

Akcelerirana rekonstrukcija slika magnetske rezonancije temeljena na dubokim difuzijskim modelima.

Krčmar, Tea

Master's thesis / Diplomski rad

2024

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:200:679910>

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

Download date / Datum preuzimanja: **2025-03-31**

Repository / Repozitorij:

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



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

Sveučilišni diplomski studij

**AKCELERIRANA REKONSTRUKCIJA
SLIKA MAGNETSKE REZONANCIJE
TEMELJENA NA DUBOKIM
DIFUZIJSKIM MODELIMA**

Diplomski rad

Tea Krčmar

Osijek, 2024.

Sadržaj

1 UVOD	1
2 PREGLED PODRUČJA	3
2.1 Magnetska rezonancija	3
2.1.1 Akvizicija slika	6
2.1.2 MRI sekvence	8
2.2 Suvremene metode rekonstrukcije MRI slika	10
2.2.1 Konvolucijske neuronske mreže	10
2.2.2 U-Net arhitektura	13
2.2.3 Generativna kontradiktorna mreža	15
2.3 Difuzijski modeli	16
2.3.1 Proces difuzije prema naprijed	16
2.3.2 Proces obrnute difuzije	18
2.3.3 Treniranje difuzijskih modela	19
3 PREDLOŽENA METODA	20
3.1 Model za akceleriranu rekonstrukciju	20
3.2 Difuzijski model	21
3.3 Model U-Net mreže	23
3.4 Maske za nedovoljno uzorkovanje k-prostora	24
3.4.1 Kartezijeva maska	25
3.4.2 Spiralna maska	26
3.4.3 Radijalna maska	29
3.4.4 Nasumičan odabir maske	29
4 REZULTATI	31
4.1 Skupovi podataka	31
4.1.1 Skup podataka IXI	32
4.1.2 Skup podataka fastMRI	34
4.2 Objektivna metrika kvalitete slika	37
4.2.1 Omjer vršnog signala i šuma	37
4.2.2 Strukturna sličnost	38

4.3 Kvantitativna analiza	38
4.3.1 Odabrane metode za usporedbu	39
4.3.2 Hiperparametri predloženog modela i treniranje	40
4.3.3 Analiza vremena rekonstrukcije	44
4.4 Kvalitativna analiza	45
5 ZAKLJUČAK	48
LITERATURA	49
SAŽETAK	55
ABSTRACT	56
ŽIVOTOPIS	57

1 UVOD

Magnetska rezonancija (engl. *magnetic resonance imaging*, MRI) medicinska je tehnika snimanja koja koristi snažna magnetska polja i radiovalove kako bi proizvela detaljne slike unutarnjih struktura tijela. Osnovna ideja magnetske rezonancije je mjerjenje signala koje emitiraju protoni u molekulama vode u tijelu, što se može koristiti za izradu slika tkiva i organa tijela. Međutim, kako bi se do bile visokokvalitetne slike gubi se na brzini akvizicije. MRI je ograničen fizičkim (amplitudom gradijenta i brzinom promjene gradijenta) i fiziološkim (stimulacijom živaca) ograničenjima. Zbog toga mnogi istraživači traže metode za smanjenje količine prikupljenih podataka bez degradacije kvalitete slike [1, 2]. U medicinskom slikanju, duboko učenje pokazalo se izuzetno korisnim za rekonstrukciju MRI slika. Duboko učenje napredna je vrsta strojnog učenja koja koristi složene neuronske mreže za izdvajanje značajki iz ogromnih količina podataka [3]. Glavna prednost dubokih metoda u ovom kontekstu je njihova sposobnost da izravno uče iz podataka koji su teški za modelirati tradicionalnim metodama [4, 5]. Ovaj pristup utemeljen na podacima (engl. *data-driven*) posebno je učinkovit za zadatke s visokodimenzionalnim podacima i složenim ovisnostima, kao što je rekonstrukcija MRI slika iz nedovoljno uzorkovanih podataka. Metode dubokog učenja vođene podacima treniraju modele izravno [6] ili neizravno [7, 8], no te metode uve-like ovise o nadzoru dobro kurirane velike baze podataka k -prostora, koju je teško pribaviti. Nedavno su modeli temeljeni na ocjeni [9, 10], modeli probabilističke denoizirajuće difuzije [11, 12] i difuzijski modeli [13, 14, 15] stekli značajan interes jer postižu iznenađujuće visoke rezultate kvalitete uzoraka.

Cilj ovoga rada jest definirati difuzijski model za akceleriranu rekonstrukciju slika magnetske rezonance s posebnom pozornošću na unaprijeđivanje rekonstrukcijskog vremena i održavanja kvalitete slika. Difuzijski model potrebno je usporediti s tradicionalnim i najnovijim istraživanjima u području (engl. *state-of-the-art*) te predložiti potrebne izmjene za unaprijeđenje efikasnosti rekonstrukcije MRI-ova slika i MRI-ova s više zavojnica.

U teorijskom dijelu diplomskog rada objašnjena je magnetska rezonancija i način prikazivanja MRI slika, istražene su konvolucijske mreže i generativne kontradiktorne mreže za rekonstrukciju MRI slika, istraženi su i opisani teorijski koncepti dubokih difuzijskih modела (engl. *deep diffusion models*) te pojašnjena uloga i primjena optimizacijskih metoda.

U trećem poglavlju opisan je i objašnjen predloženi difuzijski model, njegova struktura i način simulacije stvarnog okruženja pri akviziciji MRI slika. U idućem poglavlju opisani su korišteni skupovi podataka, metrika za mjereno kvalitete rekonstrukcije slika, eksperimentalna analiza, i prikazani i objašnjeni ostvareni rezultati te određena preciznost izvođenja razvijenog modela.

2 PREGLED PODRUČJA

U ovom poglavlju detaljno je opisan pregled pozadine i problematike u području te pregled relevantnih radova koji čine temelj ovog diplomskog rada. U uvodnim dijelovima će se pojasniti osnovni principi MRI-a, akvizicija MRI slika i MRI sekvene, nakon čega slijedi rasprava o konceptu konvolucijskih mreža, generativnih kontradiktornih mreža, optimizacijskih metoda koje igraju važnu ulogu u poboljšanju kvalitete i točnosti rekonstrukcije MRI slika i difuzijskim modelima koji su stekli veliku popularnost u zadnjih par godina.

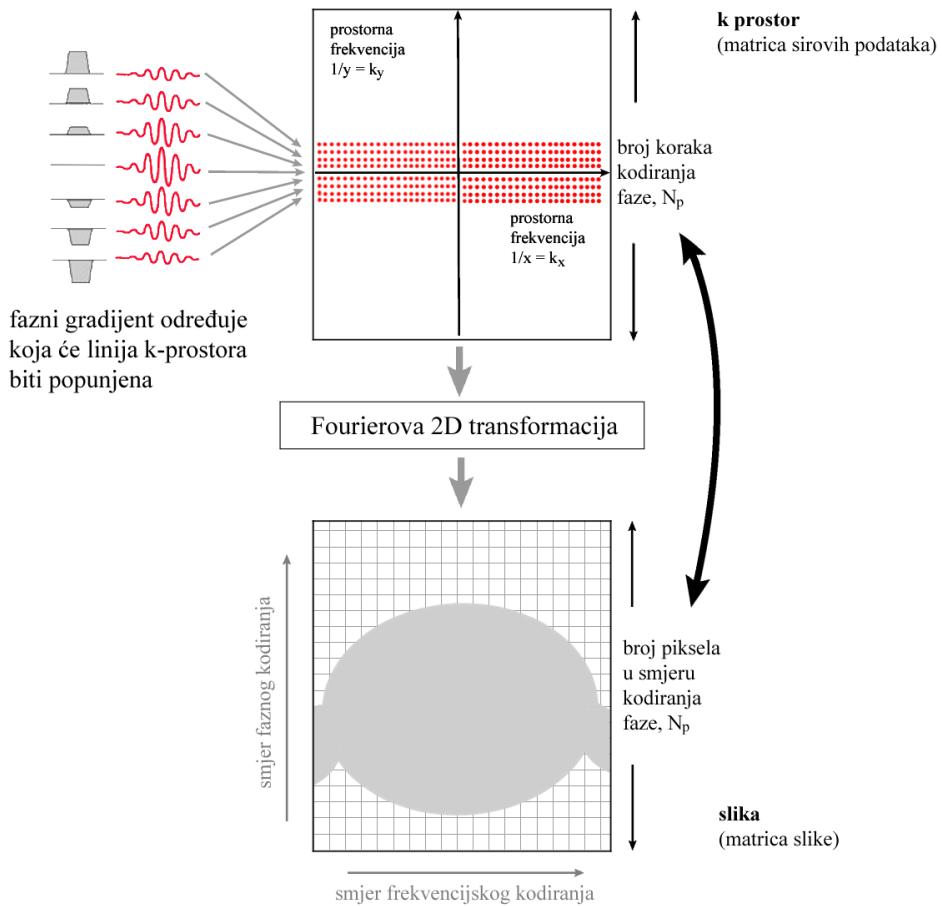
2.1 Magnetska rezonancija

Magnetska rezonancija (MRI) osjetljiva je metoda za praćenje strukturnih i funkcionalnih promjena u tkivima. Takve promjene odražavaju se na slikama putem lokalnih varijacija u hidrataciji tkiva, njegovom fizičkom stanju (npr. slobodno difuzno ili vezano za proteine) te varijacijama u vremenima nuklearne magnetske rezonancije [16]. Koristi pulsirajuće radiofrekvencijske elektromagnetske valove za poticanje i generiranje detektibilnog radiofrekvencijskog signala od vodikovih atoma koji su obilno prisutni u ljudskom tijelu, osobito u vodi i mastima. Promjene u parametrima pulsnog slijeda radiovalova mijenjaju energetsku tranziciju nuklearnog spin-protona i stvaraju magnetske gradijente, što rezultira kontrastom među generiranim slikama. Generirane radiofrekvencijske signale hvata magnetska rezonancijska zavojnica i prenosi ih u računalnu programsku opremu za generiranje slika [17].

Sirovi podaci u MRI-ju predstavljaju poprečne komponente magnetizacije u skeniranom objektu nakon pobuđenja, uzorkovane iz signala prijemne zavojnice i pohranjene kao funkcija vremena tijekom akvizicije MRI ciklusa. U poprečnom presjeku, horizontalna os obično je postavljena kao smjer kodiranja frekvencije, dok je vertikalna os smjer kodiranja faze pobuđenih protona. Ovo je također poznato kao k -prostor podataka. K -prostor je proširenje koncepta Fourierovog prostora i predstavlja prostornu frekvencijsku informaciju u dvije ili tri dimenzije objekta.

Odnos između podataka u k -prostoru i slikovnih podataka je Fourierova transformacija. Matrica akvizicije podataka sadrži sirove podatke prije obrade slika. U dvodimenzionalnoj (2D) Fourierovoj transformaciji slike, linija podataka odgovara digitaliziranom MRI signalu na određenoj razini kodiranja faze. Digitalizacija se provodi pomoću analogno-digitalnih

pretvarača, koji kontinuirane signale pretvaraju u diskrete vrijednosti. Nakon što se signali pretvore u diskrete vrijednosti, organiziraju se u matricu k -prostora, gdje svaka točka u matrici predstavlja jedan diskretni uzorak signala [18]. Na slici 2.1 prikazana je rekonstrukcija slike, k -prostor i prostor slike, gdje su koordinate k -prostora prostorne frekvencije $k_x = \frac{1}{x}$ i $k_y = \frac{1}{y} = k_y$. U Kartezijevom prikupljanju podataka prikazanom na slici 2.1, podaci se pohranjuju red po red duž smjera k_x , pri čemu svaki red odgovara zasebno uzorkovanom MRI signalu. Pozicija duž k_x ovisi o vremenskoj točki tijekom perioda uzorkovanja. Položaj svake linije podataka u smjeru k_y određen je amplitudom i trajanjem smjera kodiranja faze pri svakom koraku kodiranja faze.

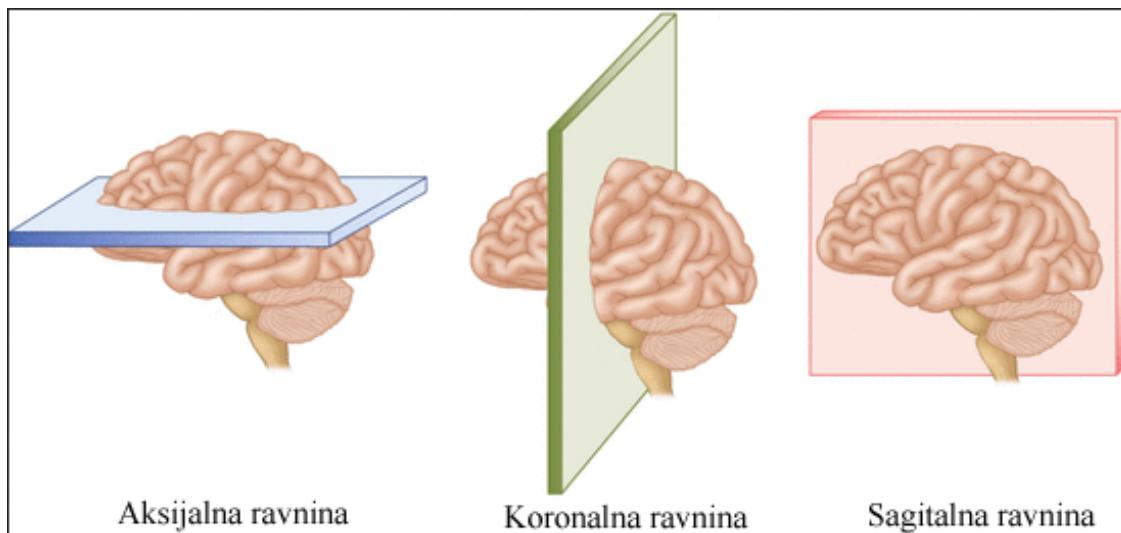


Slika 2.1. Prikaz rekonstrukcije slike, k -prostora i prostora slike [19].

Tijekom magnetske rezonancije slike tijela pacijenta mogu se snimiti u različitim ravninama, ovisno o položaju i orijentaciji magnetskog polja MRI uređaja u odnosu na subjekt. Tri najtipičnije ravnine za dobivanje MRI slika, a prikazane na slici 2.2 su:

1. **Aksijalna ravnina ili transverzalna ravnina** — tijelo pacijenta je podijeljeno na gornju i donju polovicu. Kada se snimaju MRI slike u transverzalnoj ravnini, slike se prikazuju u horizontalnom pogledu, pri čemu je gornji dio tijela pacijenta prikazan na vrhu slike, a donji dio prikazan na dnu slike. Ova se ravnina često koristi za snimanje mozga.
2. **Sagitalna ravnina** — ova ravnina dijeli tijelo pacijenta na lijevu i desnu polovicu. Slike se prikazuju u bočnom pogledu, pri čemu je lijeva strana tijela pacijenta prikazana na desnoj strani slike, a desna strana na lijevoj strani slike. Ova ravnina se često koristi za pregled mozga i kralježnice.
3. **Koronalna ravnina** — ova ravnina prolazi kroz tijelo pacijenta i dijeli ga na prednju (ventralnu) i stražnju (dorsalnu) polovicu. Ova ravnina se također naziva frontalna ravnina jer se obično prikazuje u frontalnom ili prednjem pogledu. Široko se koristi u ortopediji za pregled zglobova i kostiju, uključujući koljena, stopala, gležnjeve i kukove [20].

U nekim slučajevima koriste se 3D slike koje prikazuju strukture unutar tijela pacijenta u trodimenzionalnom prostoru što omogućuje detaljniji pregled unutarnjih organa i struktura.



Slika 2.2. Prikaz aksijalne, koronalne i sagitalne ravnine mozga [21].

Magnetska rezonancija široko se koristi za skeniranje komponenti mekih tkiva ljudskog tijela [22]. Budući da ne uključuje ionizirajuće zračenje, MRI je preferirana metoda slikanja.

Najviša razlučivost postignuta na 3 T (Tesla) iznosi $250 \mu\text{m} \times 250 \mu\text{m} \times 0,5 \text{ mm}$ uz vrijeme skeniranja od 5 do 40 minuta [23]. Viša prostorna razlučivost ($5\text{--}200 \mu\text{m}$) može se postići s mikro-MRI-jem u vrlo visokim magnetskim poljima kao što su 7–9 T [24], gdje se kontrast između mekih tkiva može dodatno poboljšati upotrebom kontrastnih sredstava poput magnetskih nanočestica [25]. Anatomske, funkcionalne i stanične informacije za različita meka tkiva mogu se dobiti korištenjem MRI zbog njegove izuzetne sposobnosti razlikovanja kontrasta mekih tkiva. Ljudi ne mogu podnijeti više razine magnetskih polja, što može izazvati nelagodu i osjećaj vrtoglavice. Zbog toga, magnetsko polje kojem su ljudi izloženi ne prelazi 3 T [17].

MRI ima nekoliko prednosti u odnosu na druge dijagnostičke tehnologije kao što su rendgenske snimke i računalna tomografija (engl. *computed tomography scan*). Prednost MRI-a je detaljnije i preciznije prikazivanje mekih tkiva i organa te neupotreba ionizirajućeg zračenja, čime je i sigurniji za pacijente.

2.1.1 Akvizicija slika

Suština magnetske rezonancije leži u prikupljanju, obradi i prikazu skupova podataka koji nose relevantne informacije za medicinsku dijagnozu. Uzorkovanje k -prostora inherentno je sporo u kontekstu MRI-ja [1]. Glavni razlog tome su tradicionalne metode koje uzorkuju brzinom višom od Nyquistove frekvencije kako bi se dobila ispravna rekonstrukcija. Nyquistova frekvencija ili frekvencija savijanja je frekvencija koja pretvara kontinuiranu funkciju ili signal u diskretni niz. Za zadanu brzinu uzorkovanja (uzorci po sekundi), Nyquistova frekvencija je ona čiji je period dvostruko veći od intervala između uzoraka [26]. Ovaj zahtjev osigurava da prikupljeni podaci sadrže dovoljno informacija za točnu konstrukciju slike bez uvođenja preklapanja artefakata (engl. *aliasing artifacts*). Artefakt se odnosi na neželjene ili lažne vizualne informacije koje se pojavljuju u slikama zbog pokreta ili nepravilnosti tijekom snimanja. Kao rezultat toga, MRI snimanje je mukotrpan i dugotrajan proces za pacijenta. Ovisno o području koje se snima, tipičan MRI pregled traje od 20 minuta do sat vremena. Tijekom tog vremena, pacijent leži unutar uske cijevi i izložen je glasnim i često neugodnim metalnim zvukovima. Osim toga, MRI snimanje je dodatno komplikirano zbog osjetljivosti na kretanje pacijenta tijekom pregleda, što može uzrokovati artefakte pokreta na konačnoj slici [27]. Kako bi se riješili ovi izazovi, predložene su razne tehnike za ubrzanje MRI akvizicije. Neke od glavnih tehnika su: fast spin echo (engl. *fast spin echo*, FSE), paralelno

snimanje i kompresno uzorkovanje.

Fast spin echo koristi višestruke korake faznog kodiranja u kombinaciji s višestrukim 180° refokusirajućim radiofrekvencijskim impulsima kako bi proizvele duljinu vlaka eha s odgovarajućim digitalnim prikupljanjem podataka po intervalu vremena ponavljanja. Višestruki redovi k -prostora popunjavaju se tijekom svakog TR intervala jednakom ETL-u, što je ujedno i faktor smanjenja vremena akvizicije. Tehnika FSE ima prednost akvizicije slike spina eha, tj. otpornost na nehomogenost vanjskog magnetskog polja, s $4\times$, $8\times$, do $16\times$ bržim vremenom akvizicije. Međutim, svaki echo doživljava različite količine intrinzičnog propadanja, što rezultira razlikama u kontrastu slike i zamućenju slike u smjeru faznog kodiranja u usporedbi s konvencionalnim spin echo slikama sličnih vremena ponavljanja i vremena eha (engl. *echo time*, TE). Niže razine signala u kasnijim ehovima proizvode manji omjer signala i šuma (engl. *signal-to-noise ratio*, SNR). Spin echo slika ($TR = 2000$ ms, 256 koraka faznog kodiranja, jedan prosjek) zahtijeva otprilike 8.5 minuta [28].

Paralelno snimanje koristi prostorne osjetljivosti profila više prijemnih zavojnica kako bi se smanjio broj potrebnih uzoraka. Ovaj pristup iskorištava prostornu redundantnost podataka za rekonstrukciju slike iz nedovoljno uzorkovanih k -prostora podataka [29]. Uglavnom su 2, 4, 8, 16, 24 (ili više) zavojnica raspoređene oko područja koje se snima. Linije u k -prostoru su definirane tek nakon obrade linearnih kombinacija signala koji su primljeni od svih zavojnica. Jedan od paralelnih pristupa, nazvan SENsitivity Encoding (SENSE), koristi profil osjetljivosti svake zavojnice za izračunavanje pozicije dolaznog signala u odnosu na zavojnicu na temelju njegove amplitude — signal generiran blizu zavojnice ima veću amplitudu nego signal najudaljeniji od nje. Ovisno o geometrijskoj konfiguraciji zavojnica, pojedinačna zavojnica može imati jedinstvene prostorne informacije koje druge zavojnice nemaju. Otvorene slike mogu se izraziti kao linearna kombinacija stečenih slika od pojedinačne zavojnice pomnoženih s njenom osjetljivošću. Paralelno snimanje također se može postići sintetiziranjem preskočenih linija k -prostora i generiranjem otvorenih slika iz pojedinačne zavojnice. Osjetljivost zavojnice u prostoru slike odgovara konvolucijskoj jezgri (engl. *kernel*) u k -prostoru (množenje u prostoru slike ekvivalentno je konvoluciji u frekvencijskom prostoru) [28]. Nakon što se popune nedostajuće linije k -prostora, slike iz svake zavojnice se generiraju i kombiniraju kako bi se stvorile konačne slike. Slično kao i mjerjenje osjetljivosti zavojnice, konvolucijski kernel svake zavojnice može se procijeniti prikupljanjem dodatnih

linija blizu središta k -prostora, a reprezentativna metoda je *Generalized Autocalibrating Partially Parallel Acquisition* (GRAPPA) [30].

Koncept kompresnog uzorkovanja (engl. *compressive sensing*) temelji se na ideji rijetkosti u prirodnim signalima. Kompresno uzorkovanje nastoji izravno prikupiti manji broj mjerenja u generičkoj bazi (npr. k -prostoru) i rekonstruirati visokokvalitetni signal (npr. sliku) iz tih nekoliko mjerena [31]. Kompresno uzorkovanje matematička je metoda koja rekonstruira poduzorkovane podatke k -prostora i omogućava brzu rekonstrukciju MRI-ja. Primjenom tehnike kompresnog uzorkovanja poboljšava se evaluacija kvalitete slike, dijagnostičke performanse i vizualizacija tkiva. Takva tehnika detaljno je razrađena primjenom 3D fast spin echo kompresnog uzorkovanja i specifičnih sekvenci za određeni organ tijela [32]. Kompresno uzorkovanje obično započinje s uzimanjem ponderirane linearne kombinacije uzoraka, nazvanih kompresivna mjerena. Ponderiranje se odnosi na naglašavanje određenih karakteristika tkiva kako bi se dobila bolja dijagnostička slika. Zadatak pretvaranja slike natrag u namjeravanu domenu uključuje rješavanje pododređenog sustava matrice jednadžbi, budući da je broj kompresivnih mjerena manji od broja slikovnih podataka (engl. *pixels*) u punoj slici. Međutim, postavljanjem ograničenja rijetkosti početnog signala omogućava se rješavanje ovog pododređenog sustava linearnih jednadžbi [33].

2.1.2 MRI sekvence

Tkivo se može karakterizirati pomoću dva različita relaksacijska vremena - T_1 i T_2 . T_1 (podudarno relaksacijsko vrijeme) vremenska je konstanta koja određuje brzinu kojom se uzbuđeni protoni vraćaju u ravnotežu s vanjskim magnetskim poljem. T_2 (poprečno relaksacijsko vrijeme) vremenska je konstanta koja određuje brzinu kojom uzbuđeni protoni dolaze do ravnoteže ili gube faznu koherentnost među jezgrama koje se vrte okomito na glavno magnetsko polje.

Najčešće MRI sekvence su T_1 -ponderirano i T_2 -ponderirano snimanje. T_1 -ponderirane slike nastaju korištenjem kratkih vremena eha (engl. *echo time*, TE) i vremena ponavljanja (engl. *repetition time*, TR). Kontrast i svjetlina slike uglavnom su određeni T_1 svojstvima tkiva. S druge strane, T_2 -ponderirane slike nastaju korištenjem dužih TE i TR vremena. Na ovim slikama, kontrast i svjetlina uglavnom su određeni T_2 svojstvima tkiva. Općenito, T_1 - i T_2 -ponderirane slike mogu se lako razlikovati promatranjem cerebrospinalne tekućine. Cere-

brospinalna tekućina je tamna na T_1 -ponderiranom snimanju i svijetla na T_2 -ponderiranom snimanju.

Treća često korištena sekvenca je *Fluid Attenuated Inversion Recovery* (FLAIR). FLAIR sekvenca je slična T_2 -ponderiranoj slici osim što su TE i TR vremena vrlo duga. Na taj način, abnormalnosti ostaju svijetle, ali normalna cerebrospinalna tekućina je smanjena i postaje tamna. Ova sekvenca olakšava razlikovanje između cerebrospinalne tekućine i abnormalnosti.

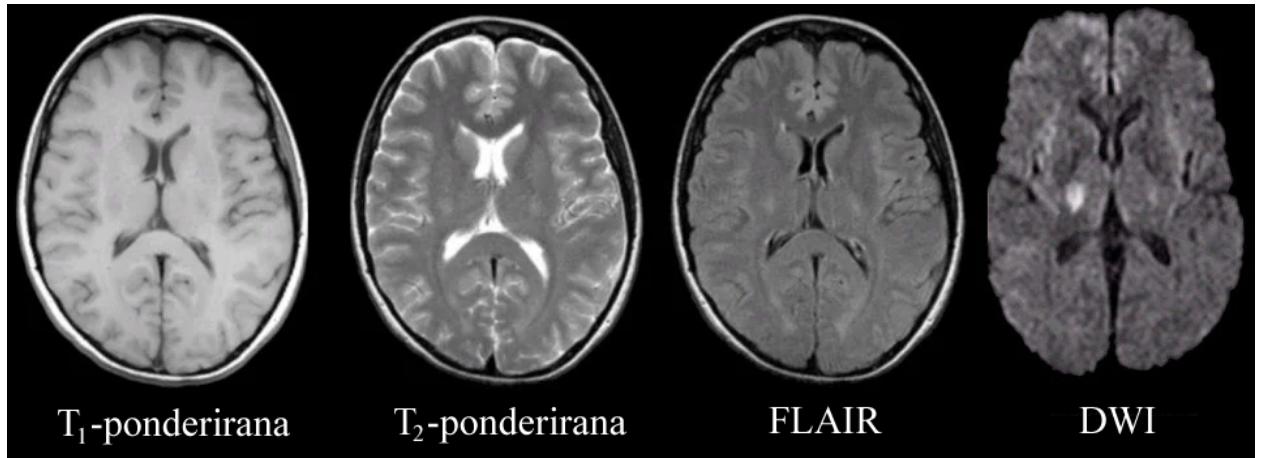
Snimanje slika difuzijskim ponderiranjem (engl. *diffusion weighted imaging*, DWI) namijenjeno je otkrivanju slučajnih pokreta vodikovih protona. Vodikove molekule relativno slobodno difuziraju u izvanstaničnom prostoru, jer je njihovo kretanje značajno ograničeno u unutarstaničnom prostoru. Spontane kretnje, nazvane difuzijom, brzo postaju ograničene u ishemijskom moždanom tkivu. Tijekom ishemije, natrij-kalijeva pumpa prestaje raditi i natrij se nakuplja unutar stanica. Voda se zatim premešta iz izvanstaničnog u unutarstanični prostor zbog osmotskog gradijenta. Kako kretanje vode postaje ograničeno unutarstanično, može rezultirati izuzetno svijetlim signalom na DWI-u. Stoga je DWI korisna metoda za otkrivanje akutnog moždanog udara [34]. U tablici 2.1 prikazana je usporedba T_1 -ponderiranog snimanja, T_2 -ponderiranog snimanja i FLAIR sekvence pri snimanju ljudskog tijela.

Tablica 2.1. Karakteristike MRI tkiva [34].

Tkivo	T_1 -ponderirana	T_2 -ponderirana	Flair
Cerebrospinalna tekućina	Tamno	Svijetlo	Tamno
Bijela tvar	Svijetlo	Tamnosiva	Tamnosiva
Korteks	Sivo	Svijetlosiva	Svijetlosiva
Masno tkivo (unutar koštane srži)	Svijetlo	Svijetlo	Svijetlo
Upala (infekcija, demijelinizacija)	Tamno	Svijetlo	Svijetlo

Snimanje s difuzijskom težinom nije uključeno u originalnu tablicu zbog svoje specifične prirode i načina na koji se interpretira u kontekstu MRI skeniranja. Dok se T_1 -ponderirane, T_2 -ponderirane i FLAIR sekvence fokusiraju na različite aspekte relaksacijskih svojstava tkiva, DWI sekvenca se temelji na detekciji difuzije vodenih protona u tkivu. Ovisno o značajkama difuzije vode, signali na DWI-u mogu varirati i nisu uvijek jasno definirani kao "tamni", "svijetli" ili slično kao kod ostalih sekvenci. Stoga su u tablici navedene karakteristike MRI tkiva.

teristike koje se odnose na relaksacijska svojstva i kontrast koji pružaju T_1 -ponderirana, T_2 -ponderirana i FLAIR sekvenca. DWI sekvenca se koristi za otkrivanje difuzije vodenih protona, što često nije direktno usporedivo s kontrastom koji pružaju druge sekvence.



Slika 2.3. Prikaz T_1 -ponderiranog, T_2 -ponderiranog, FLAIR i DWI snimanja mozga [34].

Na slici 2.3 prikazana je razlika na MRI slikama mozga između svih objašnjениh MRI sekvenci.

2.2 Suvremene metode rekonstrukcije MRI slika

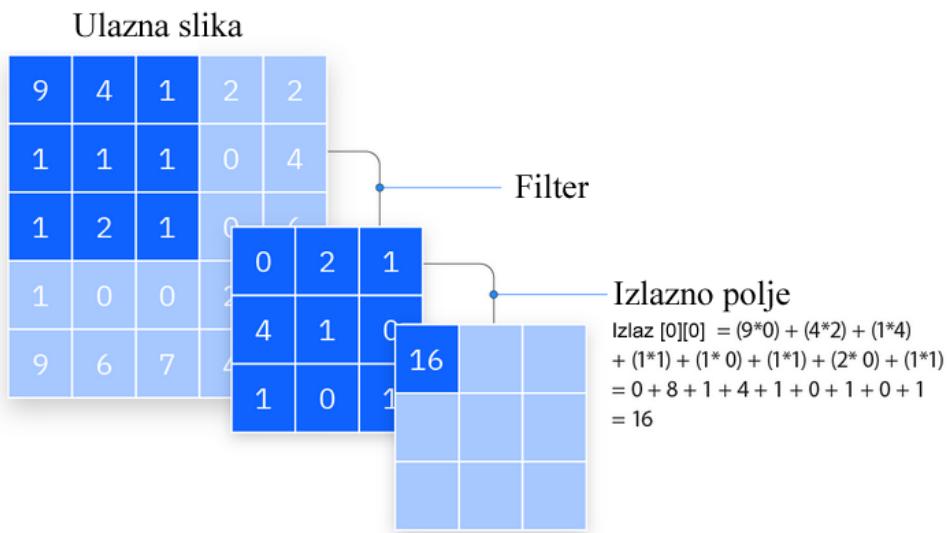
U suvremenoj medicinskoj dijagnostici, rekonstrukcija MRI slika sve više koristi napredne tehnike dubokog učenja kako bi poboljšala kvalitetu i brzinu analize. Ove metode transformiraju način na koji se sirovi podaci pretvaraju u visoko detaljne vizualizacije anatomske struktura i patoloških promjena. Umjesto tradicionalnih pristupa baziranih na signalnoj obradi, duboko učenje omogućava automatsko učenje značajki iz podataka, što rezultira preciznijim i efikasnijim dijagnostičkim alatima. Integracija složenih neuronskih mreža, kao što su konvolucijske mreže i generativni modeli, omogućava optimizaciju rekonstrukcije i interpretacije MRI slika, čime se otvaraju nove mogućnosti za personaliziranu medicinsku skrb i istraživanje [35].

2.2.1 Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (engl. *Convolutional Neural Networks*, CNN) vrsta su neuronskih mreža dizajnirana za obradu podataka koji imaju prostornu strukturu. One su široko korištene u području računalnog vida za zadatke kao što su klasifikacija slika, detekcija

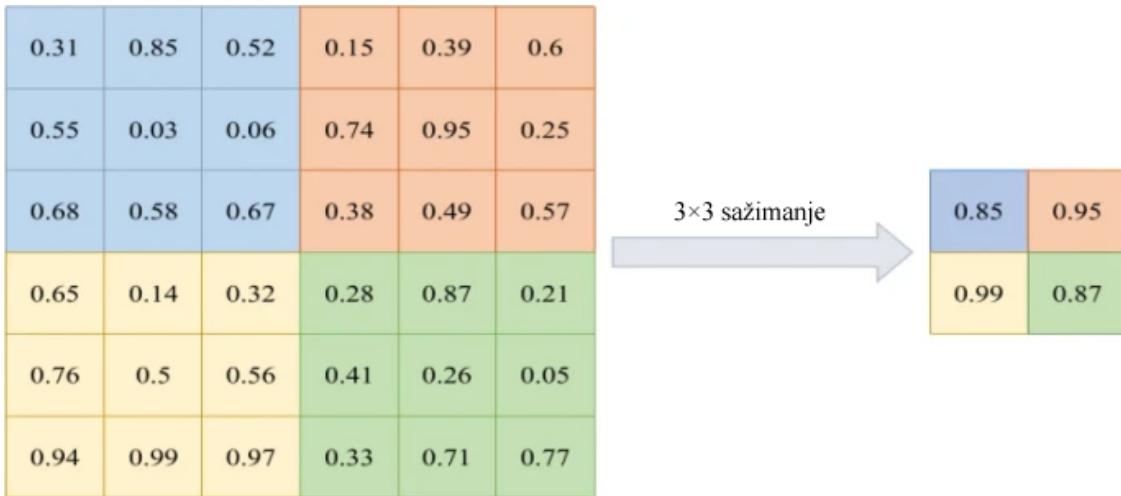
objekata, segmentacija slika i druge. Inspirirane strukturom ljudskog korteksa, sastoje se od slojeva konvolucijskih filtara.

Konvolucijski slojevi primjenjuju niz filtara (jezgri, engl. *kernel*) na ulazne podatke kako bi izvukli značajke iz njih. Konvolucijski filteri su matrice težina koje se mogu trenirati kako bi se prepoznale različite značajke. Kernel je mala matrica (obično dimenzija 3×3 ili 5×5) koja se pomiče korak po korak (engl. *stride*). Pri svakom koraku, množi se sa slikovnim podacima na svakom mjestu poklapanja. Rezultati se zbroje kako bi se dobio jedan broj koji predstavlja značajku tog dijela slike. Proces se ponavlja za svaki slikovni podatak na slici, čime se generira skup značajki koji predstavlja informacije o različitim dijelovima slike, kao što je prikazano na slici 2.4. Ovaj postupak omogućuje konvolucijskoj mreži da nauči lokalne značajke poput rubova, tekstura ili oblika, jer se kerneli mogu prilagoditi za izdvajanje određenih karakteristika iz slike [36].



Slika 2.4. Operacija konvolucije [36].

Nadalje, konvolucijske mreže često koriste i slojeve sažimanja (engl. *pooling layers*) koji smanjuju prostornu dimenzionalnost izlaza konvolucijskih slojeva. Najčešći način sažimanja je maksimalno sažimanje (engl. *max pooling*), gdje se izdvaja maksimalna vrijednost iz svake lokalne regije izlaza konvolucijskog sloja. Na taj način ovaj sloj smanjuje broj težina koje se obrađuju u sljedećem sloju konvolucije bez gubitaka na značajkama. Slika 2.5 prikazuje primjer maksimalnog sažimanja 3×3 matrice.



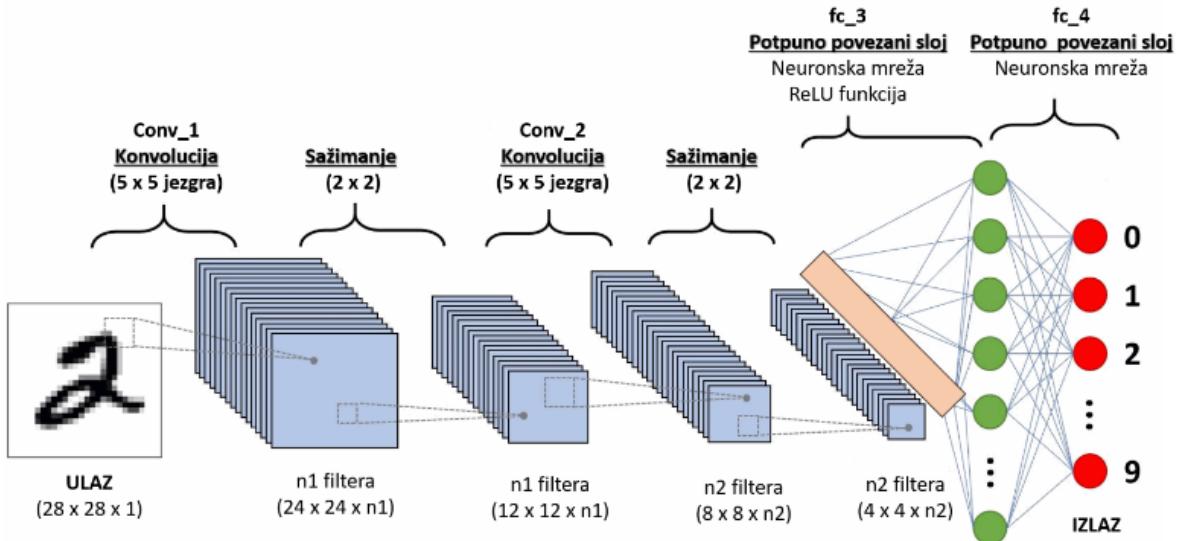
Slika 2.5. Operacija maksimalnog sažimanja [37].

Konvolucijske mreže također mogu sadržavati potpuno povezane slojeve (engl. *fully connected layers*) na kraju arhitekture, koji se koriste za klasifikaciju ili regresiju na temelju izvučenih značajki. Potpuno povezani slojevi su slojevi u neuronskim mrežama u kojima su svi neuroni povezani sa svim neuronima prethodnog sloja. Izlazni vektori neurona se obrađuju kako bi se donijela konačna klasifikacijska odluka te svaki neuron u potpuno povezanom sloju ima svoju aktivacijsku funkciju. Aktivacijske funkcije su ključne jer utječu na aktivnost neurona u neuronskoj mreži. Omogućuju neuronskoj mreži da nauči nelinearne funkcije i obavlja kompleksne zadatke.

Najčešće korištene aktivacijske funkcije su:

1. **ReLU** (engl. *Rectified Linear Unit*) koja se često koristi u skrivenim slojevima neuronske mreže. ReLU aktivacijska funkcija je definirana kao maksimum između nule i ulaznog signala. Ona potiskuje negativne vrijednosti i linearno aktivira pozitivne vrijednosti.
2. **Sigmoidna funkcija** se koristi kao funkcija odluke za binarnu klasifikaciju. Ona sažme ulazne vrijednosti u rasponu između 0 i 1, što ih može interpretirati kao vjerojatnosti.
3. **Softmax funkcija** se koristi kao funkcija odluke za višeklasnu klasifikaciju. Ona sažme ulazne vrijednosti u rasponu između 0 i 1 te ih normalizira tako da zbroj svih izlaznih vrijednosti bude jednak 1. Time se izlazi mogu interpretirati kao vjerojatnosti za svaku moguću klasu.

Sve navedene komponente zajedno čine konvolucijsku neuronsku mrežu. Primjer konvolucijske mreže vidljiv je na slici 2.6.



Slika 2.6. Primjer konvolucijske neuronske mreže [38, 39].

Prednosti konvolucijskih mreža uključuju sposobnost automatskog izvlačenja značajki iz podataka, invarijantnost na translacije i lokalne varijacije te efikasnost u obradi prostornih podataka. Zbog tih svojstava, konvolucijske mreže postigle su izvanredne rezultate u mnogim zadacima računalnog vida i postale su ključna tehnologija u području umjetne inteligencije.

2.2.2 U-Net arhitektura

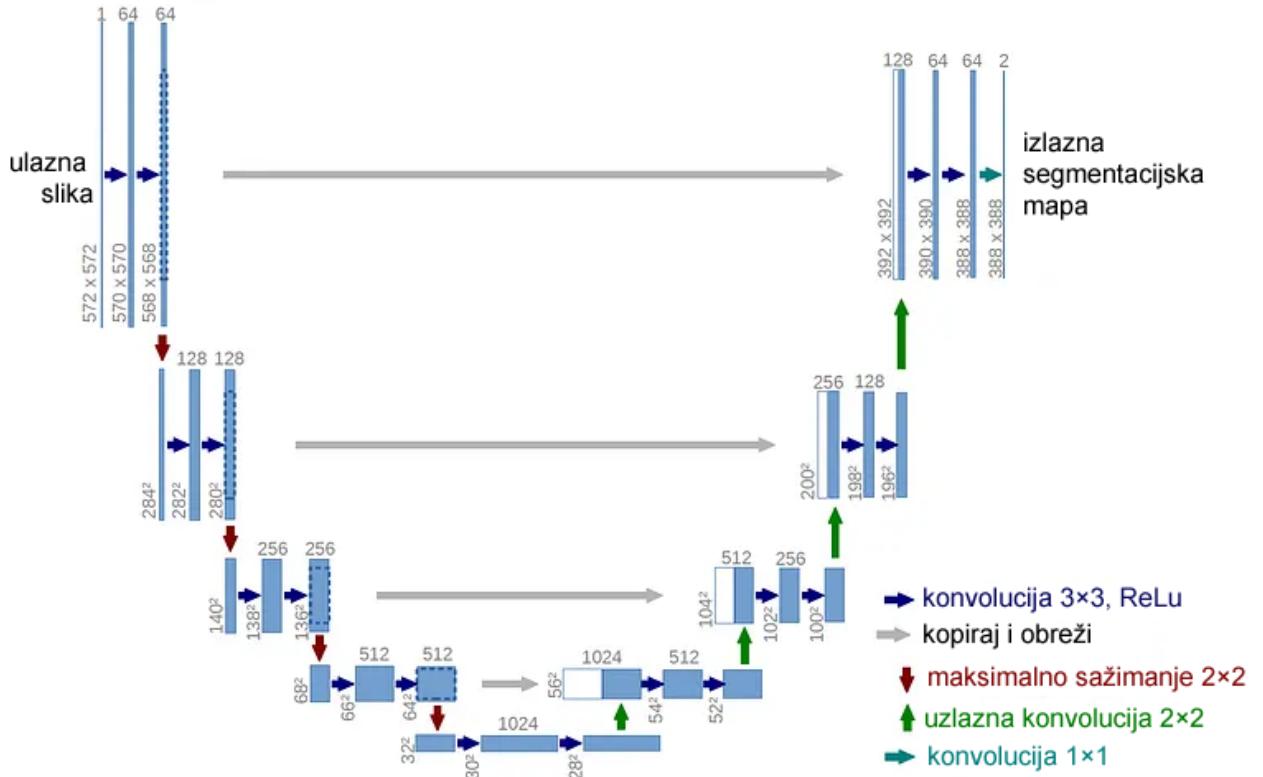
U-Net arhitektura tip je konvolucijske neuronske mreže nastao za segmentaciju medicinskih slika. Nazvana je U-Net zbog svog oblika koji podsjeća na slovo "U", a ideja joj je da koristi velik broj filtriranja u konvolucijskim slojevima za učenje značajki iz slika i održavanje prostornih informacija. U-Net arhitektura sastoji se od tri dijela: enkodera (ulazni slojevi), dekodera (izlazni slojevi) i mosta koji ih povezuje.

Enkoder ima tipičnu arhitekturu konvolucijske mreže koja se koristi za izvlačenje značajki iz ulazne slike. Svaki enkoderski blok sastoji se od dvije 3×3 konvolucije, gdje svaku konvoluciju slijedi ReLU aktivacijska funkcija. ReLU aktivacijska funkcija uvodi nelinearnost u mrežu, što pomaže u boljoj generalizaciji podataka za treniranje. Izlaz ReLU funkcije djeluje kao preskočna veza za odgovarajući dekoderski blok. Zatim slijedi 2×2 maksimalno sažimanje, gdje se prostorne dimenzije (visina i širina) karata značajki smanjuju za polovicu.

To smanjuje računalni trošak smanjenjem broja parametara koji se treniraju. Ovi slojevi postupno smanjuju prostornu rezoluciju slike, ali povećavaju broj značajki koje se izlučuju.

Most povezuje mrežu enkodera i dekodera te dovršava protok informacija. Sastoji se od dvije 3×3 konvolucije, gdje svaka konvolucija slijedi ReLU aktivacijsku funkciju.

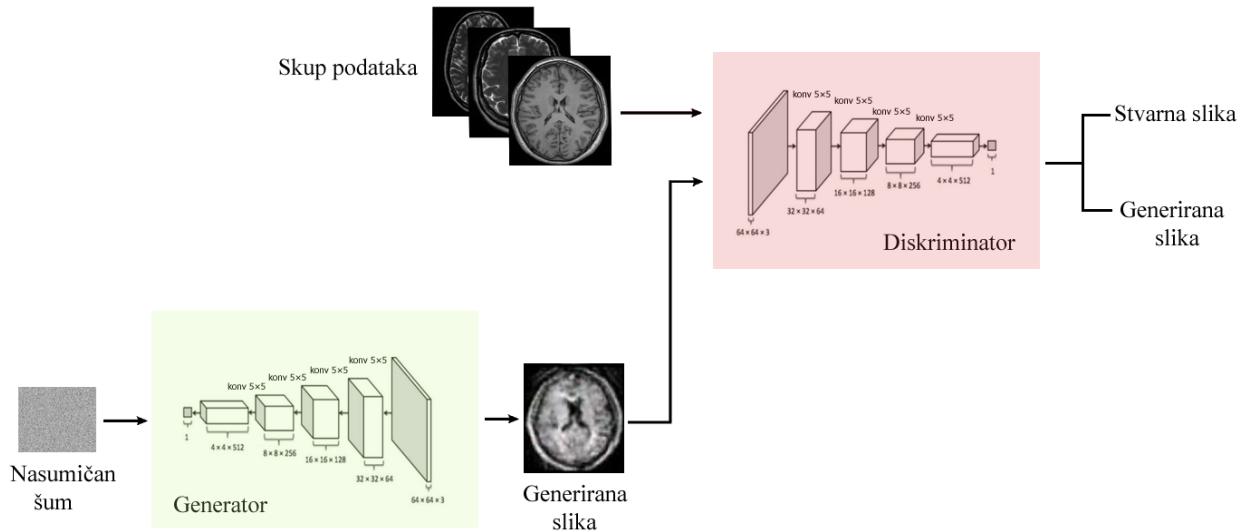
Dekoder, s druge strane, koristi slojeve za proširivanje (engl. *up-sampling*) kako bi povećao prostornu rezoluciju i rekonstruirao segmentirani izlaz. Dekoderski blok započinje s 2×2 transponiranom konvolucijom. Zatim se spaja s odgovarajućom preskočnom kartom značajki iz enkoderskog bloka. Ove preskočne veze pružaju značajke iz ranijih slojeva koje se ponekad izgube zbog dubine mreže. Nakon toga se koriste dvije 3×3 konvolucije, gdje svaka konvolucija slijedi ReLU aktivacijsku funkciju. Izlaz zadnjeg dekodera prolazi kroz 1×1 konvoluciju sa sigmoidnom aktivacijom. Sigmoidna aktivacijska funkcija daje segmentacijsku masku koja predstavlja piksel-po-piksel klasifikaciju [40]. Opisana arhitektura U-Net mreže vizualno je prikazana na slici 2.7.



Slika 2.7. Arhitektura U-Net mreže [40].

2.2.3 Generativna kontradiktorna mreža

Generativna kontradiktorna mreža (engl. *generative adversarial network*, GAN) arhitektura je dubokog učenja u kojoj se treniraju dvije neuronske mreže i međusobno se natječe kako bi generirale autentične nove podatke iz danog skupa podataka za obuku. Sustav generira novije, poboljšane verzije lažnih podataka sve dok mreža za predviđanje više ne može razlikovati lažne od originalnih podataka. Arhitektura GAN modela uključuje dva podmodела: model generatora za generiranje novih primjera i model diskriminadora za predviđanje pripadaju li generirani podaci izvornom skupu podataka, tj. model diskriminadora određuje jesu li generirani podaci lažni ili stvarni. Slika 2.8 prikazuje arhitekturu generativne kontradiktorne mreže.



Slika 2.8. Arhitektura generativne kontradiktorne mreže.

Model generatora uzima vektor slučajne duljine kao ulaz i generira uzorak u domeni. Vektor je slučajno odabran iz Gaussove distribucije i koristi se za inicijalizaciju generativnog procesa. Nakon treninga, točke u ovom višedimenzionalnom vektorskom prostoru odgovarajuće točkama u problematičnoj domeni, formirajući komprimiranu reprezentaciju distribucije podataka. Ovaj vektorski prostor naziva se latentni prostor, ili vektorski prostor koji se sastoji od latentnih varijabli. Latentne varijable, ili skrivene varijable, su one varijable koje su važne za domenu, ali nisu direktno vidljive. Često se referira na latentne varijable ili latentni prostor kao projekciju ili kompresiju distribucije podataka. Drugim riječima, latentni prostor pruža kompresiju ili visokorazinske koncepte promatranog sirovog podatka poput distribucije ulaznih podataka. U slučaju GAN-ova, model generatora dodjeljuje značenje

točkama u odabranom latentnom prostoru. Nove točke izvučene iz latentnog prostora mogu poslužiti kao ulaz modelu generatora i koristiti se za generiranje novih i različitih primjera izlaza. Nakon treniranja model generatora se čuva i koristi za generiranje novih uzoraka [41].

Diskriminatator je običan klasifikacijski model. Model diskriminatatora uzima primjer iz domene kao ulaz (stvarni ili generirani) te predviđa binarnu klasnu oznaku stvarnog ili lažnog (generiranog). Stvarni primjer dolazi iz skupa podataka za obuku dok su generirani primjeri izlaz modela generatora. Diskriminatator se zatim ažurira kako bi postao bolji u razlikovanju stvarnih i lažnih uzoraka, a generator se ažurira na temelju toga koliko su uspješno, ili ne, generirani uzorci prevarili diskriminatatora. Na taj način se ova dva modela natječu jedan protiv drugog.

2.3 Difuzijski modeli

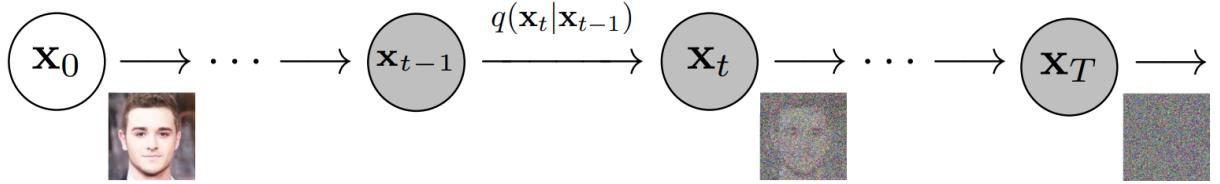
U strojnom učenju, difuzijski modeli, poznati i kao difuzijski probabilistički modeli ili generativni modeli temeljeni na rezultatima, predstavljaju klasu generativnih modela latentnih varijabli. Difuzijski model sastoji se od tri glavne komponente: procesa difuzije prema naprijed, procesa obrnute difuzije i postupka uzorkovanja ili treniranja. Cilj difuzijskih modela naučiti je difuzijski proces koji generira distribuciju vjerojatnosti za dani skup podataka iz kojeg se tada mogu uzorkovati novi elementi. Oni uče latentnu strukturu skupa podataka modeliranjem načina na koji se točke podataka šire kroz svoj latentni prostor [42].

2.3.1 Proces difuzije prema naprijed

Za zadalu podatkovnu točku iz prave distribucije podataka $\mathbf{x}_0 \sim q(\mathbf{x})$, definiran je proces difuzije prema naprijed kojim se uzorku dodaje mala količina Gaussovog šuma kroz T koraka, stvarajući slijed pošumljenih uzoraka $\mathbf{x}_1, \dots, \mathbf{x}_T$. Veličine koraka kontrolirane su rasporedom varijance $\{\beta_t \in (0, 1)\}_{t=1}^T$ koje određuju raspon dodanog šuma u svakom koraku. Jednadžbe 2-1 prikazuju računanje posteriorne vrijednosti za korak t i generalnu reprezentaciju posteriorne vrijednosti za T koraka Markovljevog lanca.

$$\begin{aligned} q(\mathbf{x}_t | \mathbf{x}_{t-1}) &= \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t} \mathbf{x}_{t-1}, \beta_t \mathbf{I}) \\ q(\mathbf{x}_{1:T} | \mathbf{x}_0) &= \prod_{t=1}^T q(\mathbf{x}_t | \mathbf{x}_{t-1}) \end{aligned} \tag{2-1}$$

Uzorak podataka x_0 postepeno gubi svoje prepoznatljive karakteristike kako korak t postaje veći. Na kraju, kada $T \rightarrow \infty$, x_T je ekvivalentan izotropnoj Gaussovoj distribuciji. Ovaj postupak generiranja prikazan je na slici 2.9.



Slika 2.9. Proces difuzije prema naprijed postepenim dodavanjem šuma u Markovljevom lancu [12].

Svojstvo gore opisanog procesa omogućuje uzorkovanje \mathbf{x}_t u bilo kojem vremenskom koraku t u zatvorenom obliku koristeći trik reparametrizacije, prikazano jednadžbama 2-2. Neka je $\alpha_t = 1 - \beta_t$ i $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$:

$$\begin{aligned}
 \mathbf{x}_t &= \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{1 - \alpha_t} \epsilon_{t-1} && ; \text{gdje je } \epsilon_{t-1}, \epsilon_{t-2}, \dots \sim \mathcal{N}(0, \mathbf{I}) \\
 &= \sqrt{\alpha_t \alpha_{t-1}} \mathbf{x}_{t-2} + \sqrt{1 - \alpha_t \alpha_{t-1}} \epsilon_{t-2} && ; \text{gdje } \epsilon_{t-2} \text{ spaja dvije Gaussove distribucije (*)} \\
 &= \dots \\
 &= \sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon
 \end{aligned} \tag{2-2}$$

Iz jednadžbi 2-2 proizlazi 2-3:

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1 - \bar{\alpha}_t) \mathbf{I}) \tag{2-3}$$

(*) Kada se spoje dvije Gaussove distribucije s različitim varijancama, $\mathcal{N}(0, \sigma_1^2 \mathbf{I})$ i $\mathcal{N}(0, \sigma_2^2 \mathbf{I})$, nova distribucija je $\mathcal{N}(0, (\sigma_1^2 + \sigma_2^2) \mathbf{I})$. Ovdje je spojeni standardni odmak prikazan izrazom 2-4.

$$\sqrt{(1 - \alpha_t) + \alpha_t(1 - \alpha_{t-1})} = \sqrt{1 - \alpha_t \alpha_{t-1}}. \tag{2-4}$$

Uglavnom se može priuštiti veći korak ažuriranja kada uzorak postane šumovitiji, tako da $\beta_1 < \beta_2 < \dots < \beta_T$ i stoga $\bar{\alpha}_1 > \dots > \bar{\alpha}_T$.

2.3.2 Proces obrnute difuzije

Proces obrnute difuzije omogućava uzorkovanje iz uzorka $q(\mathbf{x}_{t-1}|\mathbf{x}_t)$ i ponovno stvaranje, tj. generiranje, pravog uzorka iz Gaussovog šuma, $\mathbf{x}_T \sim \mathcal{N}(0, \mathbf{I})$. Ukoliko je dodani šum β_t dovoljno malen, $q(\mathbf{x}_{t-1}|\mathbf{x}_t)$ će također biti Gaussova distribucija. Nije jednostavno procijeniti $q(\mathbf{x}_{t-1}|\mathbf{x}_t)$ jer zahtjeva korištenje cijelog skupa podataka i stoga je potrebno naučiti model p_θ aproksimaciji uvjetnih vrijednosti kako bi se pokrenuo proces obrnute difuzije, prikazano jednadžbom 2-5.

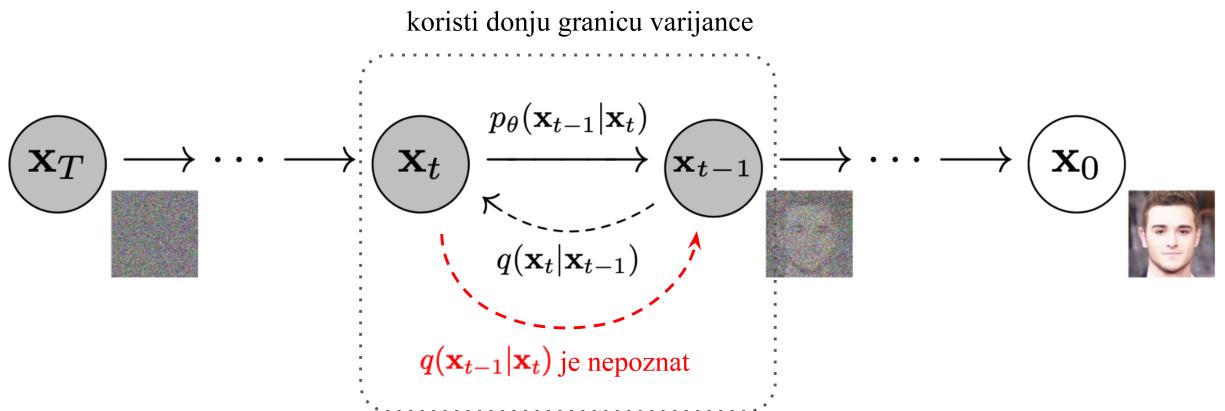
$$p_\theta(\mathbf{x}_{0:T}) = p(\mathbf{x}_T) \prod_{t=1}^T p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) \quad (2-5)$$

$$p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}; \mu_\theta(\mathbf{x}_t, t), \Sigma_\theta(\mathbf{x}_t, t))$$

Obrnuta uvjetna vjerojatnost može se pratiti kada je uvjetovana na \mathbf{x}_0 , što je prikazano u jednadžbi 2-6. Tijekom treniranja, pristupa se originalnim slikama \mathbf{x}_0 . Model uči kako ukloniti šum i obnoviti originalnu sliku putem obrnutog procesa difuzije. Ova vjerojatnost omogućava modelu da nauči koliko je šuma dodano u koraku t , odnosno \mathbf{x}_t , te kako ukloniti taj šum tijekom generiranja novih slika.

$$q(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{x}_0) = \mathcal{N}(\mathbf{x}_{t-1}; \tilde{\mu}(\mathbf{x}_t, \mathbf{x}_0), \tilde{\beta}_t \mathbf{I}) \quad (2-6)$$

Postepenim prolaskom potpuno pošumljene slike kroz naučeni model, šum se uklanja u svakom koraku t . Nakon konačnog broja koraka T , model iz slike sa šumom iz Gaussove distribucije uspijeva dobiti realističnu sliku, kao što je i prikazano na slici 2.10.



Slika 2.10. Proces (obrnute) difuzije prema naprijed postepenim dodavanjem (oduzimanjem) šuma u Markovljevom lancu [43].

2.3.3 Treniranje difuzijskih modela

Neuronsku mrežu treba naučiti kako aproksimirati uvjetne distribucije vjerojatnosti u procesu obrnute difuzije, $p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}; \mu_\theta(\mathbf{x}_t, t), \Sigma_\theta(\mathbf{x}_t, t))$. Cilj je trenirati μ_θ da predvidi $\tilde{\mu}_t = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_t \right)$. Budući da je \mathbf{x}_t dostupna kao ulaz tijekom treniranja, Gaussov šum se može reparametrizirati kako bi umjesto toga predvidio ϵ_t iz ulaza \mathbf{x}_t u trenutku t :

$$\mu_\theta(\mathbf{x}_t, t) = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_\theta(\mathbf{x}_t, t) \right) \quad (2-7)$$

Dakle, iz 2-7 proizlazi jednadžba 2-8:

$$\mathbf{x}_{t-1} = \mathcal{N}(\mathbf{x}_{t-1}; \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_\theta(\mathbf{x}_t, t) \right), \Sigma_\theta(\mathbf{x}_t, t)). \quad (2-8)$$

Gubitak L_t parametriziran je za minimizaciju razlike od $\tilde{\mu}_t$, izvedeno iz jednadžbi 2-9:

$$\begin{aligned} L_t &= \mathbb{E}_{\mathbf{x}_0, \epsilon} \left[\frac{1}{2\|\Sigma_\theta(\mathbf{x}_t, t)\|_2} \|\tilde{\mu}(\mathbf{x}_t, \mathbf{x}_0) - \mu_\theta(\mathbf{x}_t, t)\|^2 \right] \\ &= \mathbb{E}_{\mathbf{x}_0, \epsilon} \left[\frac{1}{2\|\Sigma_\theta\|_2} \left\| \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_t \right) - \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_\theta(\mathbf{x}_t, t) \right) \right\|^2 \right] \\ &= \mathbb{E}_{\mathbf{x}_0, \epsilon} \left[\frac{(1-\alpha_t)^2}{2\alpha_t(1-\bar{\alpha}_t)\|\Sigma_\theta\|_2} \|\epsilon_t - \epsilon_\theta(\mathbf{x}_t, t)\|^2 \right] \\ &= \mathbb{E}_{\mathbf{x}_0, \epsilon} \left[\frac{(1-\alpha_t)^2}{2\alpha_t(1-\bar{\alpha}_t)\|\Sigma_\theta\|_2} \|\epsilon_t - \epsilon_\theta(\sqrt{\bar{\alpha}_t}\mathbf{x}_0 + \sqrt{1-\bar{\alpha}_t}\epsilon)\|^2 \right] \end{aligned} \quad (2-9)$$

Emprijski je utvrđeno da treniranje modela difuzije radi bolje ako dođe do ignoriranja ponderiranih faktora u funkciji gubitka [12], definirano jednadžbama 2-10 i 2-11:

$$L_t^{\text{simple}} = \mathbb{E}_{t \sim [1, T], \mathbf{x}_0, \epsilon} [\|\epsilon_t - \epsilon_\theta(\mathbf{x}_t, t)\|^2] \quad (2-10)$$

$$L_t^{\text{simple}} = \mathbb{E}_{t \sim [1, T], \mathbf{x}_0, \epsilon} [\|\epsilon_t - \epsilon_\theta(\sqrt{\bar{\alpha}_t}\mathbf{x}_0 + \sqrt{1-\bar{\alpha}_t}\epsilon)\|^2] \quad (2-11)$$

Konačna funkcija gubitka izražava se jednadžbom 2-12:

$$L_t^{\text{simple}} = L_t^{\text{simple}} + C \quad (2-12)$$

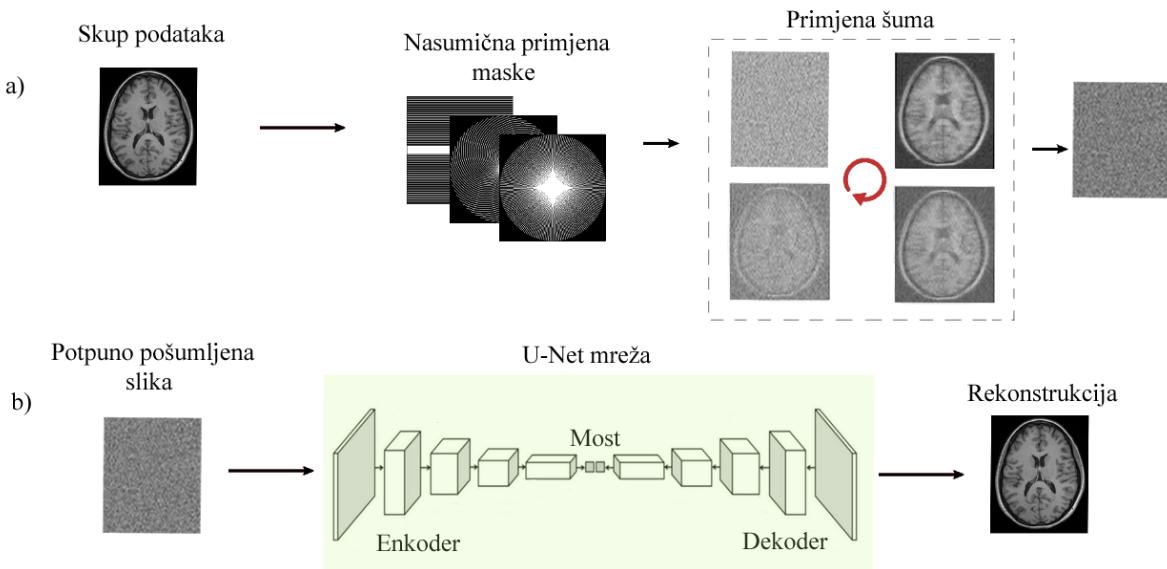
gdje je C konstanta koja ne ovisi o θ .

3 PREDLOŽENA METODA

U ovom poglavlju dublje će se objasniti korišteni model za akceleriranu rekonstrukciju slika magnetske rezonancije. Opisati će se korišteni difuzijski model, U-Net mreža i maske za nedovoljno uzorkovanje k -prostora. Pružiti će se pregled cijelokupnog procesa, a zatim se usredotočiti na detaljnu analizu svakog sloja unutar modela.

3.1 Model za akceleriranu rekonstrukciju

Model dubokog učenja za akceleriranu rekonstrukciju slika magnetske rezonancije temelji se na kombinaciji U-Net arhitekture i difuzijskog modela. Model koristi nadzirano učenje gdje se uči rekonstruirati slike iz nedovoljno uzorkovanih k -prostora simuliranih uz pomoć različitih maski za uzorkovanje, prikazano na slici 3.1. Maska se primjenjuje na najmanje slikovne podatke (ili slojeve) kako bi se izolirale određene značajke ili objekti unutar slike.



Slika 3.1. Predloženi model za rekonstrukciju MRI slika difuzijskim modelima. Pod a) prikaz procesa difuzije prema naprijed i pod b) proces obrnute difuzije i rekonstrukcija slike.

Glavna značajka modela je proces difuzije koja postepeno pogoršava ulaznu sliku primjenom niza transformacija. Proces se sastoji od dva glavna koraka: nedovoljnog uzorkovanja gdje se na ulaznu sliku primjenjuje slučajna maska i generiranja Gaussovog šuma gdje se šum dodaje nedovoljno uzorkovanoj slici. Faktor nedovoljnog uzorkovanja dinamički se izračunava na temelju broja iteracija i ukupnog broja koraka, a varijanca Gaussovog šuma kontrolira se hiperparametrima. U-Net arhitektura se koristi za proces obrnute difuzije i

rekonstrukciju izvorne slike. U predloženoj metodi U-Net se sastoji od enkodera, mosta i dekodera, gdje enkoder smanjuje prostorne dimenzije ulazne slike dok povećava broj kanala, a dekoder povećava uzorkovanje značajki kako bi rekonstruirao izvornu sliku. U-Net se sastoji od nekoliko konvolucijskih slojeva i slojeva za proširivanje, nakon čega slijedi konačni konvolucijski sloj za stvaranje rekonstruirane slike. Ovaj pristup objašnjen je u algoritmu 1.

Algorithm 1 Pregled predloženog modela za rekonstrukciju MRI slika

Require: U-Net model \mathcal{U} , originalne k -prostorne podatke k_{space} , broj koraka T , parametre varijence šuma $\beta_{\text{start}}, \beta_{\text{end}}$

- 1: Inicijaliziraj $x_0 \leftarrow k_{\text{space}}$ ▷ Započni s originalnim k -prostornim podacima
- 2: **for** $t = 0$ **to** $T - 1$ **do**
- 3: Računaj varijancu šuma β_t
- 4: Primjeni masku poduzorkovanja
- 5: Dodaj Gaussov šum
- 6: **end for**
- 7: Spoji zadnji pošumljeni podatak
- 8: Primjeni U-Net model \mathcal{U}
- 9: **return** rekonstruirane k -prostorne podatke \hat{k}_{space}

Srž ovog pristupa leži u integraciji difuzijskih procesa s podacima iz k -prostora, što omogućuje učinkovitu rekonstrukciju slika iz nedovršenih ili poduzorkovanih podataka, čime se smanjuje potreba za potpunom akvizicijom podataka. Posebnost metode je u dinamičkom određivanju maske koja varira ovisno o trenutnom koraku difuzijskog procesa, što omogućuje prilagodljivo i optimizirano poduzorkovanje k -prostora. Time se smanjuje količina podataka za obradu i ubrzava vrijeme rekonstrukcije slika magnetske rezonance.

3.2 Difuzijski model

Ranije spomenuti difuzijski model sastoji se od procesa difuzije prema naprijed i procesa obrnute difuzije. Proces difuzije prema naprijed matematički je opisan na sljedeći način jednadžbom 3-1:

$$x_t = M_t(k_{\text{space}}) + \sum_{i=0}^t \mathcal{N}(0, \beta_i^2) \quad (3-1)$$

Gdje x_t predstavlja pošumljene k -prostorne podatke pri koraku t , k_{space} predstavlja originalne k -prostorne podatke (realne i imaginarne dijelove), $M_t(k_{\text{space}})$ označava primjenu maske za nedovoljno uzorkovanje pri koraku t . $\mathcal{N}(0, \beta_i^2)$ predstavlja Gaussov šum sa sred-

njom vrijednošću nula i varijancom β_i^2 dodanom pri svakom koraku i . Raspored varijance šuma matematički je opisan jednadžbom 3-2:

$$\beta_i = \beta_{\text{start}} \left(\frac{\beta_{\text{end}}}{\beta_{\text{start}}} \right)^{\frac{i}{T}} \quad (3-2)$$

Gdje β_i označava šum varijance pri koraku i , β_{start} je početna vrijednost šuma, β_{end} je krajnja vrijednost šuma i T je ukupan broj difuzijskih koraka.

Proces obrnute difuzije pri kojemu se koristi U-Net arhitektura za rekonstrukciju slike matematički je opisan formulom 3-3:

$$\hat{k}_{\text{space}} = \mathcal{U}(x_t, t) \quad (3-3)$$

\hat{k}_{space} predstavlja rekonstruirane k -prostorne podatke predviđene od strane U-Net modela, x_t je pošumljen k -prostorni podatak pri koraku t koji ulaze u U-Net model, $\mathcal{U}(x_t, t)$ predstavlja U-Net neuronsku mrežu koja se koristi za uklanjanje šuma iz podataka i predviđanje čistih k -prostornih podataka.

Cijeli difuzijski proces dodatno je pojašnjen algoritmom 2.

Algorithm 2 Model difuzijskog procesa

Require: U-Net model \mathcal{U} , originalne k -prostorne podatke $k_{\text{space}} = (k_{\text{real}}, k_{\text{imag}})$, broj koraka T , parametre varijance šuma β_{start} , finalna varijanca šuma β_{end}

- 1: Inicijaliziraj $x_t^{\text{real}} \leftarrow k_{\text{real}}$
- 2: Inicijaliziraj $x_t^{\text{imag}} \leftarrow k_{\text{imag}}$
- 3: **for** $t = 0$ **to** $T - 1$ **do**
- 4: Računaj varijancu šuma $\beta_t \leftarrow \beta_{\text{start}} \left(\frac{\beta_{\text{end}}}{\beta_{\text{start}}} \right)^{\frac{t}{T}}$
- 5: Primjeni masku poduzorkovanja M_t na x_t^{real} i x_t^{imag}
- 6: Dodaj Gaussov šum:
- 7: $x_t^{\text{real}} \leftarrow x_t^{\text{real}} + \mathcal{N}(0, \beta_t^2)$
- 8: $x_t^{\text{imag}} \leftarrow x_t^{\text{imag}} + \mathcal{N}(0, \beta_t^2)$
- 9: **end for**
- 10: Spoji x_T^{real} i x_T^{imag} da se kreira x_T
- 11: Primjeni U-Net model \mathcal{U} :
- 12: $\hat{k}_{\text{space}} \leftarrow \mathcal{U}(x_T)$
- 13: Razdijeli \hat{k}_{space} na \hat{k}_{real} i \hat{k}_{imag}
- 14: **return** $(\hat{k}_{\text{real}}, \hat{k}_{\text{imag}})$

3.3 Model U-Net mreže

Kao prethodno spomenuto, u predloženoj metodi uloga U-Net mreže je proces obrnute difuzije i rekonstrukcija izvornih podataka, tj. slike. Algoritmom 3 definirana je njezina logika, a njezine glavne komponente matematički su zasebno opisane.

Algorithm 3 U-Net arhitektura

Require: Ulazni tenzor x oblika (batch, channels, height, width)

```

1: Enkoderska putanja:
2: for  $i = 1$  to 4 do
3:   Primjeni konvolucijski blok na  $x$ :  $E_i \leftarrow \text{ConvBlock}(x, C_{in}, C_{out})$ 
4:   Primjeni maksimalno sažimanje:  $P_i \leftarrow \text{MaxPool}(E_i)$ 
5:   Ažuriraj  $x \leftarrow P_i$ 
6: end for
7: Most:
8: Primjeni konvolucijski blok na  $x$ :  $B \leftarrow \text{ConvBlock}(x, C_{in}, C_{out})$ 
9: Dekoderska putanja:
10: for  $i = 4$  do 1 u obrnutom redoslijedu do
11:   Primjeni proširivanje:  $D_i \leftarrow \text{UpConv}(x, C_{in}, C_{out})$ 
12:   Primjeni bilinearnu interpolaciju:  $\tilde{D}_i \leftarrow \text{Interp}(D_i)$ 
13:   Spoji  $\tilde{D}_i$  s odgovarajućim izlazom enkodera
14:   Primjeni konvolucijski blok za dobivanje izlaza za ovu fazu
15: end for
16: Primjeni završnu konvoluciju:  $y \leftarrow \text{Conv}_{1 \times 1}(x)$ 
17: return  $y$ 
```

Enkoderska putanja opisana je jednadžbom 3-4, gdje C_{in} predstavlja broj ulaznih kanala, C_{out} je broj izlaznih kanala, $\text{Conv}_{3 \times 3}(C_{in}, C_{out})$ predstavlja konvolucijski sloj s jezgrom (engl. *kernel*) veličine 3×3 koji uzima ulazne podatke s C_{in} kanala i šalje izlazne s C_{out} kanala. BN(C_{out}) označava normalizaciju po seriji (engl. *batch normalization*, BN) primjenjenu na C_{out} kanalima. ReLU predstavlja ReLU aktivacijsku funkciju za normaliziranje podataka koja pomaže u dodavanju nelinearnosti modelu.

$$E_i = \text{ReLU}(\text{BN}(\text{Conv}_{3 \times 3}(C_{in}, C_{out}))) \text{ praćena s } \text{ReLU}(\text{BN}(\text{Conv}_{3 \times 3}(C_{out}, C_{out}))) \quad (3-4)$$

Nakon enkoderske putanje slijedi maksimalno sažimanje (engl. *max pooling*, MaxPool) s

jezgrom 2×2 opisano matematičkom jednadžbom 3-5.

$$P_i = \text{MaxPool}_{2 \times 2}(E_i) \quad (3-5)$$

Most U-net mreže opisan je jednadžbom 3-6, gdje je C_{in} broj ulaznih kanala i C_{out} broj izlaznih kanala.

$$B = \text{Conv}_{3 \times 3}(C_{in}, C_{out}) \quad (3-6)$$

Dekoderska putanja opisana je matematičkom jednadžbom 3-7, gdje $\text{UpConv}_{2 \times 2}(C_{in}, C_{out})$ predstavlja transponirani konvolucijski sloj s jezgrom 2×2 , C_{in} ulaznim kanalima, and C_{out} izlaznim kanalima. Interp_2 u jednadžbi 3-8 predstavlja bilinearne slojeve za proširivanje (engl. *up-sampling*) s faktorom skaliranja 2.

$$D_i = \text{ReLU}(\text{UpConv}_{2 \times 2}(C_{in}, C_{out})) \quad (3-7)$$

$$\tilde{D}_i = \text{Interp}_2(D_{i+1}) \quad (3-8)$$

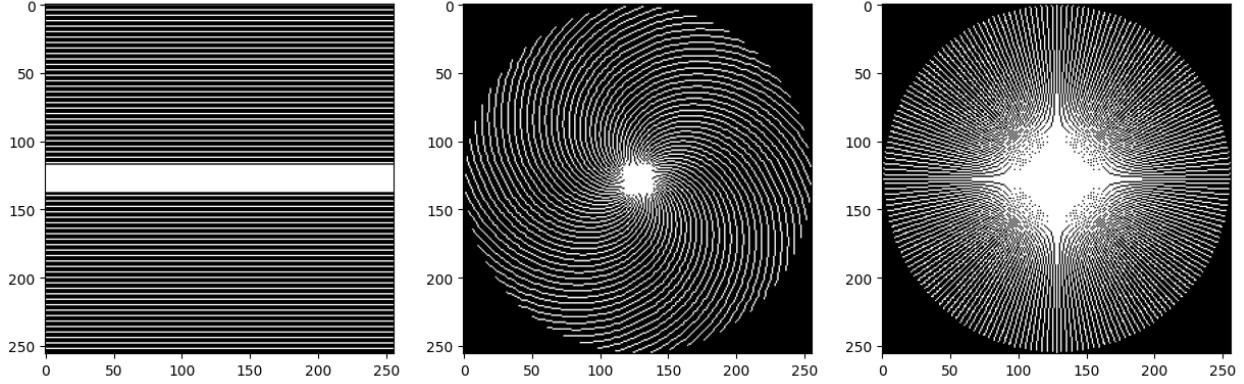
Posljednja konvolucija izražena je jednadžbom 3-9:

$$\hat{Y} = \text{Conv}_{1 \times 1}(C_{in}, C_{out}) \quad (3-9)$$

gdje $\text{Conv}_{1 \times 1}(C_{in}, C_{out})$ predstavlja posljednji konvolucijski sloj s jezgrom 1×1 .

3.4 Maske za nedovoljno uzorkovanje k -prostora

Nedovoljno uzorkovanje k -prostora ključno je za ubrzanje procesa snimanja slike. U stvarnim uvjetima, ovo nedovoljno uzorkovanje odvija se tijekom same akvizicije MRI slike, dok se u istraživačkom okruženju simulira pomoću uzorkovanih maski [44]. Zbog tog razloga, i radi izbjegavanja pretreniranja modela, koristile su se tri različite maske za nedovoljno uzorkovanje k -prostora koje su predane nasumično. Maske korištene u predloženoj metodi prikazane su na slici 3.2.



Slika 3.2. Prikaz Kartezijske maske (lijevo), spiralne maske (sredina) i radikalne maske (desno) korištene u modelu.

3.4.1 Kartezijska maska

Kartezijske maske za uzorkovanje su istaknute u MRI-u, uglavnom zbog svoje jednostavnosti i jednostavne primjene [2]. Ove maske koriste uzorak nalik mreži u k -prostoru, pružajući relativno ravnomjernu pokrivenost. Djeluju tako da uzimaju uzorke podataka duž paralelnih linija, prateći strategiju koja odražava konvencionalnu tehniku prikupljanja podataka liniju po liniju u MRI uređajima [44]. Smanjenje vremena skeniranja izravno je proporcionalno razini nedovoljno uzorkovanih podataka [2], što znači da se vrijeme akvizicije smanjuje za svaku preskočenu liniju u k -prostoru.

U korištenom modelu Kartezijska maska za nedovoljno uzorkovanje \mathbf{M}_{cart} oblika (D, H, W) , gdje D predstavlja broj slojeva, H predstavlja visinu i W predstavlja širinu, matematički je definirana u 3-10:

$$\mathbf{M}_{\text{cart}}(h, w) = \begin{cases} 1 & \text{ako je } \text{mod}(w, \frac{1}{\text{UF}}) = 0 \text{ i } h \in [C_{\text{start}}, C_{\text{end}}] \\ 0 & \text{u suprotnom} \end{cases} \quad (3-10)$$

gdje vrijedi da je:

$$C_{\text{start}} = \frac{W - C_{\text{lines}}}{2} \quad (3-11)$$

$$C_{\text{end}} = C_{\text{start}} + C_{\text{lines}} \quad (3-12)$$

$$C_{\text{lines}} = \lambda C_{\text{fraction}}, W : C_{\text{fraction}} \times W \quad (3-13)$$

$\mathbf{M}_{\text{cart}}(h, w)$ je vrijednost maske na poziciji (h, w) , $\text{mod}(w, \frac{1}{\text{UF}}) = 0$ osigurava da se maska

postavi na retke uzoraka u horizontalnom smjeru prema faktoru uzorkovanja (UF), $h \in [C_{\text{start}}, C_{\text{end}}]$ osigurava da se maska primjenjuje samo unutar određenog raspona visine h . C_{start} i C_{end} definiraju početni i završni indeks u visinskom rasponu gdje je maska aktivna, a definirane su jednadžbama 3-11 i 3-12. C_{lines} predstavlja broj linija koje se uključuju u masku, što ovisi o C_{fraction} i visini W , definirano jednadžbom 3-13.

3.4.2 Spiralna maska

Spiralne maske za uzorkovanje prate spiralnu putanju prilikom uzorkovanja podataka u k -prostoru. Počevši od središta k -prostora, maska se širi spiralno prema van, pokrivajući k -prostor u nizu kružnih putanja. Ova vrsta maske poznata je po svojoj učinkovitosti u hvatanju niskofrekventnih komponenti koje se nalaze u središtu k -prostora [45].

Spiralna maska za nedovoljno uzorkovanje, $\mathbf{M}_{\text{spiral}}$ oblika (D, H, W) , gdje D predstavlja broj slojeva, H predstavlja visinu i W predstavlja širinu, korištena u modelu primjenjuje Brasenhamov algoritam za crtanje linija između dvije točke (x_0, y_0) i (x_1, y_1) , objašnjen algoritmom 4.

Algorithm 4 Bresenhamov algoritam za crtanje linije

Require: Početna točka (x_0, y_0) , krajnja točka (x_1, y_1)

Postupak:

- 1: Izračunaj apsolutne pomake: $dx = |x_1 - x_0|$, $dy = |y_1 - y_0|$
- 2: Odredi smjer inkrementa:

$$sx = \begin{cases} 1 & \text{ako je } x_0 < x_1 \\ -1 & \text{inače} \end{cases}, sy = \begin{cases} 1 & \text{ako je } y_0 < y_1 \\ -1 & \text{inače} \end{cases}$$

- 3: Postavi početnu grešku: $\text{err} = dx - dy$
 - 4: **while** $(x_0, y_0) \neq (x_1, y_1)$ **do**
 - 5: Izračunaj $e_2 = 2 \cdot \text{err}$
 - 6: **if** $e_2 > -dy$ **then**
 - 7: $x_0 \leftarrow x_0 + sx$
 - 8: $\text{err} \leftarrow \text{err} - dy$
 - 9: **end if**
 - 10: **if** $e_2 < dx$ **then**
 - 11: $y_0 \leftarrow y_0 + sy$
 - 12: $\text{err} \leftarrow \text{err} + dx$
 - 13: **end if**
 - 14: Ispis koordinate (x_0, y_0)
 - 15: **end while**
 - 16: Algoritam se završava kada $(x_0, y_0) = (x_1, y_1)$
-

Algoritam računa apsolutne vrijednosti promjene u x i y smjeru (dx i dy) i koristi in-

krementa sx i sy kako bi se pomicao po koordinatnoj mreži. Neka su početne točke (x_0, y_0) i završne točke (x_1, y_1) . Prvo se računaju absolutne vrijednosti pomaka u koordinatama prikazane jednadžbom 3-14:

$$dx = |x_1 - x_0|, \quad dy = |y_1 - y_0| \quad (3-14)$$

Određivanje smjera inkrementa sx i sy definirano je u jednadžbi 3-15:

$$sx = \begin{cases} 1 & \text{ako je } x_0 < x_1 \\ -1 & \text{inače} \end{cases}, \quad sy = \begin{cases} 1 & \text{ako je } y_0 < y_1 \\ -1 & \text{inače} \end{cases} \quad (3-15)$$

Početna greška definirana je matematičkim izrazom 3-16:

$$\text{err} = dx - dy \quad (3-16)$$

Tijekom svake iteracije, izračunava se vrijednost e_2 definirana izrazom 3-17 koja određuje ažuriranja x_0 i y_0 :

$$e_2 = 2 \cdot \text{err} \quad (3-17)$$

Ako je $e_2 > -dy$, tada se ažurira x_0 i smanjuje greška, kao što je i definirano u izrazu 3-18:

$$\text{ako je } e_2 > -dy : \quad \text{err} = \text{err} - dy, \quad x_0 = x_0 + sx \quad (3-18)$$

Ukoliko vrijedi da je $e_2 < dx$, tada se ažurira y_0 i povećava greška, definirano izrazom 3-19:

$$\text{ako } e_2 < dx : \quad \text{err} = \text{err} + dx, \quad y_0 = y_0 + sy \quad (3-19)$$

Dok god točke nisu jednake $(x_0, y_0) \neq (x_1, y_1)$, algoritam računa pomake u koordinatama koristeći vrijednosti err . Algoritam se završava kada $(x_0, y_0) = (x_1, y_1)$.

Spiralna putanja započinje iz središta k -prostora i širi se prema van s radijusom r , koji ovisi o broju r -koraka. Kut spirale θ određuje zakrivljenost svakog kraka spirale. Putanja

spirale u Kartezijevom sustavu opisana je formulama 3-20 i 3-21:

$$x(r, \theta) = r \cdot \cos(\theta), \quad (3-20)$$

$$y(r, \theta) = r \cdot \sin(\theta) \quad (3-21)$$

gdje r predstavlja radijalnu udaljenost od središta k -prostora, a θ je kutna koordinata koja se povezuje s radijalnim korakom. Broj krakova spirale N_{arms} određuje koliko se puta spirala širi oko središta, pri čemu se kut za i -ti krak definira kao:

$$\theta_i = \frac{2\pi i}{N_{\text{arms}}} + c \cdot r \quad (3-22)$$

gdje je c parametar zakrivljenosti (engl. *curvature*), a i indeks trenutnog kraka u jednadžbi 3-22.

Središnji dio k -prostora, koji sadrži niske frekvencije, je u potpunosti uzorkovan. Definira se frakcija središta koja se potpuno uzorkuje, a opisana je jednadžbom 3-23:

$$L_{\text{center}} = \lambda \cdot f_{\text{center}} \quad (3-23)$$

gdje je f_{center} postotak središnjih linija koje se uzorkuju, a λ faktor skaliranja k -prostora. Središnji uzorci su definirani kao kvadratni prostor oko središta:

$$\mathbf{M}_{\text{spiral}}(x, y) = \begin{cases} 1 & \text{ako je } x \in \left[\frac{S_x}{2} - \frac{L_{\text{center}}}{2}, \frac{S_x}{2} + \frac{L_{\text{center}}}{2}\right] \text{ i } y \in \left[\frac{S_y}{2} - \frac{L_{\text{center}}}{2}, \frac{S_y}{2} + \frac{L_{\text{center}}}{2}\right] \\ 0 & \text{u suprotnom} \end{cases} \quad (3-24)$$

gdje su S_x i S_y dimenzije k -prostora u jednadžbi 3-24. Nakon uzorkovanja središta, generiraju se spiralni krakovi. Svaki radijalni korak r generira nove točke na spiralnoj putanji. Točke se generiraju po spiralnoj formuli u jednadžbama 3-25 i 3-26:

$$x_i = x_{\text{center}} + r \cdot \cos \left(\frac{2\pi i}{N_{\text{arms}}} + c \cdot r \right) \quad (3-25)$$

$$y_i = y_{\text{center}} + r \cdot \sin \left(\frac{2\pi i}{N_{\text{arms}}} + c \cdot r \right) \quad (3-26)$$

gdje su x_{center} i y_{center} koordinate središta, dok su x_i i y_i koordinate nove točke na spiralnoj putanji.

3.4.3 Radijalna maska

Radijalne maske koriste uzorak nalik zvijezdi, s uzorkovnim linijama koje se šire od središta k -prostora. Te su linije ravnomjerno raspoređene, osiguravajući pravednu reprezentaciju cijelog k -prostora. Radijalne maske su osobito učinkovite u slučaju artefakata pokreta [46], jer češće uzorkuju središte k -prostora.

Radijalna maska za nedovoljno uzorkovanje $\mathbf{M}_{\text{radial}}$ oblika (D, H, W) definirana je jednadžbom 3-27:

$$\mathbf{M}_{\text{radial}}(h, w) = \begin{cases} 1 & \text{ako } \exists i \text{ takav da } \text{line}(i) \text{ prolazi kroz } (h, w) \\ 0 & \text{u suprotnom} \end{cases} \quad (3-27)$$

gdje funkcija $\text{line}(i)$ opisuje radijalnu liniju u k -prostoru:

$$\text{line}(i) = \left[x = c_x + r \cdot \cos \left(\frac{i\pi}{N} \right), y = c_y + r \cdot \sin \left(\frac{i\pi}{N} \right) \right] \quad (3-28)$$

U jednadžbi 3-28, (c_x, c_y) koordinate su središta k -prostora, r je radijus linije u k -prostoru, i označava indeks radijalne linije i N je ukupan broj radijalnih linija.

3.4.4 Nasumičan odabir maske

Maska za nedovoljno uzorkovanje $\mathbf{M}_{\text{random}}$ odabire se nasumično iz skupa maski kako bi se izbjeglo pretreniranje modela prikazano izrazom 3-29:

$$\mathbf{M}_{\text{random}} = \begin{cases} \mathbf{M}_{\text{cart}} & \text{sa vjerojatnošću } p_{\text{cart}} \\ \mathbf{M}_{\text{spiral}} & \text{sa vjerojatnošću } p_{\text{spiral}} \\ \mathbf{M}_{\text{radial}} & \text{sa vjerojatnošću } p_{\text{radial}} \end{cases} \quad (3-29)$$

gdje vrijedi prema izrazu 3-30:

$$p_{\text{cart}} + p_{\text{spiral}} + p_{\text{radial}} = 1 \quad (3-30)$$

Ovaj postupak odabira može se predstaviti funkcijom nasumičnog izbora definiranom jednadžbom 3-31:

$$\mathbf{M}_{\text{random}} = \lambda_{\text{mask_type}} (\{\mathbf{M}_{\text{cart}}, \mathbf{M}_{\text{spiral}}, \mathbf{M}_{\text{radial}}\}, \{p_{\text{cart}}, p_{\text{spiral}}, p_{\text{radial}}\}) \quad (3-31)$$

gdje $\lambda_{\text{mask_type}}$ označava funkciju koja vrši nasumičan odabir temeljen na danim vjerojatnostima p_{cart} , p_{spiral} i p_{radial} .

4 REZULTATI

Ovo poglavlje bavi se praktičnom primjenom predloženog difuzijskog modela. Opisuju se korišteni skupovi podataka, uspoređuje se model s tradicionalnim i najnovijim istraživanjima u području, testira se njegova robusnost u različitim uvjetima i procjenjuje njegovu učinkovitost kroz kvalitativne i kvantitativne analize.

4.1 Skupovi podataka

U svrhu ovog diplomskog rada korištena su dva skupa podataka: skup podataka IXI [47] i skup podataka fastMRI [48]. Svi skupovi su javno dostupni i s dopuštenjem za korištenje u istraživačke i obrazovne svrhe.

Eksperimenti za treniranje i evaluaciju odrađeni su na aksijalnim presjecima slika mozga za precizniju usporedbu između korištena dva skupa podataka. Na slikama iz skupa podataka IXI provedena je obrada gdje se broj slojeva svake T_1 -ponderirane i T_2 -ponderirane slike smanjio s 256 na 21. Taj smanjeni broj slojeva obuhvaća slojeve s najboljim aksijalnim pogledom na snimljeni mozak kako bi se postigla što bolja usporedba sa skupom podataka fastMRI u kasnijim evaluacijama. Nakon obrade slojeva, slike skupa IXI pretvorene su u k -prostorne podatke.

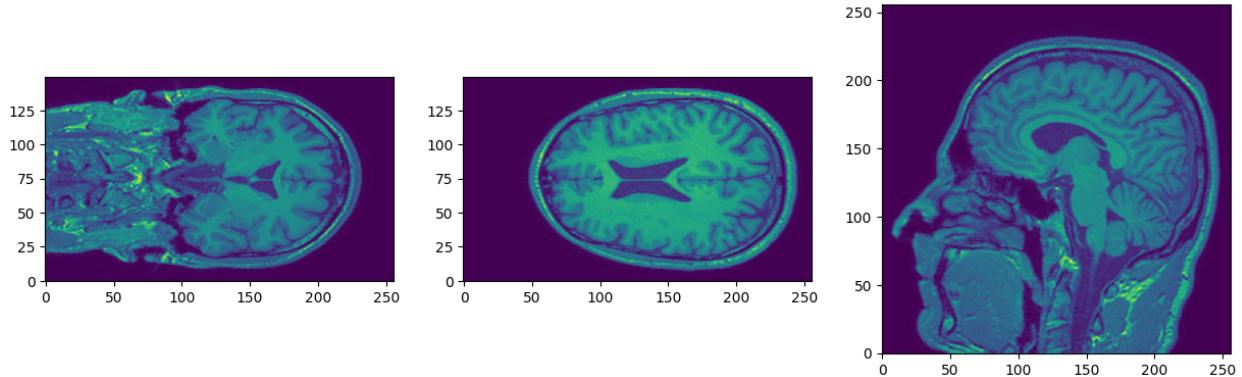
Skupovi podataka podijeljeni su u tri podskupa: skup za učenje (engl. *training*), skup za validaciju (engl. *validation*) i skup za testiranje (engl. *test set*). Skup za učenje poučava model o odnosu između ulaznih podataka i očekivanih izlaza. On služi za treniranje parametara mreže. Skup za validaciju koristi se za podešavanje hiperparametara modela, poput dubine mreže ili veličine konvolucijskih filtera. Skup za validaciju također pomaže u sprječavanju pretreniranja (engl. *overfittinga*), odnosno situacije u kojoj model pamti podatke za učenje, ali gubi sposobnost generalizacije. Na kraju, skup za testiranje koristi se za objektivnu evaluaciju konačnog modela, procjenjujući njegovu učinkovitost u radu s dosad neviđenim podacima.

Svi skupovi podataka sadrže MRI snimke s kompleksnim vrijednostima. Skup za učenje sadrži 168 uzoraka, skupovi za validaciju 48 i skup za testiranje sadrži 24 snimaka. Zbog računalne zahtjevnosti i kompleksnosti, u svrhu treniranja i evaluiranja slika skupa podataka

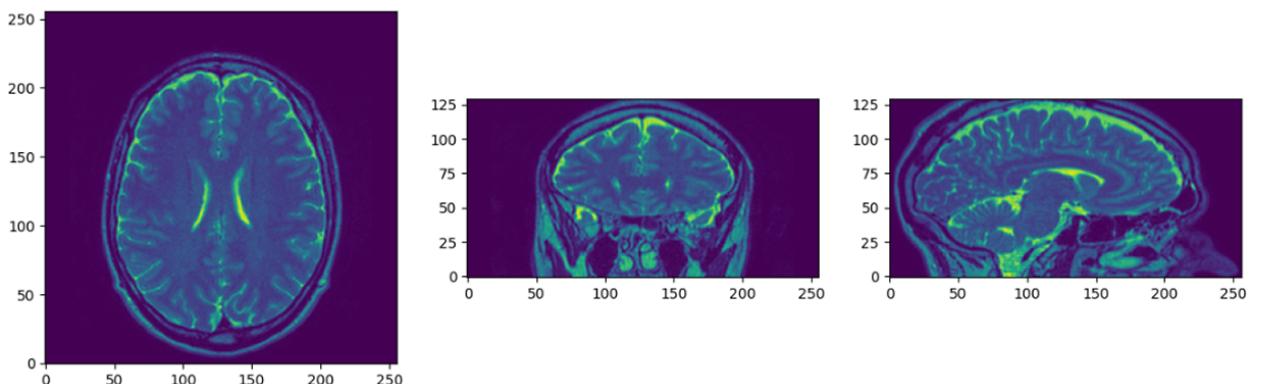
fastMRI, korištene su slike s 4, 8 i 12 zavojnica.

4.1.1 Skup podataka IXI

Skup podataka IXI sastoji se od gotovo 600 MRI slika od normalnih, zdravih ispitanika. Protokol za snimanje MRI slika za svakog ispitanika uključuje: T_1 , T_2 i PD-ponderirane slike, MRA slike i DWI (15 smjerova) [47]. Treniranje modela odvijalo se na T_1 i T_2 -ponderiranim slikama. Ove slike pohranjene su u NIfTI formatu, čije su dimenzije $256 \times 256 \times 150$ u slučaju T_1 -ponderiranih slika i $256 \times 256 \times 130$ u slučaju T_2 -ponderiranih slika. Slike 4.1 i 4.2 prikaz su vizualiziranih NIfTI podataka.



Slika 4.1. Redom: koronalni, aksijalni i sagitalni prikaz T_1 -ponderirane slike mozga IXI skupa podataka.



Slika 4.2. Redom: aksijalni, koronalni i sagitalni prikaz T_2 -ponderirane slike mozga IXI skupa podataka.

NIfTI (engl. *Neuroimaging Informatics Technology Initiative*) format standardni je format za pohranu i distribuciju medicinskih slika posebno u području neuroznanosti. Ovaj

format koristi se za 3D volumetrijske podatke poput MRI i CT skenova i PET slika. NIfTI format omogućava pohranu samih slika, kao i metapodataka poput orijentacije, rezolucije, prostornog položaja i drugih informacija o slici. Pohrana samih slika nalazi se u blokovima podataka, dok se metapodaci nalaze u glavnom zaglavlju. Ove datoteke obično imaju ekstenziju ".nii" ili ".nii.gz", pri čemu ".nii.gz" označava da je datoteka stisнута GZIP kompresijom. Datoteke s ovim ekstenzijama sadrže i glavno zaglavlje i blokove podataka, dok datoteke spremljene s ekstenzijom ".hdr" i ".img" sadrže zaglavlje i blokove podataka, ali odvojene [49].

Pretvorba NIfTI podataka u k -prostor za svaku slojnu dimenziju z može se opisati dvo-dimenzionalnom Fourierovom transformacijom po prostornim koordinatama x i y . Neka je $I(x, y, z)$ prostorni signal, gdje su x i y prostorne koordinate, a z dimenzija sloja (engl. *slice*) volumena. k -prostor $K(u, v, z)$ se dobiva primjenom Fourierove transformacije prema matematičkoj jednadžbi 4-1:

$$K(u, v, z) = \mathcal{F}\{I(x, y, z)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} I(x, y, z) \cdot e^{-2\pi i(ux+vy)} dx dy \quad (4-1)$$

Kako bi se ispravno rasporedile frekvencijske komponente za vizualizaciju i daljnju obradu, koristi se centriranje frekvencijskih komponenti pomoću funkcija S_{fft} definirane jednadžbom 4-2 i S_{ifft} definirane jednadžbom 4-3:

$$K_{\text{shifted}}(u, v, z) = S_{\text{fft}}(\mathcal{F}\{S_{\text{ifft}}(I(x, y, z))\}) \quad (4-2)$$

$$K(u, v, z) = S_{\text{ifft}}(\mathcal{F}^{-1}\{S_{\text{fft}}(K_{\text{shifted}}(u, v, z))\}) \quad (4-3)$$

Gdje je S_{fft} definiran jednadžbom 4-4 i S_{ifft} definiran jednadžbom 4-5:

$$S_{\text{fft}}(K(u, v)) = K_{\text{shifted}}(u, v) = K\left(u + \frac{N_u}{2}, v + \frac{N_v}{2}\right) \quad (4-4)$$

$$S_{\text{ifft}}(K_{\text{shifted}}(u, v)) = K(u, v) = K_{\text{shifted}}\left(u - \frac{N_u}{2}, v - \frac{N_v}{2}\right) \quad (4-5)$$

$K(u, v)$ predstavlja frekvencijsku komponentu na koordinatama (u, v) , $K_{\text{shifted}}(u, v)$ predstavlja komponentu nakon primjene S_{fft} . N_u i N_v su dimenzije signala u frekvencijskoj domeni duž osi u i v . Rezultirajući $K(u, v, z)$ predstavlja k -prostor podataka.

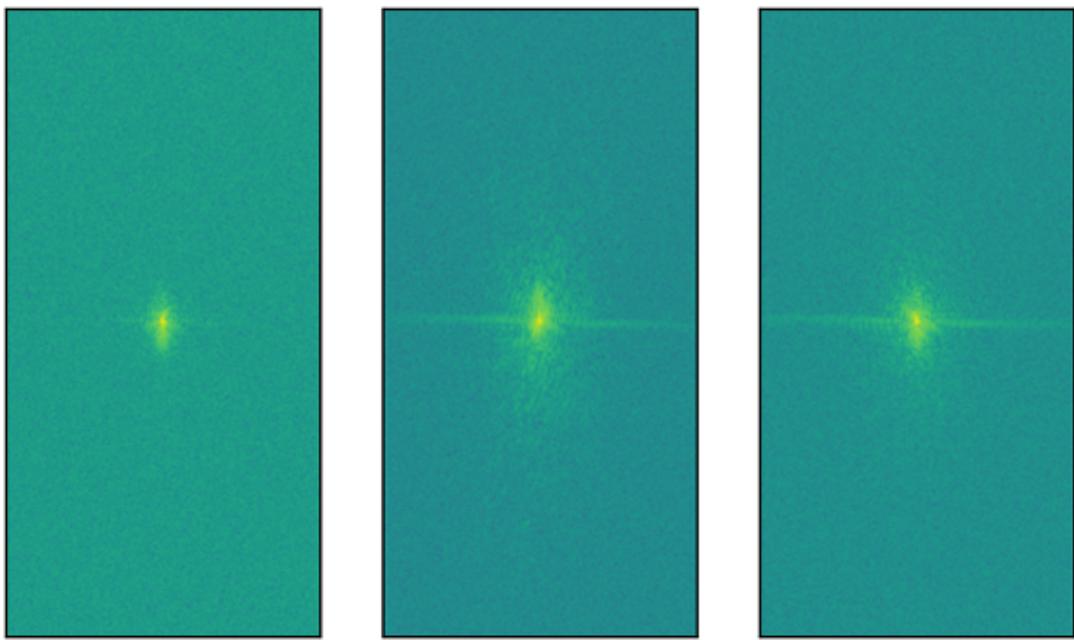
4.1.2 Skup podataka fastMRI

Skup podataka fastMRI koji pruža NYU Langone sastoji se od sirovih k -prostornih podataka u nekoliko podskupina podataka (koljeno, mozak, prostata i grudi). Korišteni skup u svrhu treniranja i evaluacije je podskup mozga. Podaci iz 6.970 potpuno uzorkovanih MRI mozgova dobiveni su na jačini magnetskog polja od 1,5 i 3 T. Sirovi skup podataka uključuje aksijalne T_1 -ponderirane, T_2 -ponderirane i FLAIR slike [48]. U tabici 4.1 nalaze se točni podaci ovoga skupa. Za treniranje su se koristili T_1 -ponderirani i T_2 -ponderirani podaci skupa podataka mozga. Zbog veličine skupa podataka i očuvanja resursa, broj subjekata korištenih za treniranje modela bio je ograničen.

Tablica 4.1. Raspodjela podataka po kategorijama i jačini magnetskog polja skenera [48].

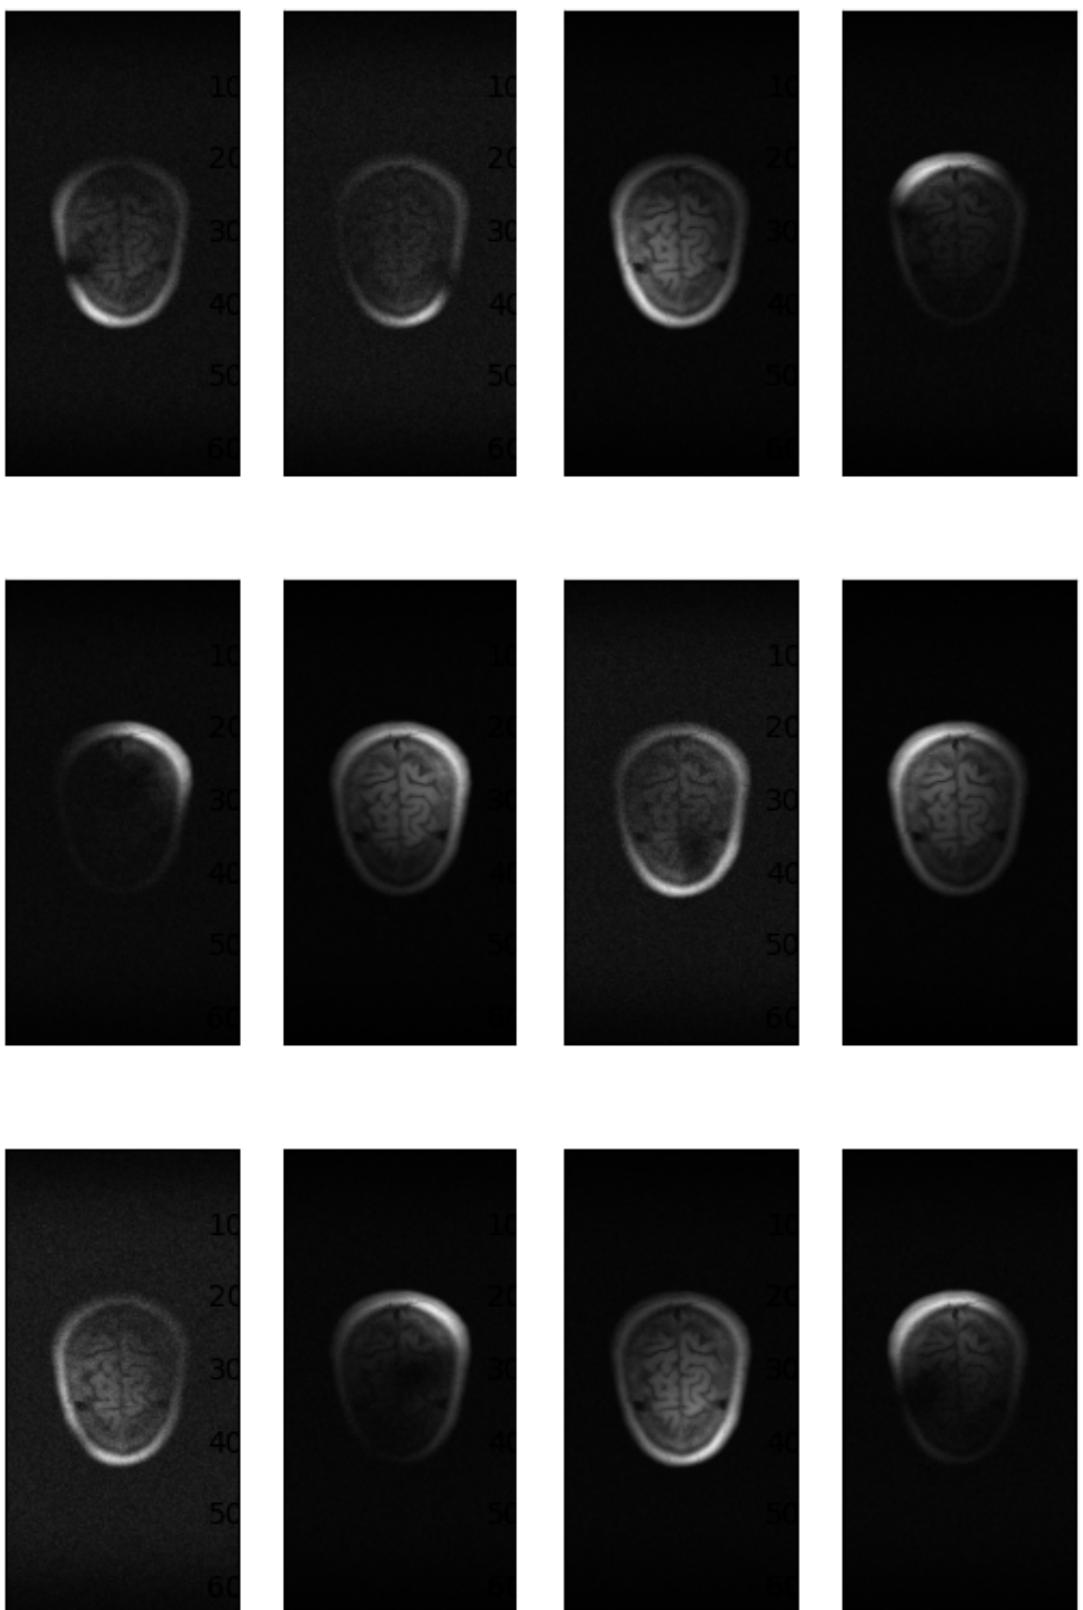
Jačina magnetskog polja	1,5 T	3 T	Ukupno
T_1 -ponderirane slike	382	409	791
T_1 -ponderirane slike s kontrastom	849	646	1495
T_2 -ponderirane slike	1655	2524	4179
FLAIR	126	411	537
Ukupno	3012	3990	7002

Skup podataka fastMRI pohranjen je u formatu k -prostornog tenzora. Ovaj četvero-dimenzionalni tenzor sadrži kompleksne vrijednosti koje predstavljaju MRI volumen u frekvencijskom prostoru. Vizualizacija sirovih k -prostornih podataka prikazana je na slici 4.3. Dimenzije u slučaju fastMRI podataka za T_1 i T_2 -ponderirane slike, $16 \times 12 \times 640 \times 320$, predstavljaju broj slojeva, broj višestrukih zavojnica (engl. *multi-coil*) te širinu i visinu svakog sloja u k -prostoru. Dimenzije fastMRI slika korištene za testiranje i evaluaciju bile su $16 \times x \times 246 \times 130$ gdje x predstavlja broj zavojnica. Korištene su slike s 4, 8 i 12 zavojnica.



Slika 4.3. Prikaz k -prostora fastMRI slika.

Za prikaz prostorno-frekvencijskih informacija sadržanih u k -prostornim podacima skupa podataka fastMRI, potrebno je primijeniti inverznu Fourierovu transformaciju. Ovaj proces pretvara kompleksne k -prostorne podatke u kompleksnu sliku, čija se absolutna vrijednost koristi za vizualizaciju realnog dijela slike. Višestruke zavojnice prikupljaju jedinstvene k -prostorne podatke, koji se zatim kombiniraju kako bi se dobila potpuna i visokokvalitetna rekonstrukcija MRI slike. Na slici 4.4 prikazani su skupljeni podaci po zavojnicama.



Slika 4.4. Vizualizacija podataka fastMRI slike s 12 zavojnica.

4.2 Objektivna metrika kvalitete slika

Za brzu procjenu učinkovitosti metoda rekonstrukcije potrebni su mjerni pokazatelji koji kvantificiraju kvalitetu rekonstruiranih slika u odnosu na originalnu, potpuno uzorkovanu sliku. Dva često korištena metrička pokazatelja u kontekstu rekonstrukcije MRI slika su omjer vršnog signala i šuma (engl. *Peak Signal-to-Noise Ratio*, PSNR) i strukturna sličnost (engl. *Structural Similarity Index Measure*, SSIM) koji su korišteni kao metrike i u ovome radu. Ove metrike omogućuju brzu kvantitativnu usporedbu kvalitete slika koje proizvode različite metode rekonstrukcije bez potrebe za pregledavanjem svake slike pojedinačno.

4.2.1 Omjer vršnog signala i šuma

Omjer vršnog signala i šuma, PSNR, objektivna je metrika kvalitete slike koja se široko koristi u području obrade slike. To je logaritamska mjera maksimalne moguće snage signala u odnosu na snagu šuma koji ga kvari. U slučaju obrade slike, PSNR je mjera razlike između izvorne, nepromijenjene slike i rekonstruirane slike. PSNR slike, izražen u decibelima (dB), opisan je matematičkom jednadžbom 4-6:

$$PSNR = 20 \cdot \log_{10} \frac{MAX_I}{\sqrt{MSE}} \quad (4-6)$$

gdje MAX_I predstavlja maksimalnu vrijednost točke prisutne u slici. Srednja kvadratna pogreška (engl. *Mean Squared Error*, MSE) izračunava se kao prosjek kvadrata razlike između vrijednosti piksela izvorne slike i rekonstruirane slike, definirano u jednadžbi 4-7:

$$MSE = \frac{1}{MN} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |O(i, j) - R(i, j)|^2, \quad (4-7)$$

gdje $O(i, j)$ i $R(i, j)$ predstavljaju vrijednosti izvorne i rekonstruirane slike na mjestu točke (i, j) , a M i N su dimenzije slike. Ova formula srednje kvadratne razlike uzima apsolutnu vrijednost razlike između vrijednosti točaka budući da su slike s kompleksnim vrijednostima.

Što je PSNR veći, to je rekonstruirana slika sličnija izvornoj slici. Međutim, nedostatak PSNR-a je to što se temelji na razlikama piksel-po-piksel (engl. *pixel-to-pixel*) između slika, kao što je vidljivo u jednadžbi 4-7. Zbog toga ne uzima u obzir nikakve promjene u

strukturnim informacijama ili vizualnoj percepцији.

4.2.2 Strukturalna sličnost

Strukturalna sličnost, SSIM, za razliku od PSNR-a i MSE-a koji se usredotočuju na razlike u pojedinačnim točkama uzima u obzir promjene u strukturalnim informacijama slike, što se često bolje slaže s načinom na koji ljudi percipiraju kvalitetu slike. SSIM indeks se kreće od 0 (potpuno različite slike) do 1 (identične slike). Općenito, viša vrijednost SSIM-a ukazuje na bolju rekonstrukciju jer su strukture u rekonstruiranoj slici vjernije reproducirane.

SSIM indeks između originalne slike o i rekonstruirane slike r opisan jednadžbom 4-8 može se izračunati kao:

$$\text{SSIM}(o, r) = \frac{(2\mu_o\mu_r + c_1)(2\sigma_{or} + c_2)}{(\mu_o^2 + \mu_r^2 + c_1)(\sigma_o^2 + \sigma_r^2 + c_2)} \quad (4-8)$$

gdje je μ_o prosjek originalne slike, μ_r prosjek rekonstruirane slike, σ_o^2 varijanca originalne slike. σ_r^2 predstavlja varijancu rekonstruirane slike, σ_{or} je kovarijanca originalne i rekonstruirane slike $c_1 = (0.01L)^2$ i $c_2 = (0.03L)^2$.

Iako PSNR i SSIM pružaju objektivne načine mjerjenja kvalitete rekonstrukcije MRI slika, imaju svoja ograničenja. Ponekad se ove metrike ne podudaraju u potpunosti s ljudskom procjenom kvalitete slike. Također, postoji mogućnost da ne otkriju sve elemente degradacije slike i time dobre vrijednosti ne jamče nužno visokokvalitetnu rekonstrukciju. Zbog toga je, uz kvantitativnu analizu, važno uključiti i subjektivnu evaluaciju slike, koja uzima u obzir oštrinu, kontrast i vidljivost detalja—elemente koje objektivne metrike možda neće u potpunosti obuhvatiti.

4.3 Kvantitativna analiza

Kako bi se procijenile performanse predloženog difuzijskog modela za akceleriranu rekonstrukciju MRI slika, uspoređen je s četiri različita modela: LORAKS [50], DiffRecon [51], AdaDiff [14] i DDPM [12].

4.3.1 Odabrane metode za usporedbu

Model LORAKS (engl. *Low-rank modeling of local k-space neighborhoods with parallel imaging data*) tradicionalna je metoda rekonstrukcije MRI slika. Implementirana je auto-kalibrirana rekonstrukcija niskog ranga [50] gdje su radijus susjedstva u k -prostoru i rang matrice sustava odabrani $(2, 6)$ za skup podataka IXI i $(2, 30)$ za skup podataka fastMRI [52]. LORAKS je javno dostupan za edukacijske svrhe [53].

Model DiffRecon bezuvjetni je difuzijski model s arhitekturom i funkcijama gubitka opisanim u radu Penga i suradnika [51]. Hiperparametri su postavljeni na: stopu učenja 1×10^{-4} , veličinu koraka $k = 1$, $T/k = 4000$ difuzijskih koraka, 300 epoha za treniranje; 400 grubih i 20 finih iteracija obrnute difuzije i projekcije konzistentnosti podataka za zaključivanje [51]. Kodu je pristupano s javnog repozitorija [54].

Model AdaDiff (engl. *Adaptive Diffusion Priors for Accelerated MRI Reconstruction*) adaptivni je difuzijski prior za MRI rekonstrukciju. AdaDiff koristi učinkovit difuzijski prior treniran putem mapiranja tijekom velikih koraka obrnute difuzije [14]. Hiperparametri za AdaDiff su: stopa učenja 6×10^{-3} , 300 epoha, veličina koraka $k = 125$, $T/k = 8$ difuzijskih koraka za treniranje; 8 iteracija koje kombiniraju korak obrnute difuzije i projekciju konzistentnosti podataka za brzu difuziju te stopa učenja 1×10^{-3} i 1000 iteracija za prilagodbu apriornog znanja. Kod se nalazi na javno dostupnom repozitoriju [55].

Model DDPM (engl. *Denoising diffusion probabilistic models*) nadzirana je difuzijska rekonstruksijska metoda. DDPM je treniran s potpuno uzorkovanim MRI slikama te slijedi novi pristup uzorkovanju u k -prostoru tijekom zaključivanja, koji su uveli Peng i suradnici [12]. Koristi se 500 koraka naprijed i natrag u procesu difuzije tokom treniranja, tj. tijekom učenja modela. Kod je javno dostupan u objavljenom repozitoriju [56].

Predloženi model za akceleriranu rekonstrukciju temeljen na dubokim difuzijskim modelima treniran je na 300 epoha, 1000 iteracija u procesu difuzije, akceleracijskog faktora $R = 4$, s vrijednostima $\beta_{\text{start}} = 1 \times 10^{-4}$, $\beta_{\text{end}} = 0.02$ i optimizacijskom funkcijom Adam = 0.005. Za treniranje i demonstraciju su korištene četiri grafičke kartice NVIDIA A40 s kapacitetom memorije od 48 GB.

4.3.2 Hiperparametri predloženog modela i treniranje

Treniranje predloženog modela uključuje podešavanje hiperparametara modela i korištenje specifičnih postupaka i tehnika treniranja. Hiperparametri su vrijednosti za podešavanje i optimizaciju tijekom procesa treniranja modela koje utječu na arhitekturu mreže, proces učenja i, posljedično, performanse. Glavni hiperparametri predloženog modela su akceleracijski faktor R , , vrijednosti Gaussovog šuma β_{start} i β_{end} , veličina grupe koje predaju podatke (engl. *batch size*), dubina U-net mreže i broj radnih procesa (engl. *number of workers*).

S obzirom na to da se predloženi model bavi problemom akcelerirane rekonstrukcije MRI slika, posebna je pažnja posvećena vremenu rekonstrukcije i kvaliteti rekonstruiranih slika. Odabrani akceleracijski faktor je $R = 4$. Povećanjem akceleracijskog faktora agresivnije se nedovoljno uzorkuje slika (engl. *undersampling*) što dovodi do smanjenja kvalitete rekonstrukcije. Razlog tomu je činjenica da algoritam rekonstrukcije radi s manje podataka, što dovodi do povećanog broja artefakata poduzorkovanja, gubitka prostorne rezolucije i pojačanja šuma. Odabранe vrijednosti Gaussovog šuma su $\beta_{\text{start}} = 1 \times 10^{-4}$ i $\beta_{\text{end}} = 0.02$. Povećanjem vrijednosti Gaussovog šuma β_{start} i povećanjem vrijednosti β_{end} povećava se vrijeme izvođenja i usporava rekonstrukcija slike, jer algoritam mora obraditi više pošumljenih podataka. Smanjenjem ovih vrijednosti ubrzava se vrijeme izvođenja i ubrzava rekonstrukcija slike.

Odabranu dubinu U-Net mreže je 3×3 . Iako daljnje povećanje dubine poboljšava kvalitetu slike, značajno povećava i vrijeme izvođenja. To povećano vrijeme izvođenja u kombinaciji sa smanjenim prinosima od povećanja dubine mreže čini proces manje učinkovitim. Veličina predanih k -prostornih podataka, tj. slike, također je utjecala na vrijeme rekonstrukcije, gdje se povećanjem veličine slike linearno povećalo i vrijeme rekonstrukcije. Doduše, smanjenjem k -prostornih podataka smanjuje se i kvaliteta slike, što je očekivano. Sukladno tome, s većim brojem aktivnih radnih procesa pri izvođenju koda poboljšava se, odnosno smanjuje, vrijeme potrebno za rekonstrukciju slike.

U tablici 4.2 prikazana je usporedba različitih ranije opisanih hiperparametara predloženog modela za rekonstrukciju MRI slika tijekom treniranja.

Tablica 4.2. Performanse rekonstrukcije za različite skupove podataka i hiperparametara predloženog modela.

Skup podataka	Broj zavojnica	Veličina slike (MB)	Vrijeme treniranja (dara)	Akceleracijski faktor	Dubina mreže	Prosječni PSNR	Prosječni SSIM
IXI - T ₁	-	13	1.2	4x	3x3	42.1	98.7
IXI - T ₁	-	13	0.8	8x	3x3	32.6	93.5
IXI - T ₁	-	13	2.1	4x	5x5	45.7	99.1
IXI - T ₁	-	13	2.9	8x	5x5	33.2	95.2
fastMRI - T ₁	4	108	4.3	4x	3x3	38.0	96.2
fastMRI - T ₁	4	108	5	4x	5x5	41.6	98.5
fastMRI - T ₁	8	306	8.9	8x	3x3	37.7	95.7
fastMRI - T ₁	12	306	13.6	8x	3x3	38.3	98.8
IXI - T ₂	-	11	1.1	4x	3x3	45.8	97.3
IXI - T ₂	-	11	1.7	4x	5x5	39.7	98.0
fastMRI - T ₂	4	102	4.1	4x	3x3	40.3	96.7
fastMRI - T ₂	4	102	5.7	4x	5x5	36.1	94.1
fastMRI - T ₂	8	298	8.7	8x	3x3	44.2	97.2
fastMRI - T ₂	12	298	13.4	8x	3x3	45.4	99.2

Nakon provedenih testiranja predloženog modela na skupovima podataka i analize promjene vremena i kvalitete slika, za ostale metode je korišten faktor ubrzanja $R = 4$ i broj zavojnica je postavljen na četiri.

U tablici 4.3 uspoređene su performanse predloženog modela s performansama modela LORAKS, DiffRecon, AdaDiff i DDPM na skupu podataka IXI. Najbolji rezultati performansi su potamnjeni.

Tablica 4.3. Usporedba performansi različitih modela rekonstrukcije na skupu podataka IXI.

		LORAKS	DiffRecon	AdaDiff	DDPM	Predloženi model
T ₁	PSNR	28.0±1.7	38.2±0.8	39.9±0.4	40.3±1.5	42.1±1.3
	SSIM	77.4±4.5	97.5±0.8	94.5±1.4	96.8±0.9	98.7±0.6
T ₂	PSNR	28.5±2.1	40.4±0.9	42.2±1.1	43.6±1.0	45.8±1.5
	SSIM	73.2±3.8	96.2±0.7	97.0±0.4	95.3±1.6	97.3±0.5

U tablici 4.4 prikazane su vrijednosti performansi različitih metoda na skupu podataka fastMRI. Metrike evaluacije korištene za usporedbu su PSNR i SSIM. Modeli su evaluirani prema podešenim hiperparametrima objašnjjenima u 4.3.1 i slikama jednakih rezolucija. Najbolji rezultati performansi su potamnjeni.

Tablica 4.4. Usporedba performansi različitih modela rekonstrukcije na skupu podataka fastMRI.

		LORAKS	DiffRecon	AdaDiff	DDPM	Predloženi model
T ₁	PSNR	34.4±2.0	36.7±1.1	37.6±1.3	37.7±1.0	38.0±0.8
	SSIM	84.3±2.6	91.5±4.1	94.4±2.1	95.4±1.6	96.2±1.1
T ₂	PSNR	32.9±0.8	35.9±0.6	37.8±0.6	39.5±0.8	40.3±1.5
	SSIM	93.4±0.8	94.0±2.5	94.4±0.6	97.7±0.5	96.7±0.6

Predloženi model daje bolje rezultate od tradicionalnog modela LORAKS i uspješno konkurira suvremenijim metodama u području. U IXI skupu podataka, predloženi model postiže najviše performanse među konkurentnim metodama u T₁-ponderiranim i T₂-ponderiranim slikama, iako DDPM ima slične performanse na istim kontrastima. Metode AdaDiff i DiffRecon imaju također slične SSIM vrijednosti kao i predloženi model. U fastMRI skupu podataka, predloženi model nadmašuje konkurentne metode za T₁-ponderirane slike, dok je za T₂-ponderirane slike druga najbolja. Za T₁-ponderirane slike na slikama fastMRI skupa podataka, DDPM ponovno pokazuje slične vrijednosti i nadmašuje predloženi model za T₂-ponderirane slike. Pad vrijedosti PSNR-a i SSIM-a pri rekonstrukciji skupa podataka fastMRI očekivan je u svim metodama zbog rekonstrukcije kompleksnijih i većih podataka.

U prosjeku, za T₁-ponderirane slike, predloženi model nadmašuje tradicionalnu metodu

LORAKS za 18.3 dB PSNR i 19.3% SSIM na skupu podataka IXI te za 1.7 dB PSNR i 9.46% SSIM na skupu podataka fastMRI. Predloženi model u prosjeku nadmašuje model DiffRecon za 3.9 dB PSNR i 1.6% SSIM na skupu podataka IXI te za 1.4 dB PSNR i 3.8% SSIM na skupu podataka fastMRI, model AdaDiff za 2.7 dB PSNR i 5.2% SSIM na skupu podataka IXI te za 0.3 dB PSNR i 2.3% SSIM na skupu podataka fastMRI, i model DDPM za 2.4 dB i 1.7% SSIM na skupu podataka IXI te za 0.5 dB PSNR i 1.6% SSIM na skupu podataka fastMRI.

U prosjeku, za T_2 -ponderirane slike, predloženi model nadmašuje tradicionalnu metodu LORAKS za 19.3 dB PSNR i 27.2% SSIM na skupu podataka IXI te za 5.4 dB PSNR i 2.8% SSIM na skupu podataka fastMRI. Predloženi model u prosjeku nadmašuje model DiffRecon za 6.8 dB PSNR i 0.9% SSIM na skupu podataka IXI i za 3.2 dB PSNR i 2.1% SSIM na skupu podataka fastMRI, model AdaDiff za 3.2 dB PSNR i 0.3% SSIM na skupu podataka IXI te za 2.4 dB PSNR i 2.2% SSIM na skupu podataka fastMRI, i model DDPM za 2.7 dB i 2.3% SSIM na skupu podataka IXI te za 0.1 dB PSNR i -1.1% SSIM na skupu podataka fastMRI, tj. ne nadmašuje metodu DDPM u SSIM vrijednosti za T_2 -ponderirane slike.

Poboljšanje u metrikama PSNR i SSIM računa se kao razlika između vrijednosti dvaju modela za svaki uzorak. Poboljšanje u PSNR između modela A i B za uzorak i definirano je jednadžbom 4-9:

$$\Delta \text{PSNR}_i = \text{PSNR}_{A,i} - \text{PSNR}_{B,i} \quad (4-9)$$

gdje $\text{PSNR}_{A,i}$ predstavlja PSNR vrijednost modela A za uzorak i , $\text{PSNR}_{B,i}$ je PSNR vrijednost modela B za uzorak i .

Poboljšanje u SSIM između modela A i B za uzorak i definirano je jednadžbom 4-10:

$$\Delta \text{SSIM}_i = \text{SSIM}_{A,i} - \text{SSIM}_{B,i} \quad (4-10)$$

gdje $\text{SSIM}_{A,i}$ predstavlja SSIM vrijednost modela A za uzorak i i $\text{SSIM}_{B,i}$ je SSIM vrijednost modela B za uzorak i .

Prosječno poboljšanje PSNR i SSIM vrijednosti definirane su formulama 4-11 i 4-12 kao

prosjek svih pojedinačnih poboljšanja za N uzoraka.

$$\overline{\Delta \text{PSNR}} = \frac{1}{N} \sum_{i=1}^N \Delta \text{PSNR}_i \quad (4-11)$$

$$\overline{\Delta \text{SSIM}} = \frac{1}{N} \sum_{i=1}^N \Delta \text{SSIM}_i \quad (4-12)$$

4.3.3 Analiza vremena rekonstrukcije

Procjena kvalitete rekonstrukcije ovisi o vremenu obrade modela. Budući da je cilj ubrzati proces rekonstrukcije MRI slika, jedan od ključnih faktora u ocjenjivanju performansi ovih modela je vrijeme obrade.

Predloženi model značajno smanjuje vrijeme rekonstrukcije slika skupa podataka IXI u usporedbi s drugim testiranim modelima. Razlog tome je obrada NIfTI podataka i prelazak u k -prostor naspram tradicionalnog i suvremenih modela koji obrađuju NIfTI podatke. Značajna razlika u veličini podataka gdje su podaci $3.7\times$ manji od originalnog formata po hrane daje bitnu prednost predloženome modelu. Doduše, pri obradi velikih k -prostornih podataka skupa podataka fastMRI, predloženi model rekonstruira slike sporije od DDPM-a, ali još uvijek brže od druga tri testirana modela. Prema tome, prednost predloženog modela ističe se pri rekonstrukciji podataka iz formata koji nisu zadani u k -prostoru, iako zadovoljava i svojom brzinom rekonstrukcije većih k -prostornih podataka. Tablica 4.5 prikazuje prosječno vrijeme rekonstrukcije testiranih modela. Najbolja vremena rekonstrukcije su podebljana.

Tablica 4.5. Prosječno vrijeme računanja (u sekundama) za različite modele rekonstrukcije na skupovima podataka IXI i fastMRI.

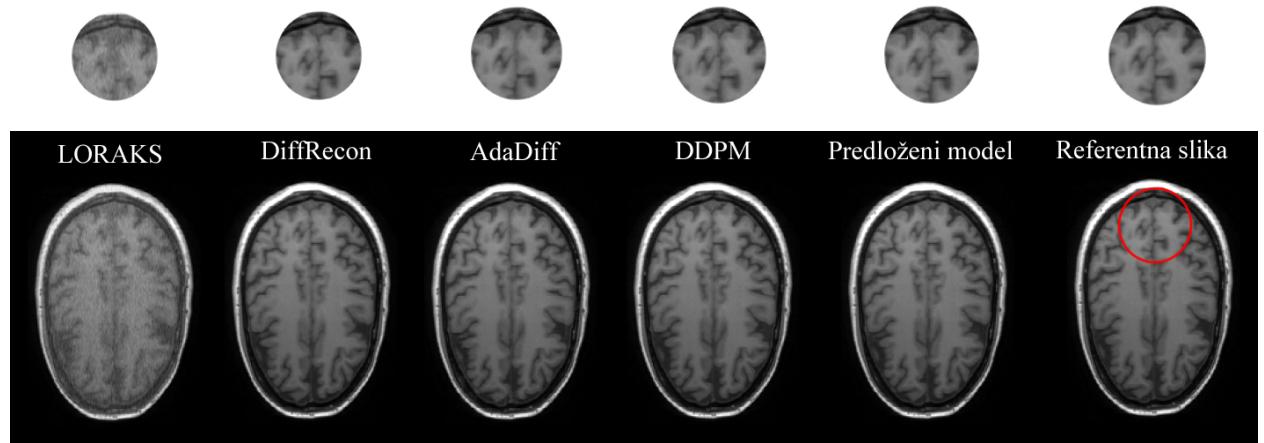
Model	IXI	fastMRI
LORAKS	471.58 ± 9.32	1189.8 ± 36.79
DiffRecon	57.13 ± 7.51	82.24 ± 4.78
AdaDiff	54.86 ± 3.89	88.14 ± 6.08
DDPM	29.75 ± 3.92	42.56 ± 2.53
Predloženi model	5.32 ± 1.62	49.72 ± 3.41

Vrijeme po rekonstrukciji naspram tradicionalnog modela LORAKS smanjeno je za više od sedam minuta u slučaju skupa podataka IXI, s otprilike 471.58 sekundi na 5.32 sekunde, i 19 minuta u slučaju skupa podataka fastMRI. Ovo smanjenje, koje je višeg reda veličine, je značajno poboljšanje, osobito prilikom obrade velikih skupova podataka. Iako je predloženi model sporiji od DDPM-a, rezultati rekonstrukcije MRI slika bili su bolji za predloženi model kao posljedica kompromisa između točnosti rekonstrukcije i brzine.

4.4 Kvalitativna analiza

Osim kvantitativne analize, provedena je i kvalitativna analiza rekonstrukcije slika od strane predloženog modela, modela LORAKS, modela DiffRecon, modela AdaDiff i modela DDPM. Njome se pruža uvid u vizualnu kvalitetu rekonstruiranih slika koju objektivne metrike kao što su PSNR i SSIM ne obuhvaćaju.

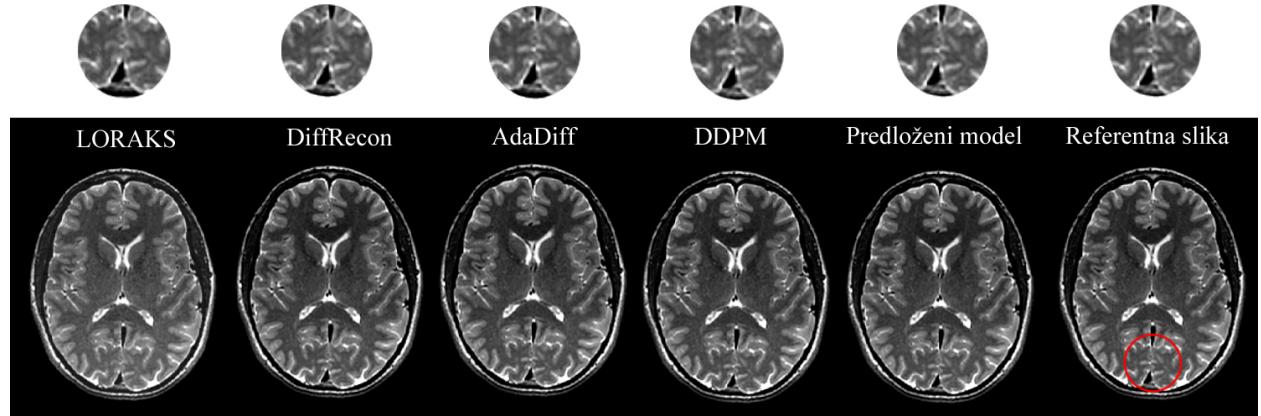
Reprezentativne rekonstrukcije na T_1 -ponderiranim podacima skupa podataka IXI prikazane su slikom 4.5. Sukladno kvantitativnim rezultatima, LORAKS ima najlošiju rekonstrukciju. Na slici se vide ostaci šuma i mjestimično zamućenje. Modeli AdaDiff i DiffRecon imaju zaostale artefakte presavijanja koji smanjuju preciznost rekonstrukcije, dok su rekonstrukcije DDPM-a i predloženog modela najsličnije referentnoj slici.



Slika 4.5. Rekonstrukcije T_1 -ponderiranih podataka MRI slika mozga skupa podataka IXI zajedno s uvećanim regijama na vrhu.

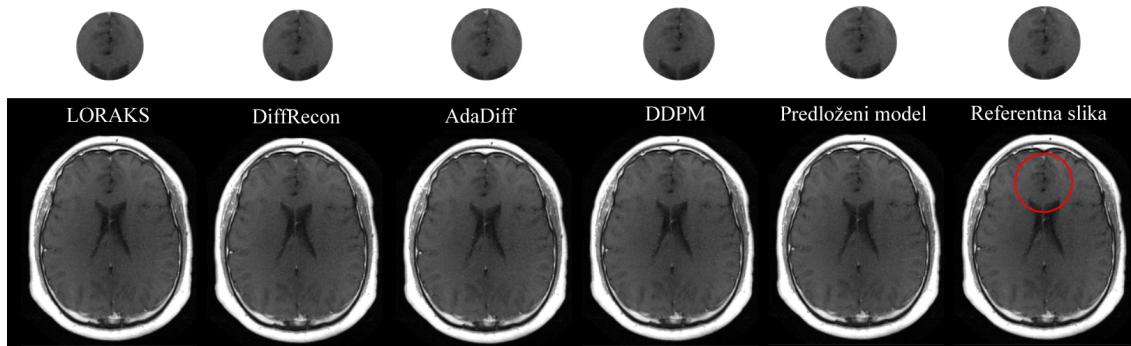
Slika 4.6 prikazuje reprezentativne rekonstrukcije na T_2 -ponderiranim podacima skupa podataka IXI. Sukladno kvantitativnim rezultatima, model LORAKS ponovno ima najlošiju rekonstrukciju slike. Kao i u slučaju T_1 -ponderirane slike, na slici se vide ostaci šuma i

zamućenje. Predloženi model i AdaDiff imaju najsličniju rekonstrukciju referentnoj slici, dok DiffRecon i DDPM imaju zaostale artefakte presavijanja.



Slika 4.6. Rekonstrukcije T_2 -ponderiranih podataka MRI slika mozga skupa podataka IXI zajedno s uvećanim regijama na dnu.

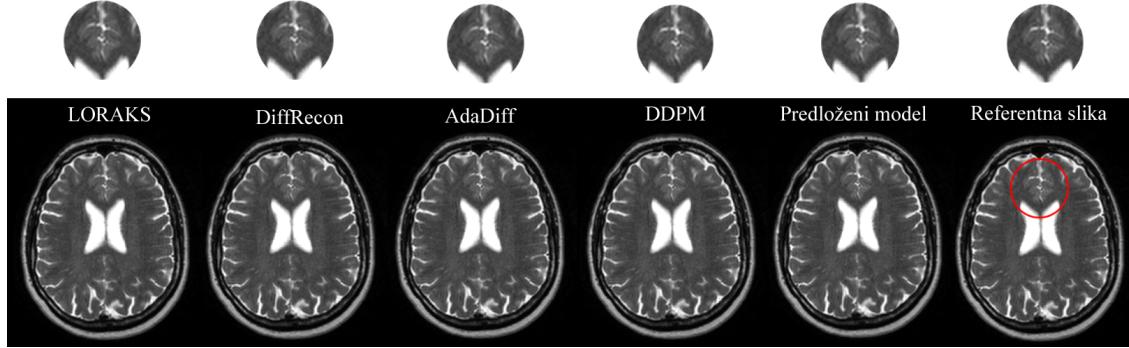
Reprezentativne rekonstrukcije na T_1 -ponderiranim podacima skupa podataka fastMRI prikazane su slikom 4.7. Sukladno kvantitativnim rezultatima, LORAKS ima najlošiju rekonstrukciju, iako bolju nego na skupu IXI podataka. Na slici se vide ostaci šuma, mjestimično zamućenje i zaostali artefakti presavijanja. Modeli AdaDiff i predloženog modela najsličnije su referentnoj slici, iako se i kod njih primjećuju blaga zamućenja pri rekonstrukciji.



Slika 4.7. Rekonstrukcije T_1 -ponderiranih podataka MRI slika mozga skupa podataka fastMRI zajedno s uvećanim regijama na vrhu.

Slika 4.8 prikazuje reprezentativne rekonstrukcije na T_2 -ponderiranim podacima skupa podataka fastMRI. Kao i u prijašnjim vizualizacijama rekonstrukcija, model LORAKS ima najslabiju rekonstrukciju slike. Modeli AdaDiff i DiffRecon vizualno su slični sa zaostalim

artefaktima presavijanja i naznakama zamućivanja. Najveća razlika u prijašnjim vizualizacijama rezultata, a sukladna kvantitativnim rezultatima, je nadmašivanje predloženog modela od strane modela DDPM koji rekonstruira najsličniju sliku referentnoj slici. Predloženi model i dalje ima visoku kvalitetu rekonstrukcije.



Slika 4.8. Rekonstrukcije T_2 -ponderiranih podataka MRI slika mozga skupa podataka fastMRI zajedno s uvećanim regijama na vrhu.

Nakon provedenih kvalitativnih i kvantitativnih analiza rezultata predloženog modela, model pokazuje visoku razinu rekonstrukcije slika mozga s unaprijeđenim vremenom rekonstrukcije. Model nadmašuje rezultate tradicionalnog modela i suvremenih modela rekonstrukcije slika mozga u ispitivanom okružju. S obzirom na ograničen broj uzoraka korištenih za treniranje modela i nedostatkom neviđenih skupova podataka, daljnja ispitivanja bi pokazala jasniju i realniju sliku učinkovitosti predloženog modela u drugim okruženjima.

5 ZAKLJUČAK

Cilj ovoga diplomskoga rada bila je izrada akceleriranoga modela za rekonstrukciju MRI slika mozga koji se temelji na dubokim difuzijskim modelima. U radu je opisano područje magnetske rezonancije, način prikupljanja njenih slika, opisane su suvremene metode koje se primjenjuju u rekonstrukciji MRI slika i njihove arhitekture te detaljno opisani i objašnjeni difuzijski modeli. Predložena je i matematički objašnjena metoda za ubrzavanje rekonstrukcije MRI slika temeljena na difuzijskim modelima. Pojašnjena je arhitektura predložene metode i istaknuta njenja inovativnost s dinamičkom primjenom maski za uzorkovanje k -prostora kako bi se smanjilo vrijeme akvizije u istraživačkom okruženju uz istovremeno održavanje što više kvalitete rekonstruiranih slika. Model je treniran i analiziran na dva različita skupa podataka gdje je ispitana u različitim uvjetima i pri različitim hiperparametrima. Model također daje novi pristup obradi medicinskih podataka s prebacivanjem u k -prostor neovisno o njihovom originalnom formatu, čime se smanjuje količina podataka za obradu i ubrzava vrijeme rekonstrukcije.

Predloženi model uspoređen je s tradicionalnim i suvremenim modelima za rekonstrukciju MRI slika te ih nadilazi u preciznosti i brzini rekonstrukcije. Najveće je unaprjeđenje rekonstrukcije MRI slika primjećeno između tradicionalnog modela LORAKS i predloženoga modela. Predloženi model se pokazao bolji i od novijih metoda DiffRecon, AdaDiff i DDMP. Rezultati mjerenja između modela objašnjeni su i analizirani kvantitativno i kvalitativno gdje se pokazalo da je predloženi model uspješno izveo svoj zadatak. Pored toga, predloženi model ima potencijala za nadogradnju i usavršavanje. Iako je model pokazao obećavajuće rezultate na jednom skupu podataka (IXI) i znatno smanjenje vremena rekonstrukcije, našao se pred preprekom pri drugome (fastMRI) gdje su podaci bili zadani u k -prostoru. Njegovi rezultati su bili na razini suvremenih modela korištenih u području magnetske rezonancije, ali dodatnom nadogradnjom i daljnjim ispitivanjem različitih hiperparametara, kao i ispitivanjem na raznim skupovima podataka, model može postići još bolje rezultate.

Literatura

- [1] M. Lustig, D. Donoho, and J. M. Pauly, “Sparse mri: The application of compressed sensing for rapid mr imaging,” *Magnetic Resonance in Medicine*, vol. 58, no. 6, pp. 1182–1195, 2007.
- [2] M. Lustig, D. L. Donoho, J. M. Santos, and J. M. Pauly, “Compressed sensing mri,” *IEEE Signal Processing Magazine*, vol. 25, no. 2, pp. 72–82, 2008.
- [3] S. Ranjbar, F. M. Nejad, H. Zakeri, and A. H. Gandomi, “Computational intelligence for modeling of asphalt pavement surface distress,” in *New Materials in Civil Engineering*, P. Samui, D. Kim, N. R. Iyer, and S. Chaudhary, Eds. Butterworth-Heinemann, 2020, pp. 79–116. , s Interneta, <https://www.sciencedirect.com/science/article/pii/B978012818961000003X>
- [4] K. Hammernik, T. Klatzer, E. Kobler, M. P. Recht, D. K. Sodickson, T. Pock, and F. Knoll, “Learning a variational network for reconstruction of accelerated mri data,” *Magnetic Resonance in Medicine*, vol. 79, no. 6, pp. 3055–3071, 2018.
- [5] T. M. Quan, T. Nguyen-Duc, and W.-K. Jeong, “Compressed sensing mri reconstruction using a generative adversarial network with a cyclic loss,” *IEEE Transactions on Medical Imaging*, vol. 37, no. 6, pp. 1488–1497, 2018.
- [6] S. Wang, Z. Su, L. Ying, X. Peng, S. Zhu, F. Liang, D. D. F. Feng, and D. Liang, “Accelerating magnetic resonance imaging via deep learning,” in *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, vol. 2016, 04 2016, pp. 514–517.
- [7] G. Oh, B. Sim, H. Chung, L. Sunwoo, and J. C. Ye, “Unpaired deep learning for accelerated mri using optimal transport driven cyclegan,” *IEEE Transactions on Computational Imaging*, vol. 6, pp. 1285–1296, 2020.
- [8] B. Yaman, S. A. H. Hosseini, S. Moeller, J. Ellermann, K. Uğurbil, and M. Akçakaya, “Self-supervised learning of physics-guided reconstruction neural networks without fully sampled reference data,” *Magnetic Resonance in Medicine*, vol. 84, no. 6, pp. 3172–3191, 2020.

- [9] A. Hyvärinen, “Estimation of non-normalized statistical models by score matching,” *Journal of Machine Learning Research*, vol. 6, no. 24, pp. 695–709, 2005.
- [10] Y. Song, L. Shen, L. Xing, and S. Ermon, “Solving inverse problems in medical imaging with score-based generative models,” *ArXiv*, vol. abs/2111.08005, 2021.
- [11] J. Sohl-Dickstein, E. A. Weiss, N. Maheswaranathan, and S. Ganguli, “Deep unsupervised learning using nonequilibrium thermodynamics,” in *Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37*, ser. ICML’15. JMLR.org, 2015, p. 2256–2265.
- [12] J. Ho, A. Jain, and P. Abbeel, “Denoising diffusion probabilistic models,” *Advances in Neural Information Processing Systems*, vol. abs/2006.11239, p. 6840–6851, 2020.
- [13] H. Chung and J. C. Ye, “Score-based diffusion models for accelerated mri,” *Medical Image Analysis*, vol. 80, p. 102479, 05 2022.
- [14] A. Güngör, S. U. Dar, Şaban Öztürk, Y. Korkmaz, H. A. Bedel, G. Elmas, M. Ozbey, and T. Çukur, “Adaptive diffusion priors for accelerated mri reconstruction,” *Medical Image Analysis*, vol. 88, p. 102872, 2023.
- [15] B. Ozturkler, C. Liu, B. Eckart, M. Mardani, J. Song, and J. Kautz, *SURE-Based Robust MRI Reconstruction with Diffusion Models*. Cham: Springer Nature Switzerland, 10 2023, pp. 199–209.
- [16] H. Xu, F. Othman, and R. Magin, “Monitoring tissue engineering using magnetic resonance imaging,” *Journal of bioscience and bioengineering*, vol. 106, pp. 515–27, 01 2009.
- [17] I. Ozbolat and H. Gudapati, “A review on design for bioprinting,” *Bioprinting*, vol. 3-4, pp. 1–14, 2016.
- [18] D. Moratal, A. Vallés-Luch, L. Martí-Bonmatí, and M. Brummer, “k-space tutorial: An mri educational tool for a better understanding of k-space,” *Biomedical imaging and intervention journal*, vol. 4, p. e15, 01 2008.
- [19] J. Ridgway, “Cardiovascular magnetic resonance physics for clinicians: Part i,” *Journal*

of cardiovascular magnetic resonance : official journal of the Society for Cardiovascular Magnetic Resonance, vol. 12, p. 71, 11 2010.

- [20] K. Davidson, “A guide to body planes and their movements,” <https://www.healthline.com/health/body-planes#coronal-plane>, pristupano: 27.06.2024.
- [21] M. Modalities, “The three perspective planes of the brain,” <https://bit.ly/37Ci6R7>, 2013, pristupano: 27.06.2024.
- [22] J. Wells and M. Fewtrell, “Measuring body composition,” *Archives of disease in childhood*, vol. 91, pp. 612–7, 08 2006.
- [23] J. Ballyns and L. Bonassar, “Image-guided tissue engineering,” *Journal of cellular and molecular medicine*, vol. 13, pp. 1428–36, 08 2009.
- [24] S. Y. Nam, L. M. Ricles, L. J. Suggs, and S. Y. Emelianov, “Imaging strategies for tissue engineering applications,” *Tissue Engineering Part B: Reviews*, vol. 21, no. 1, pp. 88–102, 2015, pMID: 25012069.
- [25] E. Terreno, D. D. Castelli, A. Viale, and S. Aime, “Challenges for molecular magnetic resonance imaging,” *Chemical Reviews*, vol. 110, no. 5, pp. 3019–3042, 2010.
- [26] J. M. Hammersley, “Probability and Statistics: The Harald Cramér Volume,” *Royal Statistical Society. Journal. Series A: General*, vol. 123, no. 3, pp. 339–339, 12 2018. , s Interneta, <https://doi.org/10.2307/2342476>
- [27] R. Obuchowicz, A. Piórkowski, A. Urbanik, and M. Strzelecki, “Influence of acquisition time on mr image quality estimated with nonparametric measures based on texture features,” *BioMed Research International*, vol. 2019, 2019.
- [28] R. Key, “Magnetic resonance imaging: Advanced image acquisition methods, artifacts, spectroscopy, quality control, siting, bioeffects, and safety,” <https://radiologykey.com/magnetic-resonance-imaging-advanced-image-acquisition-methods-artifacts-spectroscopy-quality-control-siting-bioeffects-and-safety/>, 2021, pristupano: 27.06.2024.

- [29] K. P. Pruessmann, M. Weiger, M. B. Scheidegger, and P. Boesiger, “Sense: Sensitivity encoding for fast mri,” *Magnetic Resonance in Medicine*, vol. 42, no. 5, pp. 952–962, 1999.
- [30] M. Griswold, P. Jakob, R. Heidemann, M. Nittka, V. Jellus, J. Wang, B. Kiefer, and A. Haase, “Generalized autocalibrating partially parallel acquisitions (grappa),” *Magnetic resonance in medicine : official journal of the Society of Magnetic Resonance in Medicine / Society of Magnetic Resonance in Medicine*, vol. 47, pp. 1202–10, 06 2002.
- [31] J. C. Ye, “Compressed sensing MRI: a review from signal processing perspective,” *BMC Biomedical Engineering*, vol. 1, no. 1, p. 8, Mar. 2019.
- [32] H. Yang and R. U. Din, “Chapter 14 - 3d geometric analysis of the knee with magnetic resonance imaging,” in *Cartilage Tissue and Knee Joint Biomechanics*, A. R. Nochehdehi, F. Nemavhola, S. Thomas, and H. J. Maria, Eds. Academic Press, 2024, pp. 201–229.
- [33] D. Donoho, “Compressed sensing,” *IEEE Transactions on Information Theory*, vol. 52, no. 4, pp. 1289–1306, 2006.
- [34] D. C. Preston, “Magnetic resonance imaging (mri) of the brain and spine: Basics,” <https://case.edu/med/neurology/NR/MRI>
- [35] A. S. Lundervold and A. Lundervold, “An overview of deep learning in medical imaging focusing on mri,” *Zeitschrift für Medizinische Physik*, vol. 29, no. 2, pp. 102–127, 2019, special Issue: Deep Learning in Medical Physics.
- [36] IBM, “What are convolutional neural networks?” <https://www.ibm.com/topics/convolutional-neural-networks>, pristupano: 27.06.2024.
- [37] L. Zhao and Z. Zhang, “A improved pooling method for convolutional neural networks,” *Scientific Reports*, vol. 14, no. 1, p. 1589, Jan. 2024.
- [38] S. Saha, “A comprehensive guide to convolutional neural networks — the eli5 way,” <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Dec. 2024, pristupano: 27.06.2024.

- [39] D. Zelenika, “Detekcija ljudi na slikama snimljenih iz zraka,” 2020.
- [40] N. Tomar, “What is unet?” <https://medium.com/analytics-vidhya/what-is-unet-157314c87634>, Jan. 2021, pristupano: 27.06.2024.
- [41] J. Brownlee, “A gentle introduction to generative adversarial networks (gans),” <https://machinelearningmastery.com/what-are-generative-adversarial-networks-gans/>, Jul. 2019, pristupano: 30.06.2024.
- [42] Y. Song, J. Sohl-Dickstein, D. P. Kingma, A. Kumar, S. Ermon, and B. Poole, “Score-based generative modeling through stochastic differential equations,” 2020.
- [43] L. Weng, “What are diffusion models?” <https://lilianweng.github.io/posts/2021-07-11-diffusion-models/>, Jul 2021, pristupano: 30.06.2024.
- [44] E. Moerman, “Accelerated mri reconstruction using deep unrolled compressed sensing algorithms,” Master’s thesis, Ghent University, 2023.
- [45] C. Meyer, B. Hu, D. Nishimura, and A. Macovski, “Fast spiral coronary artery imaging,” *Magnetic resonance in medicine*, vol. 28, no. 2, p. 202—213, December 1992.
- [46] K. Scheffler and J. Hennig, “Reduced circular field-of-view imaging,” *Magnetic Resonance in Medicine*, vol. 40, 1998.
- [47] “Ixi dataset,” <https://brain-development.org/ixi-dataset/>, pristupano: 04.03.2024.
- [48] “fastmri dataset,” <https://fastmri.med.nyu.edu/>, pristupano: 05.03.2024.
- [49] “The nifti file format,” <https://brainder.org/2012/09/23/the-nifti-file-format/>, Sep. 2012, pristupano: 21.06.2024.
- [50] J. Haldar and J. Zhuo, “P-loraks: Low-rank modeling of local k-space neighborhoods with parallel imaging data,” *Magnetic Resonance in Medicine*, vol. 75, 05 2015.
- [51] C. Peng, P. Guo, S. K. Zhou, V. M. Patel, and R. Chellappa, “Towards performant and reliable undersampled mr reconstruction via diffusion model sampling,” in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022*, L. Wang, Q. Dou, P. T. Fletcher, S. Speidel, and S. Li, Eds. Cham: Springer Nature Switzerland,

2022, pp. 623–633.

- [52] G. Elmas, S. U. H. Dar, Y. Korkmaz, E. Ceyani, B. Susam, M. Ozbey, S. Avestimehr, and T. Çukur, “Federated learning of generative image priors for mri reconstruction,” *IEEE Transactions on Medical Imaging*, vol. 42, no. 7, pp. 1996–2009, 2023.
- [53] <https://mr.usc.edu/download/LORAKS2/>, pristupano: 01.08.2024.
- [54] <https://github.com/cpeng93/DiffuseRecon>, pristupano: 05.07.2024.
- [55] <https://github.com/icon-lab/AdaDiff>, pristupano: 23.07.2024.
- [56] <https://github.com/hojonathanho/diffusion>, pristupano: 08.08.2024.

Sažetak

Ovaj diplomski rad istražuje primjenu dubokih difuzijskih modela za akceleriranu rekonstrukciju slika magnetske rezonancije mozga. Rad pruža pregled područja magnetske rezonancije, uključujući tehnike akvizicije i suvremene metode rekonstrukcije. Predstavljen je novi model temeljen na difuzijskim modelima s inovativnim pristupom dinamičkog uzorkovanja k -prostora. Evaluacija modela na dva različita skupa podataka pokazuje poboljšanja u brzini i preciznosti rekonstrukcije u odnosu na tradicionalne i suvremene metode. Kvantitativna i kvalitativna analiza rezultata potvrđuje uspješnost modela uz prostor za buduću nadogradnju i optimizaciju posebno u radu s podacima u k -prostoru.

Ključne riječi: akcelerirana rekonstrukcija, difuzijski modeli, duboko učenje, magnetska rezonancija, U-net

Abstract

Accelerated Magnetic Resonance Image Reconstruction Based on Deep Diffusion Models

This thesis investigates the application of deep diffusion models for accelerated reconstruction of brain magnetic resonance imaging. The thesis provides an overview of the field of magnetic resonance imaging, including acquisition techniques and state-of-the-art reconstruction methods. A novel diffusion-based model is introduced, featuring an innovative dynamic k -space sampling approach. Evaluation of the model on two different datasets demonstrates improvements in both reconstruction speed and accuracy compared to traditional and contemporary methods. Quantitative and qualitative analysis of the results confirms the effectiveness of the model while also highlighting the potential for future enhancements and optimization, particularly in handling k -space data.

Keywords: accelerated reconstruction, deep learning, diffusion models, magnetic resonance imaging, U-Net

Životopis

Tea Krčmar rođena je 23. lipnja 1998. godine u Osijeku u Hrvatskoj. Pohađala je Prirodoslovno-matematičku gimnaziju u Osijeku. Nakon završetka srednjoškolskog obrazovanja upisuje studij računarstva na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija koji uspješno završava te nastavlja Diplomski studij Izborni blok Informacijske i podatkovne znanosti na istom fakultetu. 2024. godine dobitnica je Rektorove nagrade za izradu 3D video igre "Apocalypse" u programskom alatu Unity. 2024. godine u sklopu Erasmus+ programa odlazi na sveučilište u Gentu u Belgiji na Fakultet inžinjerstva i agrokulture, Zavod za telekomunikacije i obradu informacija gdje izrađuje diplomski rad i odradjuje stručnu praksu.

Potpis autora