

Rekonstrukcija MRI slika mozga pomoću fastMRI biblioteke

Bertić, Dražen

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://um.nsk.hr/um:nbn:hr:200:243073>

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

Download date / Datum preuzimanja: **2025-04-02**

Repository / Repozitorij:

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



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

Sveučilišni diplomski studij Računarstva

REKONSTRUKCIJA SLIKA MAGNETSKE REZONANCE
MOZGA UPORABOM FASTMRI BIBLIOTEKE

Diplomski rad

Dražen Bertić

Osijek, 2024.

Sadržaj

1.	Uvod	2
2.	Pregled područja teme	3
2.1.	Magnetska rezonanca	3
2.2.	fastMRI	4
2.3.	Metode rekonstrukcije MRI slika	5
2.4.	Zero-fill	5
2.4.1.	Compressed Sensing	5
2.4.2.	U-Net	6
2.4.3.	End-to-end VarNet	9
2.5.	Skupovi podataka	10
2.5.1.	fastMRI skup podataka	10
2.5.2.	Calgary	11
3.	Predobrada podataka	13
3.1.	Matrice šuma.	14
4.	Treniranje modela	17
4.1.	Metrike rezultata	17
4.2.	Rezultati treniranja	18
5.	Rezultati	20
6.	Zaključak.	27
	Sažetak	30
	Abstract	31
	Životopis	32

1. UVOD

Magnetska rezonanca je metoda medicinskog snimanja koja omogućava neinvazivno i detaljno prikazivanje mekog tkiva tijela poput mozga. Proces snimanja magnetskom rezonancom dugotrajan je postupak u kojem najmanje kretnje uzrokuju umanjenje kvalitete slike. Navedeni problemi ističu potrebu za razvoj postupaka za ubrzanje snimanja uz očuvanje kvalitete slike. Tehnike dubokog učenja otvaraju nove mogućnosti za rekonstrukciju slika poduzorkovanih podataka. Projekt fastMRI nudi alate i modele za rekonstrukciju slika tehnikama dubokog učenja. Ovaj rad istražuje mogućnosti prijenosa učenja na unaprijed istreniranim modelima, U-Net i End-to-End VarNet, radi poboljšanja kvalitete rekonstrukcije slika na novim skupovima podataka. Analiziraju se utjecaji različitih maski poduzorkovanja te se rezultati evaluiraju uporabom metrika poput PSNR i SSIM. Dobiveni rezultati doprinose razumijevanju primjenjivosti dubokog učenja u ubrzanju snimanja magnetskom rezonancom i poboljšanju dijagnostičke učinkovitosti.

2. PREGLED PODRUČJA TEME


U ovom poglavlju opisana je pozadina teme i problematike koju ovaj rad rješava. Objašnjava se važnost i postupak dobivanja slika magnetskom rezonancom te se objašnjavaju tehnike i modeli za rekonstrukciju MRI slika koji se nalaze unutar fastMRI projekta.

2.1. Magnetska rezonanca

Metoda slikanja magnetskom rezonancom (engl. *Magnetic Resonance Imaging* (MRI)) je neinvazivna metoda koja proizvodi detaljne anatomske slike mekog tkiva. U kontekstu ovog rada korištena je za detaljno prikazivanje unutrašnje strukture mozga. Ona je od velike važnosti u području medicinske dijagnostike. Služi za dijagnostiku različitih neuroloških poremećaja poput tumora mozga, multiple skleroze, moždanog udara, epilepsije i drugih bolesti. Uz to se koristi i za praćenje napredovanja bolesti i planiranje kirurških zahvata. Potpuno je bezbolna metoda koja za stvaranje slike koristi jako magnetsko polje i radiovalove, a time nema štetnog ionizirajućeg zračenja i nuspojava. Postupak dobivanja slike traje od 15 do 90 minuta, a tijekom postupka osoba mora mirno ležati unutar stroja. Najmanje kretnje uzrokuju šum i artefakte. S obzirom na trajanje postupka, iskustvo može biti neudobno i klaustrofobično. Dugo trajanje postupka ima i posljedice na povećanje cijene snimanja jer je potrebno više vremena po osobi. Sposobnost detaljnog slikanja mekog tkiva nije zamjenjiva metodama poput CT snimanja i rendgenskog snimanja. Prema tome, smanjenje trajanja slikanja postupkom magnetske rezonance je poželjno [1].

Magnetska rezonanca se temelji na fizikalnoj pojavi nuklearne magnetske rezonancije. U toj pojavi jezgre određenih atoma (na primjer vodikovih jezgri u magnetskoj rezonanciji mozga) pokazuju sposobnost upijanja i odašiljanja elektromagnetske energije prilikom stavljanja u magnetsko polje. Ponašaju se kao mali štapićasti magneti te ako se nalaze u magnetskom polju oni će se poravnati s njim. Zatim, stroj za magnetsku rezonancu odašilje u njih elektromagnetski puls radio frekvencije te ih time izbija iz poravnanja s magnetskim poljem. Ovdje je značajno djelovanje nuklearne magnetske rezonance. Jezgre atoma će se rotirati i time odašiljati radio signal. Nakon određenog vremena njihova će rotacija stati te će se ponovno poravnati s magnetskim poljem. S obzirom na vrijeme potrebno da se jezgra atoma prestane rotirati, vrijeme potrebno da se ponovno poravna s magnetskim poljem te količinu energije koja je ispuštena, moguće je razaznati razliku između različitih vrsta tkiva. Mjerenja su obično predstavljena u

višedimenzionalnom Fourierovom prostoru. Ovaj Fourierov prostor je u zajednici medicinskog snimanja poznat kao *k-prostor*. U najosnovnijoj upotrebi snimanja magnetskom rezonancom, puna Fourierova reprezentacija dobiva se nizom uzoraka koji popunjavaju prostor do određene maksimalne frekvencije. Poveznica između *k-prostora* i krajnje slike je Diskretna Fourierova Transformacija (DFT) kao što je prikazano na slici 2.1 [2].




Slika 2.1: Prikazana je pretvorba *k-prostora* u rekonstrukciju.

Broj snimljenih uzoraka u *k-prostoru* je faktor koji ograničava brzinu snimanja magnetskom rezonancom. Uzorkovanjem do niže maksimalne frekvencije možemo dobiti manji broj uzoraka, a time i brži proces slikanja, no time smanjujemo prostornu rezoluciju slike. Alternativni pristup poduzorkovanja uključuje izostavljanje određenog broja uzoraka *k-prostora*, što rezultira artefaktima aliasinga. Kako bi se uklonili artefakti i kako bi dobili stvarnu prostornu strukturu snimljenog subjekta, primjenjujemo niz metoda rekonstrukcije [2]. U ovom projektu koristimo metode rekonstrukcije koju fastMRI projekt pruža.

2.2. fastMRI

fastMRI je zajednički istraživački projekt između *Facebook AI Research*-a i *NYU Langone Health*-a. Cilj projekta je razvijanje bržih postupaka slikanja magnetskom rezonancom uporabom tehnika dubokog učenja. Projekt je javan i sadrži velike skupove podataka magnetske rezonance koljena, mozga, prostate i grudi koji se mogu koristiti za treniranje i testiranje modela dubokog učenja za bržu rekonstrukciju slika. Projekt se sastoji od skupa podataka koji je javno dostupan, Python biblioteke i GitHub repozitorija.



Slika 2.2: Prikaz pretvorbe poduzorkovanog k -prostora u rekonstrukciju.

2.3. Metode rekonstrukcije MRI slika


Najizravniji pristup ubrzanju snimanja magnetskom rezonancom može biti postignut paralelnim snimanjem. Paralelno snimanje uvedeno je u 90-ima i ono omogućava uzorkovanje više podataka istovremeno za razliku od tradicionalnog sekvencionalnog snimanja [2]. Svaka dodana zavojnica snima zasebno područje u k -prostoru. Nad dobivenim k -prostorima primjenjuje metoda zbroja kvadrata i time se dobiva krajnji k -prostor. Uporaba više zavojnica zahtjeva dodatni korak kalibracije kojim dobivamo podatke osjetljivosti zavojnice. To se postiže korištenjem mapa profila osjetljivosti ili korištenjem konvolucijskih kernela u k -prostoru [3].

2.4. Zero-fill

Zero-Fill ili metoda popunjavanja nulama, postavlja nulu na mjesto svih neuzorkovanih podataka u k -prostoru. Zatim je primjenjena dvodimenzionalna inverzna Fourierova transformacija na rezultate i izračunata je konačna vrijednost. Rezultat je obrezana slika u sredini kako bi se uklonio višak podataka [2].

2.4.1. Compressed Sensing

Compressed sensing (CS) tehnika je predstavljena 2006. kao značajan napredak u smanjenju vremena snimanja MR. U osnovi omogućava rekonstrukciju signala ili slike iz manje informacija nego što je inače potrebno. Mjeri se mali broj slučajnih linearnih kombinacija signala.



Slika 2.3: Prikaz rezultata paralelnog slikanja.

Compressed sensing pristup zahtjeva da je željena slika kompresibilna, da artefakti aliasinga zbog poduzorkovanja k -prostora budu nekoherentni u toj domeni transformacije te da se koristi nelinearna rekonstrukcija kako bi se osigurala i rijetkost reprezentacije slike i konzistentnost stečenih podataka [4].

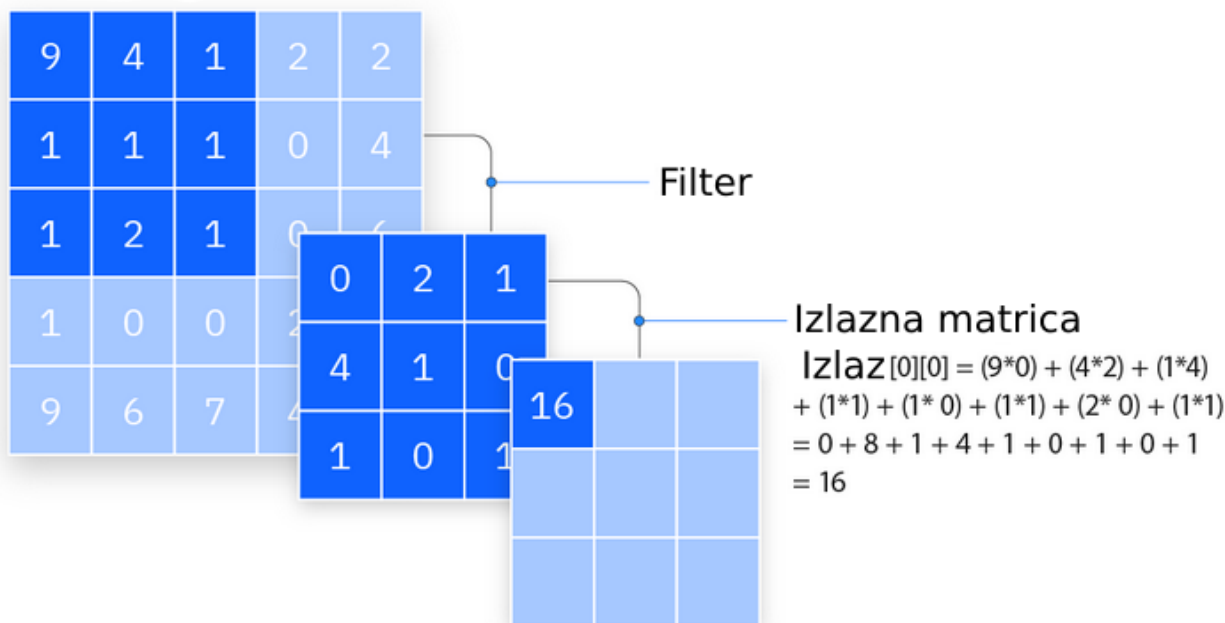
Implementacija se temelji na ESPiRiT [5] radu. Također koristi BART [6] (engl. *The Berkeley Advanced Reconstruction Toolbox*) besplatni i open-source set alata za rekonstrukciju slika magnetske rezonance. Pruža česte operacije na multi dimenzionalnim poljima, Fourierove i wavelet transformacije, kao i implementacije iterativnih optimizacijskih algoritama. Alati za komandnu liniju pružaju direktni pristup rekonstrukcijskim algoritmima za paralelno slikanje i *compressed sensing*.

2.4.2. U-Net

U-Net [7] je arhitektura razvijena 2015. sa svrhom segmentacije biomedicinskih slika. U-Net je konvolucijska mreža koja je poboljšanje postojeće mreže razvijene u radu [8]. Konvolucijske neuronske mreže su jedna od glavnih mreža za klasifikaciju i segmentaciju slika. Sastoje se od konvolucijskih slojeva, slojeva sažimanja (*Pooling layer*), aktivacijskih funkcija i potpuno povezanih slojeva. Konvolucijski sloj je osnovni blok mreže. Njegova operacija prikazana je na Slici 2.4. On primjenjuje kernel (matrica) na ulaznoj slici. Primjenjuje se na način da se kernel pomiče korak po korak te se pri svakom koraku množi s izvornom slikom na mjestu preklapa-

nja. Korak se može mijenjati, s time da veći korak daje manju izlaznu matricu. Na kraju svake operacije konvolucije, primjenjuje se aktivacijska funkcija na matrici značajki. Nakon primjene kernela, kao rezultat dobivamo matricu u kojoj su izražene određene informacije poput rubova ili tekstura. Primjenom niza konvolucijskih slojeva, mrežu učimo prepoznavanju značajki na slikama.

Ulazna slika



Slika 2.4: Ilustracija operacije konvolucije [9]

Najčešće aktivacijske funkcije koje se koriste su:

1. **ReLU (Rectified Linear Unit)** aktivacijska funkcija popularna je aktivacijska funkcija koja negativne ulaze postavlja na nulu, a pozitivne ulaze ostavlja nepromijenjenima. ReLU je naširoko prihvaćena zbog svoje jednostavnosti i mogućnosti ublažavanja problema nestajanja gradijenta [10].
2. **Sigmoidna** aktivacijska funkcija preslikava ulaz u vrijednost između 0 i 1. Široko se koristi u problemima binarne klasifikacije, gdje je cilj klasificirati ulaze u jednu od dvije klase [10].
3. **Softmax** aktivacijska funkcija se obično koristi u problemima klasifikacije više klasa. Pretvara izlaze neuronske mreže u distribuciju vjerojatnosti, gdje svaki izlaz predstavlja

vjerojatnost da ulaz pripada određenoj klasi. Softmax aktivacijska funkcija osigurava da zbroj vjerojatnosti za sve klase iznosi 1 [10].


Slojevi sažimanja obavljaju funkciju smanjenja dimenzija, time smanjuje količinu parametara na ulazu. Poput konvolucijskog sloja, sloj sažimanja pomiče filter po danoj matrici. Najčešći tipovi sažimanja:

1. **Max pooling**: filter odabire najveću vrijednost i u nju sprema u izlaznu matricu.
2. **Average pooling**: filter računa prosječnu vrijednost koju zapisuje u izlaznu matricu.

Potpuno povezani slojevi se nalaze na kraju arhitekture i koriste se za konačnu klasifikaciju.

Uobičajena uporaba U-Net mreže je u segmentacijskim zadacima, gdje je izlaz za sliku jedinstvena klasa. No, u mnogim zadacima, pogotovo u biomedicinskoj obradi slika, potrebno je postići lokalizaciju, odnosno, dodjeljivanje klase svakom pikselu slike [7]. Model koji pruža fastMRI biblioteka je namijenjen za rekonstrukciju slika. Prikazan je na Slici 2.5 i sastoji se od dvije duboke konvolucijske mreže, a i dekodera. Sloj enkodera se sastoji od dvije 3×3 konvolucije. Iza koje slijedi ReLU aktivacijska funkcija i funkcija normalizacije. Izlaz sloja popraćen je *max pooling* sažimajućim slojem s korakom veličine 2. Time se prepolavlja svaka prostorna dimenzija. Slojevi dekodera se sastoje od dvije 3×3 konvolucije, od koje je svaka zapraćena ReLU aktivacijskom funkcijom i funkcijom normalizacije. Za razliku od puta enkodera, deko-der na ulazu spaja dva ulaza u prvu konvoluciju u svakom bloku. " *Up-sampled* aktivacije iz prethodnog bloka, zajedno s aktivacijama iz *skip* veze. Kraj mreže sadrži serije 1×1 konvolucija koje smanjuju broj kanala na jedan. Put enkodera hvata značajke i otkriva što je na slici, dok put dekodera otkriva gdje se to nalazi na slici. *Skip* veze povezuju izlaz enkodera s ulazom dekodera kako bi mu pružile značajke visoke rezolucije i time poboljšali lokalizaciju.

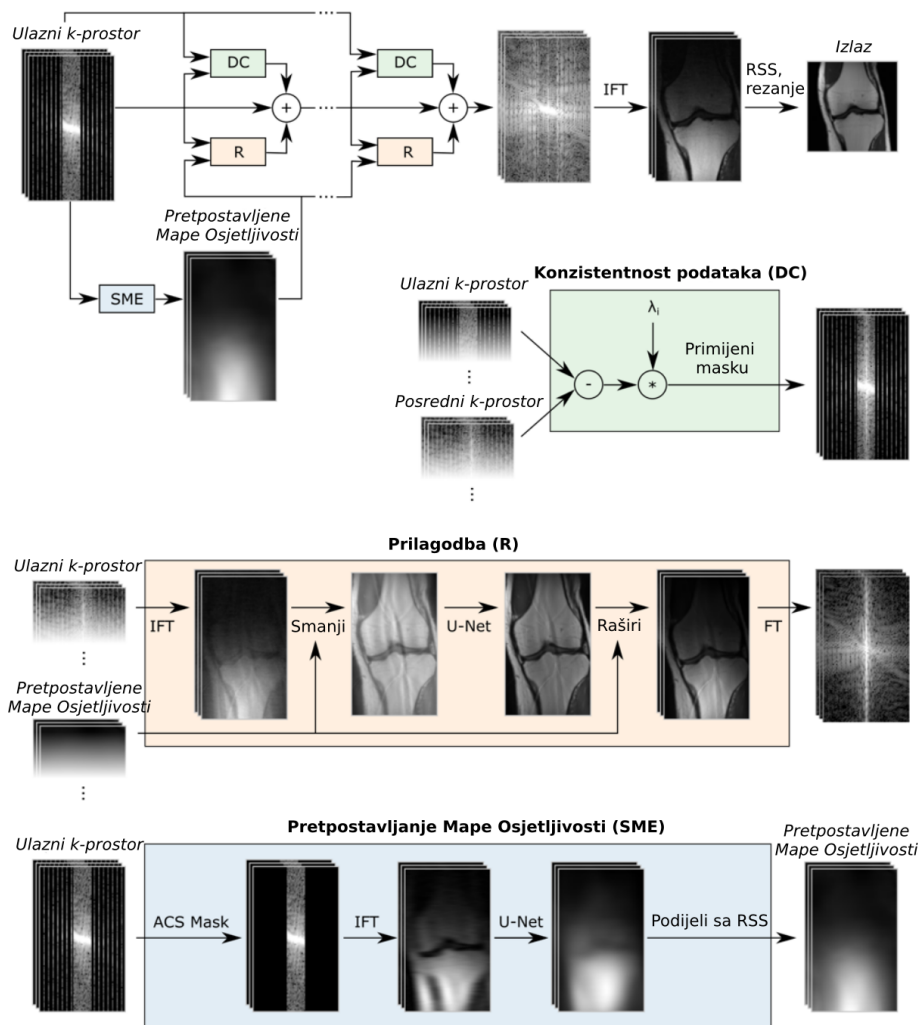
Pruženi model je namijenjen za rekonstrukciju slika uzorkovanih jednom zavojnicom. Za uporabu nad slikama uzorkovanih s više zavojnica potrebno izvršiti *zero-fill* metodu nad slikom svake zavojnice. Nakon primjene *zero-fill* metode, slike zavojnica se povezuju korištenjem metoda zbroja kvadrata. Model je treniran kako bi minimizirao gubitak srednje apsolutne pogreške (RMSE) [2].



Slika 2.5: U-Net arhitektura.

2.4.3. End-to-end VarNet

End-to-End VarNet model uzima maskirani k-prostor kao ulaz, primjenjuje niz koraka obrade na njemu. Jedan korak se naziva kaskada. Arhitektura mu je prikazana na Slici 2.6. Prvi modul **SME** (engl. *Sensitivity Map Estimation*) pretpostavlja mape osjetljivosti zavojnica k-prostora. Dobivene mape, zajedno s ulaznim k-prostorom se koriste u modulu **prilagodbe R** (engl. **Refinement**) koji mapira k-prostor više zavojnica u jednu sliku. Na njoj primjenjuje U-Net te ju zatim rastavlja nazad u oblik k-prostora više zavojnica. **DC** (engl. **Data Consistency**) blok računa mape korekcije koje dovode posredne vrijednosti k-prostora bliže izmjerenim vrijednostima. Nakon što se sve kaskade izvrše, na krajnji k-prostor se primjenjuje inverzna Fourierova transformacija, nakon toga RSS operacije i rezanje slike. Cijeli postupak rekonstrukcije slike, od sirovih podataka do konačne rekonstrukcije slike obavlja se unutar mreže. Model koji pruža fastMRI projekt treniran je s 30 milijuna parametara korištenjem Adam optimizacije sa stopom učenja od 0.0003 za 50 epoha, bez upotrebe tehnika regularizacije ili augmentacije podataka [11].



Slika 2.6: End-to-End VarNet arhitektura [11].

2.5. Skupovi podataka

U ovom radu korišteni su fastMRI i Calgary-Campinas skupovi podataka. Navedeni skupovi snimki mozga magnetskom rezonancom opisani su u idućim potpoglavljima.

2.5.1. fastMRI skup podataka

fastMRI skup podataka, koji pruža fastMRI projekt, ujedno je i najveći javno dostupan skup podataka slika magnetske rezonance. Navedeni skup podataka sadrži veliku količinu neobrađenih slika magnetske rezonance mozga, koljena i prostate. Isto tako, skup podataka sadrži i snimke uslikane jednom zavojnicom (engl. *singlecoil*) i s više zavojnica (engl. *multicoil*) te snimane s različitim kontrastnim agentima. Slike mozga su snimljene s dva magneta različite snage, od 1.5T i od 3T, a korišteni su T1, T1 post contrast, T2 i FLAIR kontrastni agenti. Sve slike mozga snimljene su s više zavojnica. Sveukupno se sastoji od 7002 snimke koje su prethodno podijeljene u podskupove za trening, validaciju i testiranje.

	Snaga Magneta		Total
	1.5T	3T	
T1	382	409	791
T1 Post Contrast	849	646	1495
T2	1655	2524	4179
FLAIR	126	411	537
Total	3012	3990	7002

Tablica 2.1: *Prikaz podataka u skupu podataka*


Podatci su spremljeni u hdf5 formatu što je hijerarhijski format podataka optimiziran za spremanje velikih količina podataka. Svaka datoteka odgovara jednom slikanju magnetskom rezonancom i sadrži k-prostor, krajnju rekonstrukciju svakog sloja i metapodatke. K-prostor, spremljen pod ključem "k-space", u slučaju slikanja s više zavojnica je spremljen u formatu (broj slojeva, broj zavojnica, visina slike, širina slike). Rekonstrukcije, spremljene pod ključem "reconstruction_rss", su spremljene u formatu (broj slojeva, visina rekonstrukcije, širina rekonstrukcije). Metapodatci, spremljeni pod ključem "ismrmr_header", sadrže informacije o postavkama uređaja kojime je slika snimljena te podatke o dimenzijama slika. Razina akceleracije, način akvizicije (kontrastni agent), broj niskih frekvencija i anonimni identifikacijski kod pacijena su spremljeni kao atributi u datoteci. Pruženi UNet i VarNet modeli koje koristimo prethodno su trenirani na ovom skupu podataka.

2.5.2. Calgary

Calgary-Campinas [12] je javni skup podataka koji se sastoji od slika magnetske rezonance mozga. Zajednički je projekt istraživača Vascular Imaging Laba sa Sveučilišta Calgary i Medical Image Computing Laba sa Sveučilišta Campinas. Sastoji se od slika snimanih jednom zavojnicom i slika snimanih s više zavojnica. Skup podataka slikan jednom zavojnicom obuhvaća 35 potpuno uzorkovanih MR snimaka mozga s T1 kontrastnim agentom. Podatci su prikupljeni na Discovery MR750 kliničkom MR skeneru. Snimke su slikane s 12 zavojnica i rekonstruirane u format jednog kanala. Sastoji se od 35 snimaka, podijeljenih na 25 za trening i 10 za validaciju. Testni podatci nisu dostupni i njime se testira funkcioniranje modela. Veličina matrice je 256x256.

Skup podataka slikan s više zavojnica sastoji se od 167 trodimenzionalnih MR snimaka mozga zdravih osoba dobi od 20 do 80 godina. Snimke su snimljene uporabom T1 kontrastnog agenta na Discovery MR750 skeneru. Sastoji se od snimaka snimljenih uporabom 12 zavojnica i 32 zavojnice. Skup slikan uporabom 12 zavojnica sastoji se od 47 snimki za treniranje, 20 za validaciju i 50 snimki za testiranje, dok se skup slikan s 32 zavojnice sastoji od 50 snimki

za testiranje. Podatci su poduzorkovani tako što su djelomično prikupljeni do 85% veličine matrice u smjeru kodiranja slojeva (kz), a neprikupljeni dio je napunjen nulama (slika 2.7). Testni podatci su poduzorkovani k-prostori sa $R=5$ i $R=10$ faktorima akceleracije.



Slika 2.7: *Prikaz poduzorkovanih podataka unutar Calgary-Campinas skupa podataka*

3. PREDOBRAĐA PODATAKA

Predobrada podataka je ključan korak kojim se osigurava da su svi podatci ispravnog formata, što je nužno za uspješno treniranje modela. Za treniranje modela potrebne su slike snimljene s više zavojnica. Calgary-Campinas skup podataka se koristi jer nudi snimke s jednom ili više zavojnica, no zbog navedenog zahtjeva koriste se samo snime s više zavojnica. Calgary-Campinas skup podataka već je spremljen u hdf5 formatu. U svakoj datoteci unutar skupa nalazi se ključ `kpace'`, u kojem su spremljeni 3D podatci k -prostora kao polje. Prva dimenzija polja je širina snimke, visina snimke, broj slojeva snimke, broj snimanih kanala. Dimenzija kanala u polju izmjenjuje se između realnih i imaginarnih komponenti kompleksnih vrijednosti, pa se za podatke s 12 kanala dobiva 24 kanala u posljednjoj dimenziji polja, dok za podatke s 32 kanala dobiju se 64 kanala.

Kako bi se postigao željeni format podataka, proveden je niz koraka obrade. Prvo su odabrani odgovarajući slojevi iz skupa podataka, pri čemu je osigurano njihovo podudaranje s onima iz fastMRI skupa. U tom procesu uklonjene su slike očiju i područja ispod njih te je obuhvaćena cijela lubanja. Prikaz seta prije ovog koraka prikazan je na slici 3.8.

Slijedeći korak je manipulacija k -prostora. Podatci su izvorno pohranjeni s realnim i imaginarnim komponentama koje se izmjenjuju. Preoblikovani su u "complex64" format, gdje su obje komponente predstavljene jednim zapisom. Nakon toga je izvršena normalizacija k -prostora. Za svaku snimku u skupu podataka, zabilježena je maksimalna vrijednost koju sadrži. Ova vrijednost je pohranjena pod ključem "max" te je nužna za End-to-End VarNet model tijekom obrade. Također je primjenjen pomak FFT-a kako bi spektar bio centriran. Krajnji dio procesa bilo je i oblikovanje ISMRMRD metapodataka koji opisuju karakteristike slike. Konačno, na testne podatke postavljene su maske poduzorkovanja, a matrica maske spremljena je pod ključem `mask`. Od trening skupa, odvojeno je pet snimki radi kasnije evaluacije rada modela.




Slika 3.8: Prikaz obuhvaćanja slojeva Calgary-Campinas skupa.

3.1. Matrice šuma

U radu su korištena tri tipa maski poduzorkovanja: maska ekvidistantnog uzorkovanja (engl. *equispaced mask*), slučajnog ekvidistantnog uzorkovanja (engl. *random equispaced*) i maske s Gausovim šumom.


Maske ekvidistantne udaljenosti (slika 3.9) $M_e(r, l)$ uzorkuju l niskofrekventnih linija iz središta k -prostora, a svaku r -tu liniju iz preostalog k -prostora. One se koriste jer ih je lako

implementirati u MRI uređaje [11].




Slika 3.9: *Prikaz maske ekvidistantne udaljenosti.*

Maske slučajnog ekvidistantnog uzorkovanja (slika 3.10) $M_r(a, f)$ uzorkuju dio f pune širine središta k-prostora uz podskup visokofrekventnih linija, odabranih jednoliko nasumično, kako bi ubrzanje bilo jednako a [11].



Slika 3.10: *Prikaz nasumične ekvidistantne udaljenosti.*

Za razliku od prethodne dvije maske, maska s Gausovim šumom (slika 3.11) nije implementirana u fastMRI biblioteci. Ta vrsta maske se inače ne susreće u snimanjima magnetskom rezonancom zbog njihove složenosti implementacije. Maska uzorkuje punu širinu središta k-prostora, zatim se generira Gausov šum sa standardnom devijacijom koja je prilagođena faktoru ubrzanja. Maska se kombinira s Gausovim šumom tako da se šum dodaje samo u područja izvan središnjeg dijela.



Slika 3.11: *Prikaz maske Gausovog šuma.*

4. TRENIRANJE MODELA

Tehnika prijenosa učenja [13] koristi prethodno istrenirane modele na određenom zadatku ili skupu podataka s ciljem poboljšanja performansi na srodnom zadatku ili skupu podataka. U kontekstu ovoga rada tehniku prijenosa učenja je primjenjena na prethodno istrenirane modele pružene od fastMRI projekta. U-Net i End-to-End VarNet modeli pruženi iz fastMRI projekta su trenirani na fastMRI skupu podataka. Cilj je poboljšanje performansi na Calgary-Campinas skupu podataka. Trening se odvija sa stopom učenja od 10^{-4} , koja se smanjuje za faktor 10^{-1} svakih 5 epoha te ranijim zaustavljenjem ukoliko se SSIM ne povećava za više od 10^{-2} . Kod UNet modela se zamrzavaju enkodirajući slojevi radi smanjenja broja parametara za treniranje. Time je proces treniranja ubrzan i manjih računalnih zahtjeva treninga. S obzirom da je korišten model prethodno treniran na puno većem skupu podataka, ovim postupkom je smanjen rizik overfittinga gdje se model previše privikne manjem skupu podataka, a istovremeno su očuvane korisne značajke naučene iz prethodnog treninga. End-to-End-VarNet model nije imao posebne korake smrzavanja slojeva ili preinake modela.

4.1. Metrike rezultata

PSNR ili vršni omjer signala i šuma (engl. *Peak Signal to Noise Ratio*) [14] je numerički prikaz omjera između najveće moguće snage signala i najveće vrijednosti šuma. Što je vrijednost veća to je bolje, a računamo ju po formuli (4-1):

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (4-1)$$

gdje MAX predstavlja najveću moguću vrijednost piksela na slici, a MSE je srednja kvadratna pogreška između dvije slike koje se uspoređuju.

SSIM ili index mjere strukturne sličnosti (engl. *Structural Similarity Index Measure*) [14] je metrika koja se koristi za procjenu perceptivne kvalitete slike. Mjeri sličnost slika u tri aspekta: svjetlina, kontrast i struktura. Vrijednosti metrike su u rang [0, 1], a što je veća vrijednost, manja je distorzija. Računa se po formuli (4-2).


$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (4-2)$$

gdje je:

- μ_x srednja vrijednost uzorka piksela x ,
- μ_y srednja vrijednost uzorka piksela y ,
- σ_x^2 varijanca x ,
- σ_y^2 varijanca y ,
- σ_{xy} kovarijanca x i y ,
- $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$ dvije varijable za stabilizaciju dijeljenja sa slabim nazivnikom.


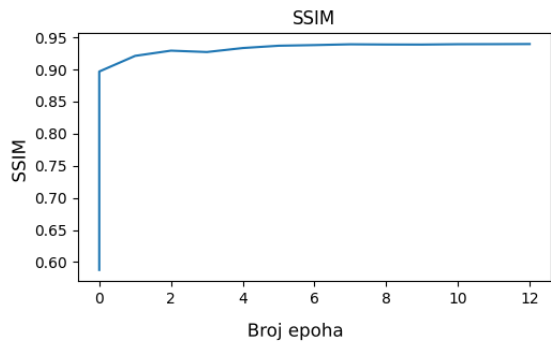


4.2. Rezultati treniranja

Trening U-Net modela je završen nakon 8 epoha s vrijednosti SSIM od 0.9270, vrijednosti PSNR od 36.88 dB, vrijednosti validacijskog gubitka od 0.2117 te vrijednosti gubitka od 0.0412. Grafovi na slici 4.12 prikazuju napredak metrika tokom treninga. Najbolji rezultat metrike SSIM je postignut u 8. epohi.



Slika 4.12: *Prikaz metrika prijenosa učenja U-Net modela.*

Trening End-to-End VarNet modela je završen nakon 12 epoha s vrijednosti SSIM od 0.9397, vrijednosti PSNR od 38.02 10 dB, vrijednosti validacijskog gubitka od 0.0603 te vrijednosti gubitka od 0.0266. Grafovi na slici 4.13 prikazuju napredak metrika, a najbolji rezultat metrike SSIM je postignut u 12. epohi.




Slika 4.13: Prikaz metrika prijenosa učenja VarNet modela.


5. REZULTATI

U ovom poglavlju prikazane su usporedbe rekonstrukcija originalnih metoda i modela iz fastMRI projekta i modela istreniranih na novom skupu podataka. Rezultati su uspoređeni vizualno prikazom slika i numerički prikazom metrika. Metrike su izračunate usporedbom rekonstrukcija s izvornom slikom. Također su dodane rekonstrukcije modela nakon manjeg broja epoha radi usporedbe napretka rekonstrukcije.

Modeli su trenirani na podacima poduzorkovanim *equispaced* maskom i zato očekujemo najbolje rezultate rekonstrukcije u ovom slučaju. Prikaz rekonstrukcija je na slici 5.14, a metrike su prikazane na slici 5.15 i u tablici 5.2. Primjećujemo kako su se rezultati kod U-Net modela nakon treniranja pogoršali. I SSIM i PSNR su se smanjili. Kod End-to-End VarNet modela imamo suprotnu situaciju. Dodatno treniranje je znatno poboljšalo i SSIM i PSNR. End-to-End VarNet model prije treniranja daje drastično lošije rezultate. Također možemo uočiti kako tradicionalna metoda *compressed sensing* ima bolje rezultate nego rekonstrukcija U-Net modelom te općenito najbolje rezultate u ovoj usporedbi.



Slika 5.14: *Prikaz rekonstrukcija nakon primjene equispaced maske.*




Slika 5.15: Usporedba rezultata nakon primjene equispaced maske.


	MSE	NMSE	PSNR	SSIM
Zero-Fill	0.005901	0.1042	22.31	0.6331
Compressed Sensing	0.001615	0.02794	28.13	0.8487
U-Net	0.002384	0.0402	27.35	0.8076
U-Net 5 epoha	0.004879	0.08763	23.25	0.6643
U-Net 8 epoha	0.005641	0.1016	22.7	0.655
E2E VarNet	0.03095	0.5169	15.62	0.4076
E2E VarNet 5 epoha	0.002451	0.04129	26.39	0.8581
E2E VarNet 12 epoha	0.002126	0.03612	26.95	0.8683

Tablica 5.2: Metrike rekonstrukcija nakon primjene equispaced maske.


Rekonstrukcije slika na koje je primjenjena *random equispaced* maska prikazuju rezultate slične slučaju s *equispaced* maskama. Rekonstrukcije su prikazane na slici 5.16, a metrike su prikazane na grafovima na slici 5.17. Rezultati U-Neta se pogrošavaju daljnjim treniranjem, sporijim tempom, dok se rezultati End-to-End VarNet-a poboljšavaju. Rezultati su u svim slučajevim znatno lošiji u usporedbi s prošlim primjerom. Najvidljivije je u slučaju *compressed sensing* rekonstrukcije gdje bi mogli reći čak da rekonstrukcija nije cjelovita. U konačnici možemo zaključiti da VarNet model treniran 12 epoha ima najbolje rezultate u ovom slučaju.




Izvorna slika




Slika s maskom




Zero-Fill




CS




U-Net




U-Net nakon 5 epoha




U-Net nakon 8 epoha



E2E VarNet




E2E VarNet nakon 5 epoha




E2E VarNet nakon 12 epoha

Slika 5.16: Prikaz rekonstrukcija nakon primjene random equispaced maske.




Slika 5.17: Usporedba rezultata nakon primjene random equispaced maske.


U ovom slučaju dobivamo nešto drukčije rezultate. Dok se rekonstrukcije End-to-End modela neznatno poboljšavaju nakon treniranja, za razliku do sad, U-Net model ima bolje rezultate nakon treniranja. Rekonstrukcije U-Net modela su također bolje od rekonstrukcija End-to-End VarNet modela te najbolje rezultate općenito u ovoj usporedbi. Rekonstrukcije su prikazane na slici 5.18, graf metrika je prikazan na slici 5.19, a tablica metrika u tablici 5.3.




Izvorna slika




Slika s maskom




Zero-Fill




CS




U-Net




U-Net nakon 5 epoha




U-Net nakon 8 epoha



E2E VarNet




E2E VarNet nakon 5 epoha



E2E VarNet nakon 12 epoha

Slika 5.18: Prikaz rekonstrukcija nakon primjene maske Gaussovog šuma.



Slika 5.19: Usporedba rezultata nakon primjene Gaussovog šuma.

	MSE	NMSE	PSNR	SSIM
Zero-Fill	0.008216	0.1454	20.88	0.5723
Compressed Sensing	0.05177	0.8954	12.93	0.1154
U-Net	0.006443	0.1132	21.95	0.6398
U-Net 5 epoha	0.004957	0.08762	23.14	0.6968
U-Net 8 epoha	0.005049	0.08924	23.09	0.7074
E2E VarNet	0.00837	0.1476	20.84	0.5094
E2E VarNet 5 epoha	0.007133	0.125	21.54	0.5672
E2E VarNet 12 epoha	0.006787	0.1192	21.73	0.5889

Tablica 5.3: Metrike rekonstrukcija nakon primjene maske Gaussovog šuma.

6. ZAKLJUČAK

Uspješna rekonstrukcija slika snimljenih magnetskom rezonancom mozga kompleksan je i zahtjevan zadatak. Python biblioteka *fatMRI* pruža funkcije korisne za rad s rekonstrukcijom magnetske rezonance. Nudi gotove gotove tehnike za rekonstrukciju, poput *zero-fill* i *compressed sensing* tehnika, i istrenirani modeli, U-Net i End-to-End VarNet. U ovom radu se primjenjuje metoda prijenosa učenja s ciljem poboljšanja rezultata na novim skupovima podataka istog tipa podatka. Na potpuno uzorkovanu sliku postavlja se maska poduzorkovanja i time se imitira šum. Zatim se nad tom slikom primjenjuju prethodno spomenute metode i modeli za rekonstrukciju. Rezultati metoda i modela uspoređeni su s izvornim podacima. Korištene su tri vrste maska: *equispaced*, *random equispaced* i maska Gausovog šuma. Kod *equispaced* i *random equispaced* maski primjećujemo pogoršanje kvalitete rekonstrukcije nakon naknadnog treniranja u slučaju U-Net modela, dok se kod End-to-End VarNet modela poboljšala. U slučaju maske Gausovog šuma rezultati su suprotni, U-Net se poboljšao, a End-to-End VarNet pogoršao. Ovi rezultati dovode do zaključka da različiti modeli različito reagiraju na različite maske te da se prijenosom učenja rezultati rekonstrukcija mogu poboljšati. Izbor metode rekonstrukcije i maske poduzorkovanja je ključna stavka za dobivanje kvalitetnih slika magnetskom rezonancom. U nijednom slučaju kvaliteta rekonstrukcije nije dovoljno blizu izvornoj kvaliteti kako bi se koristile u medicinske svrhe. No, i dalje kvaliteta slike je vidljivo veća te se s prijenosom učenja i boljom optimizacijom može poboljšati kvaliteta rekonstrukcije.

LITERATURA

- [1] Magnetic resonance imaging (mri). National Institute of Biomedical Imaging and Bioengineering (NIBIB). Retrieved from <https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>.
- [2] Florian Knoll Jure Zbontar and Anuroop Sriram. fastmri: An open dataset and benchmarks for accelerated mri. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 2019.
- [3] Florian Knoll and Zbontar. fastmri: A publicly available raw k-space and dicom dataset of knee images for accelerated mr image reconstruction using machine learning. *Radiology: Artificial Intelligence*, 2(1):e190007, 2020.
- [4] Michael Lustig and Donoho. Sparse MRI: The application of compressed sensing for rapid MR imaging. *Magnetic Resonance in Medicine*, 58(6):1182–1195, 2007.
- [5] Martin Uecker and Lai. Espirit—an eigenvalue approach to autocalibrating parallel mri: Where sense meets grappa. *Magnetic Resonance in Medicine*, 71(3):990–1001, 2014.
- [6] Mri reconstruction toolbox (bart). <https://mrirecon.github.io/bart/index.html>. Accessed: April 17, 2023.
- [7] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. *arXiv preprint arXiv:1811.08839*, 2015.
- [8] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation, 2015.
- [9] IBM Cloud Education. Convolutional neural networks, 2023. Accessed: November 17, 2024.
- [10] EITCA Academy. What is the role of activation functions in a neural network model?
- [11] Jure Zbontar Anuroop Sriram and Tullie Murrell. End-to-end variational networks for accelerated mri reconstruction. 2020.
- [12] Roberto Souza and Oeslle Lucena. An open, multi-vendor, multi-field-strength brain mr dataset and analysis of publicly available skull stripping methods agreement. *NeuroImage*, 170:482–494, 2018. Segmenting the Brain.

[13] Transfer learning, 2023. Accessed: November 18, 2024.

[14] Visionular. Vmaf, ssim, psnr: Which is the best video quality metric?, 2023.

SAŽETAK

Ovaj se rad bavi rekonstrukcijom slika magnetske rezonance mozga primjenom metoda dubokog učenja implementiranih u fastMRI biblioteku. Magnetska rezonanca je ključna metoda za dijagnostiku u medicini. Cilj ovog rada je istražiti primjene tehnike prijenosa učenja na unaprijed istreniranim U-Net i End-to-End VarNet modelima kako bi se poboljšala kvaliteta rekonstrukcije slika uz poduzorkovane podatke. Korišteni su fastMRI i Calgary-Campinas skupovi podataka, a podatci su pripremljeni uz primjenu različitih maski poduzorkovanja ekvidistantnih, slučajnih ekvidistantnih i maski s Gaussovim šumom. Modeli su trenirani i evaluirani pomoću SSIM i PSNR metrika. Rezultati pokazuju da prijenosom učenja možemo poboljšati kvalitetu rekonstrukcije, pogotovo na End-to-End VarNet modelu. Kvaliteta rekonstrukcija još uvijek ne doseže razinu potrebnu za kliničku upotrebu.

Ključne riječi: magnetska rezonanca, rekonstrukcija slika, duboko učenje, fastMRI, prijenos učenja

ABSTRACT

Reconstruction of magnetic resonance imaging of the brain using the fastMRI library.

This paper addresses the reconstruction of magnetic resonance images using deep learning methods implemented in fastMRI library. Magnetic resonance is a key diagnostic tool in medicine. The aim of this paper is to research uses of transfer learning techniques on pre-trained U-Net and End-to-End VarNet models to improve the quality of image reconstruction from undersampled data. fastMRI and Calgary-Campinas datasets were used, and data was prepared using multiple undersampling masks: equispaced, random equispaced and masks with Gaussian noise. The models were trained and evaluated using SSIM and PSNR metrics. Results show that transfer learning can enhance reconstruction quality, particularly for the End-to-End VarNet model. However, the quality of reconstructions still falls short of the level required for clinical use.

Keywords: magnetic resonance, image reconstruction, deep learning, fastMRI, transfer learning.

ŽIVOTOPIS

Dražen Bertić rođen je 3. kolovoza 2000. u Osijeku. Pohađao je Osnovnu školu Mladost u Osijeku. Nakon završetka upisuje Elektrotehničku i prometnu školu Osijek koju završava 2019. godine. Nakon završetka srednje škole upisuje sveučilišni prijediplomski studij Elektrotehnika i informacijska tehnologija na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Na drugoj godini studija, akademske godine 2020./2021., se opredjeljuje za smjer Komunikacije i informatika koji završava 2022. godine. Nakon završenog prijediplomskog studija upisuje sveučilišni diplomski studij Računarstvo, smjer Informacijske i podatkovne znanosti na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Od 2022. kao student radi na poziciji sistem inženjera u tvrtki Intheos d.o.o..



Potpis autora