditi i generirati slike za učenje, validiranje i testiranje konvolucijske mreže.



Sl. 4.1.: Slike iz skupa podataka

Budući da snimke iz skupa podataka sadrže mjerni šum, može se zaključiti da se ne radi o CT snimkama koje su snimljene korištenjem uobičajene (visoke) količine zračenja.

4.5. Jednostavna konvolucijska neuronska mreža

Budući da je konvolucijska mreža opisana u potpoglavlju 3.1. ostvarila dobre rezultate unaprjeđivanja kvalitete CT snimki, predlaže se implementacija opisane konvolucijske mreže. Radi se o konvolucijskoj mreži koja se sastoji samo od 3 sloja:

1. sloj - konvolucijski sloj s ReLU aktivacijskom funkcijom,
2. sloj - konvolucijski sloj s ReLU aktivacijskom funkcijom,
3. sloj - konvolucijski sloj.

Primarna razlika između mreže iz članka i konvolucijske mreže implementirane u ovom diplomskom radu je u tome što mreža iz članka nakon ulaza dijeli sliku na više manjih dijelova (*engl. slices*), a prije izlaza rekonstruira sliku da bi dobila izlaz prikladnog oblika. Implementirana konvolucijska mreža za sve korake, od učenja pa do testiranja, koristi slike pune veličine.

4.5.1. Predobrada skupa podataka

Budući da konvolucijska neuronska mreža za ulaz i izlaz koristi slike, iz skupa podataka je bilo potrebno generirati prikladne slike. Skup podataka je učitani u memoriju i pretvoren u matrični oblik koristeći programsku biblioteku SimpleITK i njene metode "ReadImage" i "GetArray". Zatim je odbačeno prvih i zadnjih 5% slika iz svake snimke budući da su one sadržavale znatno više mjernog


```

slices = []
path = "./dataset/"

# Extract slices from the dataset
for filename in sorted(os.listdir(path)):
    print(filename)
    image = sitk.ReadImage(path + filename)
    nda = sitk.GetArrayFromImage(image)

    size = image.GetSize()
    first_slice = int(0.05 * size[2])
    last_slice = int(0.95 * size[2])

    for j in range(first_slice, last_slice):
        slice = nda[j, :, :]
        slices.append(slice)

slices = np.array(slices, dtype=np.float32)

# Scale 0 - 255
ma = np.max(slices)
mi = np.min(slices)
slices = (slices - mi) / (ma - mi) * 255.0

# Add noise
noisy_slices = np.random.poisson(slices)
noisy_slices = noisy_slices.clip(0.0, 255.0)

```

Ispis koda 4.1.: Implementacija učitavanja skupa podataka i generiranja zašumljenih slika

šuma u odnosu na ostale slike. Pomoću informacija dobivenih koristeći metode "max" i "min" programske biblioteke NumPy, vrijednost piksela svake slike je skalirana na interval [0, 255] te je na slike primijenjen nasumični Poissonov šum da bi se dobile zašumljene slike. Za primjenu nasumičnog Poissonovog šuma na slike prvo je korištena NumPy metoda "random", a zatim metoda "poisson". Nakon primjene Poissonovog šuma, koristeći NumPy metodu "clip", sve vrijednosti piksela iznad 255 su postavljene na 255, a sve vrijednosti piksela manje od 0 su postavljene na 0. Na ispisu programskog koda 4.1. nalazi se opisani postupak implementiran koristeći programski jezik Python.

Nakon odbacivanja prvih i zadnjih 5% slika iz svake snimke, u skupu podataka je ukupno ostalo 5911 referentnih slika. Da bi mreža prilikom učenja brže konvergirala prema minimumu hiperravnine, slike su ponovno skalirane, ali na interval [0, 1]. Zatim su slike nasumično podijeljene na 3 dijela u omjeru:

- 70% skup slika za učenje mreže (4137 parova slika),
- 20% skup slika za validiranje mreže (1182 parova slika),
- 10% skup slika za testiranje mreže (592 parova slika)

te spremljene u obliku prikladnom za korištenje s konvolucijskim mrežama. Svaki skup slika sastoji se od referentnih (izvornih) slika i zašumljenih slika, tj. izvornih slika kojima je kvaliteta pogoršana koristeći nasumični Poissonov šum.

Na ispisu programskog koda 4.2. nalazi se implementacija navedene podjele. Koristeći metodu "train_test_split" programske biblioteke Scikit-learn, skup podataka je prvo podijeljen na skupove

```

X = noisy_slices.astype(np.float32)
y = slices.astype(np.float32)

# Reshape
X = X.reshape(-1, 512, 512, 1)
y = y.reshape(-1, 512, 512, 1)

# Split
X_train, X_valid, y_train, y_valid = train_test_split(X, y , test_size=0.3,
                                                    random_state=42)
X_valid, X_test, y_valid, y_test = train_test_split(X_valid, y_valid, test_size=1/3,
                                                    random_state=42)


```

Ispis koda 4.2.: Implementacija podjele skupa podataka

slika za učenje i validiranje mreže u omjeru 70%/30%, a zatim je skup slika za validiranje mreže podijeljen u skup za validiranje i testiranje mreže u omjeru 66.66%/33.33%. Time je dobivena željena podjela na 3 dijela u omjeru 70%/20%/10%. Referentne slike su označene s y , a zašumljene s X .

4.5.2. Učenje predložene konvolucijske neuronske mreže


Odabrana arhitektura konvolucijske neuronske mreže je implementirana u programskom jeziku Python koristeći Keras. Cilj mreže je da zašumljenim slikama na ulazu unaprijedi kvalitetu te da na izlazu prikaže slike što sličnije referentnim slikama. Na slici Sl. 4.2. nalazi se prikaz arhitekture predložene konvolucijske neuronska mreže.



Sl. 4.2.: Arhitektura predložene konvolucijske neuronske mreže

Mreža se sastoji od ulaza i 3 sloja, a sadrži otprilike 24 tisuće težina. Ulaz mreže je crno-bijela slika rezolucije 512x512 piksela. Prvom konvolucijom ulazna slika dobije 64 dimenzije, drugom konvolucijom se broj dimenzija reducira na 32, a na kraju se konvolucijom broj dimenzija reducira na 1 te se na izlazu dobije crno-bijela slika.

Kao kriterijska funkcija korištena je srednja kvadratna pogreška, a kao metoda optimizacije korištena je SGD metoda. Mreža je učena 200 epoha, koristeći veličinu *batcha* od 32 te je nakon svake epohe



Sl. 4.3.: Greška u odnosu na epohe

```
def autoencoder(input_img):
    out = Conv2D(64, 9, activation='relu', padding='same')(input_img)
    out = Conv2D(32, 3, activation='relu', padding='same')(out)
    out = Conv2D(1, 5, padding='same')(out)

    return out

# Setup
batch_size = 32
epochs = 200
input_img = Input(shape=(512, 512, 1))

model = Model(input_img, autoencoder(input_img))
model.compile(loss='mse', optimizer='sgd')

# Load data
X_train = np.load("X_train.npy")
X_valid = np.load("X_valid.npy")
y_train = np.load("y_train.npy")
y_valid = np.load("y_valid.npy")

# Train
hist = model.fit(X_train, y_train, batch_size=batch_size, epochs=epochs, verbose=1,
                 validation_data=(X_valid, y_valid))

# Save
np.savez("history.npz", history=hist.history)
model = model.save_weights('autoencoder.h5')
```

Ispis koda 4.3.: Implementacije učenja konvolucijske mreže

validirana na skupu slika za validaciju. Na slici Sl. 4.3. nalazi se prikaz promjene greške pri učenju i greške pri validiranju u odnosu na epohe. Nakon učenja, spremljene su težine mreže i povijest učenja.

Na ispisu koda 4.3. nalazi se implementacija konvolucijske mreže i opisanog procesa učenja. Funkcija "autoencoder" predstavlja implementaciju predložene konvolucijske mreže koja koristi Keras metodu "Conv2D" za kreiranje konvolucijskih slojeva. Koristeći Keras metodu "compile" kreirana je konvolucijska mreža, a koristeći metodu "fit" izvršen je proces učenja.


4.5.3. Evaluacija predložene konvolucijske neuronske mreže

Nakon učenja, konvolucijska mreža je testirana koristeći zašumljene slike iz testnog skupa slika. Učitane su težine mreže koje su spremljene na kraju učenja, inicijalizirana je mreža te su joj na ulaz predane zašumljene slike. Ona je kao izlaz dala niz rekonstruiranih slika koje su spremljene zbog daljnje evaluacije.

Na slici Sl. 4.4. nalazi se prikaz rezultata za dvije slike iz skupa za testiranje. Na lijevom dijelu slike se nalazi referentna slika, na srednjem dijelu slika pogoršane kvalitete, a na desnom dijelu rekonstruirana slika, tj. rezultat neuronske mreže.



(a) Rezultati za referentnu sliku dobre kvalitete




(b) Rezultati za zašumljenu referentnu sliku

Sl. 4.4.: Dio rezultata dobivenih neuronskom mrežom, gdje je lijevo referentna slika (ulaz pri testiranju), na sredini slika pogoršane kvalitete, a desno rekonstruirana slika, tj. rezultat neuronske mreže

Za kvantitativnu evaluaciju konvolucijske mreže korištene su dvije metode: PSNR i SSIM. Navedene metode služe za usporedbu zašumljenih slika i rekonstruiranih slika s referentnim slikama. Na slici 4.5. nalazi se prikaz dobivenih rezultata.

Prosječna vrijednost PSNR metode prikazuje poboljšanje s 32.7169 dB na 38.8981 dB, a prosječna



Sl. 4.5.: Kvantitativna evaluacija testnih slika koristeći dobiveni model konvolucijske neuronske mreže

vrijednost SSIM metode prikazuje poboljšanje s 0.761 na 0.9512. Može se zaključiti kako mreža ima dobre kvantitativne rezultate iako se kvalitativnom evaluacijom koja se sastoji od pregleda rekonstruiranih slika ne može zaključiti isto. Iako je šum vidljivo prigušen, detalji s referentne slike nisu ispravno rekonstruirani nego su mutni.

4.6. Konvolucijska neuronska mreža temeljena na U-net arhitekturi

Budući da kvalitativna evaluacija jednostavne mreže iz potpoglavlja 4.5. nije dala prikladne rezultate, predlaže se korištenje kompleksnije U-net arhitekture konvolucijske mreže koja je opisana u potpoglavlju 3.6.. Glavna ideja izvornog članka je to da se za unaprjeđivanje kvalitete slika ne mora imati referentne slike bez šuma nego neuronska mreža može, na temelju jače zašumljenih slika i blaže zašumljenih referentnih slika, rekonstruirati referentne slike. Budući da se skup podataka sastoji od snimki na kojima već postoji mjerni šum, odlučeno je implementirati danu arhitekturu te evaluirati njene rezultate.

4.6.1. Predobrada skupa podataka

Skup slika za učenje, validiranje i testiranje mreže bilo je potrebno generirati iz skupa podataka koji se sastoji od 20 CT snimki. Slike su učitane u memoriju te je prvih i zadnjih 5% slika iz svake snimke odbačeno budući da su one sadržavale znatno veći mjerni šum nego ostale slike. Nakon odbacivanja slika, u skupu podataka je ukupno ostalo 5911 slika. Njima je razlučivost smanjena s 512x512 piksela na 256x256 piksela zbog velikih memorijskih zahtjeva U-net arhitekture. Slike su također skalirane na interval [0, 255] budući da se crno-bijela slika tako sprema u računalnu memoriju.

Preostale slike su nasumično podijeljene na 3 dijela u omjeru:

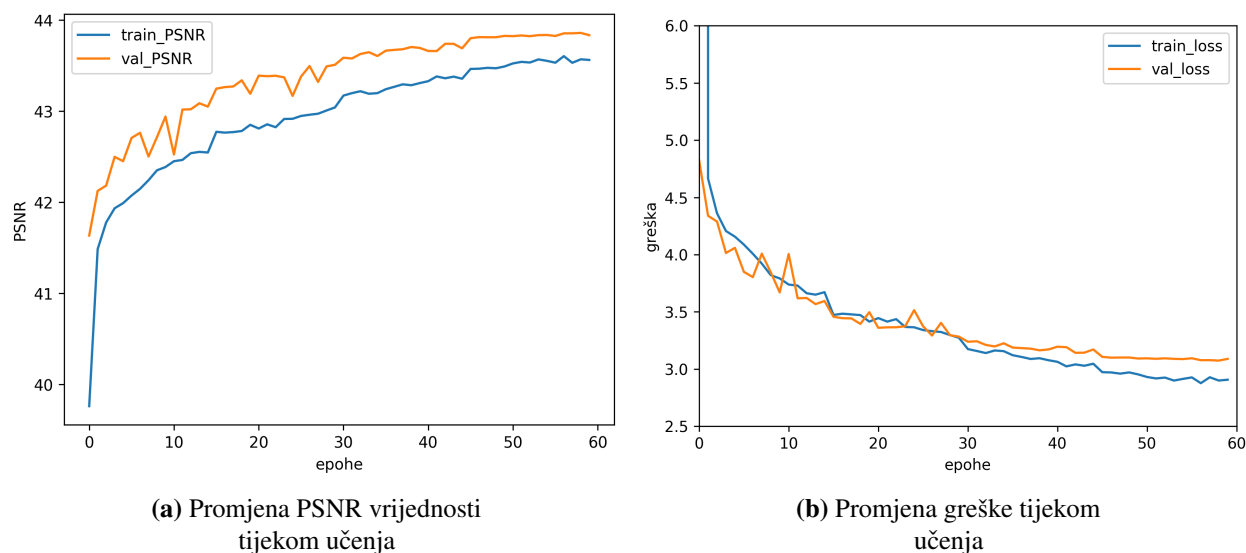
- 70% skup slika za učenje mreže (4137 slika),
- 20% skup slika za validiranje mreže (1182 slika),
- 10% skup slika za testiranje mreže (592 slika)

te su spremljene na čvrsti disk.

Svaki skup slika sastoji se samo od referentnih slika. Poissonov šum nije primijenjen na slike budući da se implementacija U-net arhitekture temelji na tome da se šum nasumično generira prilikom učenja, validiranja i testiranja neuronske mreže.

4.6.2. Učenje predložene konvolucijske neuronske mreže

Implementacija neuronske mreže se temelji na programskom kodu s mrežne stranice GitHub [14] gdje je mreža implementirana koristeći programski jezik Python i Keras. Prikaz arhitekture implementirane mreže nalazi se u prilogu. Kao kriterijska funkcija korištena je srednja kvadratna pogreška, kao optimizacijska metoda korištena je Adam metoda, inicijalna stopa učenja postavljena na 0.001, a veličina *batcha* je bila 16. Mreža je učena 60 epoha, od kojih se svaka sastojala od 1000 koraka. Mreža ukupno sadrži 31 milijun težina, a učenje je ukupno trajalo 6 sati i 30 minuta na NVIDIA Titan V grafičkoj kartici. Nakon učenja, spremljene su težine mreže i povijest učenja. Na slici Sl. 4.6. nalazi se prikaz učenja neuronske mreže.



Sl. 4.6.: Učenje konvolucijske mreže

Učenje se odvijalo tako da se prilikom svakog koraka epohe nasumično odabralo 16 slika iz seta za učenje koje predstavljaju referentne slike i na njih primijenio nasumični Poissonov šum, čime se dobilo zašumljene slike. Mreža je pri svakoj epohi učila na temelju 16 tisuća slika, što ukupno daje gotovo milijun slika tijekom procesa učenja. Tradicionalna definicija epohe podrazumijeva

```

model.compile(optimizer=Adam(lr=0.001), loss="mse", metrics=[PSNR])

source_noise_model = get_noise_model("poisson")
target_noise_model = get_noise_model("clean")
val_noise_model = get_noise_model("poisson")

generator = NoisyImageGenerator(image_dir,
                                source_noise_model,
                                target_noise_model,
                                batch_size=16,
                                image_size=256)
val_generator = ValGenerator(test_dir, val_noise_model)

hist = model.fit_generator(generator=generator,
                          steps_per_epoch=steps,
                          epochs=nb_epochs,
                          validation_data=val_generator,
                          verbose=1)

```

Ispis koda 4.4.: Dio implementacije učenja konvolucijske mreže

jedan prolaz skupom slika za učenje mreže, ali će se u nastavku diplomskog rada epohom nazivati i jedan prolazak kroz 16 tisuća slika iz skupa slika za učenje. Tijekom učenja se računala greška i prosječna vrijednost PSNR metode nad podacima za učenje, a na kraju svake epohe, mreža se validirala nad cijelim validacijskim setom te se izračunala greška i prosječna vrijednost PSNR metode nad validacijskim skupom. Validacijski skup se prilikom svake epohe kreirao tako da se na svaku sliku iz validacijskog skupa primijenio nasumični Poissonov šum te se time dobilo referentne i zašumljene slike.


Na ispisu koda 4.4. nalazi se dio implementacije opisanog procesa učenja kreirane konvolucijske neuronske mreže. Također je, kao i u ispisu koda 4.3., za kreiranje mreže korištena Keras metoda "compile", ali se korištena metoda za učenje mreže "fit_generator" znatno razlikuje. Njoj su predane informacije o tome kako će se prilikom učenja generirati podatci za učenje i validiranje mreže koje su dobivene koristeći funkcije "NoisyImageGenerator" i "ValGenerator".

4.6.3. Evaluacija predložene konvolucijske neuronske mreže

Nakon učenja, mreža je testirana tako da se na svaku sliku iz testnog skupa dodao nasumični Poissonov šum. Koristeći težine dobivene učenjem, inicijalizirana je mreža te su joj na ulaz predane zašumljene slike. Ona je kao izlaz dala niz rekonstruiranih slika koje su spremljene zbog daljnje evaluacije.

Kvalitativna evaluacija mreže izvršena je koristeći PSNR i SSIM metode koje služe za usporedbu zašumljenih i rekonstruiranih slika s referentnim slikama. Na slici 4.7. nalazi se prikaz dobivenih rezultata.

Uspoređujući rezultate sa slike Sl. 4.7. i rezultate dobivene u potpoglavlju 4.5.3. koji se nalaze na slici Sl. 4.5. može se zaključiti da je U-net mreža ostvarila bolje rezultate. Prosječna vrijednost



Sl. 4.7.: Kvantitativna evaluacija testnih slika koristeći dobiveni model konvolucijske neuronske mreže

PSNR metode prikazuje poboljšanje s 32.8015 dB na 43.3944 dB, a prosječna vrijednost SSIM metode prikazuje poboljšanje s 0.7894 na 0.9722.

Na slici Sl. 4.8. nalazi se prikaz rezultata za dvije slike iz skupa za testiranje. Na lijevom dijelu slike se nalazi referentna slika, na srednjem dijelu slika pogoršane kvalitete, a na desnom dijelu rekonstruirana slika, tj. rezultat neuronske mreže. Promatranjem slike, ali i ostalih rezultata, može se zaključiti kako je mreža ostvarila izvrsne rezultate. Dio rekonstruiranih slika gotovo je jednak referentnima (a), a dio je bolje kvalitete (b).

Uspoređujući rezultate sa slike Sl. 4.8. i rezultate dobivene u potpoglavlju 4.5.3. koji se nalaze na slici Sl. 4.4., može se zaključiti da je U-net mreža ponovno ostvarila bolje rezultate. Kvalitativnom evaluacijom, koja je izvršena pregledom svih rezultata za testni skup slika, može se zaključiti da je U-net mreža bolje sačuvala detalje prilikom rekonstrukcije te je u svakom pogledu ostvarila bolje rezultate.


4.6.4. Optimizacija parametara predložene konvolucijske neuronske mreže

Da bi se dobili što bolji rezultati, mreža je učena koristeći različite parametre i testirana koristeći testni skup slika. Mreža sa svim navedenim konfiguracijama je učena koristeći stopu učenja od 0.001, a za kvantitativnu evaluaciju su iskorištene one težine mreže koje su ostvarile najbolje rezultate PSNR metode nad slikama iz skupa za validaciju. U tablici Tab. 4.1. se nalaze rezultati kvantitativne evaluacije za nekoliko različitih konfiguracija učenja mreže.

Mreža koja je učena koristeći Adam optimizacijsku metodu i MSE kriterijsku funkciju ostvarila



(a) Rezultati za referentnu sliku dobre kvalitete



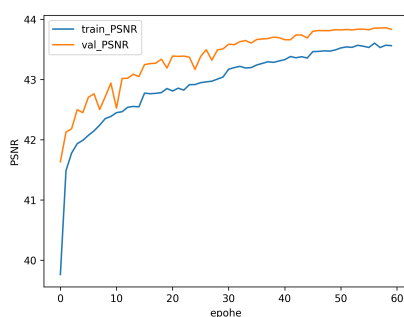
(b) Rezultati za zašumljenu referentnu sliku

Sl. 4.8.: Dio rezultata dobivenih testiranjem neuronske mreže, gdje je lijevo referentna slika (ulaz pri testiranju), na sredini slika pogoršane kvalitete, a desno rekonstruirana slika, tj. rezultat neuronske mreže


je najbolju prosječnu vrijednost PSNR metode nad testnim slikama, a mreža koja je učena koristeći RMSprop optimizacijsku metodu i MAE kriterijsku funkciju ostvarila je najbolju prosječnu vrijednost SSIM metode nad testnim slikama. Budući da je razlika u prosječnoj vrijednosti SSIM metode za navedene konfiguracije tek na četvrtom decimalnom mjestu, a razlika u prosječnoj vrijednosti PSNR metode na drugom decimalnom mjestu, odabrana je konfiguracija koja koristi Adam optimizacijsku metodu. U tablici Tab. 4.1. se ne nalaze rezultati za SGD optimizacijsku metodu gdje se koriste L0 i MSE kriterijske funkcije budući da je pri tim konfiguracijama pogreška pri početku učenja mreže znatno divergirala. Na slici Sl. 4.9. nalazi se prikaz promjene vrijednosti PSNR metode za svaku od konfiguracija prikazanih u tablici Tab. 4.1.

Tab. 4.1.: Usporedba rezultata za različite konfiguracije učenja mreže


metoda optimizacije	kriterijska funkcija	PSNR [dB]	SSIM
Adam	MSE	43.3944	0.9722
	MAE	42.8227	0.9694
	L0	42.9572	0.9708
RMSprop	MSE	43.3530	0.9722
	MAE	43.3475	0.9723
	L0	43.3064	0.9719
SGD	MAE	40.7548	0.9586




(a) Adam, MSE




(b) Adam, MAE




(c) Adam, L0




(d) RMSprop, MSE



(e) RMSprop, MAE



(f) RMSprop, L0



(g) SGD, MAE

Sl. 4.9.: Promjena PSNR vrijednosti tijekom učenja za različite parametre

5. ZAKLJUČAK

Umjetne neuronske mreže su našle široku primjenu u rješavanju problema kao što su računalni vid, obrada prirodnog jezika i prepoznavanje govora. Iako postoje već dugo godina, tek su se u zadnje vrijeme postavile kao bolji izbor u odnosu na konkurentne metode strojnog učenja. Razlog tome je brzi razvoj računalne tehnologije i činjenica da neuronske mreže omogućuju korištenje jedinice za obradu grafike (GPU) koja je znatno brža od središnje jedinice za obradu (CPU) za rješavanje problema strojnog učenja.

U diplomskom radu je dana teorijska podloga vezana za umjetne neuronske mreže, duboke neuronske mreže i konvolucijske mreže. Navedene su i opisane različite vrste slojeva konvolucijske neuronske mreže te je opisano kako neuronske mreže uče. Proučene su i opisane *state of the art* metode za unaprjeđivanje kvalitete CT snimki primjenom neuronskih mreža te je to znanje primijenjeno prilikom razvoja praktičnog dijela rada.

Za praktični dio diplomskog rada implementirane su dvije konvolucijske neuronske mreže za unaprjeđivanje kvalitete CT snimki. Opisan je postupak predobrade kojim se skup podataka prilagodio svakoj od mreža, opisan je proces učenja te su uspoređeni rezultati njihove evaluacije.

Budući da je konvolucijska mreža za unaprjeđivanje kvalitete CT snimki koja se temelji na U-net arhitekturi ostvarila bolje rezultate u svakom aspektu evaluacije, predlaže se njeno korištenje za rješavanje zadanog problema. Usporedbom rezultata dobivenih kvantitativnom evaluacijom predložene mreže s rezultatima *state of the art* metoda može se zaključiti kako im je predložena mreža konkurentna.

LITERATURA

- [1] I. Borić, R. Ivelj, M. Leko, Z. Bahtijarević, I. Bojanić, G. Roić, *Mogućnost radiološke dijagnostike u prikazu športskih ozljeda u djece športaša*, Paediatrica Croatica, br. 2, sv. 52, str. 105-110, travanj 2008.
- [2] H. Chen, Y. Zhang, W. Zhang, P. Liao, K. Li, J. Zhou, G. Wang, *Low-dose CT via convolutional neural network*, Biomedical Optics Express, br. 2, sv. 8, str. 679-694, veljača 2017.
- [3] I. Vasilev, D. Slater, G. Spacagna, P. Roelants, V. Zocca, *Python Deep Learning*, Packt Publishing Ltd., Birmingham, Ujedinjeno Kraljevstvo, 2019.
- [4] P. Jain, *Towards Data Science: Complete Guide of Activation Functions*, Medium, dostupno na: <https://towardsdatascience.com/complete-guide-of-activation-functions-34076e95d044> [03.09.2019.]
- [5] *An image search application that uses the Vision API and Cloud AutoML Vision*, Google Cloud, dostupno na: <https://cloud.google.com/solutions/image-search-app-with-cloud-vision> [17.09.2019.]
- [6] *Amazon Rekognition FAQs*, Amazon Web Services, dostupno na: <https://aws.amazon.com/rekognition/faqs/> [17.09.2019.]
- [7] J. Lehtinen, J. Munkberg, J. Hasselgren, S. Laine, T. Karras, M. Aittala, T. Aila, *Noise2Noise: Learning Image Restoration without Clean Data*, arXiv: 1803.04189, 2018.
- [8] M. Johnson, M. Schuster, Q.V. Le, M. Krikun, Y. Wu, Z. Chen, N. Thorat, F. Viégas, M. Wattenberg, G. Corrado, M. Hughes, J. Dean, *Google's Multilingual Neural Machine Translation System: Enabling Zero-Shot Translation*, arXiv: 1611.04558, 2016.
- [9] *Assistant*, Google, dostupno na: <https://assistant.google.com/> [17.09.2019.]
- [10] *Hey Siri: An On-device DNN-powered Voice Trigger for Apple's Personal Assistant*, Apple Machine Learning Journal, dostupno na: <https://machinelearning.apple.com/2017/10/01/hey-siri.html> [17.09.2019.]
- [11] *Deep Learning on AWS*, Amazon Web Services, dostupno na: <https://aws.amazon.com/deep-learning/> [17.09.2019.]
- [12] *AlphaGo*, DeepMind, dostupno na: <https://deepmind.com/research/case-studies/alphago-the-story-so-far> [17.09.2019.]

- [13] G. Drakos, *Towards Data Science: How to select the Right Evaluation Metric for Machine Learning Models: Part 1 Regression Metrics*, Medium, dostupno na: <https://towardsdatascience.com/how-to-select-the-right-evaluation-metric-for-machine-learning-models-part-1-regression-metrics-3606e25beae0> [06.09.2019.]
- [14] Y. Uchida, *yu4u/noise2noise*, GitHub, dostupno na: <https://github.com/yu4u/noise2noise> [02.09.2019.]
- [15] E.Y. Sidky, X. Pan, *Image reconstruction in circular cone-beam computed tomography by constrained, total-variation minimization*, *Physics in Medicine and Biology*, br. 17, sv. 53, str. 4777-4807, rujan 2008.
- [16] Y. Chen, X. Yin, L. Shi, H. Shu, L. Luo, J. Coatrieux, C. Toumoulin, *Improving abdomen tumor low-dose CT images using a fast dictionary learning based processing*, *Physics in Medicine and Biology*, br. 16, sv. 58, str. 5803-5820, kolovoz 2013.
- [17] K. Sheng, S. Gou, J. Wu, S. X. Qi, *Denoised and texture enhanced MVCT to improve soft tissue conspicuity*, *Medical Physics*, br. 10, sv. 41, listopad 2014.
- [18] E. Kang, J. Min, J.C. Ye, *A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction*, *Medical Physics*, br. 10, sv. 44, str. 360-375, listopad 2017.
- [19] H. Chen, Y. Zhang, M. K. Kalra, F. Lin, Y. Chen, P. Liao, J. Zhou, G. Wang, *Low-Dose CT with a Residual Encoder-Decoder Convolutional Neural Network (RED-CNN)*, *IEEE Transactions on Medical Imaging*, br. 12, sv. 36, str. 2524-2535, prosinac 2017.
- [20] W. Yang, H. Zhang, J. Yang, J. Wu, X. Yin, Y. Chen, H. Shu, L. Luo, G. Coatrieux, Z. Gui, Q. Feng, *Improving Low-Dose CT Image Using Residual Convolutional Network*, *IEEE Access*, sv. 5, str. 24698-24705, listopad 2017.
- [21] Y. Chen, Z. Yang, Y. Hu, G. Yang, Y. Zhu, Y. Li, L. Luo, W. Chen, C. Toumoulin, *Thoracic low-dose CT image processing using an artifact suppressed large-scale nonlocal means*, *Physics in Medicine and Biology*, br. 9, sv. 57, str. 2667-2688, svibanj 2012.
- [22] G.-H. Chen, C.-L. Yang, S.-L. Xie, *Gradient-based structural similarity for image quality assessment*, 2006 International Conference on Image Processing, str. 2929-2932, Atlanta, Sjedinjene Američke Države, studeni 2006.
- [23] Q. Yang, P. Yan, M. K. Kalra, G. Wang, *CT Image Denoising with Perceptive Deep Neural Networks*, arXiv: 1702.07019, 2017.
- [24] O. Ronneberger, P. Fischer, T. Brox, *U-net: Convolutional networks for biomedical image segmentation*, *Medical Image Computing and Computer-Assisted Intervention*, str. 234-241, München, Njemačka, listopad 2015.

- [25] *General Python FAQ*, Python, dostupno na: <https://docs.python.org/3.7/faq/general.html> [03.09.2019.]
- [26] O. Kharkovyna, *Towards Data Science: A Beginner's Guide to Python for Data Science*, Medium, dostupno na: <https://towardsdatascience.com/a-beginners-guide-to-python-for-data-science-60ef022b7b67> [03.09.2019.]
- [27] *TensorFlow*, Wikipedia, dostupno na: <https://en.wikipedia.org/wiki/TensorFlow> [03.09.2019.]
- [28] *Keras: The Python Deep Learning library*, Keras, dostupno na: <https://keras.io> [03.09.2019.]
- [29] A. Hore, D. Ziou, *Image quality metrics: PSNR vs. SSIM*, 2010 International Conference on Pattern Recognition, 2010.

SAŽETAK

Iako su CT snimke pogodne za prikaz koštanih struktura, slobodnih zglobnih tijela te topografskog odnosa koštanih i mekotkivnih struktura, njihov rastući broj povećava potencijalni rizik od zračenja i postaje razlog zabrinutosti javnosti. Da bi se smanjio potencijalni rizik, CT s niskom dozom zračenja privlači sve veću pozornost, ali smanjivanje količine zračenja znatno pogoršava kvalitetu CT snimke. U sklopu ovog diplomskog rada proučene su *state of the art* metode te su implementirane dvije konvolucijske neuronske mreže za unaprjeđivanje kvalitete CT snimki. Opisan je postupak predobrade kojim se skup podataka prilagodio svakoj od mreža, opisan je proces učenja te su uspoređeni rezultati njihove evaluacije. Budući da je konvolucijska mreža za unaprjeđivanje kvalitete CT snimki koja se temelji na U-net arhitekturi ostvarila bolje rezultate u svakom aspektu evaluacije, predlaže se njeno korištenje za rješavanje zadanog problema. Usporedbom rezultata dobivenih kvantitativnom evaluacijom predložene mreže s rezultatima *state of the art* metoda može se zaključiti kako im je predložena mreža konkurentna.

Ključne riječi: umjetne neuronske mreže, duboko učenje, konvolucijske neuronske mreže, unaprjeđivanje kvalitete CT snimki, U-net arhitektura

SUMMARY: CT IMAGE ENHANCEMENT USING NEURAL NETWORKS

Although CT scans are suitable for displaying bone structures, joints, and the topographic relationship of bone and soft tissue structures, their growing number increases the potential risk of radiation and is a cause for public concern. To reduce the potential risk, low-dose CT is gaining increasing attention, but reducing the amount of radiation significantly degrades the quality of the CT scan. As part of this graduate thesis, state of the art methods were studied and two convolutional neural networks were implemented to improve the quality of CT images. Both data preprocessing, which was used to adapt the dataset to each network, and the learning process were described, and the evaluation results of both networks were compared. As the convolutional network for CT image enhancement based on the U-net architecture has achieved better results in every aspect of the evaluation, its use is proposed as a solution for the given problem. Comparing the results obtained by quantitative evaluation of the proposed network with the results of the state of the art methods, one can conclude that the results closely match.

Keywords: artificial neural networks, deep learning, convolutional neural networks, CT image enhancement, U-net architecture

ŽIVOTOPIS

Kristijan Pavlović rođen je 12. listopada 1995. godine u Frankfurtu na Majni, SR Njemačka. Srednjoškolsko obrazovanje u Graditeljsko-geodetskoj školi Osijek završava 2014. godine te upisuje preddiplomski sveučilišni studij računarstva na Elektrotehničkom fakultetu Osijek, koji se danas naziva Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek. Preddiplomski studij računarstva završava 2017. godine i upisuje sveučilišni diplomski studij računarstva, izborni blok Robotika i umjetna inteligencija. Od početka diplomskog sveučilišnog studija radi kao *backend developer* u tvrtki BambooLab koja se bavi razvojem mrežnih i mobilnih aplikacija te digitalnim marketingom.

PRILOZI

Prilog P.4.1.: shema neuronske mreže opisane u potpoglavlju 4.6.

