



Številka naloge: M-1007/2004
Datum: 10. 6. 2004

Fakulteta za elektrotehniko Univerze v Ljubljani izdaja naslednjo nalogo:

Kandidat: **Darko ŠKERL**, univ. dipl. inž. el.

Naslov: ***VREDNOTENJE MER PODOBNOSTI ZA PORAVNAVO
MEDICINSKIH SLIK***

Vrsta naloge: Magistrsko delo

Tematika naloge:

Poravnava slik je ena najpomembnejših operacij obdelave in analize medicinskih slik. Natančnost in zanesljivost poravnave je predvsem odvisna od tehnike zajemanja, vsebine slik, prostorske preslikave, mere podobnosti ter optimizacijskega postopka. Zaradi kompleksne soodvisnosti teh vplivov je zelo težko ocenjevati posamezne vplive na kvaliteto poravnave.


V magistrskem delu se predvsem posvetite vplivu mere podobnosti na poravnavo. Razvijte postopek za objektivno vrednotenje vpliva mere podobnosti na poravnavo medicinskih slik, zajetih z istimi in/ali različnimi tehnikami. S predlaganim postopkom testirajte in ovrednotite najpogosteje uporabljene mere podobnosti. Preučite uporabnost postopka za študij vplivov vzorčenja, interpolacije, velikosti histogramov ter šuma, svetlostnih nehomogenosti, geometrijskih popačitev, delnega prekrivanja slik in razlik v slikovni vsebini na različne mere podobnosti.

Mentor:


prof. dr. Franjo Pernuš



Predstojnik katedre:


prof. dr. Rihard Karba

Dekan:


prof. dr. Tomaž Slivnik

Univerza v Ljubljani
Fakulteta za elektrotehniko

Darko Škerl

**Vrednotenje mer podobnosti za
poravnavo medicinskih slik**

Magistrsko delo

Mentor:

Prof. dr. Franjo Pernuš

Ljubljana, junij 2004

ma 1083



D 50825 / 2.7.04

ZAHVALA

Za podporo, nasvete, ideje in drugo pomoč bi se zahvalil svojemu mentorju prof. dr. Franju Pernušu. Zahvalil bi se tudi doc. dr. Boštjanu Likarju, ki mi je pri razvoju postopka, ki ga opisujem v nalogi zelo pomagal in je bil vedno na voljo za konstruktivne pogovore in nasvete.

Za prijetno delovno vzdušje na delovnem mestu v laboratoriju se zahvaljujem tudi vsem sodelavcem, ki so s svojimi idejami tudi pripomogli k izdelavi tega dela.

Zahvala pa gre tudi moji puncu Tjaši, ki me že toliko časa podpira pri mojem delu ter mi tudi pomaga kadarkoli potrebujem njeno pomoč.

Na koncu pa bi se zahvalil še mami, sestri, bratu in ostalim sorodnikom ter prijateljem in znancem, ki so me spremljali na moji poti.

V Ljubljani, junij 2004

Darke Škerl



Povzetek

Vrednotenje poravnave je pomemben, a zapleten postopek. Točnost in robustnost metod poravnave je odvisna od vrste elementov kot so postopek zajema slik in nastavitve parametrov zajema, vsebina slik, transformacije na sliki, uporabljena mera podobnosti in uporabljena optimizacija. Zapleten medsebojni vpliv vseh teh parametrov otežuje vrednotenje vplivov posameznih parametrov na potek poravnave. V tem delu smo se osredotočili na analizo mer podobnosti za togo poravnavo. Predlagali smo postopek za vrednotenje mer podobnosti, ki omogoča vrednotenje brez uporabe optimizacijskih algoritmov. Omogoča tudi analizo vplivov različnih parametrov kot so šum, svetlostne nehomogenosti, velikost vezanega histograma, podvzorčenje, ... na potek mer podobnosti. Postopek smo v magistrskem delu natančno opisali. S predlaganim postopkom smo ovrednotili enajst mer podobnosti, ki se uporabljajo v togi poravnavi. Vrednotenje smo opravili na 3D simuliranih in realnih magnetno resonančnih slikah (MR), na realnih slikah računalniške tomografije (CT) slikah in na slikah pozitronske tomografske emisije (PET). Pokazali smo, da sta medsebojna informacija in normalizirana medsebojna informacija zelo natančni pri vseh kombinacijah poravnave, ki smo jih analizirali.

Abstract.

Evaluation of a registration method is an important but complex and application-dependent task. The accuracy and robustness of a registration method depends on a number of factors, such as image acquisition protocol and parameter settings, image content, spatial transformation, similarity measure, and optimization. The complex interdependence of these factors makes the assessment of a particular factor on registration difficult even for very specific registration tasks. In this thesis we study the influence of similarity measures on the accuracy and robustness of rigid registrations. To reduce the degree of complexity or uncertainty in similarity measure evaluation, we propose an evaluation protocol that enables optimization-independent quantitative evaluation including the study of the influence of different implementation issues. With the proposed protocol we have evaluated 11 different similarity measures used for rigid body registration. The evaluation has been performed on simulated 3D magnetic resonance (MR) images and real computed tomography (CT), MR and PET images. Besides, the effects of histogram binning, noise and intensity inhomogeneity on the similarity measures have been studied. We have shown that the mutual information (MI) and normalized MI performed the best.

KAZALO POGLAVIJ

| | | |
|-----------|--|-----------|
| 1 | UVOD | 1 |
| 2 | TEHNIKE ZAJEMANJA SLIK | 4 |
| 2.1 | RAČUNALNIŠKA TOMOGRAFIJA (CT) | 4 |
| 2.2 | MAGNETNA REZONANCA (MR) | 7 |
| 2.3 | POZITRONSKA EMISIJSKA TOMOGRAFIJA (PET) | 10 |
| 3 | PORAVNAVA MEDICINSKIH SLIK | 11 |
| 3.1 | PORAVNAVA | 11 |
| 3.2 | MERA PODOBNOSTI | 13 |
| 3.3 | TOGA PORAVNAVA | 14 |
| 4 | MERE PODOBNOSTI | 16 |
| 4.1 | VEZANI HISTOGRAM SVETLOSTI IN INTERPOLACIJA | 16 |
| 4.2 | MERE PODOBNOSTI..... | 18 |
| 4.2.1 | <i>Korelacijsko razmerje (CR)</i> | 20 |
| 4.2.2 | <i>Energija (E)</i> | 21 |
| 4.2.3 | <i>Vezana Entropija (Ent)</i> | 22 |
| 4.2.4 | <i>Medsebojna informacija (MI)</i> | 24 |
| 4.2.5 | <i>Normalizirana medsebojna informacija (NMI)</i> | 25 |
| 4.2.6 | <i>Točkovna mera podobnosti na osnovi medsebojne informacije (PSMI)</i> | 26 |
| 4.2.7 | <i>Spremenjena točkovna mera podobnosti na osnovi medsebojne informacije (PSUH)</i> .. | 27 |
| 4.2.8 | <i>Entropijski korelacijski koeficient (ECC)</i> | 27 |
| 4.2.9 | <i>Woodsov kriterij (WC)</i> | 28 |
| 4.2.10 | <i>Medsebojna informacija na osnovi Havrda-Charvatove entropije 2. reda (HCE2)</i> | 28 |
| 4.2.11 | <i>Medsebojna informacija na osnovi Havrda-Charvatove entropije 3. reda (HCE3)</i> | 28 |
| 4.2.12 | <i>Logaritmična podobnost</i> | 29 |
| 5 | PREGLED DOSEDANJIH ANALIZ MER PODOBNOSTI | 30 |
| 6 | PROTOKOL ZA ANALIZO MER PODOBNOSTI | 33 |
| 7 | EKPERIMENTALNA BAZA SLIK | 37 |
| 7.1 | SKUPINA 1 | 37 |
| 7.2 | SKUPINA 2A | 37 |
| 7.3 | SKUPINA 2B | 38 |
| 7.4 | SKUPINA 3 | 38 |
| 7.5 | SKUPINA 4 | 39 |
| 8 | EKSPERIMENTI IN REZULTATI | 40 |
| 8.1 | IMPLEMENTACIJA | 40 |
| 8.2 | REZULTATI | 41 |
| 9 | ZAKLJUČEK | 48 |
| 10 | LITERATURA | 50 |

KAZALO SLIK

| | |
|---|----|
| Slika 1 Prikaz delovanja naprave za računalniško tomografijo..... | 5 |
| Slika 2 Primeri rezin CT slik | 6 |
| Slika 3 Primer rezin MR slike..... | 9 |
| Slika 4 Rezina 3D slike PET, ki prikazuje možgane..... | 10 |
| Slika 5 Grafični prikaz postopka poravnave..... | 12 |
| Slika 6 Dve preprosti sliki predstavljeni s svetlostmi | 16 |
| Slika 7 Vezani histogram verjetnosti..... | 17 |
| Slika 8 Interpolacija delnih volumnov | 18 |
| Slika 9 Vezani histogram za poravnan par slik (levo), medsebojno premaknjen za 2 mm (sredina) in 5 mm (desno) | 23 |
| Slika 10 Potek mere podobnosti, ki prikazuje točke uporabljene v enačbah za izračun lastnosti..... | 34 |
| Slika 11 Rezina 32 iz T1, T2 in PD umetnih slik možganov..... | 37 |
| Slika 12 Sedma rezina slik T1, T2 in PD s tumorjem | 38 |
| Slika 13 Deseta rezina slike T1, T2 in PD brez tumorja..... | 38 |
| Slika 14 MR slika vretenca L3 in CT slika vretenc L1 do L5..... | 39 |
| Slika 15 Rezina 7 MR T2 ter PET slike | 39 |
| Slika 16 Model svetlostne nehomogenosti s katero je množena vsaka rezina slike..... | 46 |

KAZALO TABEL

| | |
|---|----|
| Tabela 5.1 Primerjava postopkov analize mer podobnosti..... | 30 |
| Tabela 8.1 Lastnosti mer podobnosti pri poravnavi MR –CT (skupina 3), MR – MR (skupina 2a) in MR - PET (skupina 4) slik | 42 |
| Tabela 8.2 Lastnosti mer podobnosti pri poravnavi MR – CT (skupina 3) slik in spreminjanju dimenzij histograma..... | 43 |
| Tabela 8.3 Lastnosti mer podobnosti pri MR - MR T1, T2 in PD (skupina 2a in 2b) poravnava slika | 44 |
| Tabela 8.4 Analiza s simuliranimi slikami in različnim številom točk..... | 45 |
| Tabela 8.5 Poravnava pošumljenih slik in slik, ki imajo prisotne svetlostne nehomogenosti | 46 |

INDEKS

2

2D, 1, 4, 7, 11, 17, 22, 31, 52

3

3D, 1, 4, 5, 10, 11, 14, 17, 31, 51, 52

C

CT, 1, 3, 4, 5, 6, 8, 30, 31, 37, 38, 39, 41, 42, 43, 46, 50, 51, 52

E

elastična poravnava, 11
 energija, 13
 energija histograma, 18
 entropija, 13, 18, 19, 22, 24, 25, 27, 28, 44, 47, 48, 49
 entropijski korelacijski koeficient, 19, 27

F

fMRI, 1, 7, 11

G

gladkost, 34, 35, 41, 44

H

Havrda – Charvat, 19
Hountsfieldovo število, 5

I

interpolacija, 3, 12, 13, 16, 17, 18, 24, 30, 40, 45, 48
interpolacija delnih volumnov, 17
najbližji sosed, 17
trilinearna interpolacija, 18
iznihavanje, 7
izrazitost optimuma, 34, 36, 41, 47, 49

K

kontrastno sredstvo, 7
korelacijsko razmerje, 13, 19, 20, 21

M

medicinske slike, 11, 17, 24, 48
medsebojna informacija, 13, 18, 19, 24, 25, 26, 27, 28,
44, 47, 48, 49
mera podobnosti, 3, 13, 16, 18, 19, 30, 32, 33, 34, 36,
40, 42, 45, 48, 49
MR, 1, 3, 4, 7, 8, 9, 30, 31, 37, 38, 39, 40, 41, 42, 43, 44,
46, 48, 50, 51, 52

N

najbližji sosed, 30
natančnost, 32, 34, 35, 41, 42, 44
normalizirana medsebojna informacija, 19

O

območje konvergence, 31, 34
optimizacija, 3, 11, 12, 30, 32, 48

P

PET, 1, 3, 4, 10, 30, 31, 37, 39, 40, 41, 42, 48, 51
plavajoča slika, 12

poravnava, 2, 3, 11, 12, 13, 19, 21, 27, 30, 31, 32, 33, 35,
40, 42, 48, 49
cilj postopka, 11
elastična, 11
enomodalna, 12
grafični potek, 12
toga, 11
večmodalna, 12
psevdoobarve, 4

R

registracija, 2

S

Shannon, 24, 48, 50
spremenjena točkovna mera podobnosti na osnovi
medsebojne informacije, 19, 27
svetlostne nehomogenosti, 3, 45, 47, 48, 49

Š

šum, 3, 45, 47, 48, 49

T

točkovna mera podobnosti na osnovi medsebojne
informacije, 19, 26
točnost, 34, 35, 36, 40, 42, 43, 44, 49
toga poravnava, 11, 14, 15

U

ustavitveni kriterij, 3

V

vezani histogram, 16, 17, 23, 40
voksel, 5, 7, 12, 16, 17, 19, 25, 28, 37, 38, 39

W

woodsov kriterij, 13, 19, 28, 42, 48

Z

zlati standard, 30, 31, 33, 37, 38, 39, 48

1 Uvod

Življenjski standard sodobne družbe se ves čas povečuje. S tem je povezana tudi večja skrb za zdravje, zaradi česar se vedno več sredstev vlaga v boljše diagnostične postopke in učinkovitejše zdravljenje.

Pri diagnostiki, načrtovanju in izvajanju terapije ter spremljanju poteka bolezni oz. učinkov zdravljenja si zdravniki z medicinskimi slikami vedno bolj pomagajo. Z odkritjem slikovnih postopkov, kot so magnetna resonanca (MR), ultrazvok (US), računalniška tomografija (CT) in druge, smo si odprli boljši pogled v notranjost človeškega telesa. Slikovne tehnike lahko delimo po različnih kriterijih. Glede na prostorske dimenzije slik delimo medicinske slikovne tehnike na dvodimenzionalne (2D) in tridimenzionalne (3D). Tridimenzionalne slikovne tehnike poskušajo zajeto informacijo o anatomski strukturi oz. njeni funkciji predstaviti v 3D sliki, pri čemer se geometrijski odnosi strukture ohranjajo. Tridimenzionalne slike zagotavljajo kvalitetno in podrobno informacijo o določeni anatomiji ali funkciji anatomske strukture. Z različnimi slikovnimi tehnikami lahko pridobimo različno informacijo o anatomskih strukturah in njihovih funkcijah. Slikovne tehnike nadalje delimo v anatomske in funkcionalne. Anatomske (rentgen, CT, MR, ultrazvok) dajejo informacijo o zgradbi neke strukture, funkcionalne (fMRI, PET in SPECT) pa o funkciji. S funkcionalnimi slikovnimi tehnikami lahko na primer določimo, kateri del, npr. možganov, je aktiven in kateri ne. Dvodimenzionalne oslikave realnega sveta lahko delimo na projekcijske oslikave in na oslikave preseka. Pri projekcijskih slikovnih tehnikah, značilni predstavnik je rentgenska slikovna tehnika, je 3D informacija o strukturi projicirana na 2D slikovno ravnino. Nasprotno pa oslikava preseka podaja 2D sliko ravnine, ki seka 3D strukturo, primer je ultrazvočna slikovna tehnika (US). Dodatno lahko slikovne tehnike delimo na tiste, ki se uporabljajo pred terapevtskim posegom, za diagnozo in načrtovanje posega, ter na slikovne tehnike, ki se med samim posegom uporabljajo za spremljanje in nadzor posega. Večino medicinskih slikovnih tehnik lahko uporabimo tako pred terapevtskim posegom kot med samim posegom, vendar različni faktorji, kot so omejitve in zahteve določenih medicinskih postopkov ter kvaliteta, invazivnost, hitrost in cena slikanja, določajo glavno področje uporabe. Zaradi visoke cene in počasnosti se 3D slikovne tehnike v glavnem uporabljajo za postavljanje diagnoze, za načrtovanje kirurških in radioloških posegov ter za vrednotenje uspešnosti posegov, njihova uporaba med samim terapevtskim posegom pa je

redkejša. Rentgenske slikovne tehnike, kot sta fluoroskopija ali digitalna radiologija ter 2D ultrazvok, so občutno cenejše, poleg tega pa zagotavljajo sliko v realnem času. Te slikovne tehnike se uporabljajo tako za diagnozo in načrtovanje posega pred terapevtskim posegom, kot za nadzor kirurških ali radioloških posegov. Rentgensko slikanje in ultrazvok se zelo pogosto uporabljata, vendar sta dvodimenzionalni slikovni tehniki in zato ne zagotavljata takšne prostorske informacije kot 3D slikovne tehnike. Poleg tega obstaja veliko število anatomskih značilnic, ki so dobro vidne na CT ali MR slikah in niso vidne na rentgenskih slikah oziroma ultrazvoku.

Medicinske slike so pomembne tudi za terapijo npr. s kirurškim posegom. Pred operacijo se zdravnik na podlagi potrebne informacije o organu odloči, katere slikovne tehnike bo potreboval. Informacijo, ki mu jo da posamezna tehnika, mora združiti v zgoščeno obliko tako, da prikaže le tisto, kar ga zanima. Tako dobi zadostno količino podatkov, na podlagi katerih se lahko odloči za načrt operacije. Tudi med operacijo lahko uporablja medoperativno zajete slike s katerimi lahko preverja skladnost poteka operacije z načrtovano operacijo.

Medoperativne slikovne tehnike, kot sta rentgensko slikanje s pomočjo fluoroskopije in ultrazvok, omogočajo kirurgu spremljanje položaja kirurškega orodja glede na zdravljen organe v realnem času. Tako je lahko zareza v koži pri operaciji z uporabo slikovnih tehnologij manjša kot brez uporabe teh tehnologij saj kirurgu ni treba razgrniti vsega tkiva, da bi videl strukturo, ki jo kirurško odstranjuje oz. zdravi. Lahko se tudi izogiba pomembnim živcem, žilam in ostalim strukturam v bližini operacijskega polja, ki bi jih lahko poškodoval.

Posamezne medicinske slike so torej zelo pomembne za slikovno podprto postavljanje diagnoz, načrtovanje in slikovno vodenje terapij ter učinkov terapij. V zadnjem času pa je vedno pomembnejše tudi združevanje informacij iz večjega števila slik, ki so lahko zajete z isto slikovno tehniko ob različnih časih, z različnimi slikovnimi tehnikami ali pa z isto slikovno tehniko različnih subjektov.

Slike pridobljene ob različnih časih ali z različnimi tehnikami so lahko med seboj premakanjene in zarotirane ali pa tudi še drugače deformirane. Zaradi lažje primerjave jih je treba preslikati tako, da bodo iste anatomske strukture na istih mestih na obeh oz. vseh slikah. Temu postopku pravimo poravnava ali registracija. S postopkom poravnave eno sliko spreminjamo toliko časa, dokler ni kar najbolj podobna drugi. V večini primerov spreminjamo eno sliko, medtem ko druga ostaja nespremenjena; lahko pa spreminjamo tudi obe. Po vsakem koraku spreminjanja ene slike moramo biti zmožni oceniti kako podobni sta si sliki. Za to potrebujemo neko mero podobnosti. Uporabljamo jo kot kriterijsko funkcijo pri

optimizaciji parametrov geometrijske poravnave. Mera geometrijske preslikave podobnosti ima minimum oz. maksimum pri tisti transformaciji, ki spremeni prvo sliko tako, da je vsebinsko najbolj podobna drugi.

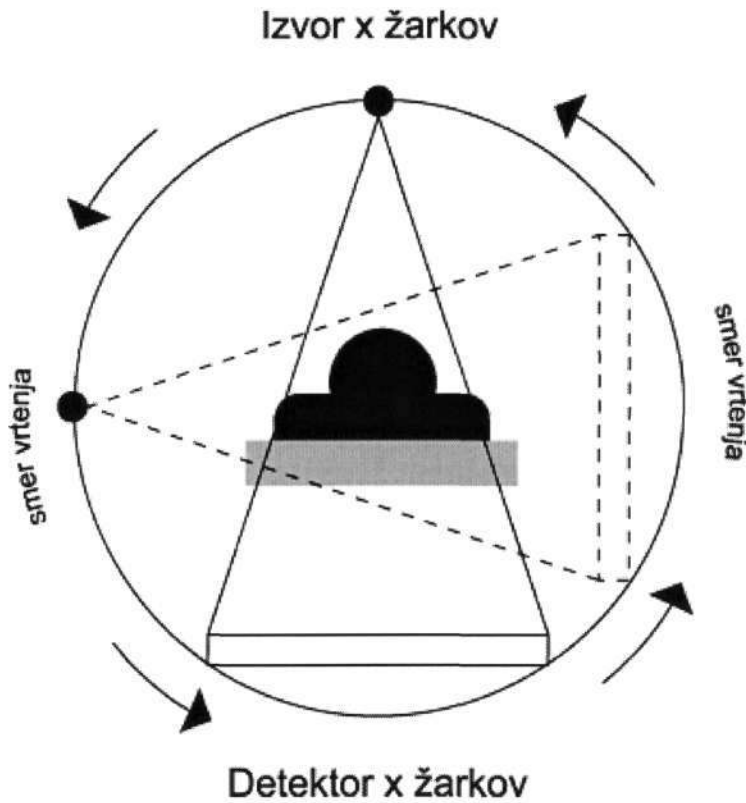
Obstaja več vrst mer, ki se uporabljajo pri poravnavi (registraciji). Ene so informacijske, druge korelacijske. Vsaka ima svoje specifične lastnosti, ki določajo in omejujejo njeno uporabo. V magistrski nalogi sem se osredotočil na analizo mer podobnosti. Obnašanje mer podobnosti je odvisno od različnega števila parametrov. Nekatere mere imajo parametre, ki jih je potrebno pravilno nastaviti, če hočemo dobiti smiselne rezultate. Vse pa so na nek način odvisne od vsebine slik, prisotnosti šuma, svetlostnih nehomogenosti, vrste interpolacije, območja prekrivanja med slikami, ... Za uporabo mer podobnosti je torej pomembno vprašanje, kako vse to vpliva na potek mer. Če vplive poznamo, se lahko med merami, ki jih imamo na razpolago, odločimo katero bomo uporabili. Mere podobnosti uporabljamo v kombinaciji z optimizacijsko metodo. Zaradi tega je pomembno poznati tudi nekatere lastnosti mere podobnosti, ki jih lahko uporabimo za nastavitve parametrov optimizacije (ustavitveni kriterij). Zaradi naštetega sem razvil protokol za kvantitativno analizo mer podobnosti [1], ki ga bom predstavil v tem delu skupaj z rezultati analize lastnosti enajstih mer podobnosti, ki sem jih uporabil pri poravnavi MR slik na CT, MR na MR in MR na PET.

2 Tehnike zajemanja slik

Poznamo več tehnik zajemanja slik. Nekaj najpogosteje uporabljenih sem omenil že v uvodu. V tem poglavju bom na kratko opisal fizikalno in tehnično ozadje računalniške tomografije (CT), magnetne resonance (MR) in pozitronske emisijske tomografije (PET). Slike zajete s temi tehnikami sem uporabil v eksperimentih, ki so opisani v poglavjih 7 in 8. Naj poudarim, da so medicinske slike črnobelega. Področja na slikah lahko po želji pobarvamo, da poudarimo ali ločimo posamezne dele slike ali organe med seboj. Takim barvam pravimo *psevdoobarve*.

2.1 Računalniška tomografija (CT)

Z računalniško tomografijo dobimo 3D slike anatomskih struktur. Ponavadi se zajemajo 2D rezine slike eno za drugo. Iz rezin zgradimo 3D sliko. 2D rezino dobimo z rekonstrukcijo z uporabo projekcij X-žarkov iz različnih smeri. Žarke iz različnih kotov projiciramo na detektor. Detektor X-žarkov zazna signal, ki predstavlja slabljenje na poti od izvora žarka skozi objekt do detektorja. Z računalnikom nato obdelamo informacijo, ki jo dobimo iz senzorja, in tako dobimo koeficiente slabljenja. Najpogosteje uporabljena metoda za to rekonstrukcijo se angleško imenuje *backprojection* [2]. Na naslednji sliki je shematično prikazano delovanje CT naprave.




Slika 1 Prikaz delovanja naprave za računalniško tomografijo

Če hočemo primerjati podatke iz drugih CT skenerjev, ki imajo lahko drugačne izvore X-žarkov z drugačno energijo in zato drugačno slabljenje v istem materialu, moramo svetlosti vokslov CT slike podati v Hounfield-ovih enotah H:

$$H = \frac{\mu - \mu_W}{\mu_W} 1000 \quad (1)$$

μ predstavlja linearno slabljenje voksla, μ_W pa predstavlja linearni koeficient slabljenja za vodo. Voksel je najmanjši element 3D slike. Hounsfildovo število omogoča enostavno kalibracijo CT skenerja samo s skeniranjem vode. Ker je Hounsfildovo število linearno odvisno od koeficienta slabljenja μ , izgledajo kosti na CT slikah svetleje kot ostalo tkivo.

Slika 2 prikazuje nekaj primerov CT slik možganov, hrbtenice in medenice.



Slika 2 Primeri rezin CT slik

2.2 Magnetna resonanca (MR)

Metode za anatomsko slikanje delov teles z jedrsko magnetno resonanco so v razvoju že od zgodnjih sedemdesetih let. Z odličnim razlikovanjem mehkih tkiv je magnetno resonančno slikanje postalo orodje za diagnozo skoraj vseh možganskih anomalij. Ogawa [3] in Turner [4] sta spoznala, da bi bile MR slike lahko občutljive na količino kisika v krvi v možganih. Tako sta odprla pot v razvoj tehnike fMRI (funkcionalna magnetna resonanca), ki omogoča vpogled tudi v aktivnost (funkcijo) možganov.

V postopku slikanja z MR tehniko predmet slikanja postavimo v močno magnetno polje z gostoto večjo od 1 T. Zaradi zunanjega magnetnega polja se molekule z magnetnim dipolom orientirajo v smeri polja in material tako postane namagneten. Material izpostavimo močnemu radio frekvenčnemu (RF) impulzu, ki je pravokoten na smer magnetnega polja. To v materialu povzroči nihanje molekul. Po impulzu se magnetni dipoli začnejo umirjati. Temu koraku rečemo iznihavanje ali relaksacija. Iznihavanje magnetnih dipolov povzroča spremembo magnetnega polja v okolici materiala, kar lahko zaznamo s sprejemno anteno.

V enem ciklu zajemanja slike merimo iznihavanje magnetnega polja v okolici materiala. Če hočemo uspešno rekonstruirati 2D rezino slike, moramo ponoviti veliko zaporednih odzivov na zaporedje magnetno polje - radio frekvenčni signal. V vsakem ciklu spremenimo gradient magnetnega polja. Debelino rezine določa dolžina RF impulza, faza pa položaj znotraj ene rezine. Svetlost vokslov je odvisna od vrste parametrov. S spreminjanjem teh parametrov dobimo T1, T2 ali PD utežene slike.


Kontrast med tkivi je na T1, T2 in PD slikah drugačen. Tkiva z malo vodnih molekul, ki se lahko prosto gibljejo, so na MR slikah videti temnejša. Zaradi relativno visokega števila kombinacij različnih parametrov je za natančno diagnozo potrebno razumevanje vpliva posameznih lastnosti organa na njegovo MR-svetlost in vpliva parametrov snemanja na kontrast [5]. Selektivna sprememba katerega koli parametra ima lahko za posledico spremembo kontrasta. Ker želimo zajeti čim bolj kvalitetne slike v čim krajšem času, za zajem uporabljamo kontrastna sredstva, ki zmanjšujejo čase iznihavanja. Pri magnetno resonančnem slikanju kontrastnih sredstev ne vidimo neposredno kot na primer pri rentgenskem slikanju, ampak merimo njihov vpliv na iznihavanje vode v snovi. Končni učinek pa je odvisen od uporabljenega impulznega zaporedja in ni vedno linearno odvisen od odmerka kontrastnega sredstva.

Preiskave z MR so po diagnostičnih področjih razporejene približno na naslednji način: 50 – 60 % slikanja z MR je namenjenega pojasnjevanju patologije glave, 10 – 15 % bolezni hrbtenice, 15 – 20 % kostno-mišičnega sistema in po 5 % patologije trebuha in prsnega koša.

Pomankljivosti MR sta, da premiki preiskovanca med snemanjem povzročijo več popačenj kot pri CT in da zahteva več časa. CT tehnika je zato primernejša za slikanje nesodelujočih ljudi ter za ugotavljanje znotrajlobanjske krvavitve, saj v prvih urah lažje odkrije svežo kri kot MR.

Zaradi visokega magnetnega polja v MR napravi obstaja tudi nekaj nevarnosti za okolico in za samo napravo. Edina resna nevarnost slikanja z MR so feromagnetni materiali v okolici. Veliki feromagnetni predmeti v bližini kot so vlaki, avtobusi... lahko vplivajo na homogenost magnetnega polja in s tem posledično na kakovost slike. Sila s katero magnet deluje na okoliške feromagnetne predmete je odvisna od teže predmeta. MR napravo je torej potrebno namestiti v prostor, ki je obdan s Faradayevo kletko. Paziti pa moramo, da v bližino MR naprave ne prinesemo škarij, ključev, verižic in podobno. Zelo pomembno pa je, da se radiolog pred zajemanjem MR slik prepriča o morebitnih feromagnetnih vsadkih, ki jih lahko ima pacient. Magnetno polje nad 0.01 T na primer zmoti delovanje srčnega vzpodbujevalnika in lahko povzroči, da se vključi. Vzpodbujevalnik sicer deluje normalno, vendar se moramo zavedati, da je taka motnja lahko potencialna nevarnost za bolnika, ki ima težave s srcem. Med delovanjem se lahko žice magneta, ki so potopljene v tekoči helij, na nekem delu segrejejo in jim zraste električna upornost, zaradi katere se poveča količina sproščene toplote. To ima lahko za posledico izparitev helija in posledično tudi zadušitev pacienta, če prezračevalni sistem ne bi dobro deloval. Pri testnem pregretju navitja se pacientu zaradi dobrih varnostnih ukrepov ni zgodilo nič.

Slika 3 prikazuje nekaj primerov MR slik.




Slika 3 Primer rezin MR slike

2.3 Pozitronska emisijska tomografija (PET)

PET tehnika je neinvazivna in je namenjena merjenju aktivnosti celic v telesu. V praksi je uporabljena pri pacientih z določenimi težavami z možgani ali s srcem, vedno pogosteje pa tudi pri pacientih z rakom. PET tehnika omogoča zajem slik, na katerih je vidna funkcionalnost določene anatomske strukture, prej omenjeni tehniki pa omogočata vpogled v anatomijo telesa. Vidimo lahko torej spremembo v strukturi oz. anatomiji, ki je lahko posledica bolezni. Bolezen pa lahko vpliva tudi na biokemijske procese, ki se lahko pojavijo pred pojavom anatomske spremembe. PET je torej tehnika, ki omogoča vpogled v nekatere od teh sprememb. Celo pri boleznih kot je Alzheimerjeva bolezen, kjer ni večjih strukturnih sprememb, s PET tehniko lahko vidimo določene biokemijske spremembe.

Pozitronska emisijska tomografija je nuklearnomedicinska preiskava, pri kateri s kratkoživimi izotopi elementov, ki sodelujejo v presnovi (glukoza, ogljik, dušik, vodik itd) prikažemo najzgodnejše spremembe v presnovi celic, kar je prvi znak rakaste tvorbe. S to metodo lahko odkrijemo maligne tumorje, ki so veliki le nekaj milimetrov in katerih zdravljenje je navadno uspešno. Slikovna tehnika je pomembna za prikaz razširjenosti rakaste bolezni ali njene zgodnje ponovitve.

Pred zajemom PET slike v pacienta vbrizgamo radioaktivno snov. PET detektorji nato sprejemajo pozitrone, ki se sproščajo v tkivu. Z izračuni korelacij med detektorji pozitronov dobimo slike krvnih tokov in glukozne aktivnosti. Glukoza prek krvnega obtoka energijsko napaja celice, zato glukozna aktivnost označuje tudi aktivnost nevronov. Takšno slikanje prikazuje vidne razlike med npr. možganskimi aktivnostmi v različnih stanjih, npr. poslušanje glasbe, računanje, pogovor ali spominjanje na pogovor ipd. Na naslednji sliki lahko vidimo PET slike možganov.



Slika 4 Rezina 3D slike PET, ki prikazuje možgane

3 Poravnava medicinskih slik

V tem poglavju je razloženih nekaj osnovnih pojmov, ki se uporabljajo pri poravnavi medicinskih slik in se bodo pojavljali v nadaljevanju. Opisal bom tudi matematično ozadje toge poravnave.

3.1 Poravnava

Iskanje geometrijske poravnave, ki pripelje eno sliko v najboljšo lego glede na drugo sliko, se imenuje poravnava. Poravnavo lahko definiramo tudi kot iskanje take preslikave med koordinatami enega in drugega prostora, da točke v obeh slikah, ki pripadajo istim anatomskim strukturam, ležijo na istih koordinatah. Algoritmi za poravnavo slik iščejo tisto geometrijsko preslikavo med vsemi dovoljenimi preslikavami med dvema ali več prostoroma, ki izpolni oziroma optimizira kriterij o ujemanju prostorov. Kriterij o ujemanju prostorov je lahko kriterijska funkcija ali mera podobnosti, ki opisuje prostorsko ujemanje značilnic, na katerih temelji poravnava. Tako je cilj postopka za poravnavo najti takšno geometrijsko preslikavo, ki optimizira dani kriterij. Postopke za poravnavo medicinskih slik lahko delimo glede na prostorsko domeno, naravo značilnic, na katerih temelji poravnava, naravo geometrijskih preslikav, naravo interakcij z uporabnikom, glede na postopek optimizacije, modaliteto slik in glede na osebek in objekt poravnave [6].

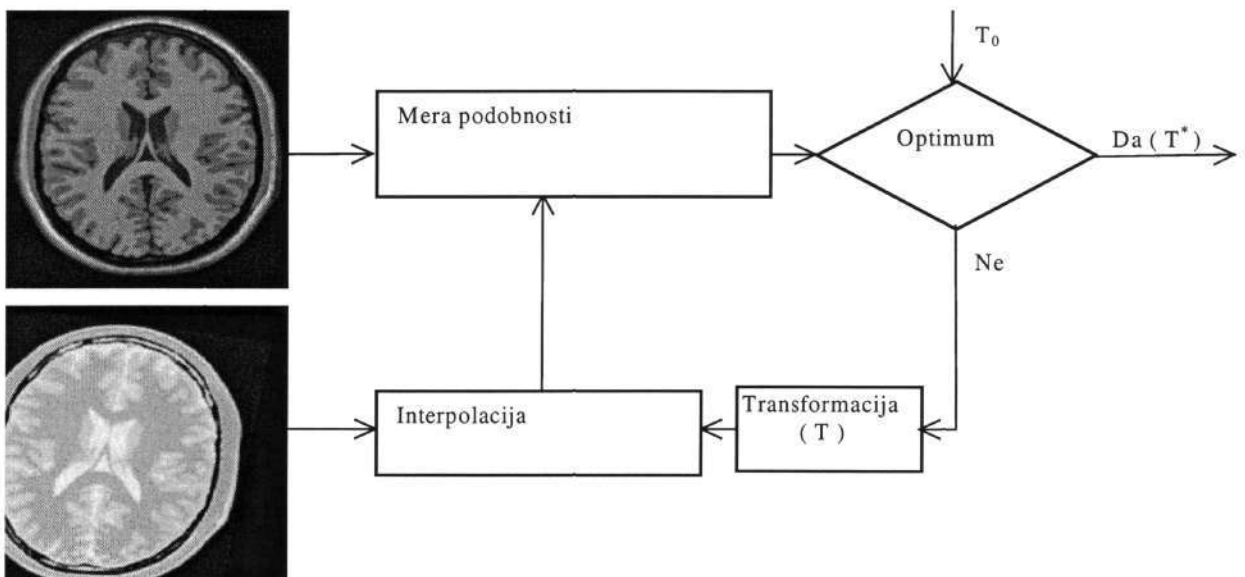
V grobem pa jih lahko delimo na toge in elastične. Pri togi poravnavi eno sliko prilegamo na drugo le z obračanjem in premikanjem. Objekti na sliki tako ohranjajo obliko. Togo poravnavo uporabljamo, da želeni objekt na eni sliki postavimo na iste koordinate kot na drugi sliki. Tudi v primeru, da objekta na obeh slikah nimata popolnoma enake oblike, lahko uporabimo tovrstno poravnavo. Toga preslikava ima v 2D prostoru tri prostostne stopnje, v 3D prostoru pa šest. Pri nekaterih slikovnih tehnikah, kot je na primer funkcionalna magnetna resonanca (fMRI), lahko pride tudi do manjšega popačenja oblike organov glede na ostale tehnike slikanja. Tega ne moremo odpraviti s pomočjo toge poravnave, morali bi spremeniti tudi obliko organov, ne samo njihovega položaja. Elastična poravnava sliko na določenih mestih krči in na drugih širi. S tem se spremeni oblika objektov na sliki. Število prostostnih stopenj elastične poravnave je lahko zelo veliko. S kombinacijo obeh poravnav lahko združimo slike, ki so med seboj dokaj različne.

Poravnave lahko delimo tudi na enomodalne in na večmodalne. Enomodalne poravnave so tiste pri katerih poravnavamo slike zajete z isto slikovno tehniko. Uporabimo jo, kadar nas zanimajo spremembe anatomije istega osebkca v določenem obdobju ali pa razlike med anatomijo različnih osebkov. Poravnava slik različnih modalitet se uporablja za združevanje informacije iz komplementarnih slikovnih tehnik. Večmodalna poravnava je v splošnem bolj zahtevna od enomodalne zaradi zapletenih in neznanih povezav med svetlostjo slikovnih elementov slik.

Poravnavo lahko matematično zapišemo kot iskanje transformacije T^* , ki bo rezultat naslednje optimizacije:

$$T^* = \underset{T}{\operatorname{argopt}}(SM(T(A), B)) \quad (2)$$

T^* je torej tista transformacija, pri kateri sta si sliki $T(A)$ in B glede na mero podobnosti SM najbolj podobni. $T(A)$ je transformirana slika A . Grafični potek poravnave je prikazan na sliki spodaj.



Slika 5 Grafični prikaz postopka poravnave

Plavajočo sliko rotiramo ter premikamo in zaradi tega nove koordinate vokslov niso vedno celoštevilske. V tem primeru potrebujemo interpolacijo, da lahko določimo vezani

histogram. Postopek določitve histograma je podrobneje opisan v poglavju 4.1. Nato izračunamo podobnost med obema slikama; mirujočo in transformirano. Rezultat peljemo v optimizacijsko metodo, ki se odloči ali je mera podobnosti dosegla optimum ali še ne. Če mera še ni dosegla optimuma, potem optimizacija spremeni parametre transformacije in postopek se ponovi. T_0 je začetna transformacija.

Iz diagrama zgoraj lahko razberemo tri ključne elemente poravnave. To so interpolacija, mera podobnosti in optimizacijska metoda. Vse tri imajo zelo velik vpliv na rezultat poravnave.

3.2 Mera podobnosti

Ko eno sliko spreminjamo, moramo vedeti, kako dobro je že poravnana z drugo. Sliki moramo torej primerjati med sabo. Najbolj intuitiven način primerjave je izračun neke značilnice, katere vrednost pove, kako dobro se sliki prilegata pri neki preslikavi. Značilnice se imenujejo mere podobnosti. Nekaterim meram podobnosti vrednost narašča, ko se sliki bolje prilegata, drugim pa manjša. Ta razlika med merama ni pomembna, ker lahko s preprosto matematično operacijo obrnemo potek vrednosti mere podobnosti in s tem ne zmanjšamo natančnosti in drugih lastnosti mere.

Mere podobnosti lahko delimo na globalne in točkovne. Globalne mere podobnosti opisujejo podobnost celih slik, medtem ko točkovne mere uporabljamo za meritev podobnosti manjših področij slike ali celo samo posameznih točk [7]. Točkovne mere podobnosti lahko izpeljemo iz globalnih in jih lahko tudi uporabimo za meritev podobnosti celih slik [7].

Mere podobnosti lahko delimo tudi na informacijske in korelacijske. Informacijske mere poskušajo maksimizirati informacijo, ki jo ima ena slika o drugi [8]. Nekaj primerov takih mer so medsebojna informacija, energija in entropija, ki jih bom podrobneje opisal v podpoglavju 4.2. Primeri korelacijskih mer so korelacijsko razmerje in Woodsov kriterij, ki jih bom tudi opisal kasneje.

3.3 Toga poravnava

Linearno preslikavo lahko predstavimo v obliki produkta med transformacijsko matriko in vektorjem. V dveh dimenzijah lahko vsako točko predstavimo v obliki vektorja

$$\vec{p} = \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3)$$

v treh dimenzijah pa v obliki

$$\vec{r} = \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (4)$$

Zadnji element v obeh vektorjih je potreben zaradi matričnega množenja.

Toga transformacija predpostavlja, da se slika navzven obnaša kot tog objekt, ki ga lahko le rotiramo in premikamo. Tridimenzionalna transformacija je predstavljena s 4x4 matriko T . Nove koordinate vseh točk na sliki izračunamo z matričnim množenjem

$$\vec{r} = T * \vec{r}' \quad (5)$$

kjer vektor \vec{r}' vsebuje koordinate pred transformacijo, vektor \vec{r} pa koordinate po transformaciji. Predmet lahko v 3D rotiramo okrog treh osi, premaknemo pa ga lahko prav tako vzdolž treh osi. S kombinacijo treh rotacij in treh translacij lahko predmet postavimo v poljubno lego v prostoru. Predmet lahko preslikamo na veliko načinov. Transformacijsko matriko je v tem primeru potrebno razdeliti na posamezne podmatrike.

$$\vec{r} = \mathbf{R}_x * \mathbf{R}_y * \mathbf{R}_z * \mathbf{T}_x * \mathbf{T}_y * \mathbf{T}_z * \vec{r}' \quad (6)$$

V primeru, da zamenjamo vrstni red translacij in rotacij, se spremenijo tudi matrike, saj množenje matrik ni komutativno. Vse tri translacijske matrike lahko združimo v matriko T_p .

$$T_p = \begin{bmatrix} 1, & 0, & 0, & t_x \\ 0, & 1, & 0, & t_y \\ 0, & 0, & 1, & t_z \\ 0, & 0, & 0, & 1 \end{bmatrix} \quad (7)$$

Parametri t_x , t_y in t_z predstavljajo premik v smereh x , y in z . Vrstni red premikov ni pomemben za končni položaj predmeta.

Tri rotacijske matrike lahko med seboj zmnožimo na šest načinov. V teh primerih matrike niso enake, če želimo predmet postaviti v določeno orientacijo. Vse tri matrike lahko najdemo v [9]. Vrstni red množenja je torej pomemben. V enačbi 6 je preslikana točka najprej zarotirana okoli z osi, nato okoli y in na koncu še okoli x osi. Najpogosteje pa se toga transformacija izvaja tako, da se predmet najprej zavrti okoli koordinatnega izhodišča in šele nato translira. Koordinatno izhodišče pa je napogosteje v enem od oglišč slike. Najbolje pa je, da se ga najprej premakne v središče slike. To naredimo tako, da koordinate najprej pomnožimo s translacijsko matriko T_C .

$$T_C = \begin{bmatrix} 1, & 0, & 0, & t_{cx} \\ 0, & 1, & 0, & t_{cy} \\ 0, & 0, & 1, & t_{cz} \\ 0, & 0, & 0, & 1 \end{bmatrix} \quad (8)$$

kjer so t_{cx} , t_{cy} in t_{cz} premik slike v x , y in z smeri, s katerim postavimo koordinatno izhodišče v središče slike.

Pri togi poravnavi je potrebno vedeti, da je pomemben vrstni red rotacij in translacij. Pravtako je tudi pomembno ali najprej rotiramo in nato transliramo ali obratno. V primeru, da zamenjamo vrstni red, se matrike spremenijo.

4 Mere podobnosti

V svoji magistrski nalogi sem izvedel analizo enajstih različnih mer podobnosti. Analiziral sem tudi dve točkovni meri. Ena je izpeljana iz medsebojne informacije, druga pa je nekoliko spremenjena točkovna mera na osnovi medsebojne informacije. Za izračun vseh mer smo potrebovali vezani histogram svetlosti obeh slik. Če imata sliki enake dimenzije vokslov in če sliko premikamo le vzdož osi koordinatnega sistema za velikost voksla v tej dimenziji, potem je histogram enostavno izračunljiv. V primeru, da sliko rotiramo ali premikamo za poljubno vrednost razdalje, pa je za izračun histograma potrebna interpolacija.

4.1 Vezani histogram svetlosti in interpolacija

8 bitne sivinske slike imajo največ 2^8 (256) sivinskih nivojev. Vezani histogram 8 bitne slike bo imel dimenzije $2^8 \times 2^8$. To pomeni, da bo imel lahko največ 2^{16} različnih vrednosti. Določimo jih tako, da v histogramu vrednost na koordinati (i,j) povečamo za 1 za vsak istoležni par svetlosti (i, j), na katerega naletimo pri preletu obeh slik. Na koncu še vse elemente delimo z vsoto vseh elementov v histogramu. Dobimo histogram verjetnosti. Vsaka vrednost v histogramu tako predstavlja verjetnost, da se pripadajoči par svetlosti pojavi na istih koordinatah obeh slik. V primeru, da imamo slike z veliko sivinskimi nivoji, dobimo redek histogram ali pa imamo v njem majhne vrednosti. Da zgostimo histogram in zmanjšamo njegovo velikost, razpon sivinskih nivojev razdelimo na enako dolge intervale sivin.

Recimo, da imamo dve dvodimenzionalni dvobitni sliki dimenzij 2×2 .

| | |
|---|---|
| 1 | 3 |
| 0 | 2 |

| | |
|---|---|
| 1 | 3 |
| 1 | 2 |

Slika 6 Dve preprosti sliki predstavljeni s svetlostmi

Ker sta sliki dvobitni, imata lahko največ 4 različne vrednosti svetlosti. Vezani histogram verjetnosti parov svetlosti bo izgledal kot prikazuje slika 5.

| | | | |
|---------------|---------------|---------------|---------------|
| 0 | 0 | 0 | $\frac{1}{4}$ |
| 0 | 0 | $\frac{1}{4}$ | 0 |
| $\frac{1}{4}$ | $\frac{1}{4}$ | 0 | 0 |
| 0 | 0 | 0 | 0 |

Slika 7 Vezani histogram verjetnosti

V primeru, da sta sliki, s katerima gradimo histogram, popolnoma enaki, bodo vse izvendiagonalne vrednosti enake nič.


Nekoliko več matematičnega truda je potrebno za določitev vezanega histograma, če eno sliko premaknemo za poljubno razdaljo v poljubni smeri. V tem primeru se voksel s svetlostjo i slike A v splošnem ne pokriva popolnoma z vokslom s svetlostjo j slike B, ampak leži med štirimi (2D) oz. osmimi (3D) vokslu slike B.

Pojavi se vprašanje, na katero mesto v vezani histogram naj zdaj prištejemo enico. To je odvisno od vrste interpolacije, ki jo uporabimo. Opisal bom tri vrste interpolacije.

Če algoritem zahteva veliko interpolacij, se lahko odločimo za interpolacijo *Najbližji sosed*, ker je najhitrejša. V tem primeru vsakemu vokslu slike A poiščemo najbližji voksel na sliki B. Enico prištejemo dobljenemu svetlostnemu paru.

Interpolacija delnih volumnov (partial volume interpolation - PVI) se pogosto uporablja v poravnavi medicinskih slik. Slika 8 prikazuje, kako izračunamo površine oz. volumne. Vrednosti P_0 do P_3 predstavljajo svetlosti mirujoče slike, $T(A)$ predstavlja transformirano koordinato točke na sliki A, S_0 do S_3 pa predstavljajo površine, na katere transformirana točka razdeli površino med štirimi sosednjimi vokslu mirujoče slike. Vsakemu paru v histogramu prištejemo vrednost nasprotne površine oz. volumna, kot je zapisano v naslednji enačbi.

$$(P_i, T(A))_+ = S_i, \forall i \quad (9)$$



Slika 8 Interpolacija delnih volumnov

Pri PVI obstoječim svetlostnim parom prištejemo delež enice v odvisnosti od površin oz. volumnov. Pri trilinearni interpolaciji pa izračunamo novo svetlost po enačbi:

$$S_N = \sum_i P_i S_i \quad (10)$$

Enico nato prištejemo paru $(S_N, T(A))$. S to interpolacijo v histogram vnašamo neobstoječe svetlosti, kar ni zaželeno.

4.2 Mere podobnosti

Implementirali in analizirali smo 11 mer podobnosti:

1. Energija histograma [10],
2. Entropija [10]
3. Medsebojna informacija [11]

4. Normalizirana medsebojna informacija [11]
5. Točkovna mera podobnosti na osnovi medsebojne informacije [7]
6. Spremenjena točkovna mera podobnosti na osnovi medsebojne informacije [7]
7. Korelacijsko razmerje [12]
8. Woodsov kriterij [13]
9. Entropijski korelacijski koeficient [14]
10. Medsebojna informacija na osnovi Havrda – Charvatove entropije 2. reda [14]
11. Medsebojna informacija na osnovi Havrda – Charvatove entropije 3. reda [14]

Vse mere podobnosti smo računali na prekrivajočem se področju plavajoče (tiste, ki jo premikamo) in mirujoče (referenčne) slike. Področje prekrivanja na obeh slikah bom označeval z X . V tem področju se nahaja L vokslov mirujoče slike B , ki imajo pripadajoče lokacije v plavajoči sliki A . $X = \{x: x \in B \cap T(A)\}$, kjer je T toga poravnava določena s šestimi parametri. Svetlost voksla na položaju x v transformirani sliki $T(A)$ označujemo z $z_a(x)$ in pripadajočo svetlost v sliki B z $z_b(x)$. Množico svetlosti prekrivajočega področja plavajoče in mirujoče slike označujemo z $Z_a, Z_a = \{z_a\}$ in $Z_b, Z_b = \{z_b\}$. Verjetnost pojava svetlosti $z_a, z_a \in Z_a$ in $z_b, z_b \in Z_b$ označujemo s $p(z_a)$ in $p(z_b)$. Vezano verjetnost pojava svetlosti z_a in z_b na enakih lokacijah v sliki A in B pa označujemo z $p(z_a, z_b)$. Najbolj neposreden način za izračun verjetnosti $p(z_a), p(z_b)$ in $p(z_a, z_b)$ je določitev s pomočjo vezanega histograma pojavnosti posameznih svetlosti $h(z_a, z_b)$. Vsako število v histogramu, ki je določen s pari svetlosti (z_a, z_b) , pove kolikokrat položaj voksla s svetlostjo z_a na sliki A sovпада s položajem voksla s svetlostjo z_b na sliki B . Če vsako število v histogramu pojavnosti delimo z vsoto vseh števil v tem histogramu, dobimo verjetnostno porazdelitev parov svetlosti $p(z_a, z_b)$. Verjetnost $p(z_a)$ dobimo tako, da seštejemo vezane verjetnosti po enačbi

$$p(z_a) = \sum_{z_b} p(z_a, z_b). \text{ Na podoben način izračunamo tudi verjetnosti } p(z_b).$$

S $H(Z_a)$ and $H(Z_b)$ označimo Shannonovi entropiji slik A in B , $H(Z_a, Z_b)$ pa je vezana entropija obeh slik.

$$\begin{aligned}
 H(Z_a) &= -\sum_{z_a} p(z_a) \cdot \log(p(z_a)) \\
 H(Z_b) &= -\sum_{z_b} p(z_b) \cdot \log(p(z_b)) \\
 H(Z_a, Z_b) &= -\sum_{z_a, z_b} p(z_a, z_b) \cdot \log(p(z_a, z_b))
 \end{aligned}
 \tag{11}$$

Enajst mer podobnosti, ki so bile vse izračunane iz vezanega histograma svetlosti $h(z_a, z_b)$, so opisane v naslednjih podpoglavjih.

4.2.1 Korelacijsko razmerje (CR)

Predpostavimo, da sta sliki A in B poravnani. Če naključno izbiramo istoležne voksele iz obeh slik, opazimo da so taki pari statistično odvisni. Vsem vokslom z intenziteto z_a na sliki A pripada nek roj intenzitet na sliki B. Te intenzitete so med seboj lahko zelo različne in tudi roji se zaradi tega lahko prekrivajo. Torej lahko iz intenzitet slike A predvidimo intenzitete slike B. Ta argument velja le, če sta sliki dobro poravnani. Kot merilo poravnaniosti lahko torej uporabimo funkcijsko odvisnost med obema slikama.

Zdaj se pojavi vprašanje kako meriti funkcijsko odvisnost med slikama. Svetlostne vrednosti slik lahko obravnavamo kot naključne spremenljivke. Določitev funkcijske odvisnosti med dvema takima spremenljivkama lahko obravnavamo kot regresijski problem. Recimo, da hočemo določiti, kako natančno A opisuje B.

1. Poiščemo funkcijo $Q(A)$, ki bo svetlosti slike A spremenila tako, da se bodo kar najboljše ujemale s svetlostmi slike B
2. Izmerimo kvaliteto ujemanja

Najprej je treba določiti kriterijsko funkcijo. Primerna izbira je varianca, ki je merilo razpršenosti okoli povprečne vrednosti.

Funkcijo Q določimo na naslednji način:

$$Q_{opt} = \arg(\min_Q \text{Var}[Z_b - Q(Z_a)]) \tag{12}$$

V tej enačbi funkcija \arg vrne funkcijo Q , pri kateri je varianca najmanjša. Če za funkcijo Q ne vpeljemo nobenih omejitev, je rezultat [12]

$$Q_{opt}(z_a) = \int z_b p(z_b | z_a) dz_b \quad (13)$$

kjer je $p(z_b | z_a)$ pogojna porazdelitvena funkcija verjetnosti B-ja pri predpostavki, da je $A=z_a$.

Zdaj uporabimo naslednji teorem

$$\text{Var}(Z_b) = \text{Var}(E(Z_b | Z_a)) + \text{Var}(Z_b - E(Z_b | Z_a)) \quad (14)$$

Varianca spremenljivke Z_b je razdeljena v dva dela. Prvi del je merilo B-ja, ki ga lahko predvidimo z A-jem, drugi pa je merilo B-ja, ki je neodvisen od A-ja. Pri poravnavi želimo minimizirati drugi del. Le ta je lahko majhen zaradi dveh razlogov. Sliki sta lahko med seboj zelo odvisni, ali pa sama slika B daje zelo malo informacije. V primeru poravnave lahko varianco spremenljivke (slike) B izračunamo le na področju, kjer se sliki prekrivata in je lahko zelo majhna, če se sliki slabo prekrivata. Če bi torej minimizirali le drugi del, bi tako sliki popolnoma razmaknili eno glede na drugo.

Bolj smiselno je torej za kriterijsko funkcijo izbrati razmerje med prvim delom variance in celotno varianco:

$$CR(Z_b | Z_a) = \frac{\text{Var}(E(Z_b | Z_a))}{\text{Var}(Z_b)} = 1 - \frac{\text{Var}(Z_b - E(Z_b | Z_a))}{\text{Var}(Z_b)} \quad (15)$$

Tej kriterijski funkciji pravimo *korelacijsko razmerje*. Meri funkcijsko odvisnost med A-jem in B-jem. Vrednosti korelacijskega razmerja se gibljejo med 0 (ni odvisnosti) in 1 (popolna odvisnost). Korelacijsko razmerje je neobčutljivo na množenje slike B s skalarjem. Lastnost korelacijskega razmerja je, da $CR(Z_b | Z_a)$ ni enako $CR(Z_a | Z_b)$.

4.2.2 Energija (E)

Enačba za energijo histograma E je zelo preprosta.

$$E(Z_a, Z_b) = \sum_{z_a, z_b} p^2(z_a, z_b) \quad (16)$$

Vsoto naredimo po vseh možnih svetlostnih parih. Pri poravnavi iščemo maksimum energije. Zaradi kvadrata je vpliv manjših verjetnosti nizek, vpliv večjih verjetnosti pa je povečan. Povečevanje energije ima za posledico zbijanje in povečevanje rojev.


4.2.3 Vezana Entropija (Ent)

Vezana entropija $H(Z_a, Z_b)$ je merilo za količino informacije med slikama. Če sta si sliki A in B popolnoma tuji, bo vezana entropija enaka vsoti entropij posameznih slik. Bolj kot sta si sliki podobni, nižja je vezana entropija v primerjavi s posameznima.

$$H(Z_a, Z_b) \leq H(Z_a) + H(Z_b) \quad (17)$$

Vrednosti $p(z_a, z_b)$, ki se pojavljajo v enačbi za vezano entropijo, se spreminjajo s transformiranjem slike A.

Če si histogram predstavljamo kot 2D sliko, lahko vrednosti predstavimo s sivinami. Višja kot je vrednost, večja je svetlost.



Slika 9 Vezani histogram za poravnan par slik (levo), medsebojno premaknjen za 2 mm (sredina) in 5 mm (desno)

Opazimo, da s povečevanjem razdalje med slikama roji bledijo in postajajo manj izraziti. Črna področja predstavljajo svetlostne pare, ki ne obstajajo ali pa jih je zelo malo. Neporavnava povzroči zmanjšanje najvišjih vrednosti in števila neobstojećih parov. To poveča entropijo. S poravnavo želimo doseči čim višje vrednosti v histogramu in čim večje število ničel. Želimo minimizirati vezano entropijo.

Preprosta oblika enačbe za vezano entropijo lahko skriva pomembno omejitev te mere. Vezana entropija je odvisna od transformacije. $p(z_a, z_b)$ pa je zelo odvisna od območja prekrivanja obeh slik ter od vrste interpolacije, ki jo uporabimo.

S premikanjem in obračanjem slike lahko spremenimo velikost področja slike, ki predstavlja zrak v okolici pacienta. Ta področja, ki tudi vsebujejo šum, se nahajajo v nižjih svetlostnih intervalih. Če se prekrivanje področja z zrakom povečuje, se povečujejo verjetnosti v nižjih svetlostnih intervalih in zmanjšuje vezana entropija. Če se prekrivanje zmanjšuje, se zmanjšuje verjetnost pojavnosti nižjih svetlostnih parov in se povečuje vezana entropija. Poravnava, ki poskuša minimizirati vezano entropijo, bo tako želela povečati področje z zrakom, kar je lahko napačna rešitev.

Entropija je od interpolacije zelo odvisna. Interpolacija namreč sliko nekoliko zamegli in s tem ostri histogram slik. Spremeni se vezani histogram ter z njim vezana verjetnostna porazdelitev.

Ker je entropija minimalna pri optimalni poravnavi, smo jo množili z -1 , da smo dobili maksimum v optimumu.

4.2.4 Medsebojna informacija (MI)

Problem prekrivanja, ki ga opazimo pri vezani entropiji, lahko rešimo tako, da poleg vezane entropije upoštevamo tudi informacijo posamezne slike na področju prekrivanja. Izračunamo jo kot entropijo slike.

Čeprav je informacijska vsebina slik ves čas konstantna, je informacija prekrivajočega se dela slik odvisna od transformacije T . Transformacija slike vključuje tudi interpolacijo, ki prav tako vpliva na verjetnosti.

Enačbo, ki združuje obe vrsti entropije, je leta 1948 predlagal Shannon. »Mera prenosa informacije« je postala poznana pod imenom »Medsebojna informacija« in se danes pogosto in uspešno uporablja za poravnavo medicinskih slik različnih modalitet.

$$MI(Z_a, Z_b) = H(Z_a) + H(Z_b) - H(Z_a, Z_b) \quad (18)$$

Medsebojna informacija opisuje, kako dobro ena slika opisuje drugo. Maksimum ima pri optimalnem prekrivanju slik. Z uporabo matematike lahko definicijo tudi preoblikujemo.

$$I(Z_a, Z_b) = H(Z_a) - H(Z_b|Z_a) = H(Z_b) - H(Z_a|Z_b) \quad (19)$$

Pogojna entropija v zgornji enačbi bo nič, če poznavanje svetlosti slike A omogoča popolnoma točno napoved svetlosti slike B. Poravnava z medsebojno informacijo vrne transformacijo, pri kateri s sliko A najboljše opišemo sliko B.

Poznavanje vrednosti svetlosti voksla slike A zmanjša entropijo vrednosti svetlosti istoležnega voksla slike B, ko sta sliki pravilno poravnani. Z neporavnano sliko A postaja slabši opis slike B.

Pomembnejše lastnosti medsebojne informacije so [11]:

- | | |
|---------------------|--|
| 1. Nenegativnost: | $I(Z_a, Z_b) \geq 0$ |
| 2. Neodvisnost: | $I(Z_a, Z_b) = 0 \Leftrightarrow p_{AB}(z_a, z_b) = p(z_a)p(z_b)$ |
| 3. Simetrija: | $I(Z_a, Z_b) = I(Z_b, Z_a)$ |
| 4. Samoinformacija: | $I(Z_a, Z_a) = H(Z_a)$ |
| 5. Omejenost: | $I(Z_a, Z_b) \leq \min(H(Z_a), H(Z_b))$ $\leq (H(Z_a) + H(Z_b)) / 2$ $\leq \max(H(Z_a), H(Z_b))$ $\leq H(Z_a, Z_b)$ $\leq H(Z_a) + H(Z_b)$ |

4.2.5 Normalizirana medsebojna informacija (NMI)

S spreminjanjem položaja plavajoče slike, se spreminja tudi velikost področja prekrivanja obeh slik. Poleg spremembe medsebojnega odnosa med vokslji, zaradi katere se spremeni vezani histogram, se spremeni tudi število voksllov, ki prispevajo k histogramu. Spremembe v področjih z zelo majhnimi vrednostmi svetlosti lahko nesorazmerno veliko prispevajo k medsebojni informaciji. Zato so bile predlagane različne normalizacije medsebojne informacije [8]:

$$I_1(Z_a, Z_b) = \frac{2I(Z_a, Z_b)}{H(Z_a) + H(Z_b)} \quad (20)$$

$$I_2(Z_a, Z_b) = H(Z_a, Z_b) - I(Z_a, Z_b) \quad (21)$$

Predlagana pa je bila tudi naslednja

$$I_3(Z_a, Z_b) = \frac{H(Z_a) + H(Z_b)}{H(Z_a, Z_b)} \quad (22)$$

Tretja različica se je izkazala za bolj robustno kot medsebojna informacija. Vse tri različice normalizirane medsebojne informacije so med seboj tudi povezane po naslednji enačbi.

$$I_3(Z_a, Z_b) = \frac{H(Z_a) + H(Z_b)}{H(Z_a, Z_b)} = \frac{I(Z_a, Z_b)}{H(Z_a, Z_b)} + 1 = \frac{1}{I_1(Z_a, Z_b) - 2} \quad (23)$$

4.2.6 Točkovna mera podobnosti na osnovi medsebojne informacije (PSMI)

Točkovne mere definiramo kot mere, s katerimi lahko merimo podobnost posameznih slikovnih elementov oz. področij. P. Rogelj jih je izpeljal iz globalnih mer podobnosti [7].

Medsebojna informacija je zapisana z enačbo 26. V prispevku [7] je avtor iz medsebojne informacije izpeljal naslednjo mero podobnosti:

$$PSMI(Z_a, Z_b) = \sum_{z_a, z_b} p(z_a, z_b) \cdot PS_{MI}(z_a, z_b) \quad (24)$$

$$PS_{MI}(z_a, z_b) = \log\left(\frac{p_{MI}(z_a, z_b)}{p_{MI}(z_a)p_{MI}(z_b)}\right)$$

Funkcija PS_{MI} se imenuje funkcija točkovne podobnosti in je ocena svetlostne odvisnosti med slikama, ko sta sliki dobro poravnani. Meritev podobnosti se izvede v dveh korakih. Najprej iz obeh slik A in B določimo $PS_{MI}(z_a, z_b)$. V naslednjem koraku določimo podobnost dveh točk (z_a, z_b) tako, da v funkciji točkovne podobnosti poiščemo vrednost, ki pripada

svetlostima ter jo nato množimo z verjetnostjo. Funkcijo točkovne podobnosti lahko izračunamo le enkrat v celém postopku poravnave. Zaradi tega je ta mera tudi časovno nezahtevna.

4.2.7 Spremenjena točkovna mera podobnosti na osnovi medsebojne informacije (PSUH)

Enačba te mere je zelo podobna enačbi mere opisane v podpoglavju 4.2.6.

$$PSUH(Z_a, Z_b) = \sum_{z_a, z_b} p(z_a, z_b) \cdot SH_{MI}(z_a, z_b) \quad (25)$$

$$SH_{MI}(z_a, z_b) = \log\left(\frac{P_{MI}^2(z_a, z_b)}{P_{MI}(z_a)P_{MI}(z_b)}\right)$$

Razlika je v kvadriranju števca logaritma.

4.2.8 Entropijski korelacijski koeficient (ECC)

Izračunamo ga po naslednji enačbi:

$$ECC(Z_a, Z_b) = \sqrt{\frac{2 * MI(Z_a, Z_b)}{H(Z_a) + H(Z_b)}} \quad (26)$$

kjer je MI medsebojna informacija, H pa Shannonova entropija.

4.2.9 Woodsov kriterij (WC)

$$WC(Z_b|Z_a) = \frac{1}{L} \sum_{z_b} L_{z_b} \frac{\sigma_{z_b}}{m_{z_b}} \quad (27)$$

kjer je $\sigma_{z_b} = \sqrt{\frac{1}{L_{z_b}} \sum_{x \in X_{z_b}} z_a(x)^2 - m_{z_b}^2}$, m_{z_b} pa povprečna svetlost slike A znotraj področja X_{z_b} . $X_{z_b} \subseteq X$ je podpodročje prekrivajočega se področja X , kjer so svetlosti slike B enake z_b . L_{z_b} je število vokslov v X_{z_b} . Originalni Woodsov kriterij je množen z -1 , ker smo pri vseh merah iskali maksimum.

4.2.10 Medsebojna informacija na osnovi Havrda-Charvatove entropije 2. reda (HCE2)

$$HCE2(Z_a, Z_b) = 1 - \sum_{z_a, z_b} p^2(z_a, z_b) \quad (28)$$

V enačbi za medsebojno informacijo smo namesto H uporabili HCE2.

4.2.11 Medsebojna informacija na osnovi Havrda-Charvatove entropije 3. reda (HCE3)

$$HCE3(Z_a, Z_b) = \frac{1}{2} (1 - \sum_{z_a, z_b} p^3(z_a, z_b)) \quad (29)$$

V enačbi za medsebojno informacijo smo namesto H uporabili HCE3.

4.2.12 Logaritmična podobnost

$$ML = \sum_x \log p(z_a, z_b) \quad (30)$$

5 Pregled dosedanjih analiz mer podobnosti

Do sedaj je bilo na področju analize in primerjav mer podobnosti narejeno zelo malo. Raziskovalci so izdelali protokole za analizo svojih mer vendar objav, katerih bistvo bi bil postopek za analizo, ni veliko. Rezultate dobljene s temi protokoli so objavili v člankih, a glede na to, da se postopki med seboj razlikujejo, objektivna primerjava mer podobnosti na osnovi objavljenih rezultatov ni možna. V naslednji tabeli navajam nekaj primerov analiz mer podobnosti. V prvem stolpcu je navedena analizirana mera podobnosti, v naslednjih stolpcih pa uporabljene slike, način optimizacije, lastnosti mere podobnosti, ki so jih avtorji analizirali, prisotne nepravilnosti na slikah med analizo, uporabljena interpolacija, način pridobitve zlatega standarda ter referenca na prispevek. Zlati standard je najbolj pravilna poravnava za katero je poznana tudi napaka. Možno je, da lahko s katero od mer podobnosti slike poravnamo bolj točno, kot bi jih poravnali s parametri poravnave, ki jih vsebuje zlati standard. Ker pa rezultate primerjamo z zlatim standardom, tega ne moremo vedeti. Če hočemo mero podobnosti dobro ovrednotiti, moramo imeti zelo natančen zlati standard.

Tabela 5.1 Primerjava postopkov analize mer podobnosti

| Mera podobnosti | Slike | Optimizacija | Analizirane lastnosti | Analiza | Interpolacija | Zlati standard | Ref. |
|-----------------|-------------|---|---------------------------------------|--|---|-------------------------------|------|
| 4.2.4 | MR, CT, PET | 300 – 500 ponovitev Brent in Powel | Natančnost, robustnost | Različne interpolacije, optimizacije, podvzorčenje, področje prekrivanja, šum, svetlostne nehomogenosti, popačenja | Najbližji sosed, trilinearna interpolacija (TRI), interpolacija delnih volumnov (PVI) | Poravnava z uporabo markerjev | [11] |
| 4.2.1 | MR, CT, PET | Powel | Povprečje in mediana napake poravnave | Podvzorčenje | TRI PVI | Poravnava z uporabo markerjev | [12] |
| 4.2.4 | CT, MR | Simple x | Natačnost, mera PS | | Posplošena ocena delnih | Vanderbilto v zlati standard | [15] |

| | | | | | | | |
|---|---|---|--|-----------------------------|------------|---|------|
| | | | | | volumnov | | |
| 4.2.4 4.2.12 | Brainw eb T1, T2 3D MRA- 2D DSA | Powel | | | PVI | Podatki o C roki | [16] |
| 4.2.1 | US/MR | 5-10 min Powel | Natančnost, robustnost, preciznost | | PVI | Ročna poravnava | [17] |
| 4.2.4 4.2.5 4.2.1 | Realne in simulir ane MR in PET slike | Powel | Natančnost | | | Znana transformac ija za simulirane slike, neznani zlati standard za realne slike | [18] |
| 4.2.12 | SPGR in MR | Powel ova optimi zacija 1-2 minuti | Natančnost, področje konvergen ce | | | Znana transformac ija za MR podatke, podatki iz naprave za SPGR-PD poravnavo | [19] |
| 4.2.2 4.2.3 4.2.4 4.2.1 4.2.9 | »Visibl e Human Data« MR-T1 CT Rdeči kanal channel of cryosec tion color image | Powell | | Binning from 4096 to 256 | Tri-linear | Manual and automatic tools were used to get an initial ground truth. | [10] |
| 4.2.1 | Simulir ane in prave MR in US slike | Powell | Natančnost | | PVI | S poravnavam i $US_i \rightarrow MR_i \rightarrow MR_j \rightarrow US_j \rightarrow US_i$ so določili napako poravnave | [20] |

Največkrat analizirana značilnica mer podobnosti je natančnost. Konvergenčno področje in robustnost sta pritegnili manjše zanimanje. Nisem zasledil enotne definicije, kaj natančnost sploh je, tako da je odločitev o tem, kako jo izračunati, prepuščena avtorjem.

Uporaba optimizacije je pri analizi mer zelo pogosta. Optimizacijska metoda ima lahko velik vpliv na rezultate poravnave. Najprej se je potrebno odločiti, katero optimizacijo uporabiti, nato pa določiti, kdaj naj se optimizacija ustavi. Primeri ustavitvenih kriterijev so maksimalno število izračunov mere podobnosti ali minimalna razlika (ϵ) v vrednosti mere podobnosti med zaporednima izračunoma. Če je odvod mere podobnosti majhen, potem je razlika med zaporednima izračunoma pravtako majhna in za pravilno določitev vrednosti ϵ je potrebno imeti vsaj občutek o tem, kako majhne bodo razlike med zaporednimi izračuni mere podobnosti.

Zaradi različnih postopkov vrednotenja mer podobnosti, ki ne omogočajo objektivnih analiz in primerjav mer podobnosti, je nujen standardizirani postopek za vrednotenje mer podobnosti.

6 Protokol za analizo mer podobnosti

Parametrični prostor opisujejo parametri prostorske preslikave, ki naj bi pripeljala dve sliki v isti položaj. Najprej ga normaliziramo, tako da imajo enake spremembe parametrov približno enak vpliv. Če je parametrični prostor normaliziran, lahko uporabimo Evklidsko razdaljo in določimo razdaljo med optimumom mere podobnosti in položajem »prave« poravnave t.i. »zlatim standardom«. Recimo, da je položaj prave poravnave v koordinatnem izhodišču I-dimenzionalnega parametričnega prostora. $SM(X)$ je vrednost mere podobnosti v točki X . X je vektor parametrov. Vrednosti mere podobnosti $SM(X_{n,m})$, kjer je $n = 1, 2, \dots, N$ in $m = -M/2, \dots, 0, \dots, M/2$, izračunamo na $M+1$ ekvidistančnih točkah na N daljicah. Začetno točko $X_{n,-M/2}$ določimo naključno na razdalji R od izhodišča. Okoli izhodišča zrcaljena točka $X_{n,-M/2}$ je točka $X_{n,M/2}$. Vse začetne točke so naključno porazdeljene po hiper kroglji s polmerom R in središčem v $X_{n,0}$ ali krajše X_0 .

$$R = \|X_{n,M/2}\| \quad (31)$$

Mera podobnosti je torej izračunana v $N*(M+1)$ točkah parametričnega prostora. Vrednosti $X_{n,m}$, ki jih dobimo, skaliramo na interval med 0 in 1 po naslednji enačbi.


$$SM(X_{n,m}) = \frac{SM_o(X_{n,m}) - SM_{\min}}{SM_{\max} - SM_{\min}} \quad (32)$$

V zgornji enačbi je $SM_o(X_{n,m})$ vrednost mere podobnosti pred normalizacijo, SM_{\min} je minimalna vrednost mere podobnosti pred normalizacijo in SM_{\max} maksimalna vrednost mere podobnosti pred normalizacijo v vseh $N*(M+1)$ točkah.

Recimo, da je $X_{n,opt}$ optimalni položaj, kjer mera podobnosti zavzame optimalno (maksimalno) vrednost, $SM(X_{n,opt})$ pa vrednost mere podobnosti v tej točki na n -ti daljici:

$$opt = \arg \max_m (SM(X_{n,m})) \quad (33)$$

Slika 10 prikazuje možen potek mere podobnosti vzdolž n-te daljice.



Slika 10 Potek mere podobnosti, ki prikazuje točke uporabljene v enačbah za izračun lastnosti

Na osnovi vrednosti mer podobnosti, ki so bile izračunane v $N*(M+1)$ točkah znotraj hiperkrogle (v parametričnem prostoru) s polmerom R , smo meri določili pet značilnic:

območje konvergence, gladkost, točnost, natančnost in izrazitost optimuma.

Območje konvergence CR mere podobnosti je razdalja od optimuma do najbolj oddaljene točke od katere bo mera podobnosti zagotovo konvergirala proti globalnemu optimumu. Ta najbolj oddaljena točka je pravzaprav najbližji minimum in ga označimo $X_{n,loc}$. Zaželeno je, da je območje konvergence čim večje. Če bi poznali območja konvergence različnih mer podobnosti na slikah različnih modalitet, bi v praksi pri poravnavi najprej uporabili mero podobnosti z velikim konvergenčnim območjem in iz njenega optimuma nadaljevali z bolj natančno mero podobnosti. Konvergenčno področje izračunamo po naslednji enačbi:

$$CR = \min_n \|X_{n,opt} - X_{n,loc}\| \tag{34}$$

Poleg velikosti konvergenčnega območja je pomembno vedeti koliko in kako izrazite lokalne optimume ima mera podobnosti izven konvergenčnega območja. To lastnost smo poimenovali *gladkost* in jo označili s S . Definirana je kot povprečen pozitiven gradient (gledano iz položaja $X_{n, \text{opt}}$ navzven).

$$S = \frac{1}{M * N} \sum_{m=-M/2}^{M/2} \sum_{n=1}^N d_{n,m} \quad (35)$$

Gradient $d_{n,m}$ pa je definiran kot:

$$d_{n,m} = \begin{cases} SM(X_{n,m-1}) - SM(X_{n,m}) & \text{if } m < \text{opt} \ \& \ SM(X_{n,m-1}) > SM(X_{n,m}) \\ SM(X_{n,m+1}) - SM(X_{n,m}) & \text{if } m > \text{opt} \ \& \ SM(X_{n,m+1}) > SM(X_{n,m}) \end{cases} \quad (36)$$

Pozitivni gradienti vodijo proti lokalnim optimumom (stran od globalnega optimuma). *Točnost* σ_a pove, kako blizu od prave poravnave bo mera najverjetneje našla optimum. Če je položaj n -tega optimuma $X_{n, \text{opt}}$ in je položaj »zlatega standarda« X_0 , je točnost definirana kot standardna deviacija dolžin vektorjev $X_{n, \text{opt}} - X_0$:

$$\sigma_a = \sqrt{\frac{1}{N} \sum_{n=1}^N \|X_{n, \text{opt}} - X_0\|^2} \quad (37)$$

Če izračunamo položaj povprečnega optimuma, lahko določimo standardno deviacijo razdalj med optimumi in povprečnim optimumom. Tež standardni deviaciji pravimo *natančnost* σ_p .

$$\sigma_p = \sqrt{\frac{1}{N} \sum_{n=1}^N \|X_{n, \text{opt}} - \bar{X}_{n, \text{opt}}\|^2}; \quad \bar{X}_{n, \text{opt}} = \frac{1}{N} \sum_{n=1}^N \|X_{n, \text{opt}}\| \quad (38)$$

Natančnost je mera razpršenosti optimumov od povprečnega optimuma. Če mera podobnosti vedno najde isti optimum, ne glede na to od kje je inicializirana, potem je to

verjetno tudi pravi optimum. Vrednost natančnosti je vedno manjša ali enaka vrednosti točnosti.

Zadnja pomembna lastnost mere podobnosti, ki jo bomo ovrednotili, je ocena nedoločenosti položaja optimuma ali obnašanje mere podobnosti v bližini optimuma. Ko se mera približuje optimumu, lahko njena vrednost hitro narašča in potem tudi hitro pade, ko se od optimuma oddaljujemo. Lahko pa narašča počasi. Če mera narašča počasi, pravimo da je njen optimum manj izrazit kot optimum mere, ki narašča hitreje. To informacijo zajamemo v lastnosti, ki smo jo poimenovali *izrazitost optimuma DO*. Izrazitost je povprečna sprememba vrednosti mere podobnosti v bližini globalnega optimuma. Definirana je kot funkcija razdalje s od optimuma:

$$DO(s) = \frac{1}{2sN} \sum_{n=1}^N 2SM(X_{n,opt}) - SM(X_{n,opt-s}) - SM(X_{n,opt+s}) \quad (39)$$


Poznavanje izrazitosti optimuma omogoča določanje ustavitvenih kriterijev optimizacijske metode. Ti so ponavadi določeni kot minimalna sprememba kriterijske funkcije, kar pa je težko določiti. Z izrazitostjo lahko določimo amplitudi spreminjanja mere podobnosti v okolici optimuma. Glede na želeno točnost, ki jo v enačbi določa s , izberemo minimalno spremembo mere podobnosti.

7 Ekperimentalna baza slik

Pred začetkom vrednotenja mer 4.2.1 do 4.2.12 je bilo potrebno določiti analize, ki jih bomo izvedli ter bazo slik na kateri bomo testirali mere. Na razpolago smo imeli umetne MR slike možganov [21-23] ter realne MR, CT in PET slike možganov in hrbtenice [24-28]. Prednost umetnih slik pred realnimi je v tem, da je "zlato standard" točno poznan.

7.1 Skupina 1


T1 in T2 utežene 8 bitne MRI slike dimenzij 181 x 217 x 181 z dimenzijo voksla enako 1 x 1 x 1 mm. Slike so bile dobljene s pomočjo BrainWeb MR simulatorja [21] in prikazane spodaj.



Slika 11 Rezina 32 iz T1, T2 in PD umetnih slik možganov

7.2 Skupina 2a


T1, T2 in PD utežene realne 8 bitne MRI slike možganov dimenzij 256 x 256 x 20 vokslor z dimenzijo voksla enako 1 x 1 x 5 mm. V možganih na slikah je bil jasno viden tumor. Slike so bile zajete istočasno tako da je bil "zlato standard" poznan. Primer rezine iz slik te skupine je prikazan na naslednji sliki.



Slika 12 Sedma rezina slik T1, T2 in PD s tumorjem

7.3 Skupina 2b


T1, T2 in PD utežene realne 8 bitne MRI slike možganov dimenzij 256 x 256 x 25 vokslov z dimenzijo voksla enako 1 x 1 x 5 mm. V možganih na teh slikah ni bilo tumorja. Slike so bile zajete istočasno tako da je bil "zlati standard" poznan. Primer rezine iz slik te skupine je prikazan spodaj.



Slika 13 Deseta rezina slike T1, T2 in PD brez tumorja

7.4 Skupina 3


T1 utežena 8 bitna MRI slika dimenzij 238 x 238 x 22 vokslov z dimenzijo voksla 0.391 x 0.391 x 1.9 mm ter CT slika dimenzij 512 x 512 x 233 vokslov z dimenzijo voksla 0.273 x 0.273 x 1 mm. MR slika prikazuje hrbtenično vretenca L3, CT slika pa prikazuje vretenca L1 do L5. "Zlati standard" je bil dobljen z uporabo markerjev [29]. Slika 14 prikazuje primer slik iz te skupine.



Slika 14 MR slika vretenca L3 in CT slika vretenc L1 do L5

7.5 Skupina 4

T2 utežena 8 bitna MR slika dimenzij 256 x 256 x 26 vokslov z dimenzijo voksla 1.25 x 1.25 x 4 mm ter 8 bitna PET slika dimenzij 128 x 128 x 15 vokslov z dimenzijo 2.59 x 2.59 x 8 mm. Slike so bile zajete v sklopu projekta RIRE (Retrospective Image Registration Evaluation) [28]. Za “zlato standard” smo uporabili najboljšo poravnavo [26] v sklopu postopka vrednotenja, ki je imela najmanjšo vrednost TRE (target registration error) [30] glede na “zlato standard” dobljen z markerji. Slika 15 prikazuje rezino 7 iz MR in PET slik iz te skupine.



Slika 15 Rezina 7 MR T2 ter PET slike

8 Eksperimenti in rezultati

8.1 Implementacija

Število naključno izbranih točk (N) je bilo 50, če ni drugače specificirano. Število vzorcev mere podobnosti, ki smo jih izračunali, vzdolž ene daljice ($M+1$) od $X_{n, -M/2}$ do $X_{n, M/2}$ je bilo 61. V točki X_0 smo torej mero podobnosti izračunali N -krat. Za analizo lastnosti mer podobnosti smo izbrali dva polmera hiperkrogle. Prvi polmer je bil manjši od drugega in smo ga uporabili za analizo natančnosti, točnosti in izrazitosti optimuma. Drugega smo uporabili za izračun konvergenčnega področja in gladkosti in je bil večji zato, ker je analiza teh dveh lastnosti potrebna na večji razdalji od optimuma. Oba polmera bom predstavil v obliki $R(r_1, r_2)$. r_1 je manjši polmer, r_2 pa večji.

Parametrični prostor smo normalizirali, da je zasuk za 0.1 rad ustrezal premiku za 7 mm. Tako zasuk za 0.1 rad kot premik za 7 mm lahko predstavljata enoto v parametričnem prostoru.

Za določitev vrednosti mere podobnosti v točki $X_{n, m}$ za MR – MR poravnavo možganov je bila plavajoča slika (T1 za T1 – T2, T1 – PD poravnavo ter T2 za T2 – PD poravnavo) najprej premaknjena iz točke X_0 v točko $X_{n, -M/2}$. Vezani histogram med plavajočo in mirujočo sliko smo nato določili z upoštevanjem tega premika. Ko smo slike premaknili v položaj $X_{n, -M/2}$, smo uporabili trilinearno interpolacijo. S premikom v točko $X_{n, -M/2}$ smo se izognili izračunavanju mere podobnosti v točki X_0 , kjer ne bi potrebovali nobene interpolacije. Interpolacija vpliva na vrednost mere podobnosti. Če v neki točki interpolacije ne izvedemo, lahko opazimo nenaden skok v vrednosti mere podobnosti. To se lahko pokaže kot lokalni optimum [31]. Ko smo poravnavali slike hrbtenice in MR T2 sliko na PET, smo vrednost mere v točki $X_{n, m}$ izračunali s transformacijo iz točke X_0 v $X_{n, m}$. Slike so bile v obeh primerih zajete z različnimi tehnikami, dimenzija voksla ni bila enaka in tudi vektor »zlatega standarda« ni bil enak nič, tako da je bila interpolacija potrebna v vsaki točki.

Za uporabo protokola je potrebno poznati pravo poravnavo X_0 , ki jo je pri realnih slikah težko določiti. Točnost, ki jo dobimo s tem postopkom vrednotenja mer podobnosti, je slabša od točnosti prave poravnave.

Tabele v podpoglavju Rezultati prikazujejo izrazitost na razdalji enega koraka ($s = 1$) od optimuma. Kot je razvidno iz enačbe za izrazitost, bi jo lahko izračunavali tudi na kakšni drugi razdalji. Odvisno od tega kaj nas zanima. Zaradi lažje interpretacije rezultatov, smo vse

vrednosti lastnosti prikazali v naslednjih enotah: točnost, natančnost in konvergenčno področje v mm, izrazitost optimuma v 10^{-3} / mm, gladkost pa v 10^{-6} / mm. Ker je predstavitev v mm bolj običajna, smo se tako odločili tudi mi, čeprav bi lahko vse rezultate prikazali tudi v radianih ali v enotah normaliziranega parametričnega prostora.

8.2 Rezultati

Rezultate bom prikazal v obliki tabel. Vsaka tabela prikazuje analizo izvedeno na določenem paru slik. Najprej bom opisal katere poskuse sem prikazal v kateri tabeli, katere slike sem uporabil ter kakšni so bili polmeri.

1. Analiza - Tabela 8.1:

Realne slike

MR L3 – CT, R(1, 3)

MR T1 – MR T2, R(1, 2)

PET – MR, R(1, 5)

2. Analiza - Tabela 8.2

Realne slike

MR L3 – CT, R(1, 3)

3. Analiza - Tabela 8.3

Realne slike

MR T1 – MR T2, MR T1 – MR PD, MT T2 – MR PD, R(1, 2)

4. Analiza - Tabela 8.4

Simulirane slike

MR T1 – MR T2, R(1, 3)

5. Analiza - Tabela 8.5

Realne slike

MR – CT, R(1, 3)

V tabeli 8.1 predstavlja levo število vrednost lastnosti izračunana za poravnavo MR – CT slike, srednje število predstavlja vrednost dobljeno pri poravnavi MR T2 slike na MR T1, desno število pa predstavlja vrednost lastnosti pri poravnavi PET slike na MR T2 sliko. Odebeljeno sem označil tiste vrednosti, ki so bile najboljše, poševno pa tiste, ki so bile najslabše.

Tabela 8.1 Lastnosti mer podobnosti pri poravnavi MR –CT (skupina 3), MR – MR (skupina 2a) in MR - PET (skupina 4) slik

| | σ_a | | | σ_p | | | DO | | | CR | | | S | | |
|------|------------|------------|------------|------------|------------|------------|-----------|-----------|-----------|-------------|-------------|------------|------------|------------|------------|
| | MR-CT | MR-MR | MR-PET | MR-CT | MR-MR | MR-PET | MR-CT | MR-MR | MR-PET | MR-CT | MR-MR | MR-PET | MR-CT | MR-MR | MR-PET |
| CR | 0.6 | 1.3 | 0.8 | 0.5 | 1.1 | 0.7 | 20 | 7 | 12 | 4.8 | 0.5 | 1.1 | 73.6 | 205.7 | 8.5 |
| ECC | 0.6 | 0.7 | 1.8 | 0.5 | 0.6 | 1.7 | 17 | 10 | 18 | 15.1 | 14.0 | 2.3 | 101.3 | 0.0 | 23.3 |
| Ent | 0.7 | 1.1 | 1.7 | 0.6 | 0.9 | 1.5 | 21 | 6 | 27 | 1.4 | 0.5 | 1.1 | 96.1 | 86.0 | 722.8 |
| E | 1.0 | 2.7 | 4.3 | 0.9 | 2.5 | 3.9 | 22 | 5 | 16 | 0.7 | 2.8 | 1.1 | 297.6 | 25.3 | 385.6 |
| HCE2 | 3.3 | 4.2 | 4.3 | 3.1 | 3.9 | 3.9 | 21 | 9 | 18 | 0.7 | 0.9 | 1.1 | 1194.2 | 69.0 | 815.0 |
| HCE3 | 3.1 | 4.2 | 4.6 | 3.0 | 3.9 | 4.1 | 22 | 10 | 19 | 0.7 | 0.9 | 1.1 | 1523.9 | 53.0 | 696.0 |
| NMI | 0.6 | 0.7 | 1.8 | 0.5 | 0.6 | 1.7 | 25 | 12 | 19 | 15.1 | 14.0 | 2.3 | 41.5 | 0.0 | 20.7 |
| MI | 0.6 | 0.7 | 2.0 | 0.5 | 0.6 | 1.9 | 23 | 12 | 20 | 15.1 | 14.0 | 2.3 | 48.0 | 0.0 | 24.5 |
| PSMI | 0.6 | 0.7 | 2.0 | 0.5 | 0.6 | 1.9 | 15 | 10 | 32 | 20.7 | 14.0 | 2.3 | 0.2 | 0.0 | 11.7 |
| PSUH | 0.6 | 0.9 | 0.9 | 0.5 | 0.7 | 0.8 | 15 | 7 | 22 | 21.0 | 0.5 | 1.1 | 0.0 | 0.0 | 126.4 |
| WC | 0.6 | 2.2 | 3.6 | 0.5 | 2.2 | 3.5 | 24 | 7 | 11 | 9.6 | 0.9 | 8.0 | 887.2 | 2210.5 | 3906.4 |

Mere podobnosti so se v splošnem obnašale slabše v primeru MR - PET poravnave. To je tudi pričakovano. Pri tej poravnavi je imel Woodsov kriterij največje konvergenčno področje. Woodsov kriterij je tudi namenjen poravnavi MR – PET [13]. Meri HCE2 in HCE3 se nista dobro obnesli v nobenem primeru, če pogledamo natančnost in točnost. Opazimo lahko tudi, da so mere MI, NMI, PSUH ter PSMI zelo primerne za MR – MR in MR – CT poravnavo.

Če imamo 8-bitne sivinske slike, ima vezani histogram 65536 elementov. Večina jih ima vrednost nič in vezani histogram je zelo redek. Zaradi tega pri poravnavi histogram pogosto zgostimo tako, da zmanjšamo število svin na 2^7 ali 2^6 , lahko pa tudi manj. Naslednja tabela prikazuje vpliv velikost vezanega histograma na obnašanje mer. Vsaka lastnost vsebuje tri števila. Levo je vrednost lastnosti pri 256x256 poljih v histogramu, v sredini je vrednost lastnosti, ki ustreza 128x128 vnosom v histogram in desno vrednost, ki ustreza 64x64 vnosom.

Tabela 8.2 Lastnosti mer podobnosti pri poravnavi MR – CT (skupina 3) slik in spreminjanju dimenzij histograma

| | σ_a | | | σ_p | | | DO | | | CR | | | S | | |
|------|------------|-----|-----|------------|-----|-----|-----|-----|----|------|------|------|--------|--------|--------|
| | 256 | 128 | 64 | 256 | 128 | 64 | 256 | 128 | 64 | 256 | 128 | 64 | 256 | 128 | 64 |
| CR | 0.6 | 0.7 | 0.8 | 0.5 | 0.6 | 0.7 | 20 | 16 | 14 | 4.8 | 0.7 | 1.4 | 73.6 | 496.7 | 589.0 |
| ECC | 0.6 | 0.6 | 0.6 | 0.5 | 0.5 | 0.5 | 17 | 15 | 14 | 15.1 | 15.1 | 15.1 | 101.3 | 106.2 | 103.6 |
| Ent | 0.7 | 0.7 | 0.6 | 0.6 | 0.5 | 0.5 | 21 | 19 | 18 | 1.4 | 1.4 | 2.1 | 96.1 | 205.4 | 52.9 |
| E | 1.0 | 4.4 | 1.0 | 0.9 | 4.1 | 1.0 | 22 | 23 | 16 | 0.7 | 0.7 | 0.7 | 297.6 | 2807.2 | 1942.6 |
| HCE2 | 3.3 | 4.8 | 5.1 | 3.1 | 4.5 | 4.8 | 21 | 17 | 13 | 0.7 | 0.7 | 0.7 | 1194.2 | 1543.6 | 977.0 |
| HCE3 | 3.1 | 4.8 | 4.9 | 3.0 | 4.5 | 4.6 | 22 | 21 | 19 | 0.7 | 0.7 | 0.7 | 1523.9 | 1876.1 | 1449.0 |
| NMI | 0.6 | 0.6 | 0.6 | 0.5 | 0.5 | 0.5 | 25 | 21 | 20 | 15.1 | 15.1 | 15.1 | 41.5 | 48.8 | 52.3 |
| MI | 0.6 | 0.6 | 0.6 | 0.5 | 0.5 | 0.5 | 23 | 20 | 19 | 15.1 | 15.1 | 15.1 | 48.0 | 56.4 | 62.2 |
| PSMI | 0.6 | 0.6 | 0.6 | 0.5 | 0.5 | 0.5 | 15 | 11 | 11 | 20.7 | 17.9 | 18.6 | 0.2 | 1.1 | 1.0 |
| PSUH | 0.6 | 0.6 | 0.6 | 0.5 | 0.5 | 0.5 | 15 | 13 | 12 | 21.0 | 21.0 | 17.9 | 0.0 | 0.0 | 7.0 |
| WC | 0.6 | 0.6 | 0.7 | 0.5 | 0.5 | 0.6 | 24 | 24 | 19 | 9.6 | 6.9 | 4.8 | 887.2 | 1952.3 | 1263.8 |

Mere na osnovi medsebojne informacije niso imele opaznih sprememb v kvaliteti, za ostale pa lahko rečemo, da se jim lastnosti slabšajo. Z manjšanjem sivin v histogramu izgubimo nekaj informacije in posledica je manjša točnost. Iz tabele lahko razberemo, da se konvergenčno področje Woodsovega kriterija zmanjšuje z zmanjševanjem dimenzij histograma. Pri vseh merah pa lahko opazimo zmanjševanje izrazitosti optimuma. Gladkost pa se pri nekaterih merah pri zmanjševanju dimenzij histograma najprej poveča in nato zmanjša, pri ostalih (CR, MI, NMI in PSUH) pa do zmanjšanja vrednosti ne pride.

V naslednji tabeli so prikazani rezultati analize na realnih MR slikah iz skupine 2a (zgornje število) in 2b (spodnje število). Levo število v stolpcu za določeno lastnost predstavlja rezultat za poravnavo T1 – T2, srednje število za T1 – PD ter desno za poravnavo T2 – PD.

Tabela 8.3 Lastnosti mer podobnosti pri MR - MR T1, T2 in PD (skupina 2a in 2b) poravnava slik

| | σ_a | | | σ_p | | | DO | | | CR | | | S | | |
|------|------------|-------|-------|------------|-------|-------|-------|-------|-------|-------|-------|-------|--------|---------|---------|
| | T1-T2 | T1-PD | T2-PD | T1-T2 | T1-PD | T2-PD | T1-T2 | T1-PD | T2-PD | T1-T2 | T1-PD | T2-PD | T1-T2 | T1-PD | T2-PD |
| CR | 1.3 | 0.8 | 0.5 | 1.1 | 0.6 | 0.3 | 7 | 15 | 9 | 0.5 | 14.0 | 5.5 | 205.7 | 0.0 | 6.3 |
| | 0.8 | 0.7 | 0.4 | 0.8 | 0.7 | 0.4 | 20 | 20 | 21 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| ECC | 0.7 | 0.7 | 0.5 | 0.6 | 0.5 | 0.3 | 10 | 25 | 20 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| | 0.7 | 0.7 | 0.4 | 0.7 | 0.7 | 0.4 | 30 | 30 | 39 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| E | 2.7 | 2.4 | 2.0 | 2.5 | 2.2 | 1.8 | 5 | 4 | 6 | 2.8 | 1.8 | 0.9 | 25.3 | 16.4 | 31.1 |
| | 1.5 | 1.5 | 0.8 | 1.5 | 1.5 | 0.8 | 4 | 4 | 7 | 0.6 | 1.8 | 1.8 | 8.2 | 12.2 | 7.9 |
| Ent | 1.1 | 0.7 | 0.7 | 0.9 | 0.5 | 0.4 | 6 | 14 | 12 | 0.5 | 4.1 | 0.5 | 86.0 | 113.7 | 108.8 |
| | 0.8 | 0.8 | 0.5 | 0.8 | 0.8 | 0.4 | 20 | 20 | 31 | 10.6 | 10.6 | 10.6 | 3.2 | 2.8 | 1.6 |
| HCE2 | 4.2 | 4.1 | 4.4 | 3.9 | 3.8 | 4.2 | 9 | 9 | 9 | 0.9 | 0.9 | 0.9 | 69.0 | 86.4 | 258.9 |
| | 3.9 | 4.1 | 2.8 | 3.8 | 3.7 | 2.7 | 3.9 | 4 | 6 | 0.5 | 0.9 | 0.9 | 8.5 | 3.5 | 11.9 |
| HCE3 | 4.2 | 3.9 | 4.3 | 3.9 | 3.7 | 4.1 | 10 | 9 | 9 | 0.9 | 0.9 | 0.9 | 53.0 | 90.7 | 410.8 |
| | 4.1 | 3.9 | 3.0 | 3.8 | 3.7 | 2.9 | 4.5 | 5 | 6 | 0.9 | 0.5 | 0.9 | 7.0 | 5.5 | 25.7 |
| MI | 0.7 | 0.7 | 0.5 | 0.6 | 0.5 | 0.3 | 12 | 30 | 24 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| | 0.7 | 0.7 | 0.4 | 0.7 | 0.7 | 0.4 | 37 | 38 | 48 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| NMI | 0.7 | 0.7 | 0.5 | 0.6 | 0.5 | 0.3 | 12 | 31 | 25 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| | 0.7 | 0.7 | 0.4 | 0.7 | 0.7 | 0.4 | 39 | 39 | 53 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| PSMI | 0.7 | 0.7 | 0.5 | 0.6 | 0.5 | 0.3 | 10 | 17 | 16 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| | 0.7 | 0.7 | 0.4 | 0.7 | 0.7 | 0.4 | 21 | 20 | 21 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| PSUH | 0.9 | 0.6 | 0.6 | 0.7 | 0.5 | 0.3 | 7 | 13 | 11 | 0.5 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| | 0.8 | 0.7 | 0.4 | 0.8 | 0.7 | 0.4 | 17 | 16 | 19 | 14.0 | 14.0 | 14.0 | 0.0 | 0.0 | 0.0 |
| WC | 2.2 | 0.6 | 3.0 | 2.2 | 0.5 | 3.1 | 7 | 17 | 20 | 0.9 | 2.8 | 2.3 | 2210.5 | 8221.7 | 6859.3 |
| | 0.8 | 0.6 | 0.4 | 0.8 | 0.6 | 0.4 | 28 | 49 | 73 | 3.7 | 2.8 | 2.3 | 5544.3 | 11773.9 | 12046.0 |

Vidimo lahko, da lahko slike T2 in PD med seboj najbolj natančno poravnamo. Če pa namesto slik s tumorjem analiziramo slike brez tumorja, opazimo, da se lastnosti mer podobnosti izboljšajo. Pričakovana točnost in natančnost mer je boljša pri poravnavi slik brez tumorja kot slik s tumorjem. Poveča se konvergenčno področje, gladkost pa se močno zmanjša, kar pomeni da je mera izven konvergenčnega območja bolj umirjena. Poveča se tudi izrazitost globalnega optimuma. Najslabše sta se obnesli medsebojni informaciji na osnovi Havrda-Charvatove entropije, najboljše pa medsebojna informacija in normalizirana medsebojna informacija na osnovi Shannonove entropije.

Naslednja tabela pa prikazuje rezultate analize izvedene na simuliranih slikah. Če smo uporabili slike originalne velikosti, so vse mere vedno našle optimum v isti točki in vse so bile tudi zelo gladke. Zato jih je bilo težko primerjati. Odločili smo se, da zmanjšamo dimenzije slike za dva v vsaki smeri ter da obe dimenziji histograma zmanjšamo na 128.


Zaradi tega je bila tudi sama analiza nekoliko hitrejša. Izvedli smo analizo vpliva števila N izbranih točk na rezultate. Števila predstavljajo analizo izvedeno z 10, 50 in 100 točkami.

Tabela 8.4 Analiza s simuliranimi slikami in različnim številom točk

| | σ_a | | | σ_p | | | DO | | | CR | | | S | | |
|------|------------|-----|-----|------------|-----|-----|-----|-----|-----|------|-----|-----|--------|--------|--------|
| | 10 | 50 | 100 | 10 | 50 | 100 | 10 | 50 | 100 | 10 | 50 | 100 | 10 | 50 | 100 |
| CR | 0.5 | 0.5 | 0.5 | 0.0 | 0.1 | 0.1 | 257 | 130 | 129 | 0.7 | 0.7 | 0.7 | 2095.2 | 1612.0 | 1460.6 |
| ECC | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.0 | 227 | 142 | 141 | 6.2 | 2.1 | 1.4 | 82.0 | 289.8 | 251.7 |
| E | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.0 | 127 | 80 | 77 | 6.2 | 5.5 | 1.4 | 203.5 | 129.3 | 150.9 |
| Ent | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.1 | 311 | 196 | 197 | 4.1 | 2.1 | 1.4 | 2503.9 | 1678.1 | 1635.0 |
| HCE2 | 3.0 | 3.2 | 3.4 | 2.9 | 3.1 | 3.4 | 75 | 34 | 32 | 1.0 | 0.7 | 0.7 | 2426.2 | 1655.5 | 1609.3 |
| HCE3 | 0.5 | 1.7 | 1.6 | 0.5 | 1.7 | 1.6 | 33 | 19 | 19 | 0.7 | 0.7 | 0.7 | 1607.4 | 1273.7 | 1228.5 |
| MI | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.0 | 337 | 208 | 208 | 6.2 | 2.1 | 1.4 | 37.5 | 203.1 | 167.3 |
| NMI | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.0 | 351 | 217 | 217 | 6.2 | 2.1 | 1.4 | 41.9 | 198.5 | 163.3 |
| PSMI | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.0 | 208 | 127 | 127 | 13.8 | 4.1 | 2.1 | 7.2 | 222.9 | 132.0 |
| PSUH | 0.5 | 0.5 | 0.5 | 0.0 | 0.0 | 0.1 | 176 | 107 | 108 | 6.9 | 4.8 | 2.1 | 3901.4 | 2757.3 | 2381.9 |
| WC | 6.7 | 6.7 | 6.7 | 6.7 | 6.7 | 6.7 | 48 | 39 | 38 | 0.9 | 0.7 | 0.7 | 6361.7 | 4134.6 | 4259.3 |

Opazimo lahko, da vrednost DO-ja pade z naraščanjem števila naključno izbranih točk. Razlika v DO je večja med analizo z 10 in 50 točkami kot pa med analizo s 50 in 100 točkami. Podobno lahko opazimo tudi pri ostalih lastnostih mer podobnosti. Konvergenčno področje Woodsovega kriterija je zelo majhno in se s povečevanjem števila linij še zmanjšuje. Povdariti je tudi potrebno, da je bila v tem primeru slika T2 najprej premaknjena v točko $X_{n, -M/2}$ z uporabo trilinearne interpolacije. Razlog je opisan v nadaljevanju.

Najpomembnejša faktorja, ki vplivata na poravnavo sta šum in svetlostne nehomogenosti (ang. shading). Za analizo šuma na potek mere podobnosti sem mirujoči in plavajoči sliki dodal gausov šum s standardno deviacijo 30. Ko sem analiziral vpliv svetlostnih nehomogenosti, sem svetlosti plavajoče slike množil s faktorjem med 0.5 in 1. Na vsaki rezini slike sem uporabil enak model nehomogenosti. Zgornji levi slikovni element sem množil z ena. Faktor je padal z oddaljenostjo od tega elementa. Najbolj oddaljeni element (spodaj desno) je bil množen z 0.5. Vsako rezino sem torej množil s spodnjo sliko ustrezne dimenzije.



Slika 16 Model svetlostne nehomogenosti s katero je množena vsaka rezina slike

Naslednja tabela kaže rezultat vrednotenja mer podobnosti pri poravnavi pošumljene (N) MR L3 slike vretenca na CT sliko ter poravnavo MR L3 slike z dodanimi svetlostnimi nehomogenostmi (SN) na CT. Dimenzija vezanega histograma je bila v obeh primerih 256 x 256. Število na levi strani stolpca predstavlja lastnost mere pri poravnavi originalnih slik (O).

Tabela 8.5 Poravnava pošumljenih slik in slik, ki imajo prisotne svetlostne nehomogenosti

| | σ_a | | | σ_p | | | DO | | | CR | | | S | | |
|------|------------|-----|-----|------------|-----|-----|----|-----|----|------|------|------|--------|--------|--------|
| | O | N | SN | O | N | SN | O | N | SN | O | N | SN | O | N | SN |
| CR | 0.6 | 0.7 | 0.7 | 0.5 | 0.5 | 0.5 | 20 | 34 | 21 | 4.8 | 3.4 | 4.8 | 73.6 | 1314.1 | 72.9 |
| ECC | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 0.5 | 17 | 35 | 17 | 15.1 | 7.6 | 13.8 | 101.3 | 1810.8 | 161.3 |
| Ent | 0.7 | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 21 | 33 | 19 | 1.4 | 3.4 | 0.7 | 96.1 | 138.7 | 156.4 |
| E | 1.0 | 0.7 | 1.1 | 0.9 | 0.6 | 0.9 | 22 | 36 | 19 | 0.7 | 3.4 | 0.7 | 297.6 | 159.4 | 382.5 |
| HCE2 | 3.3 | 5.0 | 3.3 | 3.1 | 4.7 | 3.1 | 21 | 54 | 21 | 0.7 | 0.7 | 0.7 | 1194.2 | 440.9 | 1239.0 |
| HCE3 | 3.1 | 5.0 | 3.1 | 3.0 | 4.8 | 3.0 | 22 | 124 | 22 | 0.7 | 0.7 | 0.7 | 1523.9 | 1283.8 | 1534.8 |
| NMI | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 0.5 | 25 | 43 | 23 | 15.1 | 8.3 | 13.8 | 41.5 | 1407.5 | 78.8 |
| MI | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 0.5 | 23 | 43 | 23 | 15.1 | 7.6 | 13.8 | 48.0 | 1436.7 | 90.0 |
| PSMI | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 0.5 | 15 | 193 | 15 | 20.7 | 11.7 | 18.6 | 0.2 | 25.4 | 2.0 |
| PSUH | 0.6 | 0.7 | 0.6 | 0.5 | 0.6 | 0.5 | 15 | 167 | 14 | 21.0 | 7.6 | 21.0 | 0.0 | 30.8 | 0.0 |

| | | | | | | | | | | | | | | | |
|----|-----|-----|-----|-----|-----|-----|----|----|----|-----|-----|-----|-------|--------|--------|
| WC | 0.6 | 0.7 | 0.7 | 0.5 | 0.6 | 0.6 | 24 | 62 | 27 | 9.6 | 4.1 | 9.6 | 887.2 | 7342.7 | 1012.1 |
|----|-----|-----|-----|-----|-----|-----|----|----|----|-----|-----|-----|-------|--------|--------|

Vidimo lahko, da se lastnosti mer podobnosti poslabšajo z dodajanjem šuma in svetlostnih nehomogenosti. Dodajanje svetlostnih nehomogenosti k sliki ima za posledico nekoliko manjšo izrazitost optimuma v primerjavi z izrazitostjo optimuma pošumljenih slik. Opazimo pa lahko, da se konvergenčno področje mer bolj zmanjša pri poravnavi pošumljenih slik kot pa slik s svetlostnimi nehomogenostmi. Enako poslabšanje lahko opazimo tudi pri ostalih lastnostih mer. Spet je izmed vseh mer najslabša medsebojna informacija na osnovi Havrda-Charvatove entropije, najboljše lastnosti pa lahko opazimo pri merah na osnovi Shannonove entropije.

9 Zaključek

Mere podobnosti ponavadi ocenjujemo na podlagi tega kako se obnašajo v kombinaciji z optimizacijskimi metodami. Mera podobnosti bo najverjetneje dala drugačne rezultate, če bo uporabljena v kombinaciji z drugo optimizacijo. S tem ko v postopku vrednotenja mere podobnosti optimizacija ne nastopa, zajamemo le lastnosti mere podobnosti in interpolacijske sheme. S poznavanjem le teh lastnosti lahko nekdo pravilneje izbere kombinacijo mere podobnosti, interpolacije in optimizacije. Analizirali smo 11 mer podobnosti na štirih vrstah slik. Medsebojna informacija in normalizirana medsebojna informacija sta najpogosteje uporabljani meri podobnosti za poravnavo medicinskih slik. Merita statistično odvisnost dveh naključnih spremenljivk. V primeru poravnave prevzameta vlogo naključnih spremenljivk sliki. Medsebojna informacija ni odvisna od narave te odvisnosti in sloni na meritvi entropije. V našem primeru smo uporabili Shannonovo ter Havrda – Charvatovo entropijo. V magistrski nalogi smo zopet dokazali, da lahko obe vrsti medsebojne informacije na osnovi Shannonove entropije uspešno uporabimo za poravnavo medicinskih slik.

Predlagani postopek lahko uporabimo tako na slikah zajetih z isto tehniko kot na slikah zajetih z različnimi tehnikami. Poznati moramo le »zlati standard« oz. pravilno poravnavo. Ta podatek lahko dobimo z uporabo markerjev [28, 29, 32] ali na kakšen drug zanesljiv način [28]. »Zlati standard«, ki ga dobimo z uporabo zanesljivejših metod poravnave je omejen z lastnostmi le teh poravnav [26]. Za potrebe vrednotenja morajo biti te poravnave čim bolj natančne.

Postopek lahko uporabimo za analizo vpliva parametrov mere podobnosti na potek mere podobnosti. Lahko analiziramo vpliv šuma, svetlostnih nehomogenosti, geometrijskih popačenj, velikost prekrivanja, razlik v vsebini slik... Poravnava je postopek z veliko parametri in analiza vpliva vseh parametrov bi bila časovno zelo potratna.

Z rezultati takih vrednotenj si lahko olajšamo odločitev, katero mero podobnosti uporabiti za poravnavo slik. Pokazali smo kako šum, svetlostne nehomogenosti in dimenzije histograma vplivajo na potek mer podobnosti.

Pokazali smo, da Woodsov kriterij ni natančen. Opozoriti je potrebno tudi, da je ta mera podobnosti namenjena PET - MR poravnavi. V tej kombinaciji je imela mera največje konvergenčno območje od vseh ostalih mer. Optimum, ki je najbližji »zlatemu standardu«,

je bil v vsakem primeru zelo izrazit. V nekaj primerih je bila največja vrednost na intervalu od $X_{n, -M/2}$ do $X_{n, M/2}$ ravno v eni izmed teh dveh točk. To je bil tudi vzrok za velike vrednosti za točnost v nekaterih primerih. Woodsov kriterij izven konvergenčnega področja divergira zelo hitro. Zaključimo lahko tudi, da medsebojna informacija na osnovi Havrda-Charvatove entropije ni primerna za poravnavo slik.

Opazili smo, da je točnost MI in NMI manj kot 1 mm. Šum poslabša obnašanje teh dveh mer. Pokazali smo tudi, da je poravnava slik s svetlostnimi nehomogenostmi manj natančna od poravnave slik brez nehomogenosti. Mere podobnosti imajo večje konvergenčno področje in večjo izrazitost optimuma ter manjše vrednosti gladkosti, če jih uporabimo na slikah brez popačenj.

V nadaljevanju raziskav na to temo se bom posvetil analizi vplivov različnih vrst svetlostnih nehomogenosti, različnih interpolacijskih metod in kombinacij šuma in nehomogenosti na potek in obnašanje mer podobnosti.

10 Literatura

- [1] D. Škerl, B. Likar, R. Bernard, and F. Pernuš, "A protocol for optimization-independent similarity measure evaluation," in *Workshop on Biomedical Image Registration*, vol. 2717, *Lecture Notes in Computer Science*, J. C. Gee, J. B. A. Maintz, and M. W. Vannier, Eds. Philadelphia: Springer-Verlag, 2003, pp. 330-338.
- [2] Shannon, C. Elwood, Weaver, and Warren, *The mathematical theory of communication*. Urbana: University of Illinois Press, 1949.
- [3] S. Ogawa, T. M. Lee, A. R. Kay, and D. W. Tank, "Brain magnetic resonance imaging with contrast dependent on blood oxygenation," *Proc Natl Acad Sci U S A*, vol. 87, pp. 9868-72, 1990.
- [4] R. Turner, D. Le Bihan, C. T. Moonen, D. Despres, and J. Frank, "Echo-planar time course MRI of cat brain oxygenation changes," *Magn Reson Med*, vol. 22, pp. 159-66, 1991.
- [5] F. Demšar, V. Jevtič, and G. G. Bačič, *Slikanje z magnetno resonanco*. Ljubljana: Littera picta, 1996.
- [6] J. B. Maintz and M. A. Viergever, "A survey of medical image registration," *Med Image Anal*, vol. 2, pp. 1-36, 1998.
- [7] P. Rogelj, S. Kovačič, and J. C. Gee, "Point similarity measures for non-rigid registration of multi-modal data," *Computer Vision and Image Understanding*, vol. 92, pp. 112-140, 2003.
- [8] J. V. Hajnal, D. L. G. Hill, and D. J. Hawkes, *Medical Image Registration*: CRC Press, 2001.
- [9] <http://mathworld.wolfram.com/RotationMatrix.html>.
- [10] M. Bro-Nielsen, "Rigid Registration of CT, MR and Crytosection Images Using a GLCM Framework," in *CVRMed/MRCAS'97*, vol. 1205: Springer Lecture Notes in Computer Science, 1997, pp. 171-180.
- [11] F. Maes, A. Collignon, D. Vandermeulen, G. Marchal, and P. Suetens, "Multimodality image registration by maximization of mutual information," *IEEE Trans Med Imaging*, vol. 16, pp. 187-198, 1997.

- [12] A. Roche, G. Malandain, X. Pennec, and N. Ayache, "The Correlation Ratio as a New Similarity Measure for Multimodality Image Registration," in *Medical Image Computing and Computer Assisted Intervention*, vol. 1496: Springer Verlag, 1998, pp. 1115-1124.
- [13] R. P. Woods, J. C. Mazziotta, and S. R. Cherry, "MRI-PET Registration with Automated Algorithm," *Journal of Comp. Assist. Tomography*, vol. 17, pp. 536-546, 1993.
- [14] M. P. Wachowiak, R. Smolikova, and T. M. Peters, "Multiresolution Biomedical Image Registration Using Generalized Information Measures," in *Medical Image Computing and Computer-Assisted Intervention*, vol. 2879, E. R. E. and P. T. M., Eds. Montreal, Canada: Springer-Verlag, 2003, pp. 846-853.
- [15] H.-m. Chen and P. K. Varshney, "Mutual Information-Based CT-MR Brain Image Registration Using Generalized Partial Volume Joint Histogram Estimation," *IEEE Trans Med Imaging*, vol. 22, pp. 1111-1119, 2003.
- [16] A. C. S. Chung, W. M. W. III, A. Norbash, and W. E. L. Grimson, "Multi-modal Image Registration by Minimizing Kullback-Leibler Distance," presented at MICCAI, Tokio, 2002.
- [17] A. Roche, X. Pennec, G. Malandain, and N. Ayache, "Rigid registration of 3-D ultrasound with MR images: a new approach combining intensity and gradient information," *IEEE Trans Med Imaging*, vol. 20, pp. 1038-49, 2001.
- [18] T. Makela, M. Pollari, J. Lotjonen, N. Pauna, A. Reilhac, P. Clarysse, I. E. Magnin, and T. Katila, "Evaluation and comparison of surface and intensity based rigid registration methods for thorax and cardiac MR and PET images," vol. 2674, I. E. Magnin, P. Clarysse, T. Katila, J. Montagnat, and J. Nenonen, Eds.: Springer Verlag, 2003, pp. 224-233.
- [19] M. E. Leventon and W. E. L. Grimson, "Multi-Modal Volume Registration Using Joint Intensity Distributions," in *Medical Image Computing and Computer Assisted Intervention*, vol. 1496. Cambridge: Springer Verlag, 1998, pp. 1057-1066.
- [20] A. Roche, X. Pennec, M. Rudolph, D. P. Auer, G. Malandain, S. Ourselin, L. M. Auer, and N. Ayache, "Generalized Correlation Ratio for Rigid Registration of 3D Ultrasound with MR Images," in *Medical Image Computing and Computer Assisted Intervention*, vol. 1935: Springer Verlag, 2000, pp. 567-577.

- [21] <http://www.bic.mni.mcgill.ca/brainweb/>.
- [22] R. K.-S. Kwan, A. C. Evans, and G. B. Pike, "MRI simulation-based evaluation of image-processing and classification methods," *IEEE Transactions on Medical Imaging*, vol. 18, pp. 1085-97, 1999.
- [23] D. L. Collins, A. P. Zijdenbos, V. Kollokian, J. G. Sled, N. J. Kabani, C. J. Holmes, and A. C. Evans, "Design and construction of a realistic digital brain phantom," *IEEE Trans Med Imaging*, vol. 17, pp. 463-8, 1998.
- [24] D. J. Hawkes, "Algorithms for radiological image registration and their clinical application," *J Anat*, vol. 193 (Pt 3), pp. 347-61, 1998.
- [25] D. Tomaževič, B. Likar, and F. Pernuš, "Gold standard 2D/3D registration of X-ray to CT and MR images," in *Medical Image Computing and Computer Assisted Intervention*, vol. 2489, *Lecture Notes in Computer Science*, T. Dohi and R. Kikinis, Eds. Tokio: Springer-Verlag, 2002, pp. 461-468.
- [26] D. Tomaževič, B. Likar, and F. Pernuš, "Multi-Feature Mutual Information," vol. in press, 2004.
- [27] R. P. Velthuizen, L. P. Clarke, S. Phuphanich, L. O. Hall, A. M. Bensaid, J. A. Arrington, H. M. Greenberg, and M. L. Silbiger, "Unsupervised measurement of brain tumor volume on MR images," *J Magn Reson Imaging*, vol. 5, pp. 594-605, 1995.
- [28] J. West, J. M. Fitzpatrick, M. Y. Wang, B. M. Dawant, C. R. Maurer, Jr., R. M. Kessler, R. J. Maciunas, C. Barillot, D. Lemoine, A. Collignon, F. Maes, P. Suetens, D. Vandermeulen, P. A. van den Elsen, S. Napel, T. S. Sumanaweera, B. Harkness, P. F. Hemler, D. L. Hill, D. J. Hawkes, C. Studholme, J. B. Maintz, M. A. Viergever, G. Malandain, R. P. Woods, and et al., "Comparison and evaluation of retrospective intermodality brain image registration techniques," *J Comput Assist Tomogr*, vol. 21, pp. 554-66, 1997.
- [29] D. Tomaževič, B. Likar, T. Slivnik, and F. Pernuš, "3-D/2-D registration of CT and MR to X-ray images," *IEEE Trans Med Imaging*, vol. 22, pp. 1407-1416, 2003.
- [30] J. M. Fitzpatrick, J. B. West, and C. R. Maurer, Jr., "Predicting error in rigid-body point-based registration," *IEEE Trans Med Imaging*, vol. 17, pp. 694-702, 1998.
- [31] J. P. Pluim, J. B. Maintz, and M. A. Viergever, "Mutual-information-based registration of medical images: a survey," *IEEE Trans Med Imaging*, vol. 22, pp. 986-1004, 2003.

- [32] J. West, J. M. Fitzpatrick, M. Y. Wang, B. M. Dawant, C. R. Maurer, Jr., R. M. Kessler, and R. J. Maciunas, "Retrospective intermodality registration techniques for images of the head: surface-based versus volume-based," *IEEE Trans Med Imaging*, vol. 18, pp. 144-50, 1999.

Življenjepis

Darko Škerl se je rodil 7. januarja 1978 v Banja Luki. Po končani osnovni šoli Center v Novem mestu se je vpisal na Srednjo tehniško in zdravstveno šolo v Novem mestu, kjer je leta 1996 pridobil poklic elektrotehnik-elektronik. Na fakulteto za elektrotehniko se je vpisal leta 1996, kjer je izbral smer avtomatika. Leta 2001 je diplomiral na področju obdelave medicinskih slik in se istega leta vpisal v podiplomski študij na fakulteti za elektrotehniko Univerze v Ljubljani, kjer je tudi zaposlen kot mladi raziskovalec.

Bibliografija

- [1] D. Škerl, S. Pan, R. Li, J. M. Fitzpatrick, M. H. Parks, P. R. Martin, V. L. Morgan, and B. M. Dawant, "Correction of geometric distortions in EP images using nonrigid registration to corresponding anatomic images," in *Medical Imaging 2001*, M. Sonka and J. M. Fitzpatrick, Eds. San Diego, USA: SPIE press, 2001.
- [2] D. Škerl, B. Likar, R. Bernard, and F. Pernuš, "A protocol for optimization-independent similarity measure evaluation," in *Workshop on Biomedical Image Registration*, vol. 2717, *Lecture Notes in Computer Science*, J. C. Gee, J. B. A. Maintz, and M. W. Vannier, Eds. Philadelphia: Springer-Verlag, 2003, pp. 330-338.
- [3] D. Škerl, B. Likar, and F. Pernuš, "Evaluation of nine similarity measures used in rigid registration," International Conference on Pattern Recognition, in press, 2004.

Izjava

Izjavljam, da sem magistrsko delo izdelal sam pod vodstvom mentorja prof. dr. Franja Pernuša. Pomoč ostalih sodelavcev sem navedel v zahvali.

Ljubljana, 9. 6. 2004

Darko Škerl
