



UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET



Aldin Redžematović

**POBOLJŠANJE KVALITETA BIOMEDICINSKIH SLIKA
I OTKLANJANJE ŠUMA PRIMJENOM
KONVOLUCIONIH NEURALNIH MREŽA**

- master rad -

Podgorica, 2025.

UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET

Aldin Redžematović

**POBOLJŠANJE KVALITETA BIOMEDICINSKIH SLIKA
I OTKLANJANJE ŠUMA PRIMJENOM
KONVOLUCIONIH NEURALNIH MREŽA**

- master rad -

Podgorica, 2025.

PODACI I INFORMACIJE O STUDENTU

Ime i prezime: **Aldin Redžematović**

Datum i mjesto rođenja: 30.07.2000. godine, Plav

Naziv završenog osnovnog studijskog programa i godina završetka studija: Studijski program Primjenjenog računarstva, Elektrotehnički fakultet, Univerzitet Crne Gore, 180 ECTS kredita, 2022. godine.

INFORMACIJE O MASTER RADU

Naziv master studija: Master studije primijenjenog računarstva

Naslov rada: Poboljšanje kvaliteta biomedicinskih slika i otklanjanje šuma primjenom konvolucionih neuralnih mreža

Fakultet na kojem je rad odbranjen: Elektrotehnički fakultet

UDK, OCJENA I ODBRANA MASTER RADA

Datum prijave magistarskog rada: *25.11.2024. godine*

Datum sjednice Vijeća na kojoj je prihvaćena tema: *14.03.2025. godine*

Komisija za ocjenu/odbranu rada: Prof. dr Žarko Žečević, ETF Podgorica, predsjednik
Doc. dr Anđela Draganić, ETF Podgorica, mentor
Doc. dr Miloš Brajović, ETF Podgorica, član

Mentor: Doc. dr Anđela Draganić

Datum odbrane: *23.12.2025. godine*

Ime i prezime autora: Aldin Redžematović, BApp

Izjava o autorstvu

Potpisani-a Aldin Redžematović

Broj indeksa/upisa 11/22

Izjavljujem

da je master rad pod nazivom

" POBOLJŠANJE KVALITETA BIOMEDICINSKIH SLIKA I OTKLANJANJE ŠUMA PRIMJENOM KONVOLUCIONIH NEURALNIH MREŽA "

- rezultat sopstvenog istraživačkog rada,
- da predloženi master rad ni u cjelini ni u djelovima nije bio predložen za dobijanje bilo koje diplome prema studijskim programima drugih ustanova visokog obrazovanja,
- da su rezultati korektno navedeni, i
- da nijesam povrijedio/la autorska i druga prava intelektualne svojine koja pripadaju trećim licima.

U Podgorici, 11.12.2025. godine

Potpis magistranda

Aldin Redžematović

Izvod teze

Kvalitet biomedicinskih slika od suštinskog je značaja za tačnu dijagnozu, ali može biti narušen prisustvom šuma, što otežava kompjutersku obradu. Tradicionalne metode za uklanjanje šuma, kao što su Gauss-ov filter, medijan filter i Viner filter, mogu dovesti do gubitka bitnih karakteristika slike. U radu je prikazana primjena konvolucionih neuralnih mreža (CNN) u cilju poboljšanja kvaliteta biomedicinskih slika zahvaćenim šumom.

Modeli su trenirani i testirani na dva skupa medicinskih slika, na koje je prethodno dodat šum, a zatim je sprovedena uporedna analiza uzimajući u obzir standardne metode filtriranja. Procjena efikasnosti je izvršena korišćenjem standardnih metrika za ocjenu kvaliteta slike kao što su: MSE, PSNR i SSIM. Dobijeni rezultati ukazuju da metode zasnovane na CNN-u, posebno nakon dovoljnog broja epoha treniranja, ostvaruju poboljšanje u odnosu na konvencionalne metode, čime se potvrđuje njihov potencijal u oblasti medicinske slike i digitalne dijagnostike.

Ključne riječi: biomedicinske slike, uklanjanje šuma, konvolucione neuralne mreže, filtriranje

Abstract

The quality of biomedical images is essential for accurate diagnosis but can be degraded by the presence of noise, which complicates computer processing. Traditional denoising methods, such as Gaussian, median, and Wiener filters, may lead to the loss of important image features. This paper presents the application of convolutional neural networks (CNNs) aimed at improving the quality of biomedical images affected by noise.

The models were trained and tested on two sets of medical images to which noise was artificially added, followed by a comparative analysis with standard filtering methods. The effectiveness was evaluated using common image quality metrics such as MSE, PSNR, and SSIM. The obtained results indicate that CNN-based methods, especially after a sufficient number of training epochs, achieve improvements over conventional approaches, confirming their potential in the field of medical imaging and digital diagnostics.

Keywords: biomedical images, noise removal, convolutional neural networks, filtering

Sadržaj

Izvod teze.....	1
Abstract.....	2
Slike.....	5
Tabele.....	7
Uvod.....	8
1. TEORIJSKI OKVIR I ZNAČAJ BIOMEDICINSKIH SLIKA.....	14
1.1 Značaj biomedicinskih slika u savremenoj medicini.....	14
1.2 Uloga MRI, CT i ultrazvuka u dijagnostici.....	15
1.3 Problem šuma na biomedicinskim slikama.....	16
1.3.1 Uzroci šuma.....	18
1.3.2 Vrste šuma u biomedicinskim slikama.....	18
1.3.3 Negativan uticaj šuma na preciznost dijagnoze.....	19
2. TRADICIONALNE METODE ZA UKLANJANJE ŠUMA SA BIOMEDICINSKIH SLIKA.....	20
2.1 Gausov filter.....	20
2.2 Medijanski filter.....	22
2.3 Vinerov filter.....	23
3. KONVOLUCIONE NEURALNE MREŽE (CNN) U OBRADI BIOMEDICINSKIH SLIKA.....	26
3.1 Osnovni koncept konvolucionih neuronskih mreža.....	26
3.1.1 Princip rada konvolucione neuralne mreže.....	27
3.2 Prednosti konvolucionih neuronskih mreža u zadacima filtriranja šuma.....	33
3.3 Primjena konvolucionih neuronskih mreža u biomedicinskim slikama.....	34
4. MATERIJALI I METODE.....	35
4.1 Skupovi podataka.....	35
4.2 Metode za dodavanje šuma.....	35
4.3 Evaluacione metrike.....	37
4.3.1 MSE (Mean Squared Error).....	37
4.3.2 PSNR (Peak Signal-to-Noise Ratio).....	41
4.3.3 SSIM (Structural Similarity Index Measure).....	43
5. EKSPERIMENTALNI REZULTATI.....	45
5.1 Rezultati na skupu podataka LC25000.....	47

5.1.1 Gausov šum.....	47
5.1.2 Salt-and-Pepper šum.....	49
5.1.3 Speckle šum.....	51
5.2 Rezultati na skupu podataka Lungs Disease Dataset.....	53
5.2.1 Gausov šum.....	53
5.2.2 Salt-and-Pepper šum.....	55
5.2.3 Speckle šum.....	57
ZAKLJUČAK.....	59
Apendix (dodatak).....	61
Dodatak A – Gausov filter.....	61
Dodatak B – Medijan filter.....	62
Dodatak C – Vinerov filter.....	63
Dodatak D – CNN.....	64
Literatura.....	66

Slike

Slika 1. Primjeri biomedicinskih slika.....	15
Slika 2. Usporedni prikaz ultrazvučnih, MRI i CT snimaka istog anatomskog regiona [12]	16
Slika 3. Primjeri biomedicinskih slika sa šumom	17
Slika 4. Primjena Gausovog filtera na biomedicinskoj slici (gornji red – originalna slika, slika sa Gausovim šumom, Gausovo filtriranje) i slici realnog okruženja (donji red – originalna slika, slika sa Gausovim šumom, Gausovo filtriranje).....	22
Slika 5. Primjena medijanskog filtera na biomedicinskoj slici (gornji red – originalna slika, slika sa salt-and-pepper šumom, medijansko filtriranje) i slici realnog okruženja (donji red – originalna slika, slika sa salt-and-pepper šumom, medijansko filtriranje	23
Slika 6. Primjena Vinerovog filtera na biomedicinskoj slici (gornji red – originalna slika, slika sa Gausovim šumom, Vinerovo filtriranje) i slici realnog okruženja (donji red – originalna slika, slika sa Gausovim šumom, Vinerovo filtriranje).	25
Slika 7. Prikaz konvolucije 3×3 nad ulaznom matricom dimenzije 5×5 , pri čemu se filter pomjera korak po korak i generiše izlaznu matricu dimenzije 3×3	28
Slika 8. Lijevo: Ulazna mapa osobina dimenzije 5×5 (dubina 1). Desno: konvolucija dimenzije 3×3 (dubina 1).	29
Slika 9. Lijevo: Konvolucija 3×3 se primjenjuje na ulaznu mapu osobina dimenzije 5×5 . Desno: odgovarajuća konvoluisana (izlazna) mapa osobina.	29
Slika 10. Lijevo: Maks pooling primijenjen na mapu osobina dimenzije 4×4 , sa filterom dimenzije 2×2 i korakom 2. Desno: Izlaz dobijen maks pooling operacijom. Napomena: rezultujuća mapa osobina sada ima dimenziju 2×2 i sadrži samo maksimalne vrijednosti iz svake	31
Slika 11. CNN arhitektura sa dva konvoluciona modula (konvolucija + ReLU + maks pooling) za ekstrakciju karakteristika i dva potpuno povezana sloja za klasifikaciju.....	32
Slika 12. Vizuelni prikaz degradacije slike dodatkom različitih tipova šuma: originalna slika i tri primjera šumiranih verzija (Gausov, impulsni i Speckle-ov šum).....	36
Slika 13. Regresiona linija	38
Slika 14. Uklanjanje šuma uz pomoć CNN mreže trenirane sa 15 i 50 epoha	46
Slika 15. Vizuelno poređenje efekata filtriranja Gausovog šuma tradicionalnim metodama	48
Slika 16. Vizuelno poređenje efekata filtriranja Gausovog šuma primjenom CNN modela.....	48
Slika 17. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma tradicionalnim metodama	50

Slika 18. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma primjenom CNN modela	50
Slika 19. Vizuelno poređenje efekata filtriranja Speckle šuma tradicionalnim metodama.....	52
Slika 20. Vizuelno poređenje efekata filtriranja Speckle šuma primjenom CNN modela.....	52
Slika 21. Vizuelno poređenje efekata filtriranja Gausovog šuma tradicionalnim metodama	54
Slika 22. Vizuelno poređenje efekata filtriranja Gausovog šuma primjenom CNN modela.....	54
Slika 23. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma tradicionalnim metodama	56
Slika 24. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma primjenom CNN modela	56
Slika 25. Vizuelno poređenje efekata filtriranja Speckle šuma tradicionalnim metodama.....	58
Slika 26. Vizuelno poređenje efekata filtriranja Speckle šuma primjenom CNN modela.....	58
Prikaz 1. Osnovni Python kod za računanje MSE-a.	40
Prikaz 2. Osnovni Python kod za računanje PSNR-a.....	42
Prikaz 3. Osnovni Python kod za računanje SSIM-a	44

Tabele

Tabela 1. Prikaz stvarnih i predviđenih vrijednosti sa izračunatom greškom za ilustraciju srednje kvadratne greške (MSE)	39
Tabela 2. Pikselsne vrijednosti originalne slike dimenzija 3×3 za potrebe računanja SSIM metrike	43
Tabela 3. Pikselsne vrijednosti obrađene slike dimenzija 3×3 korišćene u proračunu SSIM-a.....	44
Tabela 4. Metrike uspješnosti različitih metoda filtriranja Gausovog šuma	47
Tabela 5. Metrike uspješnosti različitih metoda filtriranja Salt-and-Pepper šuma	49
Tabela 6. Metrike uspješnosti različitih metoda filtriranja Speckle šuma.....	51
Tabela 7. Metrike uspješnosti različitih metoda filtriranja Gausovog šuma	53
Tabela 8. Metrike uspješnosti različitih metoda filtriranja Salt-and-Pepper šuma	55
Tabela 9. Metrike uspješnosti različitih metoda filtriranja Speckle šuma.....	57

Uvod

Biomedicinske slike poput MRI (magnetna rezonanca), CT (kompjuterizovana tomografija) i ultrazvučnih snimaka predstavljaju neizostavan dio u medicinskoj dijagnostici. Međutim, ove slike mogu često biti podvrgnute različitim vrstama šumova poput elektromagnetnih smetnji što može značajno umanjiti tačnost podataka koju predstavljaju i na taj način uticati na medicinsku dijagnostiku ili otežati medicinskim stručnjacima u radu. U literaturi postoje i primijenjuju se različite tehnike za uklanjanje šuma bez gubitka važnih dijagnostičkih informacija. Ove metode, ipak imaju ograničene performanse, a neuralne mreže (CNN) pokazuju izuzetne rezultate u analizi slika zbog čega bi potencijalno mogle biti od važnosti i u ovoj oblasti.

Tema je od posebnog značaja u kontekstu digitalizacije i unaprijeđenja medicinske opreme a primjenom CNN metode dobijaju se potencijali za poboljšanje filtriranja šuma sa biomedicinskih slika.

Predmet istraživanja

Predmet istraživanja ovog rada jeste analiza i ispitivanje mogućnosti primjene konvolucionih neuronskih mreža u procesu uklanjanja šuma iz biomedicinskih slika, s ciljem unapređenja kvaliteta i tačnosti prikaza, kako bi se omogućila preciznija i pouzdanija medicinska dijagnostika. Glavni fokus istraživanja je poređenje efikasnosti CNN-a u odnosu na klasične metode filtriranja kako bi se potencijalno u budućnosti ove metode mogle koristiti u iste svrhe pogotovo kod slika napravljenih magnetnom rezonancom, CT-em i ultrazvukom.

CNN modeli imaju mogućnost automatskog prepoznavanja ključnih karakteristika slika što kod biomedicinskih slika može biti od interesa zbog mogućnosti razlikovanja tkiva na slici od šuma, omogućavajući preciznije otklanjanje šuma bez gubitka dijagnostičkih informacija.

U radu je dat predlog prilagođene implementacije CNN modela u obradi biomedicinskih slika i prikaz kvantitativne analize u odnosu na ostale metode. Dodatno, istraživanje uključuje predlog poboljšanja metode i analizu u različitim uslovima. Poseban doprinos rada je identifikacija optimalnih postavki i preporuka za njihovu primjenu u konkretnim dijagnostičkim scenarijima.

Motivi i ciljevi istraživanja

Kvalitet biomedicinskih slika je potrebno unaprijediti, a motiv i ciljevi istraživanja su usmjereni u tom pravcu. Usljed čestih problema u dijagnostici uzrokovanih različitim vrstama šumova na medicinskim slikama, te nedovoljne efikasnosti tradicionalnih metoda u procesu filtriranja šuma, potrebno je analizirati alternativne metode koje se koriste u svrhu otklanjanja šuma i poboljšanja kvaliteta slike.

Motivacija za istraživanje leži u mogućnosti da CNN pruži novo i efikasno rješenje ovog problema. CNN mreže su posebno dizajnirane za prepoznavanje obrazaca u slikama i mogu efikasno da izdvoje bitne karakteristike slike uklanjajući šum i čuvajući pritom sve informacije.

Ciljevi istraživanja se mogu grupisati u nekoliko kategorija i to:

1. Ispitivanje efikasnosti CNN-a u procesu otklanjanja šuma
2. Implementacija CNN modela u analizi biomedicinskih slika
3. Kvalitativna analiza rezultata
4. Analiziranje potencijala CNN-a u otklanjanju šuma.

Pregled dosadašnjih istraživanja

Dosadašnja istraživanja potvrđuju potencijal CNN-a u medicinskoj dijagnostici. Autori istraživanja [1] navode da integracija vještačke inteligencije, a posebno dubokog učenja (*deep learning*) u medicinsku dijagnostiku može značajno unaprijediti proces dijagnostike i otkrivanja bolesti. Autori navode da iako su postignuti značajni rezultati u oblastima poput detekcije dijabetičke retinopatije i predikcije kardiovaskularnih događaja, ostali su izazovi poput očuvanja kvaliteta podataka u različitim uslovima.

U radu [2], navodi se da integracija vještačke inteligencije (AI) a pogotovo dubokog učenja, u medicinske slike ima potencijal unaprijedjenje procesa okrivljanja bolesti. Autori navode da duboko učenje omogućava brže i preciznije dijagnoze što otvara put pravovremenoj intervenciji.

Sa druge strane, autori istraživanja [3] upozoravaju na opasnosti koje uvođenje vještačke inteligencije unosi u proces dijagnostike i naglašavaju važnost svjesnosti određenih nedostataka u ovom procesu.

Autori istraživanja [4] predlažu algoritam koji je implementiran u numeričkoj šemi za procjenu pravaca vlakana. Ovom metodom su istaknute sposobnosti prilagođavanja kompleksnim geometrijama vlakana što može često biti izazov klasičnim pristupima. Njena primjena otvara nove mogućnosti za unapređenje kompozitnih materijala u različitim industrijama ili naučnim oblastima, poput avioindustrije ili medicine gdje je precizno pozicioniranje vlakana od ključne važnosti za postizanje rezultata.

Metoda redukcije šuma pomoću filtera srednje vrijednosti je sprovedena na slikama a rezultati su prikazali značajno smanjenje šuma uz očuvanje prostorne rezolucije slike. Dalja evaluacija slika pacijenata uz pomoć medicinskog stručnjaka, kao i poređenje sa drugim savremenim metodama redukcije šuma, potrebna je kako bi se kvantifikovalo smanjenje zračenja i odredila optimalna vrijednost praga za kliničke slike u različitim CT pregledima [5].

Dobar kvalitet medicinskih slika je oduvijek bio od ključne važnosti u dijagnostici a pogotovo u doba digitalizacije i automatizacije nekih dijagnostičkih procesa. U radu [6] se razmatraju modeli šuma i pregled različitih metoda za redukciju šuma, te se naglašava da trenutno ne postoji univerzalni algoritam za koji bi bio primjenljiv na različitim tipovima slika i koji bi dao

zadovoljavajuće rezultate za sve moguće tipove šumova.. Takođe, analiziraju se metode redukcije šuma u medicinskim slikama koristeći evaluacione parametre poput PSNR-a i RMSE-a.

Usljed potrebe za većom dijagnostičkom preciznošću u otkrivanju raka kostiju nastalo je istraživanje [7]. U ovoj dijagnostici pojedinačni modaliteti snimanja ne uspijevaju u potpunosti obuhvatiti strukturne i funkcionalne karakteristike tumora. Predložen je pristup spajanjem karakteristika baziran na dubokom učenju koji ima za cilj poboljšanje otkrivanja raka u ranoj fazi, smanjujući broj lažno pozitivnih i negativnih rezultata. Model prikazan u radu kombinuje ResNet-50 i XGBoost, pokazao je tačnost od 96% u klasifikaciji raka kostiju, nadmašujući druge klasifikatore kao što su DT i KNN.

Autori istraživanja [8] u svom radu predstavljaju novu BICSGODL tehniku za dijagnozu raka debelog crijeva i pluća, koristeći model dubokog učenja sa podešenim hiperparametrima za poboljšanu detekciju. DenseNet se koristi za učenje složenih karakteristika, CLSTM za detekciju prostorno-vremenskih podataka, a SGO algoritam za optimizaciju performansi. Analiza na biomedicinskim slikama pokazuje efikasnost tehnike, što je čini pogodnom za automatsku detekciju raka iz medicinskih slika.

Studija [9] predlaže FNSST tehniku za restauraciju LDCT slika koristeći prostornu CNN metodu na više skala. FNSST tehnika koristi dekompoziciju na osnovu smjera šuma i artefakata u LDCT slikama. Model koristi visoko-frekventne podmape LDCT slika za učenje karakteristika šuma i artefakata, dok zaobilazni link ubrzava konvergenciju mreže. Eliminacijom downsamplinga iz CNN-a sprečava se gubitak informacija. Kombinacija FNSST-a i CNN-a efikasno uklanja šum i artefakte, zadržavajući ivice i karakteristike slika, nadmašujući metode poput KSVD, BM3D i Image-CNN.

Korišćenje hiper-konvolucija umjesto tradicionalnih konvolucija može poboljšati performanse u segmentaciji biomedicinskih slika, jer omogućava efikasnije učenje sa manjim brojem parametara i bolje generalizovanje modela [10].

Doprinosi

Istraživanje je rezultiralo potvrdom efikasnosti konvolucionih neuralnih mreža u procesu otklanjanja šuma sa biomedicinskih slika poput MRI, CT i ultrazvuka. Implementacijom CNN modela u okviru rada je omogućena kvalitativna analiza rezultata koja pruža uvid u stvarne prednosti navedenog pristupa medicinskoj praksi. Unaprijeđenje preciznosti slika u oblasti dijagnostike moglo bi imati veliku praktičnu primjenu u medicini jer bi se smanjila mogućnost pogrešnih dijagnoza usljed lošeg kvaliteta slika sa šumom. Rad je postavio dobre temelje daljeg razvoja i usavršavanja CNN tehnologija u oblasti medicine čineći je jednim od ključnih alata u budućim procesima obrade biomedicinskih slika.

Istraživanje je ukazalo na prednosti upotrebe CNN modela u poređenju sa tradicionalnim metodama filtriranja, te otvoriti vrata daljim istraživanjima na temu.

Struktura rada

1. Uvod

U uvodnom dijelu dat je kratak pregled vrsta biomedicinskih slika i njihovog značaja u medicinskoj dijagnostici. Objasnjen je pojam šuma, kao i problemi koje njegovo prisustvo može da prouzrokuje na biomedicinskim slikama. Takođe, naglašena je uloga konvolucionih neuronskih mreža (CNN) u obradi slika i njihov potencijal u poboljšanju kvaliteta istih.

2. Biomedicinske slike i problem šuma

Biomedicinske slike prepoznate su kao ključni alat za preciznu dijagnostiku i praćenje bolesti u savremenoj medicini. Prisustvo šuma, koje se može pojaviti usled ograničenja uređaja za snimanje, načini akvizicije ili spoljašnjih uticaja, identifikovano je kao faktor koji može značajno da oteža interpretaciju slika. Ukazano je na to da šum narušava detalje i smanjuje kontrast, što otežava analizu slike i prepoznavanje bolesti.

3. Konvolucione neuralne mreže (CNN)

U ovom dijelu objašnjeno je kako funkcionišu konvolucione neuralne mreže i zašto su pogodne za obradu slika u kontekstu medicinske dijagnostike.

4. Metodologija

U okviru metodologije prikazan je detaljan opis podataka koji su korišćeni za treniranje i testiranje modela, kao i opis CNN modela koji je primijenjen u eksperimentu. Takođe, navedeni su softverski alati i biblioteke korišćene za implementaciju.

5. Evaluacija performansi

U ovom dijelu prezentovani su kvalitativni i kvantitativni rezultati sprovedenog eksperimenta radi procjene uspješnosti primijenjenog pristupa.

6. Zaključak

Na kraju rada izvedeni su ključni zaključci na osnovu dobijenih rezultata, i predloženi su pravci za buduća istraživanja.


1. TEORIJSKI OKVIR I ZNAČAJ BIOMEDICINSKIH SLIKA

1.1 Značaj biomedicinskih slika u savremenoj medicini

U savremenoj medicini, biomedicinskim slikama se pridaje izuzetna važnost jer omogućavaju vizualizaciju unutrašnjih anatomskih i funkcionalnih struktura organizma bez potrebe za invazivnim procedurama. Njihova uloga se prepoznaje kao temeljna u procesu postavljanja tačnih dijagnoza, planiranja terapije i praćenja toka bolesti. Takve slike se, pored dijagnostike, koriste i u navigaciji tokom hirurških intervencija, vođenju terapijskih postupaka, kao i u evaluaciji efekata liječenja.

U okviru biomedicinskog snimanja koristi se čitav spektar tehnologija, među kojima se najčešće primjenjuju magnetna rezonanca (MRI), kompjuterizovana tomografija (CT) i ultrazvuk. Ove tehnike omogućavaju ne samo statički prikaz, već i dinamičko praćenje promjena u tkivima i organima.

S tim u vezi, sve je veća upotreba vještačke inteligencije u medicinskoj praksi, kroz alate za automatsku analizu, segmentaciju i klasifikaciju. Zahvaljujući visokoj rezoluciji, izraženom kontrastu i preciznoj reprodukciji anatomskih detalja, ovakve slike se prepoznaju kao nezamjenjiv alat u dijagnostici, dok se njihov značaj dodatno naglašava uvođenjem metoda za digitalno poboljšanje kvaliteta slike [11][37]. Na slici 1 prikazani su primjeri biomedicinskih slika.



Slika 1. Primjeri biomedicinskih slika

1.2 Uloga MRI, CT i ultrazvuka u dijagnostici

Tri najčešće primjenjivane tehnike u oblasti biomedicinskog snimanja – magnetna rezonanca (MRI), kompjuterizovana tomografija (CT) i ultrazvuk, prepoznate su kao centralni alati u savremenoj dijagnostici, zahvaljujući svojim specifičnim mogućnostima i prednostima.


Magnetna rezonanca (MRI) koristi se za generisanje visokorezolutnih prikaza mekih tkiva, uključujući mozak, kičmenu moždinu, mišiće i unutrašnje organe. Ova metoda omogućava detaljan prikaz unutrašnjih struktura bez upotrebe jonizujućeg zračenja, zbog čega se često bira u oblastima kao što su neurologija, ortopedija i onkologija. Njena visoka osjetljivost na promjene u protonskom okruženju omogućava da se patološki procesi detektuju već u ranoj fazi razvoja.

Kompjuterizovanom tomografijom (CT) omogućena je brza i precizna vizualizacija unutrašnjih anatomskih struktura, što je naročito značajno u hitnim slučajevima kada je potrebno brzo postavljanje dijagnoze. CT snimci koriste se za procjenu povreda, otkrivanje tumora, praćenje stanja pluća, srca i krvnih sudova, kao i za navigaciju tokom invazivnih procedura. Zbog svoje brzine i široke dostupnosti, CT se smatra nezamjenjivom metodom u urgentnoj medicini.

Ultrazvučno snimanje primjenjuje se kao neinvazivna i bezbjedna tehnika, kojom se pomoću zvučnih talasa u realnom vremenu prikazuju unutrašnji organi. Poseban značaj ultrazvuku dat je u oblastima kao što su ginekologija, akušerstvo, kardiologija i dijagnostika abdomena. Njegove

glavne prednosti ogledaju se u mobilnosti uređaja, pristupačnosti pregleda i mogućnosti izvođenja bez izlaganja pacijenta štetnom zračenju.

Sve tri metode (slika 2) koriste se komplementarno u kliničkoj praksi, u zavisnosti od postavljenog dijagnostičkog cilja i anatomskog regiona koji se ispituje. Njihova pravilna primjena doprinosi povećanju dijagnostičke preciznosti, ranijem otkrivanju bolesti i efikasnijem planiranju terapijskih strategija [11].



Slika 2. Uporedni prikaz ultrazvučnih, MRI i CT snimaka istog anatomskog regiona [12]


1.3 Problem šuma na biomedicinskim slikama

Uprkos visokom stepenu tehničkog razvoja savremenih modaliteta snimanja, biomedicinske slike su često pogođene pojavom šuma, koji može značajno da naruši njihovu dijagnostičku vrijednost (slika 3). Šum se definiše kao neželjena komponenta signala, koja nastaje tokom procesa akvizicije, obrade ili prenosa slike, i koja otežava preciznu interpretaciju vizuelnog sadržaja [13]. U kontekstu MRI, CT i ultrazvučnih slika, šum se može manifestovati kao granularnost, zamućenost, nasumične varijacije intenziteta piksela ili artefakti koji prikrivaju strukture od kliničkog značaja [11]. U CT snimcima, prisutni su uglavnom Poissonov i Gausovski šum, dok su u MRI slikama česti kompleksniji modeli šuma, poput Rician šuma, koji dodatno komplikuju proces filtriranja [14].

Uzroci šuma su brojni i raznovrsni, mogu poticati iz tehničkih ograničenja uređaja, kao što su niska rezolucija detektora, slab signal-to-noise odnos ili termalni šum senzora. Takođe, značajan uticaj imaju spoljašnji faktori, poput elektromagnetnih smetnji, pokreta pacijenta tokom snimanja ili loše kalibracije opreme [11].

Prisutvo šuma može dovesti do značajnog narušavanja važnih morfoloških i funkcionalnih detalja, što za posljedicu ima smanjenje kontrasta, gubitak ivica i smanjenje mogućnosti detekcije patoloških promjena. Na taj način, šum direktno utiče na pouzdanost dijagnoze, što može imati ozbiljne kliničke posljedice [13] [15].

Zbog toga se u obradi biomedicinskih slika posebna pažnja posvećuje razvoju metoda za efikasno uklanjanje šuma, uz očuvanje dijagnostički relevantnih informacija. Ovaj balans između denoisinga i zadržavanja strukture predstavlja centralni izazov u medicinskoj obradi slike.



Slika 3. Primjeri biomedicinskih slika sa šumom

1.3.1 Uzroci šuma

Uzroci šuma na biomedicinskim slikama su brojni i zavise kako od prirode samog modaliteta snimanja, tako i od spoljašnjih uslova tokom akvizicije. Šum može da nastane usljed ograničenja hardverskih komponenti, kao što su detektori sa niskom osjetljivošću, toplotni šum u elektronici, slab signal-to-noise odnos, kao i niska rezolucija senzora [13].

Dodatno, značajnu ulogu imaju faktori iz okruženja, uključujući elektromagnetne smetnje, vibracije aparata, kao i pokrete pacijenta tokom snimanja. Na primjer, kod MRI skeniranja, pokreti glave ili tijela često uzrokuju zamućenja i artefakte koji otežavaju interpretaciju. U CT snimanju, povećane doze zračenja mogu smanjiti šum, ali istovremeno predstavljaju rizik po zdravlje, pa se često radi sa nižim dozama, što povećava šumnost slike [11].

U ultrazvučnim slikama, šum je često rezultat višestrukih refleksija i akustičkih interferencija, koje dovode do takozvanog speckle šuma, vrste teksturnog šuma koja smanjuje kontrast i otežava obradu slike[38].

Razumijevanje izvora šuma predstavlja osnovu za izbor odgovarajuće metode filtriranja i poboljšanja kvaliteta slike.

1.3.2 Vrste šuma u biomedicinskim slikama

U zavisnosti od prirode modaliteta snimanja i izvora smetnji, u biomedicinskim slikama se mogu identifikovati različiti tipovi šuma. Najčešći su:

- **Gausov šum** – karakteriše se normalnom raspodjelom oko stvarne vrijednosti piksela i nastaje usljed elektronskih smetnji, naročito kod CT i digitalnih senzora. Često se koristi kao matematički model zbog svoje jednostavnosti.
- **Rician šum** – specifičan za MRI slike, gdje se javlja usljed prisustva šuma u realnom i imaginarnom dijelu kompleksnog MRI signala. Njegova distribucija zavisi od intenziteta signala i često otežava standardne metode filtriranja.
- **Speckle šum** – prisutan kod ultrazvuka i koherentnih sistema snimanja. Ima teksturalnu prirodu i manifestuje se kao granulirana šara koja degradira kvalitet slike, naročito u mekim tkivima.
- **Salt-and-pepper šum** – impulsni šum koji se javlja kao crne i bijele tačke na slici, najčešće kao posljedica grešaka u prenosu ili digitalizaciji slike.

- **Poissonov šum** – karakterističan za snimke sa malim brojem fotona, kao kod niskodoznih CT procedura. Intenzitet šuma zavisi od same slike, jer se radi o šumu koji potiče iz kvantne statistike [16].

Prepoznavanje vrste šuma ima značajnu ulogu u izboru odgovarajuće metode za njegovo uklanjanje, jer se efikasnost filtera često vezuje za konkretni šumni model.

1.3.3 Negativan uticaj šuma na preciznost dijagnoze

Prisustvo šuma na biomedicinskim slikama se smatra jednim od glavnih faktora koji negativno utiču na tačnost i pouzdanost dijagnostičkih procedura. Šum može da naruši kvalitet slike na više načina: smanjenjem kontrasta između tkiva, zamućenjem ivica anatomskih struktura, kao i prikrivanjem sitnih, ali klinički značajnih detalja.

U kliničkoj praksi, ovakvi efekti mogu dovesti do otežane interpretacije nalaza, što posebno dolazi do izražaja kod početnih stadijuma bolesti, gdje su promjene minimalne. Na primjer, kod MRI slika, šum može prikriti lezije u mozgu ili kičmenoj moždini, dok u CT slikama može zamagliti ivice tumora ili vaskularnih struktura. Kod ultrazvučnih snimaka, speckle šum otežava vizuelizaciju mekih tkiva i može dovesti do lažno negativnih ili lažno pozitivnih nalaza.

Pored kliničkog aspekta, prisustvo šuma takođe utiče i na algoritamsku obradu slika – segmentacija, ekstrakcija osobina i klasifikacija postaju znatno nepouzdanije kada su slike kontaminirane šumom. U automatskim sistemima zasnovanim na vještačkoj inteligenciji, loš kvalitet ulaznih slika dovodi do pogrešnih predikcija, čime se kompromituje čitav dijagnostički lanac.

Zbog svega navedenog, smanjenje šuma se smatra neophodnim korakom u pripremi biomedicinskih slika za kliničku upotrebu, kako bi se povećala preciznost dijagnostičkih postupaka i izbjegle pogrešne odluke koje mogu imati ozbiljne posljedice po pacijenta [39].

2. TRADICIONALNE METODE ZA UKLANJANJE ŠUMA SA BIOMEDICINSKIH SLIKA

U procesu obrade biomedicinskih slika, jedan od ključnih zadataka jeste uklanjanje šuma uz očuvanje strukturnih i dijagnostički značajnih informacija. Prije pojave naprednih metoda zasnovanih na vještačkoj inteligenciji, primjenjivane su različite tradicionalne metode filtriranja sa ciljem poboljšanja kvaliteta slike.

Ove metode zasnivaju se na matematički definisanim operacijama koje se primjenjuju nad pikselima slike u prostornom ili frekvencijskom domenu. Njihova jednostavnost, dostupnost i brzina obrade omogućile su široku primjenu u ranijim fazama razvoja digitalne medicinske dijagnostike [40]. Neki od korišćenih filtara su:

- Gausov,
- Medianov i
- Vinerov filter.

2.1 Gausov filter

Gausov filter predstavlja jednu od najčešće korišćenih metoda za uklanjanje šuma u digitalnoj obradi slike. Funkcioniše tako što smanjuje visoke frekvencije slike, odnosno eliminiše nagle promjene intenziteta koje su često rezultat šuma. Princip rada ovog filtera zasniva se na zamućivanju slike pomoću Gausove funkcije, gdje pikseli bliži centru filtera više utiču na rezultat od onih koji su dalje[17].

Zahvaljujući glatkom i simetričnom obliku Gausove funkcije, Gausov filter obezbjeđuje ravnomjerno zamućivanje slike, bez pojave naglih prijelaza ili artefakata. Ova svojstva čine ga pogodnim za osnovnu predobradu slike, naročito u slučajevima gdje je potrebno ukloniti Gausov šum, koji se često pojavljuje kao posljedica elektronskih smetnji u uređajima za snimanje [17].

Matematički model

Dvodimenzionalna Gausova funkcija definisana je izrazom:

$$G(x, y) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

gdje su:

- x i y udaljenosti piksela od centra jezgra po horizontalnoj i vertikalnoj osi,
- σ standardna devijacija koja određuje “širinu“ Gausove funkcije – tj. nivo zamućenja.

U praksi, filter se implementira kao jezgro (dimenzije npr. 3×3 , 5×5 , 7×7) sa vrijednostima izračunatim u skladu sa relacijom (1), a rezultat se dobija konvolucijom tog kernela sa originalnom slikom [17].

Primjena u biomedicinskim slikama

Gausov filter se često koristi za redukciju šuma u biomedicinskim slikama nastalim MRI, CT ili ultrazvučnim metodama. Njegova upotreba se naročito preporučuje u slučajevima kada postoji Gausov-distribuiran šum, jer je upravo za takvu distribuciju matematički optimizovan.

Ipak, osnovno ograničenje ove metode ogleda se u njoj nemogućnosti da očuva ivice slike. Zbog toga, primjena Gausovog filtera u medicinskoj slici može dovesti do gubitka važnih dijagnostičkih informacija, naročito u regijama sa visokim kontrastom i složenim teksturama [17]. Na slici 4. prikazan je primjer slike gdje je primijenjeno Gausov-o filtriranje



Slika 4. Primjena Gausovog filtera na biomedicinskoj slici (originalna slika, slika sa Gausovim šumom, Gausovo filtriranje)

2.2 Medijan filtar

Medijan filtar predstavlja nelinearnu tehniku filtriranja koja se koristi za uklanjanje šuma, naročito impulsivnog, poznatog i kao “*salt-and-pepper*“ šum. Za razliku od linearnih metoda koje izračunavaju prosječne vrijednosti piksela, kod medijan filtriranja, svaki piksel se zamjenjuje medijan vrijednošću piksela iz njegove okoline. Na taj način, ekstremne vrijednosti koje predstavljaju šum bivaju uklonjene ili redukovane, dok se ivice i strukturalni detalji slike bolje čuvaju.

Medijan filtar radi tako što uzme piksele u malom kvadratnom prozoru (npr. 3×3 ili 5×5), poređa njihove vrijednosti po veličini i zamijeni središnji piksel srednjom (medijanskom) vrijednošću tog skupa. Pošto se ne koristi aritmetički prosjek, ova metoda je robusnija na prisustvo izuzetno tamnih ili svijetlih piksela, zbog čega je pogodna za primjenu kod slika sa izraženim impulsnim smetnjama.

Matematički model

Neka je I ulazna slika, a $I(i, j)$ vrijednost piksela na poziciji (i, j) . Medijan filtar sa dimenzijama prozora $n \times n$ se definiše kao:


$$I'_{i,j} = \text{medijan}(\{I_{k,l} | (k, l) \in \mathcal{N}_{i,j}\}) \quad (2)$$

gdje $\mathcal{N}_{i,j}$ predstavlja okolinu piksela (i, j) unutar definisanog prozora.

Primjena u biomedicinskim slikama

Medijan filtar je naročito koristan u obradi ultrazvučnih i digitalno snimljenih biomedicinskih slika, gdje se impulsni šum javlja kao posljedica smetnji u prijemu signala.

Međutim, medijan filtar ima svoja ograničenja – kod slika sa kompleksnim teksturama i nejednako raspoređenim šumom može doći do osijecanja finih detalja, naročito ako se koristi veliki prozor. Zbog toga se često primjenjuje u kombinaciji sa adaptivnim ili višeslojnim metodama filtriranja () [18]. Na slici 5. prikazan je primjer slike gdje je primijenjeno medijan filtriranje.



Slika 5. Primjena medijan filtar na biomedicinskoj slici (originalna slika, slika sa salt-and-pepper šumom, medijan filtriranje)

2.3 Vinerov filtar

Vinerov filtar predstavlja linearnu tehniku filtriranja zasnovanu na statističkoj procjeni signala u prisustvu šuma. Za razliku od Gausovog i medijan filtra, koji su lokalni (obrađuju samo mali dio slike oko svakog piksela), Vinerov filtar koristi model šuma i slike kako bi pronašao optimalno rješenje u smislu minimalne srednje kvadratne greške (MSE) između originalne i slike nakon filtriranja.

Ovaj filtar se naročito koristi u situacijama kada je raspodjela šuma Gausova i kada postoji informacija o spektralnim karakteristikama slike i šuma. Njegova formulacija se zasniva na frekvencijskoj obradi signala, pri čemu se filtriranje vrši u domeni Fourierove transformacije.

Matematički model

U frekvencijskom domenu, Vinerov filter se izražava kao:

$$H(u, v) = \frac{S_{xx}(u, v)}{S_{xx}(u, v) + S_{nn}(u, v)} \quad (3)$$

gdje su:

$H(u, v)$ – prijenosna funkcija filtera

$S_{xx}(u, v)$ - spektralna gustina originalnog signala (slike),


$S_{nn}(u, v)$ - spektralna gustina šuma

U praksi, kada se ne zna tačan spektralni profil, koristi se aproksimacija pomoću lokalne varijanse, što omogućava adaptivnu verziju Vinerovog filtera i njegovu implementaciju u prostornom domenu [19].

Primjena u biomedicinskim slikama

Zahvaljujući svojoj sposobnosti da balansira između filtriranja šuma i očuvanja detalja, Vinerov filter se koristi u MRI, CT i ultrazvučnim slikama, posebno kada je poznata priroda šuma. U medicinskim aplikacijama se često primjenjuje kao postprocesorski korak nakon rekonstrukcije slike, kako bi se dodatno uklonile komponente šuma bez značajnog narušavanja finih struktura.

Njegova glavna prednost u odnosu na Gausov filter jeste prilagodljivost – Vinerov filter koristi lokalnu statistiku slike, čime se postiže bolji kompromis između efekta filtriranja šuma i očuvanja ivica. Međutim, slabost mu je što zavisi od dobre procjene šuma i lokalne varijanse, pa pri nepravilnim procjenama može doći do pojave artefakata [19]. Na slici 6 prikazan je primjer slike gdje je primijenjeno Vinerovo filtriranje.



Slika 6. Primjena Vinerovog filtera na biomedicinskoj slici (originalna slika, slika sa Gausovim šumom, Vinerovo filtriranje)

3. KONVOLUCIONE NEURALNE MREŽE (CNN) U OBRADI BIOMEDICINSKIH SLIKA

3.1 Osnovni koncept konvolucionih neuronskih mreža

Konvolucione neuralne mreže (CNN, engl. *Convolutional Neural Networks*) predstavljaju jednu od najznačajnijih arhitektura dubokog učenja koje pokazuju posebnu efikasnosti u obradi slike i prepoznavanju obrazaca. Njihova struktura je inspirisana načinom na koji funkcioniše vizuelni korteks a omogućava automatsko učenje iz podataka bez potrebe za ručnom ekstrakcijom osobina.

CNN se sastoji od niza specijalizovanih slojeva koji obrađuju ulazne slike u više faza. Ključni elementi CNN arhitekture uključuju:

- **Konvolucione slojeve** – koji primjenjuju skup filtera (jezgara) na ulaznu sliku i generišu mapu osobina. Ovi filteri se uče treniranjem tako da odgovaraju obrascima u slici kao što su ivice, teksture ili strukture.
- **Aktivacione funkcije** – kao što je ReLU (*Rectified Linear Unit*), koje uvode nelinearnost u mrežu i omogućavaju joj da uči složenije obrasce.
- **Pooling slojeve** – koji služe za smanjenje dimenzionalnosti podataka (najčešće *max pooling*) čime se obezbjeđuje robusnost mreže na translacije i manja varijacija ulaza.
- **Potpuno povezane slojeve** – na kraju mreže, koji služe za donošenje odluka ili regresiju nakon što su prostorne informacije obrađene.

Trening CNN modela se zasniva na metodi **povratnog širenja greške** (engl. *backpropagation*) i korišćenju optimizatora poput **Stochastic Gradient Descent (SGD)** ili **Adam**. Tokom obuke, mreža automatski prilagođava težine filtera kako bi minimizovala razliku između predikcije i stvarne vrijednosti [20].

Zahvaljujući ovakvoj strukturi, CNN je sposoban da identifikuje i najfinije obrasce na slikama, što ga čini izuzetno pogodnim za primjenu u obradi biomedicinskih slika gdje je precizna lokalizacija i očuvanje struktura od ključnog značaja [21][41][42].

3.1.1 Princip rada konvolucione neuralne mreže

Veliki napredak u klasifikaciji slika postignut je otkrićem da se konvolucione neuralne mreže (CNN) mogu koristiti za automatsko prepoznavanje važnih osobina slike. Umjesto da se unaprijed određuju karakteristike kao što su oblici i teksture, CNN koristi sirove piksele i sam „uči“ da prepozna te osobine i identifikuje objekte na slici.

Na početku, CNN prima ulaznu mapu osobina: trodimenzionalnu matricu u kojoj prve dvije dimenzije predstavljaju dužinu i širinu slike u pikselima. Treća dimenzija ima vrijednost 3, što odgovara slici u boju sa tri kanala boja: crvenim, zelenim i plavim (RGB).


CNN se sastoji od niza modula, a svaki od njih primjenjuje tri osnovne operacije:

1. Konvolucija

Konvolucija uzima male ploče (tile-ove) iz ulazne mape osobina i na njih primjenjuje filtre, čime se generiše nova mapa osobina (konvoluisana mapa), koja može imati drugačiju veličinu i dubinu od originalne. Konvolucija se definiše pomoću dva osnovna parametra:

- Veličina oblasti koja se izvlači iz slike (najčešće 3×3 ili 5×5 piksela)
- Dubina izlazne mape osobina, što odgovara broju filtera koji se primjenjuju

Tokom konvolucije, filteri ((matrice iste veličine kao oblast koja se obrađuje) klize horizontalno i vertikalno preko ulazne slike, piksel po piksel, i na svakom mjestu ekstraktuju odgovarajuću lokalnu oblast slike (slika 7).




...

Slika 7. Prikaz konvolucije 3×3 nad ulaznom matricom dimenzije 5×5 , pri čemu se filter pomjera korak po korak i generiše izlaznu matricu dimenzije 3×3

Za svaki par filter–ploča, CNN vrši množenje element-po-element između matrice filtera i matrice izvučene oblasti, a zatim sabira sve dobijene vrijednosti kako bi dobio jednu rezultujuću vrijednost. Svaka od tih vrijednosti, računata za svaki mogući filter–ploča par, smješta se na odgovarajuće mjesto u konvoluisanoj mapi osobina (slika 8 i 9).



Slika 8. Lijevo: Ulazna mapa osobina dimenzije 5×5 (dubina 1). Desno: konvolucija dimenzije 3×3 (dubina 1).



Slika 9. Lijevo: Konvolucija 3×3 se primjenjuje na ulaznu mapu osobina dimenzije 5×5. Desno: odgovarajuća konvoluisana (izlazna) mapa osobina.

Tokom procesa treniranja, CNN “uči“ optimalne vrijednosti filtera matrica koje mu omogućavaju da iz ulazne mape osobina izdvoji značajne karakteristike (teksture, ivice, oblike). Kako se povećava broj filtera (tj. dubina izlazne mape osobina), povećava se i broj karakteristika koje mreža može da prepozna.

Međutim, ovaj pristup ima svoju cijenu – filteri troše većinu resursa koje CNN koristi, pa se vrijeme treniranja povećava sa svakim dodatnim filtrom. Pored toga, svaki novi filter donosi sve manju dodatnu vrijednost, zbog čega se mreže obično konstruišu tako da koriste minimalan broj filtera potreban za tačnu klasifikaciju slike.

2. ReLU transformacija

Nakon svake konvolucione operacije, CNN primjenjuje ReLU na rezultat konvolucije. Ova transformacija je važna jer uvodi nelinearnost u mrežu, što omogućava modelu da uči složenije obrasce u podacima. Bez nelinearnosti, kombinovanje više linearnih slojeva i dalje bi dalo jednostavnu linearnu funkciju, ograničavajući sposobnost mreže da prepozna složene odnose u podacima.

Matematički, ReLU funkcija definiše se kao:

$$ReLU(x) = \begin{cases} x, & \text{ako je } x > 0 \\ 0, & \text{ako je } x \leq 0 \end{cases} \quad (4)$$

Sve negativne vrijednosti se poništavaju, dok se pozitivne propuštaju nepromijenjene. ReLU funkcija uklanja negativne vrijednosti koje filteri generišu, što pomaže mreži da brže uči i smanjuje rizik od problema poput nestajanja gradijenata i zastoja u optimizaciji tokom treniranja modela. Zbog svoje jednostavnosti i efikasnosti, ReLU je postala standardna aktivaciona funkcija u dubokim konvolucionim mrežama.

3. Pooling slojevi

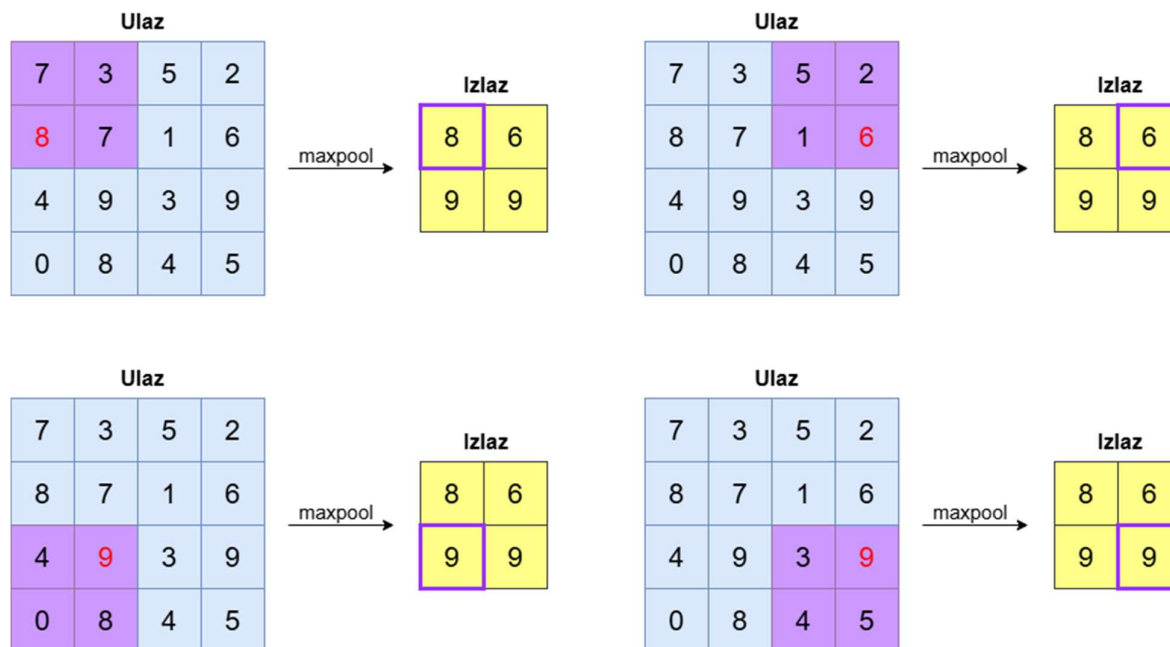
Nakon ReLU funkcije slijedi *pooling* korak, u kome CNN vrši smanjenje dimenzionalnosti konvoluisane mape osobina. Na taj način se smanjuje količina podataka za dalje procesiranje, a pritom se zadržavaju najvažnije informacije iz karakteristika slike. Najčešće korišćeni algoritam za ovu operaciju naziva se maks *pooling* (engl. *max pooling*).

Max pooling funkcioniše slično konvoluciji – prolazi se kroz mapu osobina i iz nje se izvlače oblasti definisane veličine. Za svaku ploču, u izlaznu mapu osobina se upisuje samo maksimalna vrijednost, dok se sve ostale odbacuju.

Maks pooling operacija se definiše pomoću dva parametra:

- Veličina pooling filtera (najčešće 2×2 piksela)
- Korak (eng. *stride*) – razmak u pikselima između početnih tačaka susjednih ploča. Za razliku od konvolucije, gdje se filter pomjera po jedan piksel, kod maks poolinga korak određuje tačne pozicije sa kojih se izvlače oblasti.

Na primjer, za filter dimenzije 2×2 i korak 2, maks pooling operacija će iz mape osobina izvući sve nepreklapajuće 2×2 ploče, i iz svake od njih zadržati samo najveću vrijednost (slika 10).

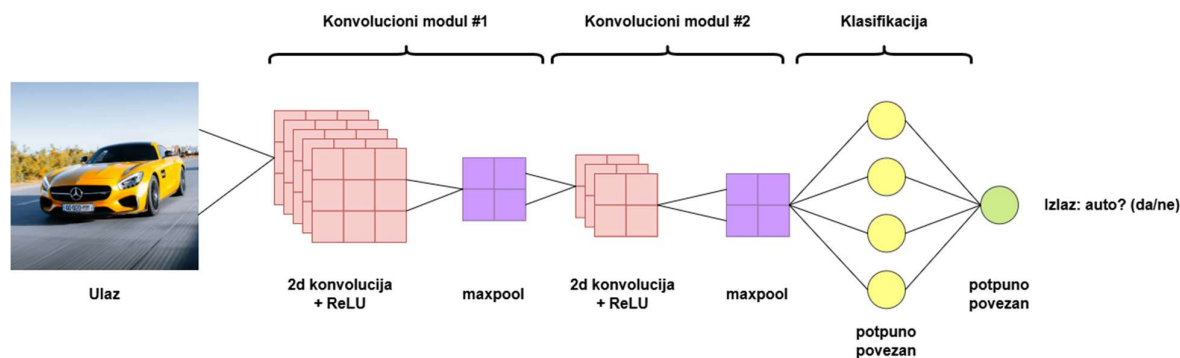


Slika 10. Lijevo: Maks pooling primijenjen na mapu osobina dimenzije 4×4 , sa filterom dimenzije 2×2 i korakom 2. Desno: Izlaz dobijen maks pooling operacijom. Napomena: rezultujuća mapa osobina sada ima dimenziju 2×2 i sadrži samo maksimalne vrijednosti iz svake oblasti

Na kraju konvolucione neuralne mreže nalaze se jedan ili više potpuno povezanih slojeva (*fully connected layers*). Kada su dva sloja „potpuno povezana“, to znači da je svaki neuron iz prethodnog sloja povezan sa svakim neuronom narednog sloja. Njihova osnovna uloga je da izvrše klasifikaciju na osnovu karakteristika koje su prethodno izdvojene konvolucijama.

Tipično, posljednji potpuno povezani sloj koristi softmax aktivacionu funkciju, koja za svaku od ponuđenih klasa vraća vjerovatnoću u rasponu od 0 do 1. Te vrijednosti predstavljaju vjerovatnoću da mreža svrstava datu sliku u svaku od ponuđenih klasa.

Slika 11 prikazuje strukturu konvolucione neuralne mreže od početka do kraja.



Slika 11. CNN arhitektura sa dva konvoluciona modula (konvolucija + ReLU + maks pooling) za ekstrakciju karakteristika i dva potpuno povezana sloja za klasifikaciju.

Prilikom dizajniranja konvolucione neuralne mreže, efikasnost filtriranja šuma značajno zavisi od izbora hiperparametara kao što su veličina filtera, broj slojeva i filtera, funkcija aktivacije (ReLU), brzina učenja i broj epoha. Svaki od ovih parametara utiče na sposobnost mreže da izdvoji relevantne karakteristike, eliminiše šum i očuva ključne dijagnostičke informacije. Pravilnim podešavanjem ovih vrijednosti postiže se optimalan balans između efikasnosti obrade slike i kompleksnosti mreže [22].

3.2 Prednosti konvolucionih neuralnih mreža u odnosu na tradicionalne metode

Konvolucione neuralne mreže su pokazale su značajne prednosti u uklanjanju šuma kod slika, posebno u poređenju sa tradicionalnim tehnikama filtriranja kao što su Gausov, medijanski i Vinerov filter. Ključna razlika leži u činjenici da CNN ne koristi unaprijed definisane filtere, već samostalno uči optimalne reprezentacije karakteristika direktno iz podataka, prilagođene specifičnim oblicima šuma prisutnim u slici.

Za razliku od klasičnih metoda koje tretiraju šum kao statički statistički proces, CNN modeli uče nelinearne i višeslojne obrasce, čime postižu viši stepen fleksibilnosti i sposobnosti adaptacije. Ovo omogućava preciznije uklanjanje šuma bez značajnog narušavanja strukture slike, što je od presudnog značaja u oblasti biomedicinske dijagnostike, gdje i najmanji detalji mogu imati kliničku važnost [23].

Pored toga, CNN može istovremeno naučiti da razlikuje šum od strukturnih karakteristika slike, kao što su ivice i teksture, čime se postiže očuvanje ivica i važnih anatomskih detalja. Ova sposobnost dolazi kao rezultat višeslojnosti mreže – svaki sloj izvlači karakteristike različitog nivoa apstrakcije, od lokalnih detalja do globalnih struktura.

Još jedna značajna prednost je mogućnost da CNN bude treniran za različite modalitete slike i vrste šuma, čime se stvara univerzalno rješenje koje se može lako primijeniti na različite tipove slika: MRI, CT, ultrazvuk, rendgen itd.

Zahvaljujući sve dostupnijim bibliotekama, vreme izvođenja i treniranja CNN modela je značajno skraćeno, što ga čini primjenjivim i u realnim kliničkim sistemima [23].

3.3 Primjena konvolucionih neuronskih mreža u biomedicinskim slikama

Konvolucione neuralne mreže (CNN) sve češće se primjenjuju u obradi biomedicinskih slika, posebno u zadacima filtriranja šuma. Njihova sposobnost da automatski uče relevantne karakteristike iz podataka omogućila je zamjenu tradicionalnih metoda filtriranja naprednim modelima dubljeg učenja, posebno u kontekstu MRI, CT i ultrazvučnih slika.

Za razliku od klasičnih filtera koji koriste unaprijed definisane operacije, CNN modeli uče obrasce šuma iz velikog broja primjera i na osnovu toga adaptivno uklanjaju šum uz očuvanje ključnih dijagnostičkih detalja. Tokom protekle decenije razvijen je niz arhitektura specijalizovanih za zadatke denoisinga.

Jedan od najpoznatijih modela jeste DnCNN (Denoising CNN), koji koristi duboku rezidualnu strukturu. Ovaj model se istakao u uklanjanju Gausovog šuma i pokazao je bolje rezultate u odnosu na metode poput BM3D i medijanskog filtera, naročito po PSNR i SSIM mjerama [24].

Takođe, model U-Net, iako prvobitno razvijen za segmentaciju, pokazao je odlične rezultate u uklanjanju šuma kada se prilagodi za denoising. Njegova simetrična arhitektura sa direktnim povezivanjem ranijih i kasnijih slojeva omogućava precizno očuvanje strukturalnih informacija, što je posebno korisno kod ultrazvučnih i MRI snimaka.

CNN modeli se danas sve češće integrišu i u komercijalne softverske alate za analizu slike, gdje se automatski primjenjuju za poboljšanje kvaliteta slike prije dalje analize. Njihova primjena značajno olakšava rad radiologa i povećava pouzdanost dijagnostike [24].

4. MATERIJALI I METODE

4.1 Skupovi podataka

Za potrebe eksperimentalne evaluacije korišćena su dva javno dostupna skupa podataka (dataset) sa biomedicinskim slikama:

- **LC25000** – skup patohistoloških slika plućnog tkiva, sa normalnim, benignim i malignim uzorcima. Karakteriše ga visoka rezolucija i raznovrsnost uzoraka, čime se omogućava evaluacija metoda obrade slike u kompleksnim uslovima [26].
- **Lungs Disease Dataset** – skup podataka koji sadrži medicinske slike pluća razvrstane po četiri vrste bolesti. Skup uključuje slike dobijene različitim modalitetima, kao što su CT, MRI, ultrazvuk i histopatologija, što omogućava testiranje robusnosti modela u zadacima filtriranja šuma i poboljšanja kvaliteta slike [25].

Slike iz oba skupa prethodno su skalirane, normalizovane i konvertovane u odgovarajući format (sivotonski ili RGB), u zavisnosti od zahtjeva primijenjenog modela. Na osnovu ovih slika sprovedena je obrada i izvršena evaluacija rezultata.

4.2 Metode za dodavanje šuma

Radi testiranja robusnosti modela, originalne slike su degradirane dodatkom različitih tipova šuma. Na taj način simulirani su uslovi koji često nastaju u medicinskom snimanju usljed ograničenja opreme, niskog kontrasta ili fizioloških smetnji.

Primijenjeni su sledeći tipovi šuma:

- Gausov šum,
- Impulsni šum (*salt-and-pepper*) i
- Speckle-ov šum.

Svi tipovi šuma generisani su pomoću funkcije *random_noise* iz biblioteke *skimage.util*, uz podešavanje odgovarajućih parametara za svaki pojedinačni slučaj. Time je obezbijedena kontrolisana degradacija podataka prije primjene modela za poboljšanje kvaliteta slike.

Gausov šum


Gausov šum je aditivni šum koji prati normalnu raspodjelu vjerovatnoće sa srednjom vrijednošću nula. On se dodaje svakom pikselu slike kao nezavisna nasumična vrijednost i najčešće je rezultat elektronskih smetnji senzora ili termalnog šuma. Zbog svoje matematičke jednostavnosti i široke primjene, često se koristi u simulacijama degradacije slike [27].

Impulsni šum (sol i biber)

Ovaj šum se manifestuje kao nasumična pojava potpuno crnih i potpuno bijelih piksela (0 i 1 u normalizovanom rasponu), zbog čega podsjeća na so i biber. Predstavlja tipičan model degradacije koji se javlja kod grešaka u komunikacionim kanalima ili grešaka senzora. U biomedicinskim slikama može simulirati smetnje koje nastaju prilikom digitalnog prenosa slike [28].

Speckle šum

Speckle šum predstavlja teksturalni šum koji nastaje kao posljedica interferencije koherentnih valova, tipično u ultrazvučnom i MRI snimanju. Karakteriše se pojavom granularnih obrazaca koji degradiraju kvalitet slike i otežavaju vizuelizaciju finih strukturnih detalja. Zbog svoje prirode, smatra se multiplikativnim šumom i posebno je izazovan za uklanjanje [29]. Na slici 12. dat je prikaz degradacije slike različitim tipovima šuma.



Slika 12. Vizuelni prikaz degradacije slike dodatkom različitih tipova šuma (originalna slika, gausov šum, impulsni šum, speckle šum)

4.3 Evaluacione metrike

Za kvantitativnu procjenu uspješnosti filtriranja šuma i poboljšanja kvaliteta slike, korišćene su tri standardne metrike koje omogućavaju poređenje između originalne i rekonstruisane slike:

- MSE (Mean Squared Error)
- PSNR (Peak Signal-to-Noise Ratio)
- SSIM (Structural Similarity Index Measure)

Ove metrike omogućavaju sveobuhvatnu analizu efekata koje primijenjeni modeli imaju na kvalitet rekonstruisanih slika, uzimajući u obzir i numeričke i vizuelne aspekte degradacije i oporavka slike.

4.3.1 MSE (Mean Squared Error)

U oblastima regresione analize i mašinskog učenja, srednja kvadratna greška (MSE) predstavlja ključnu metriku za evaluaciju performansi prediktivnih modela. Ova mjera izražava prosječnu kvadratnu razliku između predviđenih i stvarnih ciljanih vrijednosti unutar skupa podataka. Osnovna svrha MSE-a jeste procjena kvaliteta predikcija modela, kroz mjerenje njihove usklađenosti sa referentnim (ground truth) vrijednostima [30].

MSE se izračunava prema sljedećoj formuli:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5)$$

Gdje su:


MSE – srednja kvadratna greška

n – broj posmatranih podataka (tačaka)

Y_i – stvarne (posmatrane) vrijednosti

\hat{Y}_i – predviđene vrijednosti

Srednja kvadratna greška (MSE) mjeri koliko je regresiona linija blizu skupu posmatranih podataka. Predstavlja funkciju rizika koja odgovara očekivanoj vrijednosti kvadratnog gubitka. MSE se izračunava tako što se uzima prosjek kvadriranih grešaka, odnosno razlika između stvarnih i predviđenih vrijednosti, u odnosu na posmatranu funkciju. Na slici 13 prikazano je kako MSE pokazuje tačnost modela, odnosno koliko se predviđena linija razlikuje od stvarnih vrijednosti.



Slika 13. Regresiona linija

Veća vrijednost MSE-a ukazuje na to da su podaci široko raspršeni oko svoje centralne vrijednosti (sredine), dok manja vrijednost MSE-a sugerirše suprotno. Niže vrijednosti MSE-a se preferiraju, jer ukazuju na to da su podaci koncentrisaniji oko srednje vrijednosti, što implicira manju grešku. Osim toga, niži MSE odražava stabilnu i centralizovanu distribuciju vrijednosti, sa manjim odstupanjima od očekivanih rezultata [30].

Manji MSE \Rightarrow manja greška \Rightarrow bolji estimator.

Primjer:

Pretpostavimo da su date sljedeće stvarne i predviđene vrijednosti na tabeli 1:

Tabela 1. Prikaz stvarnih i predviđenih vrijednosti sa izračunatom greškom za ilustraciju srednje kvadratne greške (MSE)

	Stvarna vrijednost	Predviđena vrijednosti	Stvarna - Predviđena
1	8	7.75	0.25
2	10	9	1
3	12	11.2	0.64

Zbir kvadratnih grešaka:

$$0.25 + 1 + 0.64 = 1.89$$

Broj podataka:

$$n = 3$$

Srednja kvadratna greška je [31]:

$$MSE = 1.89/3 = 0.63$$

Prikaz 1 prikazuje jednostavnu implementaciju funkcije za računanje srednje kvadratne greške (MSE) [32].

```
import cv2
import numpy as np

def izracunaj_mse(originalna, obradjena):
    # Pretvaranje slike u float64 radi preciznog računanja greške
    greska = np.mean((originalna.astype("float64") -
    obradjena.astype("float64")) ** 2)
    return greska

def main():
    # Učitavanje originalne i obrađene slike
    originalna = cv2.imread("original_image.png")
    obradjena = cv2.imread("processed_image.png")

    # Pretvaranje u grayscale (opciono, zavisi od evaluacije)
    originalna_gray = cv2.cvtColor(originalna, cv2.COLOR_BGR2GRAY)
    obradjena_gray = cv2.cvtColor(obradjena, cv2.COLOR_BGR2GRAY)

    # Računanje srednje kvadratne greške
    mse_vrijednost = izracunaj_mse(originalna_gray, obradjena_gray)

    # Prikaz rezultata
    print(f"Srednja kvadratna greška (MSE) iznosi: {mse_vrijednost:.2f}")

if __name__ == "__main__":
    main()
```

Prikaz 1. Osnovni Python kod za računanje MSE-a.

4.3.2 PSNR (Peak Signal-to-Noise Ratio)

U oblasti obrade slike, naročito pri evaluaciji kvaliteta rekonstrukcije slike ili njenoj kompresiji, vršni odnos signal-šum (PSNR – Peak Signal-to-Noise Ratio) predstavlja jednu od najčešće korišćenih metrika za kvantitativno poređenje između originalne (referentne) i rekonstruisane slike. PSNR se koristi za ocjenu koliko je rekonstruisana slika (npr. posle filtriranja šuma, kompresije ili upotrebe neuralne mreže) vizuelno slična originalu.

PSNR se izračunava na osnovu srednje kvadratne greške (MSE) između dvije slike iste dimenzije, prema sljedećoj formuli:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX^2}{MSE} \right)$$

Gdje su:

PSNR – vršni odnos signal-šum (izražava se u decibelima – dB)

MAX – maksimalna moguća vrijednost piksela (za 8-bitne slike je to 255)

MSE – srednja kvadratna greška između originalne i rekonstruisane slike

PSNR daje vrijednost u decibelima (dB), gdje veća vrijednost ukazuje na bolji kvalitet rekonstrukcije slike, odnosno manju razliku između originala i procesirane verzije.

Interpretacija:

- Visok PSNR (npr. > 30 dB): visok kvalitet slike, razlike između slika su skoro neprimjetne.
- Srednji PSNR (20–30 dB): umjerene razlike, vidljive artefakte moguće.
- Nizak PSNR (< 20 dB): loš kvalitet rekonstrukcije, razlike su lako uočljive [33].

Primjer:

Uzima se $MSE = 0.63$ iz prošlog primjera između originalne slike i slike koju je generisala neuralne mreža nakon filtriranja šuma. Pošto radimo sa 8-bitnim slikama ($MAX = 255$), računamo po formuli i dobijamo da je PSNR jednak:

$$PSNR \sim 50.14 \text{ dB}$$

Ova vrijednost sugerise odličan kvalitet slike nakon rekonstrukcije.

U prikazu 2 je dat osnovni Python kod za izračunavanje vrijednosti PSNR-a između dvije slike [34].

```
from math import log10, sqrt
import cv2
import numpy as np

def PSNR(originalna, kompresovana):
    # Izračunavanje srednje kvadratne greške (MSE)
    mse = np.mean((originalna - kompresovana) ** 2)

    if mse == 0:
        # Ako je MSE jednak nuli, to znači da između slika nema razlike,
        # pa PSNR gubi smisao - vraća se visoka fiksna vrijednost
        return 100

    maksimalna_vrijednost_piksela = 255.0
    psnr = 20 * log10(maksimalna_vrijednost_piksela / sqrt(mse))
    return psnr

def main():
    # Učitavanje originalne i kompresovane slike
    originalna = cv2.imread("original_image.png")
    kompresovana = cv2.imread("compressed_image.png", 1)

    # Računanje PSNR vrijednosti
    vrijednost = PSNR(originalna, kompresovana)

    # Prikaz rezultata
    print(f"Vrijednost PSNR-a je {vrijednost} dB")

if __name__ == "__main__":
    main()
```

Prikaz 2. Osnovni Python kod za računanje PSNR-a.

4.3.3 SSIM (Structural Similarity Index Measure)

Strukturalni indeks sličnosti (SSIM) je metrika razvijena sa ciljem da prevaziđe ograničenja tradicionalnih mjera poput MSE i PSNR, koje ne uzimaju u obzir karakteristike ljudske percepcije. SSIM ocjenjuje sličnost između dvije slike poredeći njihove strukturalne informacije, uzimajući u obzir osvijetljenost (eng. *luminance*), kontrast, i strukturu.

Za razliku od MSE-a i PSNR-a koji mjere apsolutne pikselne razlike, SSIM pokušava da kvantifikuje vizuelnu sličnost, pa je zato znatno pogodniji za evaluaciju kvaliteta rekonstruktovanih slika, naročito u oblastima poput denoisinga, kompresije i super-rezolucije [35].

SSIM između dvije slike x i y definisan je kao:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Gdje su:

μ_x, μ_y – srednja vrijednosti slika x i y

σ_x^2, σ_y^2 – varijanse slika x i y

σ_{xy} - kovarijansa između x i y

C_1, C_2 - konstante za stabilizaciju izraza (zavisno od dinamičkog opsega slike)

Primjer

Pretpostavimo da imamo dvije grayscale slike dimenzija 3×3 piksela. Njihove vrijednosti piksela su prikazane na tabeli 1 i tabeli 2:

Tabela 2. Pikselne vrijednosti originalne slike dimenzija 3×3 za potrebe računanja SSIM metrike

Originalna slika		
52	55	61
53	59	66
58	62	69

Tabela 3. Pikselske vrijednosti obrađene slike dimenzija 3×3 korišćene u proračunu SSIM-a

Obrađena slika		
50	53	60
52	58	65
57	60	66

Računamo po formuli gdje je srednja vrijednost originalne slike 59.44, a obrađene 58. Varijanse su 29.14 i 28 a kovarijansa 28.33. Stabilizatorske konstantne su 6.5025 i 5.,5225.

i dobijamo da je SSIM jednak:

$$SSIM(x, y) = \frac{(2 * 59.44 + 58 + 6.5025)(2 * 28.33 + 58.5225)}{(3 * 533.1136 + 3 * 364 + 5.5025)(849.13 + 784 + 58.5225)} \sim 0.9931$$

Ova vrijednost sugerise odličan kvalitet slike nakon rekonstrukcije.

U prikazu 3 je dat osnovni Python kod za izračunavanje vrijednosti SSIM-a između dvije slike [36].

```
import cv2
from skimage.metrics import structural_similarity as ssim

def izracunaj_ssim(slika1, slika2):
    # Pretvaranje slika u grayscale (sivi nivo)
    siva1 = cv2.cvtColor(slika1, cv2.COLOR_BGR2GRAY)
    siva2 = cv2.cvtColor(slika2, cv2.COLOR_BGR2GRAY)

    # Računanje SSIM vrijednosti između dvije slike
    vrijednost_ssim, _ = ssim(siva1, siva2, full=True)
    return vrijednost_ssim

def main():
    # Učitavanje originalne i obrađene slike
    originalna = cv2.imread("original_image.png")
    obrada = cv2.imread("processed_image.png")

    # Poziv funkcije za računanje SSIM-a
    rezultat = izracunaj_ssim(originalna, obrada)

    # Prikaz rezultata na standardnom izlazu
    print(f"Vrijednost SSIM-a je: {rezultat:.4f}")

if name == " main ":
```

Prikaz 3. Osnovni Python kod za računanje SSIM-a

5. EKSPERIMENTALNI REZULTATI

U okviru poglavlja prikazani su primjeri filtriranja šuma (denoising) sa medicinskih slika korišćenjem klasičnih metoda filtriranja i konvolutivne neuralne mreže. Eksperimenti su sprovedeni nad dva skupa medicinskih podataka: LC25000 i Lungs Disease Dataset, od kojih je za svaki odabrano po 500 slika kako bi se obezbijedio uravnotežen i reprezentativan uzorak za analizu.

U radu je korišćen podskup slika koji se odnosi na histopatološke podatke. Skup LC25000 sadrži slike histopatoloških preparata plućnog tkiva, raspodijeljene u tri klase (normalno tkivo, adenokarcinom i skvamoznocelularni karcinom). Skup Lungs Disease Dataset predstavlja kolekciju medicinskih slika pluća, koje obuhvataju različite patološke kategorije. Slike su dobijene pomoću više modaliteta snimanja, uključujući CT i rendgenske snimke, i organizovane su u četiri klase bolesti.

Radi procjene robusnosti i efikasnosti metoda, slike su degradirane sa tri različite vrste sintetički generisanog šuma:

- Gausov šum (aditivni bijeli šum, normalna distribucija),
- Salt-and-Pepper šum (impulsni šum, nasumične crne i bijele tačke), i
- Speckle šum (multiplikativni šum karakterističan za ultrazvučne i MRI snimke).

Nakon dodavanja šuma, uklanjanje istog je izvršeno korišćenjem tri tradicionalna filtera za obradu slike:

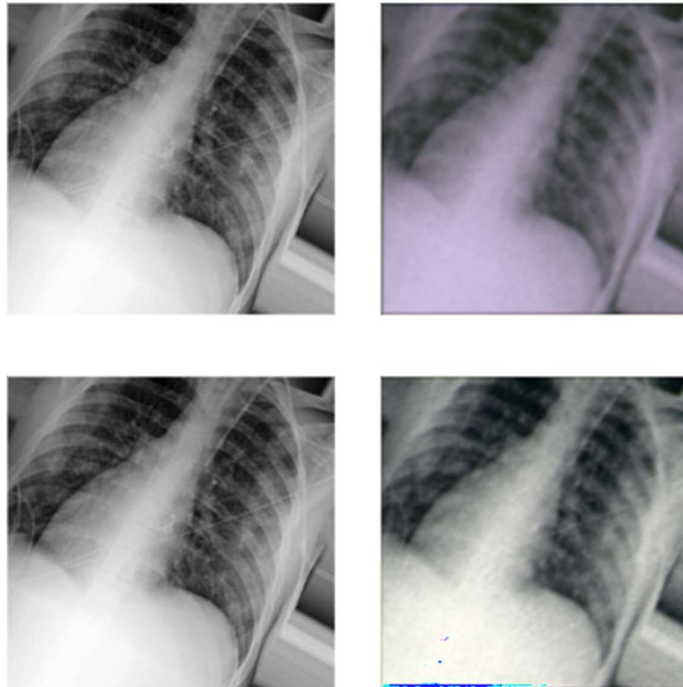
- Gausov filter,
- Medijanski filter, i
- Vinerov filter.

Pored pomenutih filtera, korišćena je i konvolutivna neuralna mreža, trenirana da uči proces filtriranja šuma na osnovu parova slika sa šumom i njihovih odgovarajućih originala. CNN je posebno trenirana za svaki dataset i za svaku vrstu šuma, pri čemu su rezultati verifikovani nakon 15 i 50 epoha kako bi se uočila razlika u kvalitetu rekonstruisanih slika.

U kontekstu treniranja neuralnih mreža, epoha predstavlja jednu potpunu iteraciju kroz sve podatke za obuku. Veći broj epoha omogućava modelu da bolje nauči obrasce u podacima, ali takođe povećava rizik od preprilagođavanja (*overfitting*), ukoliko se ne primijeni pravilan nadzor

tokom treniranja. U ovom radu, različit broj epoha je korišćen da bi se demonstrirao efekat trajanja obuke na kvalitet denoising rezultata.

Na slici 13 prikazano je uklanjanje šuma uz pomoć CNN mreže trenirane sa 15 i 50 epoha, kako bi se ilustrovalo uticaj broja epoha na kvalitet dobijenih rezultata.



Slika 14. Uklanjanje šuma uz pomoć CNN mreže trenirane sa 15 i 50 epoha (gornji red: originalna slika, uklanjanje šuma sa 15 epoha, donji red: originalna slika, uklanjanje šuma sa 50 epoha)

Evaluacija kvaliteta filtriranja vršena je upotrebom tri najčešće korišćene metrike za poređenje kvaliteta slike:

- MSE (Mean Squared Error)
- PSNR (Peak Signal-to-Noise Ratio)
- SSIM (Structural Similarity Index Measure)

Prikazani rezultati obuhvataju kvantitativnu analizu u vidu tabela sa metrikama, kao i kvalitativnu analizu kroz vizuelne primjere slika: originalna slika, degradirana slika (sa šumom), i slika nakon primjene metoda za uklanjanje šuma.

5.1 Rezultati na skupu podataka LC25000

5.1.1 Gausov šum


Prikazani su rezultati Gausovog šuma sa slikama izabranih iz skupa podataka. Upoređivane su tri klasične metode filtriranja, Gausov filter, medijanski filter i Vinerov filter, kao i pristupi zasnovani na CNN-u treniranom tokom 15 i 50 epoha. Procjena je izvršena korišćenjem standardnih metrika: MSE (*Mean Squared Error*, srednja kvadratna greška), PSNR (*Peak Signal-to-Noise Ratio*, vršni odnos signal–šum) i SSIM (*Structural Similarity Index Measure*, strukturni indeks sličnosti).

Rezultati prikazani u tabeli 4 pokazuju da najbolje performanse u uklanjanju šuma ostvaruje CNN treniran u 50 epoha, sa najnižom vrijednošću MSE (39.28), najvišim PSNR-om (59.44dB) i najpouzdanijom strukturnom sličnosti (SSIM = 0. 0.8187). Tradicionalne metode, iako jednostavne za implementaciju, pokazale su ograničenu efikasnost, naročito Vinerov filter, koji bilježi najlošiji SSIM, što ukazuje na značajan gubitak strukturalne informacije. CNN treniran kroz 15 epoha pokazuje nešto viši SSIM od svih tradicionalnih metoda, ali sa većim MSE i nižim PSNR-om, što ukazuje na kompromis između očuvanja strukture i ukupne greške u rekonstrukciji.


Na slikama 14. i 15. može se uočiti vizuelna razlika između slika filtriranih različitim metodama, ali treba naglasiti da ovaj primjer ne mora nužno odražavati rezultate na svim slikama u skupu, kod određenih slika pojedine metode mogu pokazati bolje ili lošije performanse u zavisnosti od kompleksnosti sadržaja i intenziteta šuma. Prikaz služi kao reprezentativna ilustracija ponašanja metoda u tipičnoj situaciji, ali se konačni zaključci izvode na osnovu prosječnih vrijednosti dobijenih za čitav skup podataka.

Tabela 4. Metrike uspješnosti različitih metoda filtriranja Gausovog šuma

Metoda	MSE	PSNR	SSIM
Gausov filter	23.21	56.76 dB	0.7713
Medijanski filter	31.25	57.84 dB	0.8871
Vinerov filter	26.71	47.13 dB	0.6984
CNN (15 epoha)	89.17	35.87 dB	0.7895
CNN (50 epoha)	39.28	59.44 dB	0.8187



Slika 15. Vizuelno poređenje efekata filtriranja Gausovog šuma tradicionalnim metodama



Slika 16. Vizuelno poređenje efekata filtriranja Gausovog šuma primjenom CNN modela

5.1.2 Salt-and-Pepper šum

Prikazani su rezultati filtriranja Salt-and-Pepper šuma sa slika izabranih iz skupa podataka. Upoređivane su tri klasične metode filtriranja, Gausov filter, medijanski filter i Vinerov filter, kao i pristupi zasnovani na konvolutivnoj neuralnih mreži (CNN) treniranoj tokom 15 i 50 epoha. Procjena efikasnosti izvršena je korišćenjem standardnih metrika: MSE (srednja kvadratna greška), PSNR (vršni signal-šum odnos) i SSIM (strukturni indeks sličnosti).


Rezultati prikazani u tabeli 5 pokazuju da CNN treniran u 50 epoha ponovo ostvaruje najbolje performanse, sa najnižim MSE-om (32.11), visokim PSNR-om (67.12dB) i izuzetno visokim SSIM-om (0.9131), što ukazuje na uspješnu rekonstrukciju originalnih struktura slike. Medijanski filter, kao klasična metoda često korišćena za ovaj tip šuma, takođe pokazuje visoke vrijednosti SSIM-a i PSNR-a, i u ovom slučaju nadmašuje čak i CNN po tim parametrima, iako ima nešto viši MSE. Vinerov filter i Gausov filter pokazuju lošije rezultate, naročito u pogledu očuvanja strukture, što ukazuje da nisu optimalni za eliminaciju Salt-and-Pepper šuma.

CNN treniran kroz 15 epoha daje bolje rezultate od nekih tradicionalnih metoda, ali uz znatno lošije metrike od iste mreže trenirane 50 epoha, što potvrđuje značaj dovoljne dužine procesa obučavanja.


Na slikama 16 i 17 može se uočiti vizuelna razlika između slika filtriranih različitih metoda.

Tabela 5. Metrike uspješnosti različitih metoda filtriranja Salt-and-Pepper šuma

Metoda	MSE	PSNR	SSIM
Gausov filter	33.13	56.12 dB	0.5434
Medijanski filter	27.89	55.53 dB	0.9888
Vinerov filter	39.99	49.11 dB	0.5123
CNN (15 epoha)	79.12	27.12 dB	0.8198
CNN (50 epoha)	32.11	67.12 dB	0.9131



Slika 17. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma tradicionalnim metodama



Slika 18. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma primjenom CNN modela

5.1.3 Speckle šum

Prikazani su rezultati filtriranja Speckle šuma sa slika izabranih iz skupa podataka. Upoređivane su tri klasične metode filtriranja, Gausov filter, medijanski filter i Vinerov filter, kao i dvije varijante konvolutivne neuralne mreže (CNN) trenirane tokom 15 i 50 epoha. Evaluacija efikasnosti metoda izvršena je korišćenjem metrika MSE, PSNR i SSIM, koje zajedno pružaju uvid u kvantitativnu preciznost i očuvanje strukture na obnovljenim slikama.


Rezultati prikazani u tabeli 6 ukazuju da, iako sve metode bilježe značajne poteškoće u uklanjanju ovog tipa šuma, CNN treniran u 50 epoha postiže najbolje performanse, sa najnižom vrijednošću MSE, najvišim PSNR-om i najpouzdanijim SSIM-om. Klasični filteri pokazali su ograničene mogućnosti za rekonstrukciju slike – naročito Vinerov filter, čiji SSIM iznosi svega 0.0480, što ukazuje na gotovo potpuni gubitak strukturne sličnosti u odnosu na original. Medijanski filter i Gausov filter takođe pokazuju nisku efikasnost, sa SSIM vrijednostima ispod 0.12, a veoma slični rezultati MSE i PSNR potvrđuju da su ograničeni u radu sa multiplikativnim šumom kakav je Speckle.

CNN treniran 15 epoha pokazuje nešto slabije performanse u poređenju sa verzijom treniranom u 50 epoha, ali i dalje značajno nadmašuje sve tradicionalne pristupe, što ukazuje na otpornost neuralne mreže čak i u slučajevima složenijeg šuma.


Na slikama 18 i 19 može se uočiti vizuelna razlika između slika filtriranih različitim metoda.

Tabela 6. Metrike uspješnosti različitih metoda filtriranja Speckle šuma

Metoda	MSE	PSNR	SSIM
Gausov filter	57.76	45.53 dB	0.6654
Medijanski filter	68.65	49.71 dB	0.3467
Vinerov filter	69.35	38.72 dB	0.6245
CNN (15 epoha)	76.43	23.23 dB	0.7434
CNN (50 epoha)	34.98	56.45 dB	0.8186



Slika 19. Vizuelno poređenje efekata filtriranja Speckle šuma tradicionalnim metodama



Slika 20. Vizuelno poređenje efekata filtriranja Speckle šuma primjenom CNN modela

5.2 Rezultati na skupu podataka Lungs Disease Dataset

5.2.1 Gausov šum

Prikazani su rezultati filtriranja Gausovog šuma sa slika kod skupa podataka LDD, koji sadrži rendgenske snimke pluća. Korišćene su tri standardne metode filtriranja – Gaussov filter, medijanski filter i Vinerov filter, kao i CNN modeli trenirani tokom 15 i 50 epoha. Kvalitet rekonstrukcije ocijenjen je uz pomoć metrika MSE, PSNR i SSIM.


Kao što je prikazano u Tabeli 7, najbolje rezultate postiže CNN treniran 50 epoha, sa najnižim MSE (27.92), najvišim PSNR-om (52.44dB) i najvišim SSIM-om (0.9476). Ovi rezultati ukazuju na visok stepen očuvanja strukturnih informacija i uspješno uklanjanje šuma, bez značajnog gubitka važnih detalja u plućnim strukturama. CNN treniran 15 epoha pokazuje korektne rezultate, ali sa primjetno lošijim metrikama, naročito u pogledu MSE (98.12), što potvrđuje važnost dužeg trajanja procesa treniranja.

Od tradicionalnih pristupa, Gaussov filter se pokazao kao najefikasniji, sa SSIM-om od 0.6821, dok su medijanski i Vinerov filter ostvarili slabije rezultate, pri čemu je Vinerov filter imao najniži PSNR (34.72) i SSIM (0.5182), ukazujući na značajne deformacije u rekonstruisanoj slici.

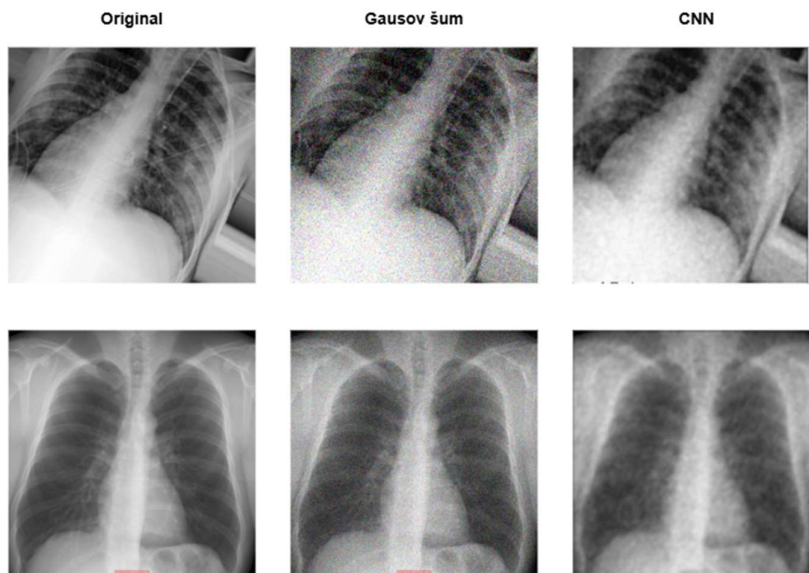
Na slikama 20 i 21 prikazani su rezultati razlika između slika filtriranih različitim metodama.

Tabela 7. Metrike uspješnosti različitih metoda filtriranja Gausovog šuma

Metoda	MSE	PSNR	SSIM
Gausov filter	39.31	47.92 dB	0.6821
Medijanski filter	42.05	45.63 dB	0.6394
Vinerov filter	48.66	34.72 dB	0.5182
CNN (15 epoha)	76.94	42.81 dB	0.8547
CNN (50 epoha)	27.92	52.44 dB	0.9476



Slika 21. Vizuelno poređenje efekata filtriranja Gausovog šuma tradicionalnim metodama



Slika 22. Vizuelno poređenje efekata filtriranja Gausovog šuma primjenom CNN modela

5.2.2 Salt-and-Pepper šum

Prikazani su rezultati filtriranja Salt-and-Pepper šuma sa slika iz skupa podataka. Evaluirane su tri klasične metode filtriranja – Gaussov filter, medijanski filter i Vinerov filter, kao i dva modela CNN-a trenirana kroz 15 i 50 epoha. Korišćene su standardne metrike MSE, PSNR i SSIM, koje omogućavaju kvantitativnu ocjenu efikasnosti svakog pristupa.


Prema rezultatima prikazanim u Tabeli 8, najbolji rezultat u pogledu očuvanja strukturnih informacija postiže medijanski filter, sa veoma niskim MSE-om (28.14), visokim PSNR-om (54.67) i SSIM-om od 0.9821, što potvrđuje poznatu efikasnost ove metode kod impulsnog šuma. CNN treniran 50 epoha takođe pokazuje dobre rezultate, posebno u pogledu strukturne sličnosti (SSIM = 0.8617), ali uz nešto viši MSE (33.24) i niži PSNR u odnosu na medijanski filter.

Nasuprot tome, Vinerov filter i Gaussov filter pokazuju lošije performanse, naročito u SSIM vrijednostima, što ukazuje na izražen gubitak detalja i strukture. CNN sa 15 epoha nalazi se između tradicionalnih i optimalno istreniranog modela, sa solidnim SSIM-om, ali značajno slabijim ostalim parametrima.


Na slikama 22 i 23 su prikazane vizuelne razlike između slika filtriranih različitih metoda.

Tabela 8. Metrike uspješnosti različitih metoda filtriranja Salt-and-Pepper šuma

Metoda	MSE	PSNR	SSIM
Gausov filter	48.17	41.42 dB	0.4123
Medijanski filter	28.14	54.67 dB	0.9821
Vinerov filter	58.39	31.99 dB	0.3158
CNN (15 epoha)	80.47	36.64 dB	0.7934
CNN (50 epoha)	33.24	42.88 dB	0.9011



Slika 23. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma tradicionalnim metodama



Slika 24. Vizuelno poređenje efekata filtriranja Salt-and-Pepper šuma primjenom CNN modela

5.2.3 Speckle šum

Prikazani su rezultati filtriranja Speckle šuma sa rendgenskih snimaka iz posmatranog skupa podataka. Upoređene su klasične metode filtriranja — Gaussov, medijanski i Vinerov filter — sa dvije varijante CNN modela treniranih tokom 15 i 50 epoha. Za kvantitativnu procjenu efikasnosti svake metode u redukciji šuma i očuvanju strukturnih karakteristika korišćene su standardne metrike: MSE, PSNR i SSIM.


Prema rezultatima prikazanim u Tabeli 9, najbolje performanse postiže CNN treniran 50 epoha, sa najnižim MSE-om (22.83), najvišim PSNR-om (45.63) i SSIM-om (0.8912), što ukazuje na njegovu sposobnost da efikasno ukloni multiplikativni šum uz očuvanje detalja. CNN sa 15 epoha postiže nešto lošije rezultate, naročito u pogledu MSE, ali i dalje značajno nadmašuje klasične metode u strukturnoj sličnosti.

Tradicionalne metode filtriranja pokazuju ograničenu efikasnost u uklanjanju ovog tipa šuma. Najniži SSIM ostvario je Vinerov filter, dok su medijanski i Gaussov filter također zabilježili niske vrijednosti SSIM-a, uz visoke MSE i niske PSNR rezultate, što ukazuje na slab kvalitet rekonstrukcije i gubitak važnih vizuelnih informacija.

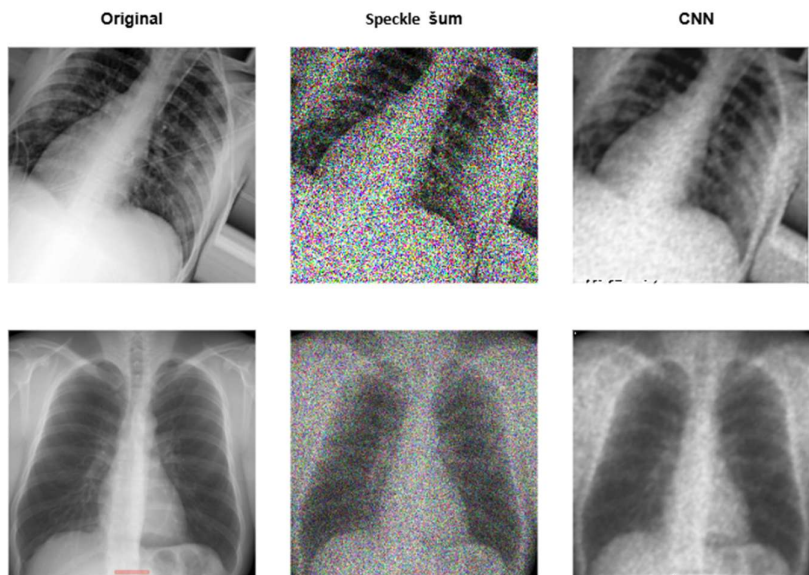
Na slikama 24 i 25 prikazani su rezultati primjene različitih metoda filtriranja, pri čemu su vidljive vizuelne razlike između dobijenih slika.

Tabela 9. Metrike uspješnosti različitih metoda filtriranja Speckle šuma

Metoda	MSE	PSNR	SSIM
Gaussov filter	49.72	38.54 dB	0.7124
Medijanski filter	52.13	36.88 dB	0.7792
Vinerov filter	55.47	34.92 dB	0.8455
CNN (15 epoha)	60.28	55.77 dB	0.8831
CNN (50 epoha)	22.83	45.63 dB	0.8912



Slika 25. Vizuelno poređenje efekata filtriranja Speckle šuma tradicionalnim metodama



Slika 26. Vizuelno poređenje efekata filtriranja Speckle šuma primjenom CNN modela

ZAKLJUČAK

Kvalitet biomedicinskih slika predstavlja ključni preduslov za pouzdanu i preciznu dijagnostiku. Međutim, prisustvo šuma može značajno umanjiti njihovu dijagnostičku vrijednost, negativno utičući kako na vizuelnu interpretaciju od strane stručnjaka, tako i na efikasnost automatizovanih metoda obrade i analize slika. S obzirom na važnost očuvanja strukturnih informacija kod medicinskih slika, u radu je analizirana efikasnost tradicionalnih metoda filtriranja i konvolucionih neurlanim mreža čiji je cilj bio da se ispita efikasnost tradicionalnih metoda filtriranja i konvolucionih neuronskih mreža (CNN) u zadatku filtriranja šuma i poboljšanja kvaliteta slike.

U okviru istraživanja primijenjene su tri klasične metode filtriranja – Gaussov, medijanski i Vinerov filter – kao i CNN modeli koji su trenirani u dvije varijante, kroz 15 i 50 epoha. Analiza je sprovedena nad dva skupa podataka: LC25000, koji sadrži histopatološke slike plućnog tkiva, i Lungs Disease Dataset, koji obuhvata rendgenske, CT, ultrazvučne i histopatološke snimke pluća svrstane u četiri klase bolesti. Na izabranim slikama su dodati različiti tipovi šuma: Gaussov šum, Salt-and-Pepper šum i Speckle šum, kako bi se ispitala otpornost metoda u različitim scenarijima degradacije.

Procjena efikasnosti izvršena je korišćenjem standardnih metrika: MSE (srednja kvadratna greška), PSNR (vršni odnos signal-šum) i SSIM (strukturni indeks sličnosti). Na osnovu dobijenih rezultata ustanovljeno je da klasične metode, iako tehnički jednostavne i brze za implementaciju, pokazuju ograničene performanse, posebno kod kompleksnijih oblika šuma. Medijanski filter se pokazao efikasnim u uklanjanju impulsnog šuma, dok je Vinerov filter ostvario najslabije rezultate u svim scenarijima, naročito u pogledu očuvanja strukture slike.

Uočeno je da CNN modeli, posebno oni trenirani tokom 50 epoha, postižu značajno bolje rezultate u svim metrikama. Zabilježene su niže vrijednosti MSE-a, više vrijednosti PSNR-a i veći SSIM, što ukazuje na sposobnost očuvanja dijagnostički važnih informacija uz efikasno uklanjanje šuma. CNN treniran kroz 15 epoha takođe je nadmašio većinu tradicionalnih metoda, ali su primijećene razlike u performansama koje ukazuju na značaj trajanja procesa treniranja.

Time je potvrđeno da konvolucione neuralne mreže imaju visoku sposobnost učenja složenih obrazaca šuma i razlikovanja istih od stvarne strukture tkiva na slici. U radu je prikazano da CNN ne samo da efikasno uklanja šumove različite prirode, već i da pri tome uspješno čuva klinički

relevantne detalje. Dodatno, pokazano je da CNN modeli mogu biti prilagođeni za rad sa slikama različitih modaliteta, što ukazuje na njihovu široku primjenjivost.

Uloga CNN arhitektura prepoznata je ne samo u zadacima filtriranja šuma, već i u brojnim drugim aspektima medicinske obrade slike, kao što su segmentacija, klasifikacija i automatsko prepoznavanje anomalija. Stoga se može zaključiti da predstavljaju sveobuhvatno rješenje koje ima potencijal da unaprijedi efikasnost i preciznost digitalne dijagnostike. Njihova implementacija u realne kliničke sisteme već je otpočela, a rezultati ovog istraživanja mogu poslužiti kao dodatna potvrda njihove vrijednosti u praksi.

Apendix (dodatak)

Dodatak A – Gausov filter

```
import numpy as np
import matplotlib.pyplot as plt
from skimage import data, img_as_float
from skimage.transform import resize
from skimage.util import random_noise
from scipy.ndimage import gaussian_filter

# Učitavanje slike i priprema
image = img_as_float(data.moon()) #data.camera()
image = resize(image, (256, 256), anti_aliasing=True)

# Dodavanje Gausovog šuma
noisy_image = random_noise(image, mode='gaussian', var=0.01)

# Primjena Gausovog filtera
filtered_image = gaussian_filter(noisy_image, sigma=1)

# Prikaz rezultata
fig, axes = plt.subplots(1, 3, figsize=(15, 5))
axes[0].imshow(image, cmap='gray')
axes[0].set_title('Originalna slika')
axes[0].axis('off')

axes[1].imshow(noisy_image, cmap='gray')
axes[1].set_title('Gausov šum')
axes[1].axis('off')

axes[2].imshow(filtered_image, cmap='gray')
axes[2].set_title('Nakon Gausovog filtriranja')
axes[2].axis('off')

plt.tight_layout()
plt.show()
```

Dodatak B – Medijan filter

```
import numpy as np
import matplotlib.pyplot as plt
from skimage import data, img_as_float
from skimage.transform import resize
from skimage.util import random_noise
from scipy.ndimage import gaussian_filter

# Učitavanje slike i priprema
image = img_as_float(data.moon()) #data.camera()
image = resize(image, (256, 256), anti_aliasing=True)

# Dodavanje Gausovog šuma
noisy_image = random_noise(image, mode='gaussian', var=0.01)

# Primjena Gausovog filtera
filtered_image = gaussian_filter(noisy_image, sigma=1)

# Prikaz rezultata
fig, axes = plt.subplots(1, 3, figsize=(15, 5))
axes[0].imshow(image, cmap='gray')
axes[0].set_title('Originalna slika')
axes[0].axis('off')

axes[1].imshow(noisy_image, cmap='gray')
axes[1].set_title('Gausov šum')
axes[1].axis('off')

axes[2].imshow(filtered_image, cmap='gray')
axes[2].set_title('Nakon Gausovog filtriranja')
axes[2].axis('off')

plt.tight_layout()
plt.show()
```

Dodatak C – Vinerov filter

```
import numpy as np
import matplotlib.pyplot as plt
from skimage import data, img_as_float
from skimage.transform import resize
from skimage.util import random_noise
from scipy.signal import wiener

# Učitavanje i priprema slike (moon)
image = img_as_float(data.moon()) #data.camera()
image = resize(image, (256, 256), anti_aliasing=True)

# Dodavanje Gausovog šuma
noisy_image = random_noise(image, mode='gaussian', var=0.01)

# Primjena Vinerovog filtera
filtered_image = wiener(noisy_image, mysize=(5, 5))

# Prikaz rezultata
fig, axes = plt.subplots(1, 3, figsize=(15, 5))
axes[0].imshow(image, cmap='gray')
axes[0].set_title("Originalna slika")
axes[0].axis('off')

axes[1].imshow(noisy_image, cmap='gray')
axes[1].set_title("Gausov šum")
axes[1].axis('off')

axes[2].imshow(filtered_image, cmap='gray')
axes[2].set_title("Vinerov filter")
axes[2].axis('off')

plt.tight_layout()
plt.show()
```

Dodatak D – CNN

```
import torch
import torch.nn as nn
import torch.optim as optim
import torchvision.transforms as transforms
from PIL import Image
import numpy as np
import matplotlib.pyplot as plt

# --- CNN model ---
class DenoisingCNN(nn.Module):
    def __init__(self):
        super(DenoisingCNN, self).__init__()
        self.encoder = nn.Sequential(
            nn.Conv2d(1, 64, 3, padding=1), nn.ReLU(),
            nn.Conv2d(64, 64, 3, padding=1), nn.ReLU()
        )
        self.decoder = nn.Sequential(
            nn.Conv2d(64, 64, 3, padding=1), nn.ReLU(),
            nn.Conv2d(64, 1, 3, padding=1)
        )

    def forward(self, x):
        x = self.encoder(x)
        x = self.decoder(x)
        return x

# --- Učitavanje slike ---
def load_image(image_path):
    img = Image.open(image_path).convert('L')
    img = img.resize((256, 256))
    img_np = np.array(img).astype(np.float32) / 255.0
    return img_np

# --- Dodavanje Gaussovog šuma ---
def add_gaussian_noise(img, sigma=25):
    noise = np.random.normal(0, sigma / 255.0, img.shape)
    noisy = img + noise
    return np.clip(noisy, 0., 1.)

# --- Prikaz slike ---
def show_images(original, noisy, denoised):
    plt.figure(figsize=(12, 4))
    titles = ['Original', 'Noisy', 'Denoised']
    for i, image in enumerate([original, noisy, denoised]):
        plt.subplot(1, 3, i + 1)
        plt.imshow(image, cmap='gray')
        plt.title(titles[i])
        plt.axis('off')
    plt.tight_layout()
    plt.show()
```

```

# --- Glavni dio ---
def main():
    image_path = "primjer_slika/slik1.png" # ← putanja do
    slike
    NUM_EPOCHS = 50                        # ← broj epoha

    clean = load_image(image_path)
    noisy = add_gaussian_noise(clean)

    transform = transforms.ToTensor()
    input_tensor = transform(noisy).unsqueeze(0).float()
    target_tensor = transform(clean).unsqueeze(0).float()

    model = DenoisingCNN()
    criterion = nn.MSELoss()
    optimizer = optim.Adam(model.parameters(), lr=0.001)

    # Treniranje modela
    model.train()
    for epoch in range(NUM_EPOCHS):
        optimizer.zero_grad()
        output = model(input_tensor)
        loss = criterion(output, target_tensor)
        loss.backward()
        optimizer.step()
        if (epoch + 1) % 10 == 0 or epoch == NUM_EPOCHS - 1:
            print(f"Epoch {epoch + 1}/{NUM_EPOCHS} - Loss:
{loss.item():.6f}")

    # Evaluacija i prikaz rezultata
    model.eval()
    with torch.no_grad():
        denoised_tensor =
model(input_tensor).squeeze().cpu().numpy()

    show_images(clean, noisy, denoised_tensor)

if __name__ == "__main__":
    main()

```

Literatura

- [1] Moses Blesing „Integration of 3D Medical Imaging with Deep Learning for Enhanced Segmentation“. Obafemi Awolowo University, 2-15, September 2024.
- [2] Dr. Abhinav Deshmukh. „Artificial Intelligence in Medical Imaging: Applications of Deep Learning for Disease Detection and Diagnosis“ Postgraduate Institute of Medical Education and Research (PGIMER), 1-6, 2024.
- [3] Burak Kocak, Andrea Ponsiglione, Arnaldo Stanzione: „Bias in artificial intelligence for medical imaging: fundamentals, detection, avoidance, mitigation, challenges, ethics, and prospects“, Diagnostic and interventional radiology (Ankara, Turkey), July 2024
- [4] Alex Keilmann: „Improved Anisotropic Gaussian Filters“, Mathematics Department, RPTU Kaiserslautern-Landau), 2023, pp. 50–55
- [5] Choirul Anam, Heri Sutanto: „Noise reduction in CT images with a selective mean filter“ Journal of Biomedical Physics and Engineering, 1-16, 2020.
- [6] Rajesh Patil, Surendra Bhosale, "Medical image denoising techniques: a review", International Journal Of Engineering Science and Technology, January 2022, 21-31
- [7] Lakashmi Naga, Rudraraju Anusha, "INTEGRATING MULTIMODAL MEDICAL IMAGING DATA FOR ENHANCED BONE CANCER DETECTION: A DEEP LEARNING-BASED FEATURE FUSION APPROACH", Journal of Theoretical and Applied Information Technology, September 2024, 6671-6771.
- [8] Thiyagarajan Manoharan, Ramalingam Velvizhi, Thiyagarajan Manoharan, "Biomedical image classification using seagull optimization with deep learning for colon and lung cancer diagnosis", Indonesian Journal of Electrical Engineering and Computer Science , September 2024, 1670-1678

- [9] Haewon Byeon, Haewon Byeon, "Non-sample fuzzy based convolutional neural network model for noise artifact in biomedical image", *DiscoverApplied Sciences*, 2024, 1-16
- [10] Tianyu Ma, Adrian V. Dalca, Mert R. Sabuncu, *Hyper-Convolution Networks for Biomedical Image Segmentation*, United States of America, 2020, 1-10
- [11] P. Suetens, *Fundamentals of Medical Imaging*, Cambridge University Press, Cambridge, 2009, str. 1–15.
- [12] Ultrasound, MRI and CT Scan: What's the Difference?, <https://www.probomedical.com/learn/blog/ultrasound-mri-and-ct-scan-whats-the-difference/> , posljednji put pristupano: 11. april 2025.
- [13] R. C. Gonzalez, R. E. Woods, *Digital Image Processing*, 4th ed., Pearson, London, 2018, str. 22–41.
- [14] S. Aja-Fernández, A. Tristán-Vega, C. Alberola-López, Noise estimation in medical images using local statistics, *Medical Image Analysis*, Vol. 13, No. 4, pp. 650–660, 2009.
- [15] D. Singh, V. Kumar, M. Kaur, H. Kaur, A review of noise types, noise models, and filtering techniques, *International Journal of Advanced Research in Computer Science*, Vol. 11, No. 1, pp. 1–5, 2020.
- [16] N. Bodaisingi, B. Narayanam, Techniques for De-noising of Bio-Medical Images, *International Journal of Biology and Biomedical Engineering*, Vol. 12, 2018, pp. 104–111. Dostupno na: <https://www.naun.org/main/NAUN/bio/2018/a122010-028.pdf> , posljednji put pristupano: 16. april 2025.
- [17] R. A. Haddad, A. N. Akansu, A Class of Fast Gaussian Binomial Filters for Speech and Image Processing, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol. 39, No. 3, pp. 723–727, March 1991.
- [18] A. Rezaee, Partition Fuzzy Median Filtar for Image Restoration, *Fuzzy Information and Engineering*, Vol. 13, No. 2, pp. 199–210, April 2021.

- [19] G. Plett, M. Vetterli, "EE264: Lecture 12 – Wiener Filtering", Stanford University, dostupno kao PDF: <https://web.stanford.edu/class/archive/ee/ee264/ee264.1072/mylecture12.pdf> , posljednji put pristupano: 20. april 2025.
- [20] I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, Cambridge, 2016.
- [21] G. Litjens, T. Kooi, B. E. Bejnordi, A. A. Setio, F. Ciompi, M. Ghafoorian, et al., A survey on deep learning in medical image analysis, Medical Image Analysis, Vol. 42, pp. 60–88, 2017.
- [22] Introducing Convolutional Neural Networks, <https://developers.google.com/machine-learning/practica/image-classification/convolutional-neural-networks> , posljednji put pristupano: 23. april 2025.\
- [23] K. Zhang, W. Zuo, Y. Chen, D. Meng, L. Zhang, Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising, IEEE Transactions on Image Processing, Vol. 26, No. 7, pp. 3142–3155, 2017.
- [24] A. A. Wulandari, S. T. Nugroho, R. E. Putra, "Comparison of Gaussian, Median, and Mean Filter to Remove Noise from MRI Brain Images", IOP Conference Series: Materials Science and Engineering, Vol. 1022, 012020, 2021.
- [25] Lungs Disease Dataset (4 Types), <https://www.kaggle.com/datasets/lungs-disease-dataset>, posljednji put pristupano: 7. maj 2025.
- [26] LC25000 (Lung And Colon Histopathological Image Dataset), <https://paperswithcode.com/dataset/lc25000>, posljednji put pristupano: 7. maj 2025.
- [27] Gaussian Noise, <https://www.geeksforgeeks.org/electronics-engineering/gaussian-noise/>, posljednji put pristupano: 7. maj 2025.
- [28] N. Alajlan, K. Mohamed, E. Jernigan, "Detail preserving impulsive noise removal", Signal Processing: Image Communication, Vol. 19, No. 10, pp. 993–1003, November 2004.
- [29] Speckle Noise, <https://medium.com/speckle-noise> , posljednji put pristupano: 7. maj 2025.

- [30] Mean Square Error (MSE), <https://encord.com/glossary/mean-square-error-mse/> , posljednji put pristupano: 7. maj 2025.
- [31] Mean Squared Error, <https://www.britannica.com/science/mean-squared-error>, posljednji put pristupano: 7. maj 2025.
- [32] Python – Mean Squared Error, <https://www.geeksforgeeks.org/python/python-mean-squared-error/>, posljednji put pristupano: 7. maj 2025.
- [33] Peak Signal-to-Noise Ratio as an Image Quality Metric, National Instruments, <https://www.ni.com//peak-signal-to-noise-ratio-as-an-image-quality-metric.html> , posljednji put pristupano: 7. maj 2025.
- [34] Python, Peak Signal-to-Noise Ratio (PSNR), <https://www.geeksforgeeks.org/python/python-mean-squared-error/>, posljednji put pristupano: 7. maj 2025.
- [35] Z. Wang, E. P. Simoncelli, A. C. Bovik, "Multiscale structural similarity for image quality assessment", Proceedings of the Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, Vol. 2, pp. 1398–1402, 1. novembar 2003.
- [36] D. Yogatama, SSIM on Python, <https://medium.com/@danielyogatama.dy/ssim-on-python-eb1a76a2799b>, posljednji put pristupano: 7. maj 2025.
- [37] A. Draganić, Dj. Stanković, C. Ioana, I. Orović, "Adaptive compressive sensing for reconstruction and denoising with sparsity-measure-driven sampling," 31st IEEE International Conference on Telecommunications, ICT 2025, Budva, Montenegro 28th to 29th April 2025
- [38] A. Bal, M. Banerjee, P. Sharma, et al., "An efficient wavelet and curvelet-based PET image denoising technique," Medical & Biological Engineering & Computing, Vol. 57, 2019, pp. 2567-2598.
- [39] I. Stanković, I. Orović, M. Daković, S. Stanković, "Denoising of Sparse Images in Impulsive Disturbance Environment," Multimedia Tools and Applications, vol. 77, no. 5, pp. 5885–5905, March 2018, DOI: <https://doi.org/10.1007/s11042-017-4502-7>

- [40] I. Orović, N. Lekić, S. Stanković, “An Analogue-Digital Hardware for L-estimate Space-Varying Image Filtering,” *Circuits, Systems and Signal Processing*, Volume 35, Issue 2, pp. 409–420, February 2016
- [41] K. Zhang, W. Zuo, Y. Chen, D. Meng, L. Zhang, “Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising,” *IEEE Transactions on Image Processing*, Vol.26, No.7, Jul.2017, pp.3142-3155.
- [42] LJ. Stanković, S. Stanković, I. Djurović, “Space/spatial-frequency analysis based filtering,” *IEEE Transactions on Signal Processing*, Vol.48, No.8, Aug.2000, pp.2343-2352'

Izjava o istovjetnosti štampane i elektronske verzije master rada

Ime i prezime autora: Aldin Redžematović

Broj indeksa/upisa: 11/22

Studijski program: Primijenjeno računarstvo

Naslov rada: Poboljšanje kvaliteta biomedicinskih slika i otklanjanje šuma primjenom konvolucionih neuralnih mreža

Mentor: Doc.dr Anđela Draganić

Potpisani/a Aldin Redžematović

Izjavljujem

da je štampana verzija mog master rada istovjetna elektronskoj verziji koju sam predao/la za objavljivanje u Digitalni arhiv Univerziteta Crne Gore.

Istovremeno izjavljujem da dozvoljavam objavljivanje mojih ličnih podataka u vezi sa dobijanjem akademskog naziva master nauka, kao što su ime i prezime, godina i mjesto rođenja, naslov master rada i datum odbrane rada.

U Podgorici, 11.12.2025. godine

Potpis magistranda

Aldin Redžematović

IZJAVA O KORIŠĆENJU

Ovlašćujem Univerzitetsku biblioteku da u Digitalnom arhivu Univerziteta Crne Gore pohrani moj master rad pod nazivom:

" POBOLJŠANJE KVALITETA BIOMEDICINSKIH SLIKA I OTKLANJANJE ŠUMA PRIMJENOM KONVOLUCIONIH NEURALNIH MREŽA "

koji je moje autorsko djelo.

Master rad sa svim prilogima predao/la sam u elektronskom formatu pogodnom za trajno arhiviranje.

Moj master rad pohranjen u Digitalnom arhivu Univerziteta Crne Gore mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (*Creative Commons*) za koju sam se odlučio/la.

1. Autorstvo
2. Autorstvo – nekomercijalno
3. Autorstvo – nekomercijalno – bez prerade
4. Autorstvo – nekomercijalno – dijeliti pod istim uslovima
5. Autorstvo – bez prerade
6. Autorstvo – dijeliti pod istim uslovima

(Molimo da zaokružite samo jednu od šest ponuđenih licenci, kratak opis licenci dat je na poledini lista).

U Podgorici, 11.12.2025. godine

Potpis magistranda

Aldin Redžemzović