

Univerza v Ljubljani
Fakulteta za elektrotehniko

Peter Rogelj

Elastična poravnava medicinskih slik različnih modalnosti

Magistrsko delo

Mentor: prof. dr. Stanislav Kovačič

Ljubljana, april 2001

Zahvala

Zahvaljujem se mentorju prof. Stanislavu Kovačiču, ki me je kot mladega raziskovalca v času mojega podiplomskega študija pozorno spremljal, usmerjal in ustvaril odlične delovne pogoje.

Zahvala gre tudi sodelavcem, ki so veliko prispevali k ustvarjanju dobrega vzdušja, predvsem pa Franciju Lahajnarju in Janezu Peršu za številne izmenjave strokovnih izkušenj in idej.

Lepo se zahvaljujem tudi staršem, sorodnikom in prijateljem, ki so me spremljali na moji poti in z menoj delili lepe in težke trenutke.

Povzetek

Poravnava slik je ena osnovnih operacij obdelave medicinskih slik. V tem delu se posvečamo enemu najtežjih problemov poravnave, to je elastični poravnavi slik različnih modalnosti. Gre za poravnavo slik zajetih z različnimi slikovnimi postopki, pri katerih ni vnaprej poznanih povezav med svetlostnimi nivoji. Elastična večmodalna poravnava omogoča odpravljanje lokalnih slikovnih neskladij, poseben problem pa predstavlja večmodalnost, ki preprečuje uporabo običajnih lokalnih mer podobnosti. Potrebna je uporaba večmodalnih mer podobnosti, ki pa v osnovi niso zmožne ocenjevati lokalnega ujemanja slik. Za učinkovito rešitev tega problema predlagamo nekaj novih mer podobnosti, ki so kljub večmodalnosti primerne za ocenjevanje poravnanih poljubno majhnih področij slik. Najboljše rezultate poravnave dobimo z uporabo predlagane mere podobnosti na osnovi segmentacije. Ta mera predstavlja povezavo med poravnavo in segmentacijo slik, saj z njo oba procesa izvedemo istočasno. Sistem za večmodalno elastično poravnavo, ki je opisan v tem delu, izkorišča dobre lastnosti novih mer podobnosti, uporablja pa tudi nov poenostavljen model elastičnosti. Poravnava slik je tako razmeroma hitra, k čemur pripomore tudi uporabljen večločljivostni pristop. Rezultati poskusnih poravnav so dobri, vendar pa kažejo na nezmožnost sistema za doseganje točnosti boljše od velikosti enega voksla. Izboljšanje točnosti je glavna smernica našega nadaljnjega dela.

Abstract

Image registration is one of fundamental tasks of medical image processing. In this work we focus on multimodal elastic matching, which is one of the hardest registration tasks. It enables accurate non-rigid registration of images acquired using different imaging techniques, where the relations between image intensities are not known in advance. Because of complex and in general unknown intensity relations multimodal registration cannot be based on common local similarity measures. Multimodal similarity measures have to be used, but unfortunately they are all inherently global and cannot measure local image correspondence. As a solution to this problem we propose novel multimodal similarity measures, which enable similarity measuring of arbitrary small image regions. The best results are achieved by using a segmentation based similarity measure which combines image registration with image segmentation and perform both of them simultaneously. The system for multimodal elastic matching, presented in this work, takes all the advantages of proposed similarity measures. It is based on simplified model of elasticity and implemented using multiresolution approach. Results are promising, although they indicate that subvoxel accuracy cannot be achieved. Improvement of accuracy is the aim of our future work.

Vsebina

1. Uvod	1
1.1 Pomen večmodalne elastične poravnave medicinskih slik	1
1.2 Modalnosti medicinskih slik	2
1.2.1 CT - računalniška tomografija	2
1.2.2 MRI - magnetna resonanca	3
1.3 Postopki poravnave slik	5
1.3.1 Delitev postopkov poravnave	5
1.3.2 Uvrstitev večmodalne elastične poravnave	9
2. Večmodalna elastična poravnava slik	11
2.1 Razvoj elastične poravnave	11
2.2 Delovanje elastične poravnave	12
2.2.1 Določanje zunanjih sil	13
2.2.2 Prostorski modeli deformacij	14
2.3 Večmodalna poravnava	19
2.3.1 Poravnava z večmodalnimi merami podobnosti	19
2.3.2 Poravnava s svetlostno preslikavo	20
3. Mere podobnosti	23
3.1 Pregled mer podobnosti	23
3.1.1 Enomodalne mere podobnosti	24
3.1.2 Večmodalne mere podobnosti	26
3.2 Merjenje podobnosti in merjenje kvalitete poravnave	29
3.2.1 Interpolacija slik	30
3.2.2 Lokalni ekstremi	32

3.2.3	Lokalnost mer podobnosti	36
3.3	Lokalne večmodalne mere podobnosti	37
3.3.1	Izpeljava lokalne večmodalne mere podobnosti	37
3.3.2	Posplošitev lokalne večmodalne mere podobnosti	39
3.4	Vezana verjetnostna porazdelitev	40
3.5	Mere podobnosti in segmentacija	44
3.5.1	Mera podobnosti na osnovi segmentacije	45
3.5.2	Poenostavitev	49
4.	Izvedba sistema za elastično poravnavo	51
4.1	Določanje zunanjih sil	52
4.1.1	Določitev podobnosti svetlostnih parov	52
4.1.2	Določitev zunanjih sil na osnovi točkovnih podobnosti . . .	53
4.2	Elastični model	56
4.3	Izračun deformirane slike	58
4.4	Večločljivostni pristop	59
4.5	Izbira postopkov predobdelave	60
5.	Rezultati	63
5.1	Primerjava lokalnih mer podobnosti	63
5.2	Primerjava elastičnih modelov	67
5.3	Izbira uporabljenih metod in ocena sistema	68
6.	Zaključek	75
6.1	Smernice nadaljnjega dela	76
	Literatura	77

1. Uvod

1.1 Pomen večmodalne elastične poravnave medicinskih slik

Hiter razvoj medicinskih slikovnih tehnik je vzpodbudil raziskave na področju anatomske in funkcionalne zgradbe človeškega telesa. Osnovna operacija, ki se pri tem uporablja je poravnava slik, katere namen je doseči, da se iste anatomske strukture na vseh slikah nahajajo v istih legah. Tovrstno odpravljanje geometrijskih neskladij med slikami olajša medicinsko diagnosticiranje ter omogoči načrtovanje operativnih posegov in radioterapij. Posebnega zanimanja so deležni človeški možgani, saj zaradi svoje zapletenosti in velike anatomske variabilnosti zahtevajo posebno natančnost obdelave, ki pa je ravno zato časovno zelo zahtevna. To je razlog za velik interes po avtomatizaciji tovrstnih postopkov. Ena od možnosti avtomatizacije je uporaba računalniškega vida. Avtomatska obdelava slik je bistveno hitrejša od ročne, mnogokrat natančnejša, pa tudi bolj objektivna.

Posebno mesto na področju poravnave medicinskih slik ima večmodalna poravnava, ki dopušča, da so uporabljene slike zajete z različnimi slikovnimi tehnikami ali postopki. Tako lahko informacijo slik, ki predstavljajo različne anatomske ali funkcionalne lastnosti tkiv, združimo v skupen, bolj zgoščen in preglednejši zapis. Tako lahko naprimer pomembno, a geometrijsko popačeno, informacijo magnetno resonančnih MRI slik (angl. textitmagnetic resonsnce imaging) poravnamo na nepopačeno sliko računalniške tomografije CT (angl. textitcomputed tomography). Prav zaradi takšnih zmožnosti je večmodalna poravnava posebno pomembno orodje pri diagnosticiranju in načrtovanju zdravljenja. Zaradi njene zmožnosti integracije informacije predoperativnih preiskav z intraoperativnimi slikami manj invazivnih in hitrih slikovnih postopkov, pa je primerna tudi za podporo operativnim posegom.

Geometrijska slikovna neskladja so lahko posledica različnih dejavnikov. Pojavijo se lahko zaradi spremenjenega položaja pacienta, drugačnih pogojev zajemanja slik, lahko pa so tudi posledica prožnosti ali patoloških sprememb tkiv. V primeru enomodalne poravnave, kjer so slike zajete z istimi slikovnimi postopki, je patološka neskladja mnogokrat zaželeno, kljub poravnavi,

ohraniti nespremenjena, saj lahko predstavljajo koristno diagnostično informacijo. Nasprotno pa je predvsem pri večmodalni poravnavi, zaželeno odpravljanje vseh neskladij, saj je le tako mogoča pravilna integracija slikovnih vsebin. Neskladja se pojavljajo na zelo različnih nivojih detajlov, od globalnih, ki vplivajo na celotno sliko, do izrazito lokalnih, ki zajamejo le omejeno področje. Prav pri odpravljanju slednjih imajo poseben pomen postopki elastične poravnave slik, ki omogočajo tudi odpravljanje najmanjših in prostorsko najbolj omejenih geometrijskih razlik. Njihova dobra lastnost je tudi ta, da lahko na osnovi podanih elastičnih lastnosti tkiv smiselno ločujejo med motilnimi in koristnimi slikovnimi neskladji.

To magistrsko delo, *Elastična poravnava medicinskih slik različnih modalnosti*, se posveča problemu poravnave z obema zgoraj omenjenima lastnostima: večmodalnostjo, ki dopušča združevanje informacije pridobljene z različnimi slikovnimi tehnikami in lokalnostjo, doseženo s postopki elastične poravnave, ki omogoča tudi odpravljanje prostorsko najbolj omejenih slikovnih neskladij. To je pereč problem, saj lastnost večmodalnosti v osnovi nasprotuje lastnosti lokalnosti.

1.2 Modalnosti medicinskih slik


Različne metode zajemanja medicinskih slik temeljijo na meritvah različnih lastnosti tkiv ali pojavov. Vsaka od njih torej predstavlja svojo modalnost, način opisa slikanega telesa. Medicinske tehnike v splošnem delimo na anatomske in funkcionalne. Anatomske slikovne tehnike podajajo informacijo o zgradbi telesa, medtem ko funkcionalne slikovne tehnike podajajo informacijo o presnovi. Med anatomske tehnike spadajo RTG (rentgensko slikanje), CT (računalniška tomografija), MRI (magnetna resonanca), US (ultrazvok), MRA (magnetno resonančna angiografija), DSR (digitalna subtrakcijska angiografija), CTA (računalniško tomografska angiografija) itd. V skupino funkcionalnih slikovnih tehnik pa uvrščamo SPECT (fotonska emisijska računalniška tomografija), PET (pozitronska emisijska tomografija), fMRI (funkcionalna magnetna resonanca), EEG (elektro encefalografija) itd. V okviru tega dela se bomo posebej posvetili osnovnima in najbolj uporabljanima trodimenzionalnima anatomskima slikovnim tehnikama, to sta CT in MRI.

1.2.1 CT - računalniška tomografija

CT (računalniška tomografija) [1] je zelo uveljavljena slikovna tehnika, v medicini prisotna od sredine sedemdesetih let. Predstavlja enega izmed največjih napredkov medicinskih ved. Osnova za CT je rentgensko slikanje, kjer slika nastane kot posledica različnega slabljenja rentgenskih žarkov pri prehodu skozi telo. Slabljenje rentgenskih žarkov je odvisno od gostote elektronov v tkivu in je največje za kosti, ki so zato videti svetle, ter manjše za mehka tkiva, ki so

zato temnejša. Trodimenzionalna slika, se izračuna na osnovi velikega števila enodimenzionalnih slik, zajetih pod različnimi koti slikanja.


CT odlikuje dobra kontrastnost trdih tkiv (kosti), medtem ko je ločevanje med različnimi mehкими tkivi slabše (slika 1.1). Uporablja se predvsem za odkrivanje tumorjev in možganskih nepravilnosti ter za nadzor in ocenjevanje uspeha operativnih posegov, radioterapij in kemoterapij. Slaba stran CT-ja je njegova invazivnost, saj je pacient izpostavljen sevanju. Nenehne izboljšave te slikovne tehnike gredo v smeri izboljšanja kvalitete slik, večanja ločljivosti in zmanjševanja pacientove izpostavljenosti sevanju.




Slika 1.1: Prerez CT slike glave.

1.2.2 MRI - magnetna resonanca

MRI (magnetna resonanca) [1–3] je neinvazivna slikovna tehnika, ki za svoje delovanje izkorišča magnetne lastnosti atomov. Gre predvsem za atome vodika, ki v glavnem pripadajo molekulam vode in predstavljajo približno 63 odstotkov človeškega telesa. Slikano telo se mora nahajati v močnem stalnem magnetnem polju, tako da gostota magnetnega polja doseže 0.04 do 4 T (Tesla). Za primerjavo: gostota magnetnega polja Zemlje znaša 0.00005 T. To magnetno polje usmeri dipole atomov, ki jih nato v postopku slikanja vzbudimo z visokofrekvenčnim radijskim impulzom. V prehodnem pojavu dipoli oddajo elektromagnetno valovanje, ki ga zazna sprejemna tuljava. Na osnovi poteka prejetega signala se določi svetlostne nivoje slike. Obstaja več različnih postopkov magnetno resonančnega zajemanja slik, ki dajejo različno informacijo o slikanem tkivu in tako predstavljajo različne modalnosti. Uveljavljene modalnosti MRI slik so T1, T2 in PD (slika 1.3).



Slika 1.2: Prerezi MRI-T1 slike glave: sagitalno (levo), prečno (v sredini) in koronalno (desno).



Slika 1.3: Različne modalnosti MRI slik: T1 (levo), T2 (v sredini) in PD (desno).


MRI odlikuje dober kontrast med različnimi tipi tkiv in je zato primerna za detajlen prikaz anatomije. Njeno uporabo omejuje zahteva po mirovanju telesa med slikanjem. Neprimerna je za slikanje v prisotnosti feromagnetnih materialov, naprimer železa, ki se lahko nahaja tudi v kirurških implantih. Slikanje z MRI poleg tega ni primerno za bolnike s srčnimi spodbujevalniki. Uporablja se predvsem za diagnosticiranje tumorjev in drugih nepravilnosti možganskih tkiv, za preiskave oči, z novejšimi tehnikami pa se vse več uporablja tudi za slikanje prsnega koša in trebuha, kjer ni mogoče doseči popolnega mirovanja.

Na kvaliteto MRI slik vpliva več dejavnikov. Nekatere napake MRI slik nastanejo zaradi neidealnih lastnosti slikovne naprave in jih je s kalibracijo naprave mogoče odpraviti. Glavni takšni vzroki napak so prostorska nehomogenost stalnega magnetnega polja, omejeno frekvenčno področje visokofrekvenčnega sprejemnika ter prostorska občutljivost visokofrekvenčnega oddajnika in sprejemnika. Nekatere napake pa so posledica prisotnosti slikanega

objekta in jih s kalibracijo ne moremo odpraviti. Do takšnih napak lahko pride zaradi premikov telesa med procesom slikanja, toka telesnih tekočin, pomemben pa je tudi vpliv samega telesa na magnetno polje, saj se zaradi njegove prisotnosti v prostoru spremeni dielektričnost, to pa vpliva na homogenost polja ter na resonančne frekvence dipolov. Zaradi omenjenih vplivov lahko pride do deformacije slik, svetlostnih nehomogenosti in pa do neizrazitosti robov.

1.3 Postopki poravnave slik

Poravnava slik je proces določanja transformacije poravnane slike B v poravnano sliko B' , z namenom doseganja čim boljšega medsebojnega prostorskega ujemanja med poravnano sliko B' in referenčno sliko A (slika 1.4).



Slika 1.4: Enostaven primer poravnave slik, A - referenčna slika, B - poravnavana slika, B' - poravnana slika

1.3.1 Delitev postopkov poravnave

Postopki poravnave se med seboj razlikujejo po svojih lastnostih, namenu, načinu delovanja in podobno. Pregled metod poravnave in njihove različne delitve so podrobno opisane v [4–7], glavne delitve pa povzemamo v nadaljevanju.

Razsežnost podatkov

Najprej lahko poravnavo delimo glede na razsežnost poravnanih podatkov. Tako ločimo dvodimenzionalno (2D:2D) in trodimenzionalno (3D:3D) poravnavo, ki sta najpogostejši, možna pa je tudi poravnava dvodimenzionalnih slik na trodimenzionalne slike in obratno (2D:3D). Posebnost so poravnave, kjer ena od dimenzij predstavlja čas. Takšne poravnave so namenjene naprimer opazovanju rasti kosti pri otrocih (dolg časovni interval), rasti tumorjev (srednje dolg interval), ali nadzoru delovanja srca (kratak interval). Tovrstne poravnave predstavljajo povezavo med področjem poravnave slik in področjem sledenja [8].

Oslonilna informacija


Druga delitev ločuje metode poravnave slik glede na uporabljeno oslonilno informacijo. Najpreprostejša je poravnava slik glede na kalibrirane koordinatne sisteme. Vendar pa koordinatni sistem slik običajno vnaprej ni poznan. Zato so se razvile metode na osnovi markerjev. Markerji so dodatni objekti, ki so čim bolj toga pripeti na slikano telo in so na poravnanih slikah dobro vidni. Vendar pa je izbira primerne namestitve markerjev težavna, saj njihov položaj mnogokrat ni dovolj stalen (maske, kožni markerji), ali pa so invazivni in zato manj sprejemljivi z medicinskega stališča (vijačni markerji). Oslonilna informacija pa se lahko razbere tudi kar iz poravnanih slik, saj te (brez markerjev) mnogokrat vsebujejo dovolj informacije o položaju slikanega telesa. Na tem principu delujejo retrospektivne metode, ki lahko temeljijo na prileganju oslonilnih točk [9, 10], robov ali površin [11], na statističnih lastnostih slik (momenti, glavne osi) ali pa za to uporabijo celotno vsebino slike.

Narava transformacije

Glede na naravo transformacije slike ločimo toga, afino, projekтивно in krivočrtno poravnavo. Najosnovnejša je toga poravnava, kjer je transformacija sestavljena le iz premika in zasuka slike, zanjo pa je značilno, da ohranja razdaljo med poljubnima dvema točkama slike. Tovrstno dvodimenzionalno transformacijo lahko zapišemo s tremi parametri, medtem ko je za trodimenzionalno poravnavo potrebnih šest parametrov. Bolj kompleksni sta afina poravnava, ki ohranja vzporednost med dvema poljubnima vzporednima premicama in projekтивna poravnava, za katero je značilno le to, da poljubno premico spet preslika v premico. Ti dve vrsti transformacije v primeru dvodimenzionalnih slik zahtevata šest, oziroma deset, parametrov. Najbolj splošna transformacija pa je krivočrtna, ki nima nobenih tovrstnih lastnosti. Takšnih transformacij se mnogokrat ne da opisati parametrično.

Modalnost podatkov

Glede na uporabljene modalnosti ločimo enomodalne in večmodalne poravnave, poravnavo slike na model in poravnava slike na pacienta. Kot je bilo že omenjeno, so v primeru zajema slik z istimi slikovnimi postopki primernejše enomodalne poravnave, medtem ko so sicer potrebni večmodalni postopki. V primeru poravnave slike na model ali na pacienta, je prisotna le ena slika, ki ji je potrebno določiti ustrezno lego v koordinatnem sistemu objekta (modela ali pacienta).



Slika 1.5: Delitev geometrijskih poravnav glede na naravo transformacije [12].

Posegi operaterja


Glede na zahtevane posege operaterja ločimo interaktivno, polavtomatsko in avtomatsko poravnavo. V primeru interaktivne poravnave uporabnik sam izvede vse potrebne postopke, sistem pa mu nudi pomoč z vizualno ali numerično oceno trenutne poravnave. Interaktivne metode običajno od uporabnika zahtevajo nastavitve začetnih parametrov, nato pa mora uporabnik le sprejeti ali zavrniti avtomatsko predlagane možnosti. V primeru avtomatskih postopkov so od uporabnika zahtevane kvečjemu informacije o postopku zajema slike, dejanska poravnava pa je izvedena brez njegovih posegov.

Pripadnost podatkov

Delitev glede na osebo, ki ji poravnane slike pripadajo, loči med poravnavo slik iste osebe (angl. *intrasubject*), ki je daleč najpogostejša, poravnavo slik različnih oseb (angl. *intersubject*) in poravnavo atlasa. Atlas je slika, določena na osnovi več realnih slik ali znanja o običajni zgradbi telesa. Poravnava atlasa tako predstavlja preslikavo slike običajne osebe, atlasa, na dejansko sliko pacienta. Poravnava slik različnih oseb in poravnava atlasa sta bolj zahtevna problema, saj morata zaradi razlik med ljudmi odpraviti več slikovnih neskladij ter zato vedno zahtevata krivočrtno transformacijo.


Lokalnost poravnave

Pojem lokalnosti poravnave govori o lokalnosti transformacije, ki je v postopku poravnave uporabljena. Ločimo globalne in lokalne poravnave. Globalne poravnave temeljijo na enotni transformaciji za celotno poravnavano sliko (slika 1.6). Transformacija je običajno podana parametrično, pri čemer se parametri določajo z optimizacijskim postopkom. Uporablja se predvsem za transformacije nižjega reda, to je za transformacije z razmeroma majhnim številom parametrov, najpogosteje je to toga ali afina poravnava.



Slika 1.6: Globalna poravnava slik.

Lokalne poravnave (slika 1.7) za razliko od globalnih razdelijo celotno sliko na več podpodročij, ki se jih poravnava z med seboj neodvisnimi lokalnimi transformacijami. Ker mora biti v večini primerov zaradi fizikalnega ozadja poravnanih slik rezultat zvezen, tako da poravnana slika ni raztrgana ali zgubana, lokalni poravnavi običajno sledi korak glajenja ali interpolacije.



Slika 1.7: Lokalna poravnava slik.

V povezavi s pojmom lokalnosti poravnave je treba omeniti tudi lokalnost slikovnih neskladij. Pomen teh dveh pojmov je namreč različen, med njima pa ni direktne povezave. Globalna in lokalna slikovna neskladja je namreč mogoče odpraviti tako z globalnimi, kot tudi z lokalnimi postopki.

Postopek določanja transformacije slik

Poravnava slik je postopek določanja najboljše transformacije poravnane slike glede na referenčno sliko in kot tak lahko temelji na različnih strategijah.

Parametri transformacije se namreč lahko izračunajo analitično ali pa se jih poišče z optimizacijskim postopkom. Analitičen izračun parametrov je vezan na manjšo količino podatkov, naprimer manjše število oslonilnih točk. Uporaba optimizacijskih postopkov pa običajno temelji na predpostavki o naravi transformacije, s čimer je določeno tudi število parametrov, ki jih je potrebno optimirati. Za kriterijsko funkcijo se v postopku optimizacije uporablja poravnava slik, ki je ocenjena z merami podobnosti (poglavje 3.).

1.3.2 Uvrstitev večmodalne elastične poravnave

Elastična poravnava je poseben postopek poravnave slik, ki temelji na fizikalnih zakonih deformabilnih teles. Kljub njenemu imenu pa ni omejena le na zakone elastičnosti, ampak pogosto tudi viskoznosti, plastičnosti ali podobnih namišljenih ali poenostavljenih lastnosti.

Poravnava slika je pri elastični poravnavi modelirana kot deformabilno telo, na katerega delujejo zunanje sile, tako da ga skušajo preoblikovati v smeri zmanjšanja slikovnih neskladij z referenčno sliko. Elastična poravnava je torej iskanje ravnovesnega stanja med zunanjimi silami, ki so določene na osnovi lokalnih podobnosti slik ter notranjimi silami, ki se deformacijam upirajo in skrbijo za zveznost in fizikalno smiselnost transformacije poravnane slike.

Gre torej za lokalno poravnavo, področja slike, ki so pri tem uporabljena pa so običajno ekstremno majhna, saj lahko vsebujejo tudi le en slikovni element (piksel v 2D oziroma voksel v 3D). Takšnih področij pa se ne poravnava povsem neodvisno, kot je sicer običaj lokalnih poravnav, ampak jih povezuje že omenjeni prostorski model deformacij.

Zaradi velike količine podatkov in zaradi nelinearnega poteka sil problem ni analitično rešljiv. Tudi optimizacijski postopek je prikrit, saj se zaradi enostavnosti vsake od lokalnih transformacij in povezav med področji, sprevrže v iteracijski postopek.

Druge lastnosti večmodalne elastične poravnave slik niso strogo določene (razen seveda večmodalnosti), vendar pa se bomo v tem delu posvetili trodimenzionalnim avtomatskim poravnavam, katerih oslonilna informacija je celotna vsebina slik in niso omejene glede na pripadnost podatkov.

2. Večmodalna elastična poravnava slik

V tem poglavju je opisana problematika večmodalne elastične poravnave slik. Najprej je predstavljena elastična poravnava, kot iterativen postopek izmeničnega določanja zunanjih sil in njim ustreznih deformacij poravnane slike. Zunanje sile in deformacije povezuje prostorski model deformacij, ki lahko izhaja iz različnih fizikalnih lastnosti materialov. V nadaljevanju je izpostavljen problem večmodalnosti, ki izhaja iz kompleksne in v splošnem nepoznane odvisnosti med svetlostnimi nivoji slik različnih modalnosti, ki predstavljajo ista biološka tkiva.

2.1 Razvoj elastične poravnave

Razvoj elastične poravnave slik se je začel leta 1981, ko je Broit v svoji doktorski disertaciji poravnavo trodimenzionalnih slik osnoval na zakonih mehanike trdnih teles [13]. Raziskave so nato potekale predvsem v smeri razvoja različnih prostorskih modelov deformacij [14, 15]. Pomembno vlogo pri razvoju elastične poravnave je odigrala tudi časovna zahtevnost algoritmov, saj je le ta kritična. Elastična poravnava dveh trodimenzionalnih slik velikosti 128^3 vokslov z računalnikom 128×64 DECMpp1200Sx/ Model 200 MASPARG (masively parallel mech-connected supercomputer) namreč zahteva kar 9,5 ur.

Eden prvih splošno namenskih postopkov za elastično poravnavo trodimenzionalnih slik je poravnava CT slik z atlasom, ki sta ga leta 1989 objavila Bajcsy in Kovačič [16]. Pri tem je pomembna tudi uporaba večočljivostnega pristopa, ki pohitri poravnavo in izboljša njeno konvergenco. Leta 1993 je Christensen predlagal uporabo prostorskega modela deformacij, ki temelji na viskoznosti in omogoča boljšo poravnavo v primeru večjih slikovnih neskladij [17]. Pomembno prelomnico pri razvoju elastične poravnave predstavlja tudi uporaba konvolucijskih filtrov [13, 18, 19], s katerimi dobimo rešitev parcialne diferencialne enačbe viskoznosti v enem samem preletu slike. S tem je mogoče elastično poravnavo slik pohitriti do 1000-krat. Omeniti velja še verjetnostno poravnavo [20–22], ki omogoča uporabo predhodnega znanja, ter hitri 'demonov' postopek poravnave [23], ki se zgleduje po osnovah termodinamike.


Pod izrazom elastična poravnava je mogoče zaslediti tudi algoritme, ki dejansko ne delujejo po zgoraj opisanem postopku. Gre za lokalne poravnave,

ki jih z elastičnostjo povezuje postopek preslikave rezultatov lokalnih poravnav v zvezno globalno transformacijo. Ta se zgluduje po elastičnih lastnostih tanke pločevine (angl. *thin-plate spline*) [24–27]. Tovrstne poravnave v tem delu ne uvrščamo med elastične poravnave.

2.2 Delovanje elastične poravnave

Referenčna slika A in poravnavana slika B sta trodimenzionalna objekta z enotnim koordinatnim sistemom (slika 2.1). Vsak voksel slike ima v tem koordinatnem sistemu svojo lego določeno z vektorjem $\mathbf{x} = [x_1, x_2, x_3]^T$. Z deformacijo poravnavane slike, se točka premakne za nek premik $\mathbf{u}(\mathbf{x}) = [u_1(\mathbf{x}), u_2(\mathbf{x}), u_3(\mathbf{x})]^T$, tako da so njene nove koordinate $\mathbf{x}' = [x'_1, x'_2, x'_3]^T$ sledeče:

$$\mathbf{x}' = \mathbf{x} + \mathbf{u}(\mathbf{x}). \quad (2.1)$$

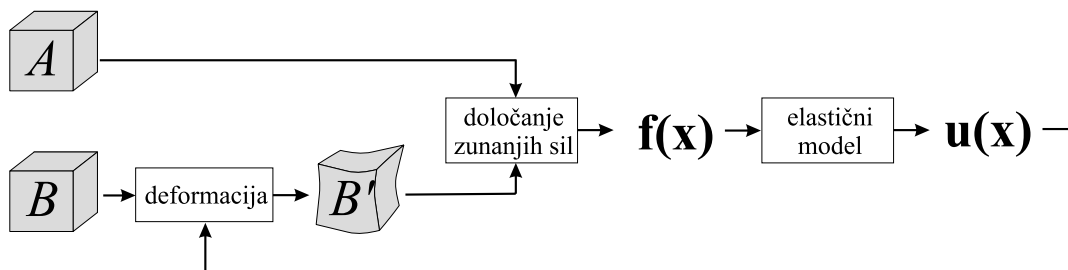


Slika 2.1: Koordinatni sistem slik.

Postopek elastične poravnave prikazuje slika 2.2. Poravnavano sliko B se s transformacijo, ki jo predpisuje funkcija premikov $\mathbf{u}(\mathbf{x})$, določi deformirano poravnavano sliko B' . Začetna vrednost premikov je enaka 0, lahko pa se tudi privzame rezultate morebitne predhodne poravnave. Na osnovi lokalnega ujemanja referenčne slike A in deformirane poravnavane slike B' se nato določi funkcijo zunanjih sil $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), f_3(\mathbf{x})]^T$. Te sile delujejo v smeri izboljšanja lokalnega ujemanja slik in povzročijo novo deformacijo $\mathbf{u}(\mathbf{x})$ poravnavane slike v skladu z uporabljenim prostorskim modelom deformacij. Postopek je iterativen in konvergira v smeri boljšega medsebojnega ujemanja slik. Na ta način se poravnava slik preslika v iskanje ravnovesnega stanja med zunanjimi silami, ki sliko silijo k takšnemu preoblikovanju, da se izboljša prileganje slik, in notranjimi silami, ki se deformacijam upirajo in skrbijo za njihovo fizikalno smiselnost. Z energijskega stališča to ustreza enačbi

$$W_{Sistema} = W_{Deformacij} - W_{Podobnosti}, \quad (2.2)$$


kjer je v primeru uporabe elastičnih lastnosti energija sistema $W_{Sistema}$ dejansko potencialna energija, ki jo želimo z omenjenim iterativnim procesom kolikor se le da zmanjšati.



Slika 2.2: Postopek elastične poravnave slik

2.2.1 Določanje zunanjih sil

Vsak vksel poravnane slike predstavlja notranje področje slike na katerega delujejo notranje in zunanje sile (slika 2.3). V splošnem so lahko notranja področja tudi večja od enega voksla, vendar pa se med seboj ne smejo prekrivati in morajo skupaj obsegati celotno sliko. Vsakemu od notranjih področij pripada zunanje področje slike, katerega dimenzije so načeloma lahko drugačne od dimenzij notranjih področij. Zunanja področja se lahko prekrivajo in ni nujno, da skupaj obsegajo celotno poravnano sliko.



Slika 2.3: Dvodimenzionalen primer delitve poravnane slike na notranja in zunanja področja.

Na osnovi zunanjih področij se določijo zunanje sile $\mathbf{f}(\mathbf{x})$, tako da so le te usmerjene v smer izboljšanja lokalnih podobnosti $S(\mathbf{u}(\mathbf{x}))$ med zunanjimi področji deformirane poravnane slike B' in istoležnimi področji referenčne slike A . Če poravnano sliko dodatno deformiramo, tako da se premik $\mathbf{u}(\mathbf{x})$ spremeni za majhen vektor $\delta\mathbf{u}$, se spremeni tudi poravnano sliko in ocenjena lokalna podobnost slik, ki je sedaj $S(\mathbf{u}(\mathbf{x}) + \delta\mathbf{u})$. Če želimo, da se pod vplivom zunanjih sil

poravnanoost slik izboljšša, morajo imeti zunanje sile $\mathbf{f}(\mathbf{x})$ smer tistega premika $\delta\mathbf{u}$, ki najbolj izboljšša podobnost $S(\mathbf{u}(\mathbf{x}) + \delta\mathbf{u})$. Sile morajo zato imeti smer gradienta ocenjene podobnosti $S(\mathbf{u}(\mathbf{x}))$. Velikost sil mora biti odvisna od pričakovanega izboljšanja lokalnega ujemanja slik. Majhne razlike med lokalnimi podobnostmi nastanejo predvsem zaradi prisotnosti šuma in zato ne smejo povzročiti velike deformacije, medtem ko so večje razlike dejansko posledica sprememb lokalne poravnanoosti slik. Velikost sil mora biti torej sorazmerna velikosti gradienta ocenjene podobnosti.

Zunanje sile so torej določene z gradientom podobnosti (2.3), iz česar je razvidno, da gre dejansko za gradientno metodo optimizacije lokalnega ujemanja slik.

$$\mathbf{f}(\mathbf{x}) = \nabla S(\mathbf{u}(\mathbf{x})) \quad (2.3)$$

Ker zunanje tudi sile delujejo na notranja področja poravnane slike, je zaželeno, da izhajajo iz ocenjenega ujemanja prav takšnih, oziroma njim čim bolj podobnih zunanjih področij. Ker so notranja področja ekstremno majhna, s čimer omogočimo dobro modeliranje fizikalnih lastnosti deformacij, morajo biti majhna tudi zunanja področja. Majhnost zunanjih področij pa je pomembna tudi zato, ker je le tako mogoče zanesljivo odkrivanje prostorsko majhnih slikovnih neskladij.

Poravnanoost zunanjih področij poravnane slike B' z referenčno sliko A ocenjujemo z merami podobnosti. Ker morajo biti zunanja področja majhna, morajo biti uporabljene mere podobnosti lokalne. Vendar pa je lokalnost sicer najprimernejših mer podobnosti, kot sta naprimer korelacijski koeficient ali medsebojna informacija (poglavje 3.), omejena. Z njimi ni mogoče primerjati ekstremno majhnih področij, velikosti enega voksla, ker za tako majhna področja sploh niso dobro definirane (pri korelacijskem koeficientu pride do deljenja z 0). Zato je potrebno uporabiti nekoliko večja zunanja področja (za korelacijski koeficient običajno velikosti $3 \times 3 \times 3$ voksle).

2.2.2 Prostorski modeli deformacij

Prostorski model deformacij predstavlja povezavo med zunanjimi silami in premiki notranjih področij, s katerimi je opisana deformacija poravnane slike. Kljub imenu elastična poravnava slik, modeli deformacij niso omejeni le na elastičnost, ampak je prav tako mogoče uporabiti tudi druge fizikalne ali namišljene lastnosti, ki sile povezujejo s premiki. Poleg elastičnosti je pogosto uporabljena viskoznost, pogoste pa so tudi njune poenostavitve [28–30].

Model elastičnosti

Fizikalno lastnost elastičnosti homogenega izotropnega togega telesa opisuje Navier-ova parcialna diferencialna enačba

$$\mu \nabla^2 \mathbf{u}(\mathbf{x}) + (\lambda + \mu) \nabla(\nabla^T \cdot \mathbf{u}(\mathbf{x})) + \mathbf{f}(\mathbf{x}) = 0, \quad (2.4)$$

kjer $\nabla^T \cdot \mathbf{u}(\mathbf{x}) = \sum \partial u_i(\mathbf{x}) / \partial x_i$ predstavlja prostorski raztezek, ∇^2 je Laplaceov operator, λ in μ pa sta Laméjeva koeficienta elastičnosti. Premiki se iz podanih zunanjih sil izračunajo z iterativnim postopkom, ki je podrobno opisan v [31]. Za modeliranje elastičnosti slik zadostuje le parameter μ , pri tem pa je vrednost λ lahko enaka nič. Pomen obeh parametrov je bolj razumljiv, če ju prevedemo v modul elastičnosti E in koeficient prečne deformacije σ , ki je razmerje med vzdolžnim raztežkom in prečnim skrčkom.

$$E = \frac{\mu(3\lambda + 2\mu)}{(\lambda + \mu)}, \quad \sigma = \frac{\lambda}{2(\lambda + \mu)} \quad (2.5)$$

Z izbiro $\lambda = 0$ je torej tudi $\sigma = 0$ kar pomeni, da raztezek v eni smeri ne povzroči prečnega krčenja. Približek elastičnih lastnosti je mogoče doseči tudi s poenostavljeno enačbo elastičnosti, ki ne upošteva stisljivosti materiala in prečnega krčenja pri nategu

$$\mu \nabla^2 \mathbf{u}(\mathbf{x}) + \mathbf{f}(\mathbf{x}) = 0. \quad (2.6)$$

Robni pogoji so običajno določeni s podanimi premiki robnih točk $\mathbf{u}(\mathbf{x})$, dobljenimi s predhodno togo poravnavo.

Diskretni model elastičnosti

Ker je poravnavana slika diskretnega značaja, je tudi elastičnost smiselno modelirati z diskretnim modelom. Diskretni model je lahko izpeljan iz zveznega modela z diskretizacijo Navier-ove enačbe, možna pa je tudi izpeljava diskretnega modela na osnovi elastičnih lastnosti posameznih vokslov, za katere lahko privzamemo, da se deformirajo homogeno. Postopek, ki ga predlagamo izhaja iz lastnosti natega in striga posameznih vokslov slike, hkrati pa ustreza poenostavljeni diskretizirani Navier-ovi enačbi.

Če upoštevamo, da je slika homogeno izotropno elastično telo, se glede na Hookov zakon pod vplivom zunanje sile $F(\mathbf{x})$ voksel slike z originalno pozicijo \mathbf{x} premakne na premik $\mathbf{u}'(\mathbf{x})$, tako da velja

$$\mathbf{u}'(\mathbf{x}) = \mathbf{u}(\mathbf{x}) + k_e \cdot \mathbf{f}(\mathbf{x}), \quad (2.7)$$

kjer konstanta k_e predstavlja elastične lastnosti materiala s katerim modeliramo deformacije. Tako dobljeni premiki pa niso v skladu z elastičnimi zakonitostmi,


saj ne upoštevajo odvisnosti med premiki posameznih vokslov slike. Položaj vsakega voksla namreč vpliva tudi na položaje vseh sosednjih vokslov, ki pa spet vplivajo na vse svoje sosede in tako vsak premik posameznega voksla vpliva na premike vseh ostalih vokslov slike. Vpliv sosednjih vokslov lahko modeliramo na osnovi nateznih in strižnih lastnosti materiala (slika 2.4), prečnega krčenja pri nategu in stisljivosti materiala pa ne upoštevamo.

Razteg zaradi zunanje sile Δl in premik l_1 zaradi strižne sile sta za elastično telo definirana na sledeč način

$$\Delta l = \frac{l\mathbf{f}}{ES} \quad , \quad l_1 = \frac{l\mathbf{f}}{GS} \quad . \quad (2.8)$$

Pri tem je \mathbf{f} zunanja sila, l prvotna dolžina, S ploščina prečnega prereza, E modul elastičnosti in G strižni modul. Parametra G in E sta povezana preko parametra μ , katerega vrednost se za realne material giblje med 0,1 in 0,5:

$$G = \frac{E}{2(1 + \mu)} \quad . \quad (2.9)$$




Slika 2.4: Razteg (levo) in strig (desno) elastičnega materiala.

Če privzamemo, da se voksli deformirajo homogeno, se posamezen voksel zaradi vpliva svojih sosedov premakne za tak \mathbf{u} , ki je uteženo povprečje premikov njegovih sosedov, ter lastnega premika zaradi zunanjih sil \mathbf{u}' :

$$\mathbf{u} = \frac{\sum k_n \mathbf{u}_n + \sum k_s \mathbf{u}_s + k_l \mathbf{u}'}{\sum k_n + \sum k_s + k_l} \quad (2.10)$$

kjer vsote tečejo po vseh sosednjih vokslih, k_n , k_s in k_l so koeficienti natega, striga in vztrajnosti lastnega premika, \mathbf{u}_n in \mathbf{u}_s pa sta natezna in strižna komponenta premikov sosednjih vokslov, kot prikazuje slika 2.5.

Zaradi posrednih odvisnosti med posameznimi voksli je potrebno iterativno računanje premikov u , tako da v vsaki iteraciji najprej upoštevamo vpliv sosednjih sil, potem pa upoštevamo medsebojno odvisnost vokslov, ki zagotovi fizikalno smiselnost transformacije.



Slika 2.5: Dvodimenzionalni primer premikov, ki vplivajo na končni položaj voksla.

Robni pogoji so lahko definirani tako, da rob slike predstavlja tudi rob materiala, s katerim je slika modelirana. V tem primeru se za robne točke spremeni le število sosedov, ki so upoštevani v enačbi 2.10. Takšni robni pogoji omogočajo ne le izboljševanje lokalnega ampak tudi globalnega ujemanja slik.

Inkrementalne deformacije

V doseženem ravnovesnem stanju elastičnega materiala so zunanje sile \mathbf{f} nasprotne notranjin silam, s katerimi se telo upira deformacijam. Če povezavo med premikom \mathbf{u} točke, na katero deluje zunanja sila F , opišemo s Hookovim zakonom $F = k \cdot \mathbf{u}$ je razvidno, da je za vsako deformacijo potrebna od nič različna zunanja sila, kar pa je indikator nepopolnega ujemanja slik. Z elastično poravnavo na osnovi Navier-ove enačbe se torej pravilni poravnavi lahko le približamo. Z večanjem prožnosti modela se napaka zmanjšuje, vendar pa vse dokler obstajajo medsebojne povezave med voksla, ni enaka nič.

Te napake je mogoče zmanjšati ali odpraviti z akumuliranjem deformacij, premikov ali sil doseženih v prejšnjih iteracijah poravnave. V primeru da akumuliramo dosežene deformacije, govorimo o inkrementalnih deformacijah [16]. V tem primeru vsaka iteracija poravnave izhaja iz slike, ki je rezultat prejšnje iteracije poravnave, pri tem pa so premiki $\mathbf{u}(\mathbf{x})$ spet enaki nič. Tako se v vsaki iteraciji elastična poravnava slik začne znova. Vsaka iteracija poravnave izboljša prileganje slik, zaradi česar so potrebni vedno manjši premiki \mathbf{u} . Končni rezultat deformacije pri tem nič več nujno ne ustreza uporabljenim parametrom elastičnosti.

V primeru predlaganega diskretnega modela gre za akumulacijo premikov \mathbf{u} , vendar pa se kljub temu elastične lastnosti z večanjem števila iteracij ne spreminjajo, saj pri upoštevanju medsebojnih zvez med premiki vedno upoštevamo celotne premike od začetnega nedeformiranega stanja.

Model viskoznosti

Problem nepopolne poravnave pri uporabi elastičnega modela deformacij rešuje model viskoznosti

$$\alpha \nabla^2 \mathbf{v}(\mathbf{x}, t) + (\alpha + \beta) \nabla(\nabla^T \cdot \mathbf{v}(\mathbf{x}, t)) + \mathbf{f}(\mathbf{x}) = 0. \quad (2.11)$$

Od modela elastičnosti se razlikuje le po tem, da so namesto premikov točk $\mathbf{u}(\mathbf{x})$ uporabljene njihove hitrosti $\mathbf{v}(\mathbf{x}, t)$, namesto parametrov elastičnosti μ in λ pa sta uporabljena parametra viskoznosti α in β . Premik $\mathbf{u}(\mathbf{x})$ nato izračunamo z integriranjem hitrosti $\mathbf{v}(\mathbf{x}, t)$ po času t . Model viskoznosti je zelo primeren tudi za velike deformacije slik, čeprav tak rezultat ne ustreza nujno realnim možnostim deformacij bioloških tkiv.

Konvolucijski filtri

Elastične lastnosti materiala lahko aproksimiramo s prostorskim filtriranjem premikov \mathbf{u} . Ta pristop zelo pohitri elastično poravnavo slik, saj se filtriranje izvede v enem samem koraku, medtem ko je sicer potrebnih več iteracij. Najenostavnejša aproksimacija elastičnosti je filtriranje z Gaussovimi filtrom. Širina filtra je obratno sorazmerna s prožnostjo elastičnega modela. Kljub enostavnosti se rezultati z uporabo Gaussovega filtra zelo približajo rezultatom elastičnih modelov [32]. Razlike se pokažejo predvsem pri velikih deformacijah in so posledica neupoštevanja stisljivosti materiala in prečnega krčenja pri nategu.

Prav tako lahko s filtriranjem aproksimiramo lastnost viskoznosti, le da gre v tem primeru za filtriranje hitrosti $\mathbf{v}(\mathbf{x}, t)$ [19], kjer je t čas, oziroma število iteracij.

Določitev parametrov modela deformacij

Namen uporabe elastičnih modelov je zagotovitev fizikalne smiselnosti transformacije, kar v prvi vrsti pomeni, da se slika ne sme trgati ali gubati.

V začetnih iteracijah poravnave slik so primernejši bolj togi modeli elastičnosti, s katerimi se zmanjša možnost napačne poravnave, do katere lahko pride zaradi lokalnih ekstremov ujemanja slik. Prav zato je pri elastični poravnavi pogosto zahtevana predhodna toga poravnava slik.

Za natančno poravnavo slik so primernejši bolj prožni modeli. Uporaba fizikalno nereálnih modelov, naprimer zelo prožnih ali viskoznih, povzroči boljše poravnavo robov slik, vendar pa s tem ni nujno zagotovljena tudi pravilna poravnava homogenih področij. Za doseg čim boljših rezultatov je zato potrebno postopno večanje prožnosti modela, s čimer dosežemo dobro poravnavo vseh področij slike.

2.3 Večmodalna poravnava

Poravnava slik različnih modalnosti je bolj zahteven problem, saj so v tem primeru relacije med svetlostnimi nivoji slik bolj kompleksne in običajno vnaprej nepoznane. Možna sta dva pristopa večmodalne poravnave:

- večmodalna poravnava z večmodalnimi merami podobnosti, kjer običajne mere, ki privzemajo linearno odvisnost med svetlostnimi nivoji slik nadomestimo z drugimi, bolj splošnimi merami podobnosti,
- večmodalna poravnava s svetlostno preslikavo, kjer eno od slik s pomočjo znane funkcije preslikave svetlosti preslikamo v ocenjeno sliko modalnosti druge slike. Tako dobljeno sliko se nato lahko poravna z običajnimi enomodalnimi merami podobnosti.

Oba pristopa sta podrobneje opisana v nadaljevanju.

2.3.1 Poravnava z večmodalnimi merami podobnosti

Zaradi kompleksne odvisnosti med svetlostnimi nivoji slik različnih modalnosti poravnava ne more temeljiti na klasičnih enomodalnih merah podobnosti, ki predpostavljajo linearno svetlostno odvisnost. Namesto njih se zato najpogosteje uporablja statistične mere, med katerimi je največkrat uporabljena medsebojna informacija. Te mere so pogosto uspešno uporabljene za večmodalno togo poravnavo slik [33, 34], za lokalno poravnavo pa so manj primerne, saj so zaradi svojega statističnega ozadja v osnovi globalne.

Odpravljanje lokalnih neskladij večmodalnih slik je zato pogosto izvedeno na osnovi globalnega merjenja podobnosti. Možna je uporaba globalnih parametričnih transformacij višjega reda [35], s katerimi pa ni mogoče odpraviti bolj kompleksnih neskladij, ki se ne podrejajo uporabljenemu modelu transformacij. Druga možnost je uporaba lokalne poravnave na osnovi globalnih mer podobnosti. V tem primeru se uspešnost vsake od lokalnih poravnav oceni na osnovi podobnosti celotnih slik [36]. Tak postopek omogoča odpravljanje poljubnih slikovnih neskladij, vendar pa je časovno zelo zahteven, saj je število potrebnih lokalnih poravnav lahko zelo veliko, pri tem pa vsak poskus lokalne poravnave zahteva ponovno ocenjevanje poravnivosti celotnih slik.

Lokalne večmodalne poravnave, ki delujejo na osnovi merjenja lokalnih podobnosti slik, zahtevajo modifikacijo večmodalnih mer, s čimer se izboljša statistična moč ocenjene verjetnostne porazdelitve svetlostnih nivojev slik [25, 37]. Vendar pa se tudi primernost teh metod z manjšanjem velikosti uporabljenih področij slik zmanjšuje.

Elastična poravnava slik zahteva ocenjevanje podobnosti izrazito majhnih področij slik, zato je njena večmodalna implementacija zelo zahtevna. Maintz je predlagal ocenjevanje lokalne podobnosti slik na osnovi globalne pogojne verjetnostne porazdelitve svetlostnih nivojev slik [27]. Ker pa pri poravnavi ni uporabljal prostorskega modela deformacij, ampak so mu omejitve predstavljala razmeroma velika zunanja področja slik, njegovega postopka ne moremo označiti kot pravo elastično poravnavo. Leventon je svojo večmodalno poravnavo [38] osnoval na *log likelihood* meri podobnosti, ki ima dobre lokalne lastnosti, ampak zahteva predhodno poznavanje verjetnostnih porazdelitev svetlostnih nivojev poravnanih slik, ki pa so v splošnem neznani. Za večmodalno elastično poravnavo je kot mero podobnosti mogoče uporabiti tudi lokalno korelacijo [39], vendar pa je ta mera občutljiva le na robove slik, zato je takšna poravnava omejena le na majhna slikovna neskladja, oziroma zahteva dobro predporavnano slik. Dober primer večmodalne elastične poravnave je delo Hate [40], ki temelji na oceni gradienta medsebojne informacije in na prostorskem modelu elastičnih deformacij.


2.3.2 Poravnava s svetlostno preslikavo

Uporaba svetlostne preslikave predstavlja alternativo pravi večmodalni poravnavi slik. To je postopek, ki omogoča, da na osnovi slike ene modalnosti ocenimo pripadajočo sliko druge, ciljne modalnosti. Na ta način večmodalni problem preslikamo v enomodalnega ter ga rešimo z običajnimi enomodalnimi postopki.


Svetlostna preslikava (REF) vsakemu svetlostnemu nivoju originalne slike, glede na funkcijo preslikave, priredi nov svetlostni nivo. Funkcija preslikave mora biti torej poznana vnaprej in določena tako, da vsak svetlostni nivo slike originalne modalnosti preslika v svetlostni nivo, ki ustreza istemu tkivu na sliki druge, ciljne modalnosti. (Slika 2.6).

Kljub enostavnosti postopka, se svetlostna preslikava za pretvorbo modalnosti v praksi le redkokdaj uporablja. Vzroka sta v glavnem dva. Prvi je v spolšnem neznana funkcija preslikave svetlosti, ki jo na osnovi neporavnanih slik ni enostavno avtomatsko oceniti. Drugi, bolj pomemben razlog pa je zelo kompleksna odvisnost med svetlostnimi nivoji slik različnih modalnosti. Tovrstna preslikava namreč običajno ni injektivna in posamezen svetlostni nivo slike ene modalnosti sovпада z več različnimi svetlostnimi nivoji slike druge modalnosti. Takšne odvisnosti se s svetlostno preslikavo ne da zajeti, zato je mogoče upoštevati le svetlostne nivoje pomembnejših tkiv. Svetlostni nivoji ostalih tkiv so torej ocenjeni napačno. Napake pa se pojavljajo tudi na mešanih vokslih, ki se nahajajo na prehodih med različnimi tipi tkiv (Slika 2.7).

Svetlostno preslikavo je možno razširiti z dodatno uporabo gradientne slike [41]. Zaradi napak pri oceni svetlosti delnih vokslov ta postopek ni primeren



Slika 2.6: Primer funkcije preslikave iz modalnosti MRI-PD v modalnost MRI-T1.



Slika 2.7: Svetlostna preslikava iz slike modalnosti MRI-PD (levo) v ocenjeno sliko modalnost MRI-T1 (v sredini). Za primerjavo je prikazana tudi originalna slika modalnosti MRI-T1 (desno).

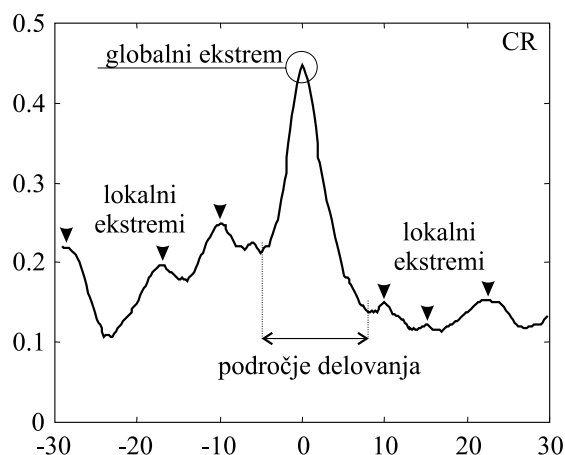
za natančno poravnavo slik. Primernejša je večmodalna poravnava slik z večmodalnimi merami podobnosti.

3. Mere podobnosti

Ocenjevanje podobnosti med poravnavano in referenčno sliko je bistven korak vsakega retrospektivnega postopka poravnave slik, ki temelji na celotni slikovni informaciji. Izbira mere podobnosti lahko usodno vpliva na rezultate poravnave, zato ji je smiselno posvetiti večjo pozornost. V literaturi je mogoče zaslediti veliko število različnih mer podobnosti [42–44], kar je posledica zelo različnih potreb. Izbira mere podobnosti je povezana z lastnostmi poravnanih slik, kot so modalnost, velikost, prisotnost svetlostnih nehomogenosti, svetlostno lezenje in podobno, po drugi strani pa tudi od postopka poravnave, kjer je pomembna lokalnost poravnave, prožnost prostorskega modela deformacij, uporabljena metoda optimizacije in tudi zahtevana točnost. Pomemben korak pri izbiri mere podobnosti je iskanje meje med slikovnimi razlikami, ki predstavljajo želeno slikovno informacijo, in tistimi razlikami, ki predstavljajo motnjo. Tako se lahko nadaljnja izbira omeji le na ožjo množico mer podobnosti, ki zadovoljijo zahteve po neobčutljivosti na motnje, hkrati pa upoštevajo čim več koristne informacije.

3.1 Pregled mer podobnosti

Naj bosta A in B referenčna in poravnavana slika, B' pa naj bo transformirana poravnavana slika B . S postopkom poravnave slik iščemo takšno transformacijo, ki povzroči najboljšo poravnavo med slikama A in B' . Pričakovano je, da funkcija podobnosti (slika 3.1), ki podaja odvisnost podobnosti od parametrov transformacije, doseže pri tej transformaciji globalni ekstrem. Poleg globalnega imajo funkcije podobnosti tudi lokalne ekstreme, ki ne ustrezajo pravilni poravnavi. Kateri ekstrem odkrijemo s postopkom poravnave je odvisno od začetnih parametrov transformacije. Področje parametrov, ki še vodi do pravilne poravnave slik imenujemo področje delovanja. Pregled najbolj uporabljenih mer podobnosti [42–46] je podan v nadaljevanju.



Slika 3.1: Funkcija podobnosti, ki podaja odvisnost korelacijskega koeficienta slik od njunega medsebojnega premika.

3.1.1 Enomodalne mere podobnosti

Enomodalne mere podobnosti so namenjene ocenjevanju poravnosti slik, ki so zajete z enakim slikovnim postopkom. Privzemajo linearno odvisnost med svetlostnimi nivoji slik in dopuščajo kvečjemu razlike v kontrastu in svetlosti slik.

Korelacijski koeficient

Korelacijski koeficient (CR) (angl. *correlation ratio*) [42] je ena najpogosteje uporabljenih mer podobnosti. Izhaja iz teorije obdelave signalov in podaja funkcijsko odvisnost med slikama. Je neobčutljiva na razlike v svetlosti in kontrastu slik, zato je primerna za večino enomodalnih slikovnih poravnav. Njena slabost je nekoliko večja računska in posledično tudi časovna zahtevnost. Izračunamo jo po sledeči enačbi:

$$CR = \frac{\sum_{\mathbf{x}} (A(\mathbf{x}) - \bar{A})(B'(\mathbf{x}) - \bar{B}')}{\sqrt{\sum_{\mathbf{x}} (A(\mathbf{x}) - \bar{A})^2 \sum_{\mathbf{x}} (B'(\mathbf{x}) - \bar{B}')^2}}, \quad (3.1)$$

kjer \bar{A} in \bar{B}' predstavljata povprečni svetlosti slik A in B' . Identični sliki imata CR enak ena, sicer pa je vrednost manjša.

Povprečna absolutna razlika

Povprečna absolutna razlika (MAD) (angl. *mean absolute difference*) [44] je zelo enostavna mera podobnosti, časovno nezahtevna in zato je tudi pogosto uporabljena. Primerna je le, če sta sliki enako svetli in enako kontrastni.

$$MAD = \frac{1}{N} \sum_{\mathbf{x}} |A(\mathbf{x}) - B'(\mathbf{x})| \quad (3.2)$$

N predstavlja celotno število slikovnih elementov uporabljenih pri izračunu podobnosti. Identični sliki imata MAD enak nič, sicer pa je vrednost večja od nič.

Povprečje kvadratov razlik

Povprečje kvadratov razlik (MSD) (angl. *mean square difference*) [44] je zelo podobna meri MAD. Edina razlika je v uporabljeni nelinearnosti, kjer absolutno vrednost nadomešča kvadriranje

$$MSD = \frac{1}{N} \sum_{\mathbf{x}} (A(\mathbf{x}) - B'(\mathbf{x}))^2 \quad (3.3)$$

Tudi ta mera je primerna le za slike z enako svetlostjo in kontrastom. Identični sliki imata MAD enak 0, sicer pa je vrednost večja od nič.

Standardna deviacija slike razlik

Standardna deviacija slike razlik (SDI) (angl. *standard deviation of image difference*) [12] ocenjuje razpršenost odstopanj svetlosti istoležnih slikovnih elementov.

$$SDI = \sqrt{\frac{1}{N} \sum_{\mathbf{x}} (A(\mathbf{x}) - B'(\mathbf{x}) - \overline{A - B'})^2} \quad (3.4)$$

Pri tem $\overline{A - B'}$ predstavlja povprečno vrednost svetlosti slike razlik. SDI je občutljiva na razlike v kontrastu slik, ni pa občutljiva na razlike v svetlosti. Identični sliki imata SDI enak nič.

Standardna deviacija histograma slike razlik


Standardna deviacija histograma slike razlik (SDH) (angl. *standard deviation of difference image histogram*) [12] je ekvivalentna meri SDI. Razlika je le v postopku izračuna

$$SDH = \sqrt{\sum_{i=-i_{max}}^{i_{max}} i^2 N_i(A - B)}, \quad (3.5)$$

kjer $N_i(A - B)$ predstavlja število parov istoležnih slikovnih elementov z razliko med svetlostnima nivojema slik i . SDH je računsko je manj zahtevna mera od mere SDI.

Deterministična sprememba predznaka

Deterministična sprememba predznaka (DSC) (angl. *deterministic sign change*) [12] je mera podobnosti, ki govori o številu sprememb predznaka slike razlik, ki ji je prištet dodatni periodični vzorec s periodo 2 in amplitudo p . Tako DSC dejansko predstavlja delež istoležnih elementov slik za katere je razlika svetlostnih nivojev manjša od p . Kaže torej kolikšen delež slike se na histogramu slike razlik nahaja na področju $-p$ do p (slika 3.2). Mera je občutljiva na razlike v svetlosti in kontrastu slik.




Slika 3.2: Histogram slike razlik (označeno področje širine $2p$ predstavlja podobne slikovne elemente pri DSC meri podobnosti)

3.1.2 Večmodalne mere podobnosti

Večmodalne mere podobnosti omogočajo ocenjevanje medsebojnega ujemanja slik zajetih z različnimi slikovnimi postopki. Takšne mere podobnosti torej niso občutljive na razlike v svetlosti in kontrastu slik, temveč dopuščajo povsem poljubne medsebojne relacije med svetlostnimi nivoji slik. Isti tip tkiva je na slikah različnih modalnosti namreč predstavljen z različnimi svetlostnimi nivoji. Zapletene relacije med svetlostnimi nivoji slik različnih modalnosti je mogoče statistično oceniti z vezanim histogramom svetlostnih nivojev (Slika 3.3). Če vsoto vseh vrednosti vezanega histograma normiramo na vrednost ena, dobimo ocenjeno vezano verjetnostno porazdelitev $p(\mathbf{i}) = p(i_A, i'_B)$. Za večmodalne mere podobnosti sta pomembni tudi lastni verjetnostni porazdelitvi svetlostnih nivojev posameznih slik $p_A(i)$ in $p_{B'}(i) = p_B(i)$ (Slika 3.4), ki jih lahko izračunamo iz

vezane porazdelitve z enostavnim seštevanjem:

$$p_A(i) = \sum_{i_A} p(\mathbf{i}), \quad p_B(i) = \sum_{i_B} p(\mathbf{i}). \quad (3.6)$$



Slika 3.3: Vezan histogram svetlostnih nivojev za sintetični sliki MRI-T1 in MRI-PD.


Medsebojna informacija

Medsebojna informacija (MI) (angl. *mutual information*) [43] je trenutno najpogosteje uporabljena večmodalna mera podobnosti. Izhaja iz teorije informacij, za uporabo področju obdelave medicinskih slik pa sta jo predlagala Viola in Wells leta 1995 [47, 48]. To je statistična mera podobnosti in ocenjuje statistično odvisnost med svetlostnimi nivoji obeh slik. Na ta način podaja oceno, koliko ena slika pove o drugi sliki in zavzame največjo vrednost, ko sta sliki geometrijsko poravnani. Medsebojno informacijo lahko izračunamo na sledeč način:

$$MI = H(A) + H(B') - H(A, B'), \quad (3.7)$$

kjer sta $H(A)$ in $H(B')$ lastni entropiji slik, $H(A, B')$ pa je njuna vezana entropija [49]. Entropije lahko izračunamo po Shannon-ovi formuli:

$$H = \sum p(\cdot) \log p(\cdot), \quad (3.8)$$



Slika 3.4: Verjetnostne porazdelitve svetlostnih nivojev slik.

kjer $p(\cdot)$ predstavlja lastno ali vezano verjetnost svetlostnih nivojev, vsota pa teče po vseh možnih svetlostnih nivojih oziroma svetlostnih parih. Limitna vrednost funkcije $p(\cdot) \log p(\cdot)$ za $p(\cdot) = 0$ je nič.

Normirana medsebojna informacija

Normirana medsebojna informacija (NMI) (angl. *normalized mutual information*) [50] se od MI razlikuje le po relaciji med lastnima in vezano entropijo:

$$NMI = \frac{H(A) + H(B')}{H(A, B')} . \quad (3.9)$$

Ta razlika povzroči manjšo odvisnost mere podobnosti od stopnje prekrivanja slik. Če se stopnja prekrivanja slik bistveno ne spreminja, je ta mera enakovredna medsebojni informaciji MI. V literaturi je pod imenom normirana medsebojna informacija mogoče zaslediti še eno izpeljanko medsebojne informacije [43], ki pa je redkeje uporabljena:

$$NMI' = \frac{2(H(A) + H(B') - H(A, B'))}{H(A) + H(B')} = \frac{2 \cdot MI}{H(A) + H(B')} . \quad (3.10)$$

Vezana entropija slik

Vezana entropija slik $H(A, B')$ (angl. *joint entropy*) [43] je najpomembnejši člen medsebojne informacije in je tudi samostojno lahko uporabljena kot večmodalna mera podobnosti. Ker ne upošteva sprememb lastnih entropij $H(A)$ in $H(B')$ je računsko manj zahtevna, a tudi bolj občutljiva na spremembe lastnih verjetnostnih porazdelitev svetlostnih nivojev slik, do katerih lahko pride zaradi sprememb pri prekrivanju slik ali zaradi interpolacije. Vendar pa je vezana entropija v primeru majhnih sprememb prekrivanja slik in pri uporabi verjetnostne interpolacije (PVI) (angl. *partial volume interpolation*) enakovredna medsebojni informaciji. Sliki se smatrata za poravnani, ko vezana entropija doseže minimum.

Entropija slike razlik

Entropija slike razlik $H(A-B')$ (angl. *entropy of image difference*) [51] je mera podobnosti, ki temelji na enodimenzionalni statistiki. Zato je statistično vedno boljše določena kot mere MI, NMI, in $H(A, B')$, ki temeljijo na dvodimenzionalni statistiki. Njena slabost je nezmožnost ločevanja med svetlostnimi pari z enako medsebojno razliko svetlosti, zaradi česar je globalni ekstrem funkcije podobnosti manj izrazit. Primerna je predvsem za začetne iteracije poravnave slik, saj je zanjo značilno široko področje delovanja. Boljša poravnava ustreza manjši vrednosti entropije.

3.2 Merjenje podobnosti in merjenje kvalitete poravnave

Mere podobnosti v postopku poravnave slik uporabljamo za merjenje poravnave slik, oziroma ustreznosti predlagane transformacije poravnave slike. Vendar pa poravnave slike pri dani transformaciji ne moremo neposredno primerjati z referenčno sliko. Obe sliki sta namreč diskretni in položaj točk s podano vrednostjo svetlosti se po transformaciji običajno ne ujema. Za ocenjevanje podobnosti je zato potrebna interpolacija slik.

Ko slike uspemo primerjati, se je potrebno zavedati, da boljša ocenjena podobnost slik še ne pomeni nujno tudi boljše medsebojne poravnave slik. Lokalni ekstremi funkcij podobnosti ovirajo poravnavo slik in so lahko vzrok za slabe rezultate poravnave.


Za čim boljše ocenjevanje ujemanja slik morajo mere podobnosti upoštevati čim več koristne in čim manj motilne slikovne informacije. Pri danih pogojih poravnave se je smiselno vprašati ali je koristne informacije dovolj za zanesljivo ocenjevanje podobnosti slik. Premajhna količina upoštevane koristne informacije je lahko ovira pri merjenju lokalnih podobnosti slik. Mere podobnosti, ki so

sposobne primerjanja izrazito majhnih področij slik, imenujemo lokalne mere podobnosti.

Omenjeni problemi in nekatere njihove možne rešitve so podrobneje opisane v nadaljevanju.

3.2.1 Interpolacija slik

Sliki A in B imata svetlost določeno le v točkah, ki ležijo na mrežasti strukturi vokslov. S transformacijo slike B v B' se položaj teh točk premakne, tako da se v splošnem nič več ne ujema s položajem podanih točk slike A . Vrednosti med podanimi točkami slik niso znane, ker pa jih potrebujemo za izračun podobnosti slik, lahko njihovo vrednost ocenimo s postopki interpolacije.



Slika 3.5: Dvodimenzionalni primer položaja podanih točk slik A in B' .

Interpolacija ničtega reda


Interpolacija ničtega reda (angl. *nearest neighbour interpolation*) [33] je najenostavnejša metoda interpolacije. Točki slike z nedoločeno vrednostjo svetlosti priredi tisto vrednost i_I , ki jo ima njej najbližja podana točka (slika 3.6)

$$i_I = \arg \min_{i_n} d(i_I, i_n). \quad (3.11)$$

Na ta način se celotnim področjem velikosti enega voksla priredi ista vrednost svetlosti. Na ta način torej ne moremo zagotoviti ločljivosti, ki bi bila manjša od velikosti voksla (angl. *subvoxel accuracy*).

Linearna interpolacija

Linearna interpolacija [52] je interpolacija prvega reda. Glede na razsežnost slik se uporablja bilinearna (2D) oziroma trilinearna (3D) interpolacija. Svetlostna




Slika 3.6: Ilustracija dvodimenzionalne interpolacije ničtega reda.

vrednost i_I v iskani točki se izračuna kot uteženo povprečje vseh sosednjih točk s podano svetlostjo

$$i_I = \sum_m w_m i_m \quad ; \quad \sum_n w_m = 1. \quad (3.12)$$

Uteži w_n predstavljajo ploščino (2D) oziroma prostornino (3D) področij, kot je prikazano na sliki 3.7. Linearna interpolacija ustvari nove svetlostne vrednosti,



Slika 3.7: Ilustracija bilinearne interpolacije.

ki na originalni sliki niso prisotne. To povzroči bistvene spremembe lastne verjetnostne porazdelitve svetlostnih nivojev interpolirane slike, prav tako pa povzročata nepredvidljive spremembe vezane verjetnostne porazdelitve slik. Zato uporaba linearne interpolacije pri uporabi statističnih mer podobnosti (MI, NMI, H) ni priporočljiva. Bolje je uporabiti verjetnostno interpolacijo.

Verjetnostna interpolacija


Rezultat verjetnostne interpolacije (PVI) (angl. *partial volume interpolation*) [53] ni svetlostna vrednost iskane točke, oziroma na ta način izračunana interpolirana slika, ampak svetlostna vezana verjetnostna porazdelitev slik

$$p(\mathbf{i}) = p(i_A, i_{B'}) = \frac{1}{N} \sum_{n=1}^N \sum_m w_{n,m} \delta(i_m, i_{n,B'}) \quad ; \quad \sum_m w_{n,m} = 1. \quad (3.13)$$

Pri tem i_A in $i_{B'}$ predstavljata svetlostne nivoje slik A in B' , $i_{n,B'}$ je svetlostna vrednost n -tega voksla slike B' , N je število vseh upoštevanih vokslov slike,

parameter m pa za vsak voksel slike B' teče po vseh njegovih sosedih na sliki A . Uteži $w_{n,m}$ voksla n so določene enako kot uteži w_m pri linearni interpolaciji (slika 3.7). Funkcija $\delta(i_m, i_{n,B'})$ je diskreten dvodimenzionalen premaknjen Diracov impulz in ima vrednost ena v točki $(i_m, i_{B'})$, sicer pa ima vrednost nič.

Verjetnostna interpolacija se torej od linearne interpolacije razlikuje po tem, da uteži $w_{n,m}$ za nek voksel n niso uporabljene za izračun nove svetlostne vrednosti, ki bi prispevala le k vezani verjetnosti enega svetlostnega para (za delež $1/N$), ampak se ta delež razporedi med več svetlostnimi pari skladno z utežmi $w_{n,m}$ (slika 3.8).



Slika 3.8: Primerjava vpliva linearne in verjetnostne (PVI) interpolacije enodimenzionalnih podatkov (levo) na vezano verjetnostno porazdelitev svetlostnih nivojev (desno).

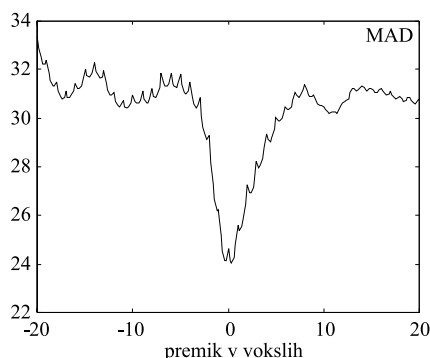
3.2.2 Lokalni ekstremi

Lokalni ekstremi funkcije podobnosti (slika 3.1) otežujejo proces poravnave slik in so lahko vzrok za slabe ali celo povsem napačne rezultate poravnave. Vzroka za pojavljanje lokalnih ekstremov sta dva (slika 3.9):

- medsebojna podobnost različnih področij iste slike,
- vpliv interpolacije, ki se kaže kot periodična funkcija s periodo enega voksla in je superponirana funkciji podobnosti.

Lokalni ekstremi, ki so posledica podobnosti med področji iste slike

Zaradi podobnosti med različnimi področji iste slike se boljša podobnost slik pojavi pri več različnih transformacijah poravnane slike. Tovrstne lokalne




Slika 3.9: Funkcija podobnosti MAD v odvisnosti od medsebojnega premika slik, z izrazitimi lokalnimi ekstremi. Lokalni ekstremi, ki so posledica interpolacije se pojavljajo periodično s periodo enega voksla.

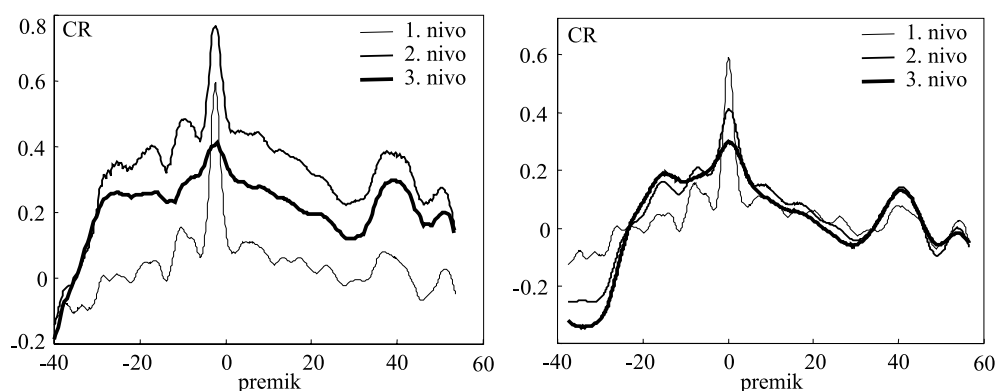
ekstreme je mogoče zmanjšati ali celo odpraviti s postopno večnivojsko poravnavo. V ta namen je potrebno s piramidnimi ali skalirnimi postopki [54–56] zmanjšati informacijo slik, s čimer iz originalnih slik odstranimo podrobnosti, ki so glavni vir lokalnih ekstremov (slika 3.10). Z odstranjanjem podrobnosti slik postaja funkcija podobnosti bolj gladka, vsebuje vse manj lokalnih ekstremov, hkrati pa postaja manj izrazit tudi globalni ekstrem, s čimer se zmanjšuje natančnost poravnave (slika 3.11). S postopno poravnavo (slika 3.12), ki v začetnih iteracijah temelji na grobih slikah z malo detajli, nadaljuje na vse bolj informacijsko bogatih slikah in konča s poravnavo originalnih slik, se je torej mogoče izogniti večini lokalnih ekstremov brez zmanjšanja natančnosti poravnave.

Lokalni ekstremi, ki so posledica interpolacije

Zaradi interpolacije slik vsebujejo funkcije podobnosti napako, ki je glede na medsebojni premik slik periodična s periodo velikosti enega slikovnega elementa [52]. Ta pojav je najbolj izrazit, ko je velikost slikovnih elementov na obeh slikah enaka in je medsebojni zasuk slik enak nič. S postopkom interpolacije namreč svetlost v poljubni točki določimo kot uteženo povprečje svetlosti sosednjih točk z znano vrednostjo, kar pa je pravzaprav filtriranje. Uteži točk so odvisne od vrste interpolacije in od položaja točke, kar pomeni, da se s spreminjanjem položaja spreminja stopnja filtriranja. Filtriranje je najbolj izrazito v primeru, ko so vse uteži enake, to je takrat, ko se interpolirana točka nahaja točno v sredini med podanimi točkami. Ko se interpolirana točka približuje eni od teh točk, se stopnja filtriranja manjša in je enaka nič, ko sta točki istoležni. Tako kot na funkcijo podobnosti vpliva filtriranje, vpliva tudi interpolacija, le da se njen vpliv spreminja s parametri uporabljene transformacije.

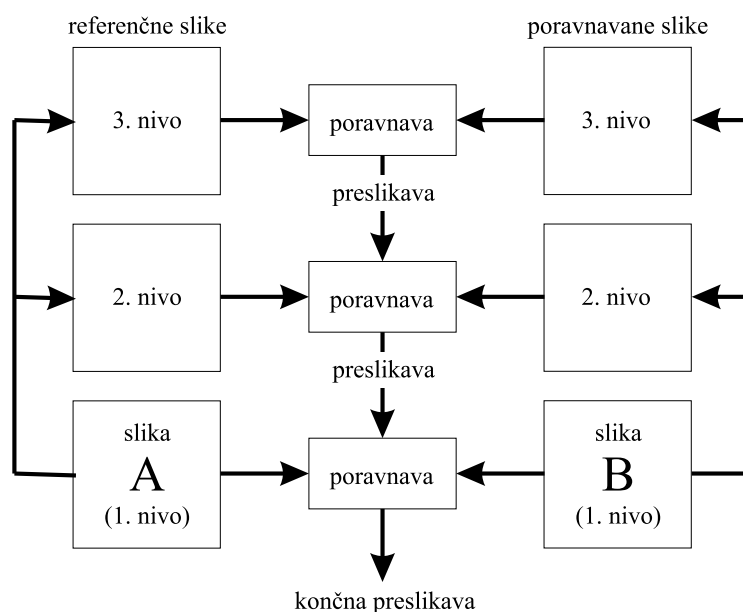


Slika 3.10: Piramidno podvzorčenje (zgoraj) in linearno skaliranje (spodaj). Prvi nivo (levo) ustreza originalni sliki, slike višjih nivojev pa vsebujejo vse manj podrobnosti.



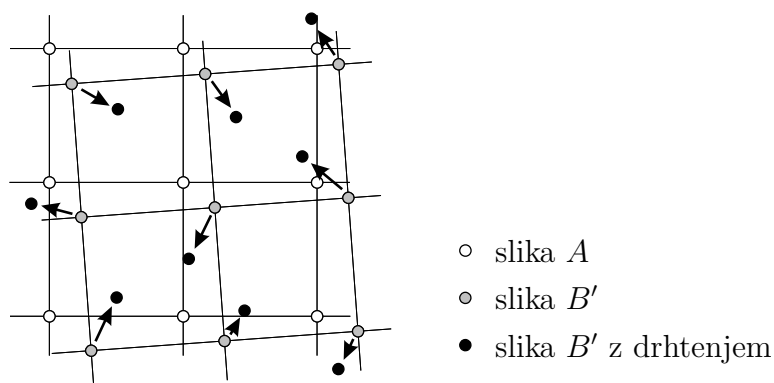
Slika 3.11: Odpravljanje lokalnih ekstremov s podvzorčenjem (levo) in s skaliranjem (desno).

Napake interpolacije najenostavneje zmanjšamo s predhodnim filtriranjem interpolirane slike (slika 3.14). Celotno filtriranje (predhodno filtriranje + interpolacija) je zato bolj enakomerno in vpliv interpolacije je zato manjši. Vendar pa filtriranje povzroči tudi zmanjšanje izrazitosti globalnega ekstrema, s čimer se zmanjša tudi točnost poravnave. Druga možnost odpravljanja interpolacijskih napak je uporaba drhtenja. Drhtenje premakne vsako interpolirano točko za nek naključen premik od njene prave lege (slika 3.13). Velikost premika se mora podrejati enakomerni porazdelitvi na področju od nič do polovice velikosti slikovnega elementa. S tem postane povprečna vrednost napak interpolacije statistično neodvisna od uporabljene transformacije poravnane slike. Ker je



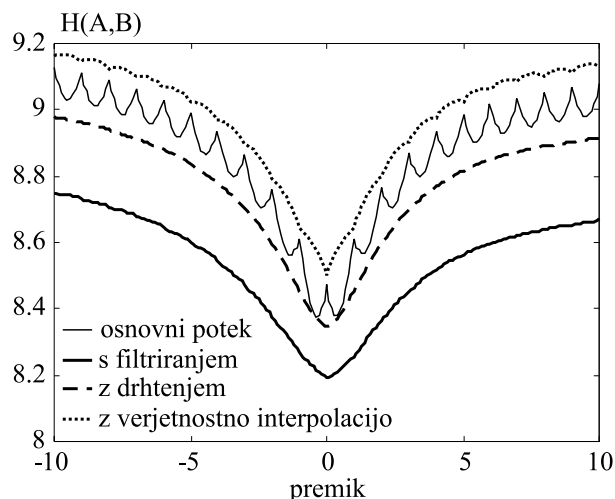
Slika 3.12: Shematski prikaz večnivojske poravnave. Poravnava se začne na najvišjem nivoju, kjer slike vsebujejo najmanj podrobnosti in ima funkcija podobnosti najmanj lokalnih ekstremov ter se konča na prvem nivoju, s poravnavo originalnih slik, ki omogoča natančno poravnavo.

pričakovana srednja vrednost naključnih premikov enaka nič, omenjen postopek ne povzroči nobene sistematske napake poravnave slik. Če je število slikovnih elementov slike majhno, je srednja vrednost premikov točk od nič različna, kar povzroči napako poravnave. Drhtenje torej ni primerno za odpravljanje interpolacijskih napak pri lokalni poravnavi, kjer so poravnavana področja majhna.



Slika 3.13: Ilustracija drhtenja kot metode za odpravljanje napak interpolacije.

Verjetnostna interpolacija ne izračunava svetlostne vrednosti interpoliranih točk in se ne odraža kot filtriranje. Interpolacijska napaka je kljub temu prisotna, izhaja pa iz sprememb medsebojnega prekrivanja slik ter nelinearnosti mer podobnosti [52]. Velikost interpolacijske napake je odvisna od statistične moči ocenjene vezane verjetnostne porazdelitve in se torej manjša z velikostjo uporabljenih slik. Interpolacijska napaka verjetnostne interpolacije je pogosto manjša od napake ostalih interpolacijskih postopkov.



Slika 3.14: Primer rezultatov različnih metod za dpravljanje napak interpolacije.

3.2.3 Lokalnost mer podobnosti

Lokalnost mer podobnosti je pomembna takrat, kadar je potrebno ocenjevanje lokalnega ujemanja slik na nekem manjšem področju. Lastnost lokalnosti mer podobnosti je povezana z dopuščenimi razlikami med slikama. V primeru enomodalnih mer podobnosti, lokalnost praviloma ni problematična, saj zaradi največ dveh neznanih parametrov funkcije svetlostne odvisnosti slik (razliki svetlosti in kontrasta) za grobo oceno podobnosti zadoščajo že samo trije svetlostni pari slikovnih elementov slik. Za enomodalne mere podobnosti, ki so občutljive na spremembo svetlosti in kontrasta (MAD, MSD) zadostujejo celo že posamezni svetlostni pari. Povsem drugače je pri večmodalnih merah podobnosti. Zaradi potrebe po ocenjevanju poljubne svetlostne odvisnosti slik, ki je običajno opisana z vezano verjetnostno porazdelitvijo, so te mere globalne in ne omogočajo ocenjevanja lokalnih lastnosti slik.

Lokalne lastnosti večmodalnih mer podobnosti je mogoče izboljšati z različnimi postopki. Najosnovnejši je zmanjšanje svetlostne ločljivosti slik, s čimer izboljšamo statistično določenost ocenjene vezane verjetnostne

porazdelitve. Podobno lahko statistično določenost izboljšamo s filtriranjem vezane porazdelitve z nizkoprepustnim filtrom, pri čemer je dobljen rezultat enak vezani porazdelitvi ocenjeni s Parzenovim postopkom [38]. Lokalnost je možno izboljšati tudi z uporabo predhodnega znanja o vezani porazdelitvi [25]. Tako je uporabljena porazdelitev določena kot uteženo povprečje porazdelitve ocenjene s slik in porazdelitve, ki je podana vnaprej. Če upoštevamo le vnaprej podano verjetnostno porazdelitev govorimo o *likelihood* merah podobnosti [38, 57].

Lokalne lastnosti mer podobnosti je mogoče zagotoviti, če predpostavimo globalno svetlostno odvisnost slik. To odvisnost torej ocenimo iz celotnih slik ter jo uporabimo za določitev podobnosti posameznih področij. Zaradi vnaprej določene svetlostne odvisnosti so ta področja lahko poljubno majhna in je podobnost mogoče določiti za vsak posamezen svetlostni par. Na tej osnovi smo izpeljali družino lokalnih večmodalnih mer podobnosti, ki je predstavljena v nadaljevanju.

3.3 Lokalne večmodalne mere podobnosti

Elastična poravnava zahteva uporabo mer podobnosti, ki so sposobne ocenjevanja kvalitete poravnave za čim manjša zunanja področja slik. Z manjšanjem zunanjih področij se manjša tudi vpliv merjenja podobnosti na deformabilne lastnosti slik, za katere hočemo, da so v pristojnosti prostorskega modela deformacij. Da merjenje podobnosti ne vpliva na deformabilne lastnosti slik morajo biti zunanja področja ekstremno majhna, velikosti enega voksla. Potrebujemo torej lokalno mero podobnosti, ki omogoča ocenjevanje posameznih svetlostnih parov slik.


Večmodalne mere podobnosti so zaradi svojega statističnega ozadja globalne in v osnovi niso primerne za ocenjevanje lokalnih lastnosti slik. Če predpostavimo, da je svetlostna odvisnost slik globalna, torej neodvisna od položaja področja na sliki, lahko večmodalne mere podobnosti priredimo za določanje lokalne podobnosti slik [51].

Naša osnova za izpeljavo lokalne večmodalne mere podobnosti je vezana entropija slik $H(A, B')$. Čeprav je to manj priznana mera podobnosti od medsebojne informacije $MI(A, B')$, pa ob uporabi verjetnostne interpolacije in pogoju, da se stopnja prekrivanja slik med poravnavo ne spreminja, dasta obe meri enakovredno oceno medsebojnega ujemanja slik (slika 3.15).

3.3.1 Izpeljava lokalne večmodalne mere podobnosti

Vezano verjetnostno porazdelitev $p(\mathbf{i})$ lahko ocenimo z normiranjem vezanega histograma slik

$$p(\mathbf{i}) = \frac{N(\mathbf{i})}{N} \quad ; \quad \mathbf{i} = (i_A, i_{B'}) \quad (3.14)$$



Slika 3.15: Primerjava medsebojne informacije (levo) in vezane entropije (desno) pri uporabi verjetnostne interpolacije.

kjer je \mathbf{i} svetlostni par $(i_A, i_{B'})$ ter i_A in $i_{B'}$ istoležni svetlosti referenčne in transformirane poravnane slike, $N(\mathbf{i})$ je število pojavov svetlostnega para \mathbf{i} in N je skupno število pojavov vseh svetlostnih parov, običajno enako številu vokslov slik. Vezano entropijo, računano po Shannonu (3.8), lahko torej izračunamo na sledeč način,

$$H = - \sum_{\mathbf{i}} p(\mathbf{i}) \log p(\mathbf{i}) = - \sum_{\mathbf{i}} \frac{N(\mathbf{i})}{N} \log p(\mathbf{i}). \quad (3.15)$$

Če sliki razdelimo na manjša neprekrivajoča se področja R_r , kjer vsako vsebuje $N_r(\mathbf{i})$ pojavov svetlostnega para \mathbf{i} , tako da je

$$N(\mathbf{i}) = \sum_r N_r(\mathbf{i}), \quad (3.16)$$

in to upoštevamo v enačbi (3.15), dobimo

$$H = - \sum_r \sum_{\mathbf{i}} \frac{N_r(\mathbf{i})}{N} \log p(\mathbf{i}). \quad (3.17)$$

Če sliki razdelimo tako, da vsako področje R_r zavzema le en voksel v , velja

$$N_r(\mathbf{i}) = N_v(\mathbf{i}) = \begin{cases} 1 & ; \quad \mathbf{i} = \mathbf{i}(v) \\ 0 & ; \quad \text{sicer} \end{cases}, \quad (3.18)$$

pri čemer je $\mathbf{i}(v)$ svetlostni par, ki se nahaja na položaju voksla v . Enačbo (3.17) lahko torej poenostavimo,

$$H = - \sum_v \frac{1}{N} \log p(\mathbf{i}(v)) = \frac{1}{N} \sum_v h(v), \quad (3.19)$$

kjer je $h(v) = -\log p(\mathbf{i}(v))$ nedoločenost svetlostnega para, ki se nahaja na položaju voksla v . Vezano entropijo, ki je globalna večmodalna mera podobnosti, lahko torej izračunamo kot prostorsko povprečje lokalnih lastnosti $h(v)$, ki torej predstavljajo lokalno podobnost slik S_v za vsak voksel v

$$S_v = h(v) = -\log p(\mathbf{i}(v)). \quad (3.20)$$

Z dobljeno lokalno večmodalno mero podobnosti lahko torej določimo podobnost poljubne točke slik in jo zato imenujemo točkovna mera podobnosti. Seveda lahko izračunamo tudi povprečje točkovnih podobnosti vokslav za poljubno področje slik R_r in rezultat je lokalna podobnost tega področja S_r .

$$S_r = \frac{1}{N_r} \sum_{v \in R_r} S_v. \quad (3.21)$$

Potrebno je opozoriti, da je vezana verjetnostna porazdelitev $p(\mathbf{i})$ in torej tudi točkovna podobnost $S_v = h(v)$ še vedno določena na osnovi celotnih slik.

3.3.2 Posplošitev lokalne večmodalne mere podobnosti

Iz enačbe (3.19) je razvidna velika podobnost z *log likelihood* mero podobnosti [38]. Edina razlika med obema merama je v uporabljeni verjetnostni porazdelitvi $p(\mathbf{i})$, ki je v našem primeru izračunana iz poravnanih slik, medtem ko mora biti sicer znana in podana vnaprej. V splošnem vezana porazdelitev vnaprej ni poznana, lahko pa je ocenjena iz drugih, predhodno poravnanih slik. V začetnih iteracijah poravnave podobnost izračunana z uporabo predhodnega znanja bolje opisuje dejansko kvaliteto poravnave, saj vezana porazdelitev, ocenjena iz poravnanih slik, zaradi slabe začetne poravnave slabo opisuje odvisnost med svetlostnimi nivoji slik. Nasprotno pa v končnih iteracijah poravnave porazdelitev ocenjena iz poravnanih slik v splošnem bolje opisuje dejanske razmere kot porazdelitev, ki je podana vnaprej. Zato je v primeru predhodnega poznavanja porazdelitve smiselno uporabiti uteženo vsoto obeh [58],

$$p(\mathbf{i}) = (1 - \lambda) \cdot p_{slike}(\mathbf{i}) + \lambda \cdot p_{podana}(\mathbf{i}) \quad ; \quad \lambda \in [0, 1], \quad (3.22)$$

kjer je $p_{slike}(\mathbf{i})$ porazdelitev ocenjena iz poravnanih slik, $p_{podana}(\mathbf{i})$ porazdelitev podana vnaprej kot predhodno znanje, λ pa je utež, ki naj bo v začetnih iteracijah poravnave enaka ena, potem pa naj se postopno zmanjšuje, dokler ni v končnih iteracijah poravnave enaka nič.

Ker postopek elastične poravnave teži k temu, da vsak voksel slike B' premakne v smeri največjega povečanja lokalne/točkovne mere podobnosti, je vezano verjetnost $p(\mathbf{i}) = p(i_A, i_{B'})$ smiselno zamenjati s pogojno verjetnostjo

$$p(i_A | i_{B'}) = \frac{p(i_A, i_{B'})}{p(i_B)} = \frac{p(i_A, i_{B'})}{\sum_{j=i_{min}}^{i_{max}} p(j, i_{B'})}. \quad (3.23)$$

Svetlost premikanih vokslov slike B' je namreč znana in se s premikom ne spreminja, zato vezana verjetnost bolje opisuje pričakovano izboljšanje ujemanja slik [27]. Seveda je možno uporabiti tudi druge vrste verjetnosti, naprimer verjetnost svetlostnih nivojev slike razlik $p(i_A - i_{B'})$, ki ima boljšo statistično moč.

Zadnja možna posplošitev omogoča zamenjavo logaritemske funkcije $S_v = \log(p)$ z drugimi funkcijami z določenimi lastnostmi. Primerna je vsaka funkcija $S_v = f(p)$, za katero je prvi odvod produkta $p \cdot f(p)$ striktno monotono naraščajoč ali striktno monotono padajoč. Če je naraščajoč, predstavlja večja izračunana vrednost podobnosti boljšo poravnanost slik in obratno, če je odvod padajoča funkcija, je boljša poravnanost slik predstavljena z manjšo vrednostjo podobnosti. Poleg logaritemske funkcije se pogosto uporablja tudi linearna funkcija $f(p) = p$. Takšna mera podobnosti se imenuje *energijska mera podobnosti*, saj se njen globalni ekvivalent lahko izračuna kot vsota kvadratov verjetnosti [59]

$$S_{\text{energijska}} = \sum_{\mathbf{i}} (p(\mathbf{i}))^2. \quad (3.24)$$

Omenjene posplošitve tvorijo družino lokalnih večmodalnih mer podobnosti, za katere je značilna sposobnost ocenjevanja poravnanosti poljubno majhnih področij slik.


3.4 Vezana verjetnostna porazdelitev

V večmodalne mere podobnosti so neposredno povezane z vezano verjetnostno porazdelitvijo svetlosti slik. Za boljše razumevanje večmodalnih mer podobnosti je torej potrebno razumevanje odvisnosti vezane porazdelitve od stopnje poravnanosti slik [60].


Vzemimo primer poravnave dveh enostavnih slik A in B , ki predstavljata isti objekt. Vsaka slika vsebuje dva različna tipa tkiv, kjer je vsak tip predstavljen s svojim svetlostnim nivojem. Tako ima slika A svetlostna nivoja i_{A1} in i_{A2} , slika B pa i_{B1} in i_{B2} , pri čemer i_{A1} predstavlja isti tip tkiva kot i_{B1} , i_{A2} pa istega kot i_{B2} . Ko sta sliki pravilno poravnani, je njuna vezana verjetnostna porazdelitev od nič različna le za dva svetlostna para (i_{A1}, i_{B1}) in (i_{A2}, i_{B2}) (slika 3.16). Oba predstavljata pravilno poravnavo slik, kar pomeni, da se na istem mestu na obeh slikah nahaja isti tip tkiva.

Kadar sliki nista pravilno poravnani (slika 3.17), je vezana verjetnost od nič različna še za dva nova svetlostna para (i_{A1}, i_{B2}) in (i_{A2}, i_{B1}) , ki predstavljata napačno poravnana področja slik, to je področja, kjer se tip tkiva na eni sliki razlikuje od istoležnega tipa tkiva na drugi sliki.

Ocenjena verjetnost posameznih svetlostnih parov je odvisna od velikosti področij, ki jih predstavljajo. S stopnjo neporavnanosti se večja velikost napačno



Slika 3.16: Primer pravilno poravnanih enostavnih slik A in B (levo) in njuna vezana verjetnostna porazdelitev (desno).




Slika 3.17: Primer nepravilno poravnanih enostavnih slik A in B (levo) in njuna vezana verjetnostna porazdelitev (desno).

poravnanih področij, medtem ko velikost pravilno poravnanih področij pada. Temu ustrezno torej s stopnjo nepravilnosti raste verjetnost svetlostnih parov različnih tkiv, verjetnost svetlostnih parov, ki ustrezajo istim tkivom na obeh slikah pa pada. Za večmodalne mere podobnosti je značilno, da večja vezana verjetnost pomeni tudi boljše podobnost. Podobnost se za pravilno poravnana področja torej slabša, medtem ko se podobnost nepravilno poravnanih področij izboljšuje. Večmodalna poravnava je tako uspešna le, če je začetna stopnja nepravilnosti dovolj majhna, da so verjetnosti svetlostnih parov različnih tkiv manjše od verjetnosti za pare istih tkiv. Prav zato je uporaba predhodnega znanja o vezani porazdelitvi svetlosti v začetnih iteracijah zelo dobrodošla, saj s tem preprečimo zgoraj omenjeni pojav.

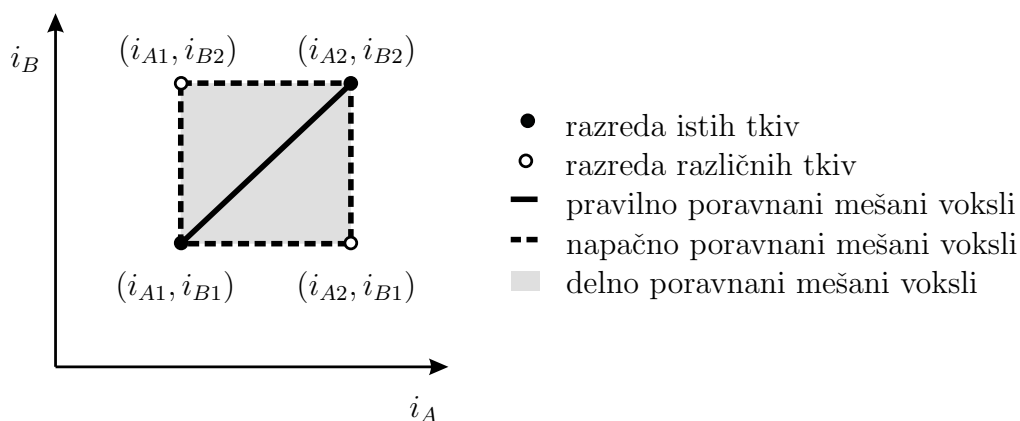
Za realne slike je značilno, da vsakemu tipu tkiva pripada več različnih svetlostnih nivojev. Pri poravnavi slik je torej vsak par tkiv v prostoru vezane

verjetnosti predstavljen z več svetlostnimi pari, ki tvorijo svetlostni razred para tkiv. Če sta sliki pravilno poravnani, je vezana verjetnost sestavljena le iz razredov istih tkiv, sicer pa so prisotni tudi razredi mešanih tkiv (slika 3.18). Razpršenost svetlostnih parov istega razreda je odvisna od količine šuma na slikah. Globalne večmodalne mere podobnosti (MI, NMI, H) dejansko ocenjujejo razpršenost vezane verjetnosti, zato se njihova vrednost z večanjem šuma manjša, čeprav se pri tem poravnanoost slik ne spremeni.

Zaradi počasnega prehajanja med tipi tkiv, se na nekaterih področjih hkrati nahaja več tipov tkiv hkrati. Na slikah so takšne točke predstavljene s svetlostjo, ki je uteženo povprečje svetlosti vsebovanih tipov tkiv, pri čemer so uteži deleži teh tkiv. Voksle, ki predstavljajo takšne točke, imenujemo mešane voksle. K pojavljanju mešanih vokslov v veliki meri prispevata tudi omejena ločljivost slik in razmazanost, njihovo število pa še povečamo z raznimi postopki filtriranja in interpolacije (razen verjetnostne). Večina mešanih vokslov je posledica mešanice dveh tipov tkiv, zato se bomo omejili le na te. V prostoru vezane verjetnosti se svetlostni pari teh vokslov nahajajo na črtah med svetlostnimi razredi (slika 3.18). V primeru pravilno poravnanih mešanih vokslov gre za črte med razredi, ki na obeh slikah predstavljata isto tkivo, v primeru napačne poravnave pa je vsaj eden od razredov razred različnih tkiv (slika 3.19). Mešani voksli, ki so napačno poravnani, vendar še vedno ležijo na prehodu med istima tkivoma, ležijo na pravokotniku, ki ga določajo razredi teh tkiv. Verjetnost mešanih vokslov je nizka, zato imajo majhen vpliv na izračunano podobnost slik. To je s stališča poravnave slik zelo neugodno, saj so robovi, kjer se mešani voksli pojavljajo, informacijsko najbolj bogati deli slik.




Slika 3.18: Pričakovana vezana verjetnost realnih slik modalnosti MRI-T1 (A) in MRI-PD (B) za pravilno poravnani sliki (levo) in za napačno poravnani sliki (desno). Temnejši odtenek pomeni večjo verjetnost. Črte med razredi parov tkiv ustrezajo mešanim vokslovom.



Slika 3.19: Položaj mešanih vokslov v vezani verjetnostni porazdelitvi glede na pravilnost njihove poravnaneosti.

Realne slike so podvržene tudi različnim motnjam, ki tudi vplivajo na vezano porazdelitev svetlosti. V tem okviru je posebno pomembna svetlostna nehomogenost slik. Tako je isti tip tkiva na različnih delih slike predstavljen z različno svetlostjo. Razredi svetlosti tkiv postanejo zato manj kompaktni in se med seboj lahko tudi prekrivajo (slika 3.20).



Slika 3.20: Vezana verjetnost realnih pravilno poravnanih slik. Slika A je modalnosti MRI-PD, slika B pa MRI-T2. Temnejši odtenek pomeni večjo verjetnost.

3.5 Mere podobnosti in segmentacija

Mere podobnosti ocenjujejo ujemanje svetlostnih nivojev slik, s tem pa posredno tudi poravnano tkiv. Vendar pa je vsak tip tkiva predstavljen s celo množico svetlostnih nivojev, pri čemer večmodalne mere podobnosti ne upoštevajo nobene njihove medsebojne povezave. Svetlostni pari so zato obravnavani povsem neodvisno, čeprav je za njih značilno, da tvorijo svetlostne razrede. Upoštevanje tega dodatnega znanja o medsebojni odvisnosti svetlostnih parov bi izboljšalo delovanje mer podobnosti, saj bi namesto z verjetnostmi svetlostnih parov lahko operirali z verjetnostmi svetlostnih razredov, ki zares predstavljajo verjetnosti posameznih parov tkiv.

Za večmodalne mere je značilno, da je izračunana podobnost za pravilno poravnana tkiva odvisna od pogostosti teh tkiv. Manjši ko je delež nekega tkiva na sliki, slabša je zanj izračunana podobnost pri pravilni poravnavi. To povzroča boljše poravnave bolj zastopanih tkiv, medtem ko se slabše zastopana tkiva poravnavaajo slabše.

Posebno mesto imajo tudi mešana tkiva, opisana z mešanimi vokslji. Verjetnost svetlostnih parov mešanih tkiv je majhna, zato zelo malo vplivajo na izračunano podobnost. Pravilna poravnava prehodov med posameznimi tkivi je zato zelo težavna. Ena od možnih rešitev tega problema je, da bi oceno poravnosti mešanih voksljov izračunali na osnovi poznavanja deleža posameznih tkiv na položaju tega voksla.

Menimo, da je vse omenjene probleme mogoče rešiti z uporabo rezultatov segmentacije slik. V primeru poravnave že segmentiranih slik omenjenih problemov namreč ne bi bilo. Podobnosti bi lahko enostavno določili tako, da zavzame vrednost ena za enak tip tkiva na obeh slikah in nič, če je tip tkiva različen. Ob upoštevanju mešanih voksljov, za katere bi bila podobnost lahko tudi med nič in ena, bi točkovno mero podobnosti lahko definirali na sledeč način:

$$S_v = \sum_k \min(t_{kA}, t_{kB'}) \quad ; \quad k = 1 \dots K, \quad (3.25)$$

kjer je K število vseh tipov tkiv, t_{kA} in $t_{kB'}$ pa predstavljata delež tkiva k na položaju opazovanega voksla slike A in B' . Vendar je tudi segmentacija [61, 62] zelo zahteven proces obdelave slik. Realizirana je lahko kot poravnava z drugo, predhodno segmentirano sliko, kar kaže na to, da sta procesa poravnave in segmentacije med seboj dualna. Menimo, da bi s postopkom, ki bi hkrati slike poravnaval in segmentiral, izboljšali rezultate obeh, poravnave in segmentacije. Zato predlagamo novo mero podobnosti, ki sloni na segmentaciji slik in povezuje oba omenjena procesa.

3.5.1 Mera podobnosti na osnovi segmentacije

Na osnovi ugotovljenih pomanjkljivosti opisanih večmodalnih mer podobnosti predlagam novo večmodalno mero podobnosti, ki združuje poravnavo slik s segmentacijo z namenom izboljšanja rezultatov poravnave [63,64]. Osnovna ideja je, da mera podobnosti neposredno predstavlja verjetnost, da določen svetlostni par predstavlja pravilno poravnana tkiva.

Predstavljajmo si, da vezana porazdelitev svetlosti sestoji iz končnega števila svetlostnih razredov M . Vsi razredi skupaj tvorijo množico $\mathcal{C} = \{C_m; m = 1..M\}$. Med njimi je natanko K razredov, ki na obeh slikah predstavljajo isti tip tkiva (K je število različnih tipov tkiva). Ti razredi tvorijo podmnožico $\mathcal{C}_S \subset \mathcal{C}$. Če sliki A in B ne vsebujeta svetlostnih nehomogenosti, lahko vse svetlostne razrede modeliramo z dvodimenzionalnimi Gaussovimi funkcijami s srednjo vrednostjo $\mu_m = (\mu_{Am}, \mu_{Bm})$, amplitudo α_m in kovariančno matriko Σ_m . Tako lahko za vsak svetlostni par \mathbf{i} izračunamo verjetnost $p(C_m|\mathbf{i})$ njegove pripadnosti razredu C_m . Če želimo določiti verjetnost $p(\mathcal{C}_S|\mathbf{i})$, da svetlostni par \mathbf{i} predstavlja pravilno poravnavo, moramo najprej vedeti, kateri razredi C_m predstavljajo pravilno poravnavo, torej, kateri razredi predstavljajo isti tip tkiva na obeh slikah. Brez predhodnega znanja tega ne moremo zagotovo vedeti, vendar pa verjetnost $p(\mathcal{C}_S|C_m)$, da to drži, kljub temu lahko ocenimo za vsak razred $C_m; m = 1..M$. Iz verjetnosti $p(C_m|\mathbf{i})$ in $p(\mathcal{C}_S|C_m)$ lahko izračunamo verjetnost, ki jo iščemo in predstavlja našo novo točkovno mero podobnosti:

$$p(\mathcal{C}_S|\mathbf{i}) = \sum_m p(\mathcal{C}_S|C_m) \cdot p(C_m|\mathbf{i}). \quad (3.26)$$

Segmentacija na osnovi vezane porazdelitve svetlosti

Za izračun mere podobnosti po zgoraj omenjenem postopku moramo najprej izvesti segmentacijo slik na osnovi vezane porazdelitve svetlosti. To je postopek, s katerim svetlostne razrede vezane porazdelitve modeliramo z Gaussovimi funkcijami $p(\mathbf{i}, C_m)$ in določimo njihove parametre. Vezano porazdelitev svetlosti $p(\mathbf{i})$ torej zapišemo kot vsoto

$$p(\mathbf{i}) = \sum_m p(\mathbf{i}, C_m) = \sum_m p(\mathbf{i}|C_m) \cdot p(C_m). \quad (3.27)$$

Pričakovano je, da so razredi med seboj dovolj oddaljeni, da je v okolici \mathcal{O}_m vrednosti μ_m dominanten razred C_m in prispevke vseh ostalih razredov $p(\mathbf{i}, C_l); l = 1..M, l \neq m$ lahko zanemarimo. Število razredov M , njihove srednje vrednosti svetlosti μ_m in amplitude α_m lahko torej določimo s pregledovanjem vezane porazdelitve svetlosti. Vsakemu najdenemu maksimumu vezane porazdelitve pripišemo nov razred s srednjo vrednostjo svetlosti μ_m , ki je enaka položaju maksimuma \mathbf{i} , amplitudo α_m , ki je enaka vezani verjetnosti

v tej točki $p(\mathbf{i})$, kovariančno matriko Σ_m pa določimo po postopku najmanjših kvadratov, kot je opisano v nadaljevanju.

Vezano verjetnost $p(\mathbf{i})$ lahko v okolici \mathcal{O}_m aproksimiramo z

$$p(\mathbf{i})|_{\mathbf{i} \in \mathcal{O}_m} \approx p(\mathbf{i}, C_m) = \alpha_m \exp\left(-\frac{1}{2}(\mathbf{i} - \mu_m)^T \Sigma_m^{-1}(\mathbf{i} - \mu_m)\right). \quad (3.28)$$

Če to enačbo logaritmiramo, dobimo

$$2 \ln\left(\frac{\alpha_m}{p(\mathbf{i})}\right) = (\mathbf{i} - \mu_m)^T \Sigma_m^{-1}(\mathbf{i} - \mu_m) \quad ; \quad \mathbf{i} \in \mathcal{O}_m \quad (3.29)$$

$$\Sigma_m^{-1} = \mathbf{U} = \begin{bmatrix} u_{11} & u_{12} \\ u_{12} & u_{22} \end{bmatrix} \quad (3.30)$$

$$2 \ln\left(\frac{\alpha_m}{p(\mathbf{i})}\right) = u_{11}(i_A - \mu_{Am})^2 + 2u_{12}(i_A - \mu_{Am})(i_B - \mu_{Bm}) + u_{22}(i_B - \mu_{Bm})^2. \quad (3.31)$$

Za vsak svetlostni par iz \mathcal{O}_m poznamo levo stran enačbe, na desni strani pa poznamo vse, razen elementov matike \mathbf{U} , ki jih torej lahko določimo z metodo najmanjših kvadratov. S tem poznamo tudi kovariančno matriko Σ_m , ki je inverz pravkar izračunane matike \mathbf{U} .

Iz poznanih parametrov Gaussovih funkcij, ki opisujejo posamezne razrede, lahko izračunamo verjetnosti posameznih razredov:

$$p(C_m) = \int p(\mathbf{i}, C_m) d\mathbf{i} = \int \alpha_m \exp\left(-\frac{1}{2}(\mathbf{i} - \mu_m)^T \Sigma_m^{-1}(\mathbf{i} - \mu_m)\right) d\mathbf{i}. \quad (3.32)$$

Dobimo sledeč rezultat:

$$p(C_m) = 2\pi\alpha_m |\Sigma_m| \quad ; \quad m = 1..M. \quad (3.33)$$

Vsota vseh verjetnosti razredov bi teoretično morala biti enaka ena. Temu v resnici ni tako, četudi bi bili vsi parametri razredov ocenjeni absolutno točno. Razlog je v svetlostnih parih, ki ne spadajo v nobenega od ocenjenih razredov. Ti v glavnem pripadajo mešanim vokslom, ki jih tokrat nismo posebej obravnavali, vendar imajo običajno zelo nizko verjetnost. Da preprečimo njihovo napačno poravnavo, uvedemo dodatni razred, ki mu za vsak svetlostni par \mathbf{i} pripišemo neko majhno verjetnost


$$p(\mathbf{i}, C_0) = \varepsilon. \quad (3.34)$$

Sodeč po opravljenih eksperimentih izbira vrednosti ε ni kritična, predlagamo pa, da je enaka verjetnosti enega voksla slike $\varepsilon = \frac{1}{N}$.

Končno lahko verjetnost posameznega razreda C_m pri danem svetlostnem paru \mathbf{i} , ki jo potrebujemo za izračun podobnosti, izračunamo po Bayesovi formuli:

$$p(C_m|\mathbf{i}) = \frac{p(\mathbf{i}, C_m)}{\sum_{l=0}^M p(\mathbf{i}, C_l)}. \quad (3.35)$$

Če vsak svetlostni par \mathbf{i} priredimo razredu z največjo verjetnostjo $p(C_m|\mathbf{i})$, dobimo segmentirano sliko (slika 3.21). V primeru, da sliki nista poravnani, so prisotni tako razredi, ki na obeh slikah predstavljajo isti tip tkiva, kot tudi razredi, ki predstavljajo različna tipa tkiv. V postopku poravnave se verjetnosti slednjih manjšajo, tako da na koncu ostanejo le še razredi, ki na obeh slikah predstavljajo isti tip tkiva. V tem primeru ti razredi predstavljajo tudi pravilno segmentacijo slike.



Slika 3.21: Primer segmentacije neporavnanih slik (levo) in poravnanih slik (desno). Vsak razred je označen z drugačno sivino.

Določitev verjetnosti pravilne poravnave $p(C_S|\mathbf{i})$

Za izračun podobnosti moramo poleg že izračunanih verjetnosti $p(C_m|\mathbf{i})$ določiti še verjetnost, da določen razred $C_m; m = 1..M$ predstavlja isto tkivo na obeh slikah. Privzemimo, da ima vsak tip tkiva na posamezni sliki drugačno srednjo vrednost svetlosti μ_{Ak} oziroma μ_{Bk} . V tem primeru izmed vseh razredov z isto srednjo vrednostjo μ_{Am} oziroma μ_{Bm} le eden predstavlja isto tkivo na obeh slikah, medtem ko so vsi ostali razredi mešani razredi (slika 3.22). Naj bo $\mathcal{C}_{\mu_A} \subset \mathcal{C}$ množica vseh razredov z enako srednjo vrednostjo μ_A . Potem je verjetnost, da razred $C_m \in \mathcal{C}_{\mu_A}$ na obeh slikah predstavlja isto tkivo, glede na svetlost slike A enaka

$$p_A(C_S|C_m) = \frac{p(C_m)}{\sum_{C_l \in \mathcal{C}_{\mu_A}} p(C_l)}. \quad (3.36)$$

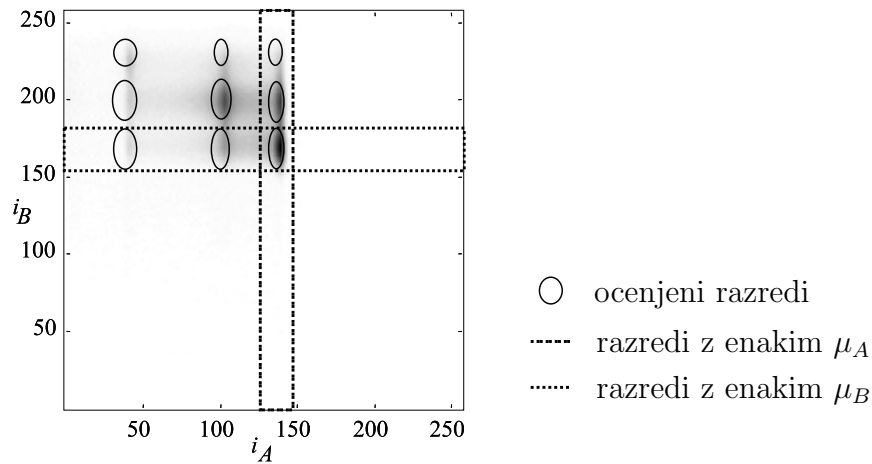
Takšna ocena ni nujno zadostna, saj imajo v primeru, da je zastopanost enega tkiva veliko večja od zastopanosti drugih tkiv na sliki, vsi razredi z največjo

vrednostjo $p_A(\mathcal{C}_S|C_m)$ enako srednjo vrednost μ_B , kar seveda ni prav. To lahko preprečimo, če ocenimo še verjetnost, da razred C_m na obeh slikah predstavlja isto tkivo glede na svetlost slike B

$$p_B(\mathcal{C}_S|C_m) = \frac{p(C_m)}{\sum_{C_l \in \mathcal{C}_{\mu_B}} p(C_l)}, \quad (3.37)$$

kjer množica $\mathcal{C}_{\mu_B} \subset \mathcal{C}$ združuje vse razrede z enako srednjo vrednostjo μ_B . Končna ocena verjetnosti, da nek razred C_m predstavlja isto tkivo na obeh slikah, je produkt obeh prej ocenjenih verjetnosti:

$$p(\mathcal{C}_S|C_m) = p_A(\mathcal{C}_S|C_m) \cdot p_B(\mathcal{C}_S|C_m). \quad (3.38)$$



Slika 3.22: Primeri področij, na katerih le eden izmed vseh razredov predstavlja isto tkivo na obeh slikah.

Vsota verjetnosti $p(\mathcal{C}_S|C_m)$ vseh razredov govori o ocenjenem številu takšnih razredov. Kadar začetna predpostavka, da ima vsak tip tkiva na posamezni sliki drugačno srednjo vrednost svetlosti, ni izpolnjena, in ima ω razredov enako svetlost na eni od slik, je ocena verjetnosti $p_A(\mathcal{C}_S|C_m)$ oziroma $p_B(\mathcal{C}_S|C_m)$ teh razredov ω -krat premajhna. Kljub temu pričakujemo, da bo rezultat poravnave pravilen, saj so razmerja med ocenjenimi verjetnostmi $p(\mathcal{C}_S|C_m)$ teh razredov še vedno pravilna. Poravnava takšnih slik lahko zahteva več iteracij.

Ko poznamo vse verjetnosti $p(C_m|\mathbf{i})$ in $p(\mathcal{C}_S|C_m)$ lahko izračunamo točkovno podobnost po že omenjeni enačbi:

$$S_v = p(\mathcal{C}_S|\mathbf{i}) = p(C_m|\mathbf{i}) \cdot p(\mathcal{C}_S|C_m). \quad (3.39)$$

Opozoriti je potrebno, da opisana mera podobnosti zahteva slike brez svetlostnih nehomogenosti, saj sicer razredov ne moremo zadovoljivo modelirati z Gaussovimi funkcijami. Slike, ki vsebujejo svetlostne nehomogenosti, moramo zato predhodno popraviti [65].

3.5.2 Poenostavitev

Za posebne primere, ko se svetlostnih razredov ne da modelirati z Gaussovimi ali podobnimi funkcijami, lahko opisano mero podobnosti poenostavimo, tako da ne zahteva segmentacije. V ta namen vsak svetlostni par obravnavamo kot svetlostni razred in mera podobnosti se poenostavi v produkt pogojnih verjetnosti:


$$S_v = p(i_A|i_B) \cdot p(i_B|i_A). \quad (3.40)$$

Ker v tem primeru ni uporabljenega znanja, ki ga sicer pridobimo s segmentacijo, je pričakovati nekoliko slabše rezultate, kot jih da mera podobnosti v enačbi (3.39). Ta postopek lahko uporabimo tudi kot predhodno obdelavo vezane porazdelitve za izračun lokalnih mer podobnosti, predstavljenih v poglavju 3.3.

4. Izvedba sistema za elastično poravnavo

V tem poglavju je podrobno predstavljena izvedba sistema za večmodalno elastično poravnavo trodimenzionalnih slik. Glavni problem večmodalne elastične poravnave, določanje lokalnega ujemanja slik, je rešen z uporabo točkovnih mer podobnosti, ki so opisane v poglavju 3. Pomembna lastnost teh mer je podkrepljenost določanja lokalne podobnosti, ki daje oceno poravnosti slik, z uporabo globalnega znanja, ki zelo zmanjša možnost napačne poravnave. Te mere podobnosti nadalje omogočajo popolno izničenje vpliva, ki ga ima sicer merjenje podobnosti na deformabilne lastnosti slik. Merjenje podobnosti v posamezni točki slike je namreč neodvisno od deformacij slik. Deformabilne lastnosti so tako povsem v domeni prostorskega modela, v našem primeru modela elastičnosti. Notranja in zunanja področja poravnane slike imajo torej velikost enega voksla.


Shema večmodalne elastične poravnave prikazuje slika 4.1. Sliki A in B sta zapisani v obliki trodimenzionalnih matrik, kjer indeks elementa označuje njegov položaj. Zunanje sile $\mathbf{f} = [f_1, f_2, f_3]^T$ so na enak način zapisane v matriki \mathbf{F} in premiki $\mathbf{u} = [u_1, u_2, u_3]^T$ v matriki \mathbf{U} . Indeks elementa teh dveh matrik vedno pomeni položaj (prijemališče sile oziroma začetno lego premikanega voksla) na nedeformirani sliki B v merilu velikosti voksla slike B . Začetna vrednost matrike \mathbf{U} je določena iz rezultatov predporavnave ali pa je enaka nič.



Slika 4.1: Shema realizirane večmodalne elastične poravnave

Zaradi uporabe verjetnostne interpolacije v postopku poravnave deformirane slike B' ni potrebno izračunavati. Ta je določena z originalno poravnano sliko B in matriko premikov \mathbf{U} in se jo izračuna le ob koncu poravnave. (slika 4.2).

Uporabljen je večločljivostni pristop, ki izboljša konvergenco poravnave in jo pohitri. Celoten postopek poravnave je kar se da enostaven in temu ustrezno



Slika 4.2: Poravnana slika B' se izračuna na osnovi originalne poravnane slike B in matrike premikov U .

razmeroma hiter. Poravnava slike velikosti $181 \times 217 \times 181$ vokslov traja na računalniku pentium III 500 20 minut. Opozoriti je potrebno še na veliko količino podatkov, zaradi česar je zaželen večja količina delovnega pomnilnika. Za poravnavo slik velikosti $181 \times 217 \times 181$ potrebujemo $2 \times 7,1 Mb$ (sliki A in B) + $2 \times 85,3 Mb$ (matriki \mathbf{F} in \mathbf{U}) = 184,8Mb pomnilnika in to le za zapis glavnih štirih spremenljivk.

4.1 Določanje zunanjih sil

V tem koraku za vsak vokal slike B določimo silo, ki ga vleče v smer boljše podobnosti s sliko A . Iščemo torej zunanje sile $\mathbf{f} = \mathbf{F}(\mathbf{x})$, kjer so vse tri komponente položaja \mathbf{x} celoštevilčne vrednosti, merilo pa velikost voksla poravnane slike. Njihova vrednost mora ustrezati gradientu točkovne podobnosti $S_v(\mathbf{u})$ glede na premik točke $\mathbf{u} = \mathbf{U}(\mathbf{x})$. Izračun zunanjih sil lahko razdelimo v dva koraka:

- določitev podobnosti $S_v(\mathbf{i})$, za vse možne svetlostne pare \mathbf{i} ,
- določitev zunanjih sil $\mathbf{f} = \mathbf{F}(\mathbf{x})$ kot gradienta točkovnih podobnosti.

4.1.1 Določitev podobnosti svetlostnih parov


Izračun podobnosti svetlostnih parov $S_v(\mathbf{i})$ izhaja iz vezane porazdelitve svetlostnih nivojev, postopek izračuna pa je odvisen od izbrane točkovne mere podobnosti. Vezano porazdelitev svetlosti $p(\mathbf{i})$ izračunamo kot uteženo povprečje vezane porazdelitve $p_{slike}(\mathbf{i})$, ki je ocenjena s slik z verjetnostno interpolacijo (poglavje 3.2.1), in vezane porazdelitve $p_{podana}(\mathbf{i})$, ki je podana vnaprej.

$$p(\mathbf{i}) = (1 - \lambda) \cdot p_{slike}(\mathbf{i}) + \lambda \cdot p_{podana}(\mathbf{i}) \quad ; \quad \lambda \in [0, 1], \quad (4.1)$$

kjer je λ utež, ki določa razmerje med obema vezanima porazdelitvama. Pogosto predhodnega znanja $p_{podana}(\mathbf{i})$ nimamo, zato mora biti takrat λ enaka 0. Če je to

predhodno znanje na voljo, pa lahko izboljša rezultate, saj zmanjšuje možnosti napačne poravnave v začetnih iteracijah poravnave.

Podobnosti vseh možnih svetlostnih parov \mathbf{i} določimo po eni od točkovnih mer podobnosti. V našem primeru smo uporabili večmodalne točkovne mere podobnosti, ki so opisane v poglavjih 3.3 in 3.5. Podobnost svetlostnih parov lahko prikažemo enako kot vezano porazdelitev svetlosti, kot dvodimenzionalno polje vrednosti. Primer za entropijsko mero podobnosti $S_v = \log(p(\mathbf{i}))$ je prikazan na sliki 4.3.




Slika 4.3: Primer vezane verjetnosti (levo) in iz nje izračunane podobnosti svetlostnih parov za entropijsko mero podobnosti $S_v = \log(p(\mathbf{i}))$ (desno).

4.1.2 Določitev zunanjih sil na osnovi točkovnih podobnosti

Za določitev zunanjih sil moramo za vsak vokal slike B oceniti potek funkcije podobnosti $S_v(\mathbf{u}) = S_v(\mathbf{i}(\mathbf{u}))$, v okolici $\mathbf{u} = U(\mathbf{x})$. Ker je slika A diskretna in ima torej svetlost i_A določeno le za celoštevilске vrednosti \mathbf{x}' , je podobnost za dano točko potrebno določiti s pomočjo interpolacije (slika 4.4). Ena od možnosti je, da neznan svetlost i_A ocenimo z linearno interpolacijo

$$i_A = \sum_j w_j \cdot i_{A_j}, \quad (4.2)$$

kjer so w_j uteži linearne interpolacije, i_{A_j} pa svetlosti osmih najbližjih podanih točk slike A . Točkovno podobnost S_v lahko nato določimo na osnovi ocenjene svetlosti i_A iz že izračunanih podobnosti svetlostnih parov kot $S_v(\mathbf{u}) = S_v(i_A, i_B)$. Vendar pa linearna interpolacija svetlosti povzroči zelo nelinearen potek točkovne podobnosti in lahko privede do pojava interpolacijskih lokalnih ekstremov. Zato



Slika 4.4: Ilustracija problema določitve točkovne podobnosti. Referenčna slika A v točki \mathbf{x}' v splošnem nima določene vrednosti, zato je potrebna interpolacija. Možna je interpolacija svetlosti slike A ali pa boljše kar podobnosti $S_v(\mathbf{u})$, s čimer se izognemo lokalnim ekstremom zaradi interpolacije.

namesto linearne interpolacije svetlosti raje uporabimo linearno interpolacijo točkovne podobnosti

$$S_v(\mathbf{u}) = \sum_j w_j \cdot S_v(i_{A_j}, i_B). \quad (4.3)$$

Pri tem so uteži w_j enake utežem pri linearni interpolaciji svetlosti.

Za določitev zunanjih sil ni potrebna le vrednost podobnosti pri $\mathbf{u} = \mathbf{U}(\mathbf{x})$, pač pa je pomemben potek funkcije v okolici te točke. V ta namen funkcijo podobnosti modeliramo s trodimenzionalno funkcijo drugega reda

$$S_v(\mathbf{u}) = \mathbf{u}^T \mathbf{P} \mathbf{u} + \mathbf{r}^T \mathbf{u} + s, \quad (4.4)$$

pri čemer so matrika \mathbf{P} , vektor \mathbf{r} in skalar s parametri te funkcije in jih določimo z metodo najmanjših kvadratov. Za to uporabimo izračunane podobnosti $S_v(\mathbf{u} + \delta \mathbf{u})$ kjer je $\delta \mathbf{u} = [\{-\varepsilon, 0, \varepsilon\}, \{-\varepsilon, 0, \varepsilon\}, \{-\varepsilon, 0, \varepsilon\}]^T$, kar torej da 27 linearnih enačb. Vsak od parametrov je torej linearna funkcija 27 podobnosti. Izračunane parametre nato uporabimo za izračun gradienta funkcije podobnosti


$$\nabla S_v(\mathbf{u}) = \left[\frac{\partial S_v(\mathbf{u})}{\partial u_1}, \frac{\partial S_v(\mathbf{u})}{\partial u_2}, \frac{\partial S_v(\mathbf{u})}{\partial u_3} \right]^T = 2\mathbf{P}\mathbf{u} + \mathbf{r}, \quad (4.5)$$

Vsaka komponenta gradienta je spet linearna funkcija 27 izračunanih podobnosti, pri tem pa so parametri teh funkcij odvisni le od izbrane vrednosti ε . Posamezne komponente gradienta lahko torej izračunamo z enostavnim množenjem izračunanih podobnosti $S_v(\mathbf{u} + \delta \mathbf{u})$ z vnaprej določenimi utežmi $w_k(\delta \mathbf{u})$, kjer

k predstavlja indeks računane komponente gradienta.

$$\frac{\partial S_v(\mathbf{u})}{\partial u_k} = \sum_{\delta \mathbf{u}} w_k(\delta \mathbf{u}) \cdot S_v(\mathbf{u} + \delta \mathbf{u}) \quad (4.6)$$

Uteži, ki jih dobimo po opisanem postopku za $\varepsilon = 1$ so prikazane na sliki 4.5. Za



Slika 4.5: Uteži $w_k(\delta \mathbf{u})$ izračunane po metodi najmanjših kvadratov za $\varepsilon = 1$.

drugačne vrednosti ε se spremeni le velikost vseh uteži, razmerje med njimi pa ostaja enako. Nove uteži so tako sledeče

$$w'_k(\delta \mathbf{u}) = \frac{w_k(\delta \mathbf{u})}{\varepsilon}. \quad (4.7)$$

Zaradi nadaljnjih operacij v opisanem postopku poravnave slik velikost sil ni pomembna, važno je le njihovo razmerje. Za izračun uteži torej lahko uporabimo poljuben ε . Nasprotno pa ε vpliva na vrednosti izračunanih podobnosti $S_v(\mathbf{u} + \delta \mathbf{u})$. Da čim boljše ocenimo gradient podobnosti v iskani točki mora biti ε majhen (manj od $\frac{1}{2}$), njegova velikost pa v tem primeru nima bistvenega vpliva na poravnavo slik. V našem primeru je uporabljen $\varepsilon = 0.1$.


Če je vrednost podobnosti pri $\delta \mathbf{u} = [0, 0, 0]^T$ boljša od podobnosti vseh ostalih 26 podobnosti, je položaj obravnavane točke že ustrezen in ne pričakujemo izboljšanja točkovne podobnosti zaradi premika točke. Zunanja sila za to točko torej ni potrebna in zanjo določimo $\mathbf{f} = [0, 0, 0]^T$. Sicer pa je velikost sile enaka izračunanemu gradientu podobnosti

$$\mathbf{f} = \nabla S_v(\mathbf{u}) = \left[\frac{\partial S_v(\mathbf{u})}{\partial u_1}, \frac{\partial S_v(\mathbf{u})}{\partial u_2}, \frac{\partial S_v(\mathbf{u})}{\partial u_3} \right]^T. \quad (4.8)$$

Opozoriti je potrebno na pojav, pri katerem se tudi za idealno poravnane slike pojavijo neke od nič različne zunanje sile, ki sliko deformirajo. Vzrok za to je v neidealnem odnosu med izračunano podobnostjo in pravo poravnano sliko oziroma točk, ki je lahko posledica motenj na sliki, npr. šuma, ali pa slabo določene mere podobnosti, npr. zaradi slabe statistične moči vezane verjetnosti.

4.2 Elastični model

Shema uporabljenega elastičnega modela prikazuje slika 4.6. Zunanje sile se vedno pojavijo zaradi neoptimalne poravnave slik. Če so zunanje sile različne od nič pa govorijo o možnem izboljšanju poravnave. Uporabljen elastični model zato zunanje sile upošteva kot sile, ki izboljšujejo poravnavo glede na prejšnje stanje, ne pa glede na začetno stanje poravnave, kot je sicer običajno za elastično poravnavo slik. Zunanje sile povzročijo neke dodatne premike točk \mathbf{U}_F . Vsota obstoječih in dodatnih premikov $\mathbf{U}' = \mathbf{U} + \mathbf{U}_F$ mora izpolnjevati pogoje, ki jih predpisuje model elastičnosti, to je ustrezno gladkost brez trganja in gubanja slike, za kar poskrbi uporabljen elastični filter. Napake ustaljenega stanja, ki nastanejo zaradi ravnovesja med zunanjimi silami in notranjimi silami elastičnosti, so zaradi tovrstnega akumuliranja premikov manjše kot bi bile sicer. Druga dobra lastnost tega pristopa je, da ni potrebno vnaprej poznati (končnega) položaja robnih točk, saj je celotna slika plavajoča. S tem je omogočeno tudi odpravljanje neskladij na robovih slik in odpravljanje globalnih neskladij.



Slika 4.6: Shema uporabljenega elastičnega modela.

Če ne upoštevamo medsebojne odvisnosti med točkami slike, lahko odvisnost med silo in premikom posamezne točke elastičnega materiala opišemo s Hookovim zakonom

$$\mathbf{U}_F(\mathbf{x}) = k_E \cdot \mathbf{F}(\mathbf{x}). \quad (4.9)$$

Parameter k_E je konstanta značilna za elastičen material s katerim modeliramo poravnavano sliko. Ker v našem primeru zunanje sile uporabimo le za odpravljanje še ne popravljenih slikovnih neskladij, parameter k_E izgubi prvotni pomen, pač pa govori o hitrosti poravnave. Hitrost poravnave je omejena s stabilnostjo poravnave, saj s prevelikimi spremembami premikov $\mathbf{U}(\mathbf{x})$ v eni iteraciji poravnave lahko preskočimo iskan optimalen premik, ki ustreza najboljši poravnavi. Največja dovoljena sprememba premika v eni iteraciji $|\mathbf{u}_{max}|$ je en voksel, oziroma manj za poravnavo z natančnostjo boljšo od velikosti enega voksla. Parameter k_E zato izračunavamo v vsaki iteraciji posebej

$$k_E = \frac{|\mathbf{u}_{max}|}{\max |\mathbf{F}(\mathbf{x})|}. \quad (4.10)$$

Glede na izračunan k_E torej po enačbi (4.9) določimo dodaten premik

posameznih točk $\mathbf{U}_F(\mathbf{x})$. Ti premiki ne ustrezajo lastnostim deformabilnega modela. Zelene lastnosti deformacij, ki preprečujejo trganje in gubanje slike zagotovi elastični filter. Ta glede na predlagane premike $\mathbf{U}'(\mathbf{x}) = \mathbf{U}_F(\mathbf{x}) + \mathbf{U}(\mathbf{x})$ določi nove premike $\mathbf{U}(\mathbf{x})$, ki od predlaganih najmanj odstopajo, a ustrezajo zahtevanim lastnostim deformacij. Obstaja več vrst elastičnih filtrov. Posebej smo se posvetili dvema: elastičnemu filtru na osnovi diskretnega modela elastičnosti in Gaussovemu filtru, ki predstavlja poenostavitev elastičnosti.


Diskretni model elastičnosti, ki ga predlagamo, je opisan v poglavju 2.2.2, filter, ki temu modelu ustreza pa je predstavljen z enačbo (2.10). Ta model smo še nekoliko poenostavili, tako da smo uporabili enaka koeficienta natega in striga $k_n = k_s = k_{ns}$. To sicer nima pravega fizikalnega ozadja, saj po fizikalnih zakonih elastičnosti velja

$$k_s = \frac{k_n}{2(1 + \mu)}, \quad (4.11)$$

kjer je μ parameter lastnosti materiala in je za vse realne snovi večji od nič. Vendar pa ta poenostavitev zelo zmanjša numerično zahtevnost filtriranja, saj premikov ni več treba deliti na njihovo natezno in strižno komponento. Tak filter lahko realiziramo s konvolucijo

$$\mathbf{U}(\mathbf{x}) = \mathbf{U}'(\mathbf{x}) * \mathbf{G}, \quad (4.12)$$

kjer je \mathbf{G} impulzni odziv filtra. Ker medsebojen vpliv vokslov z razdaljo pada, mora biti parameter k_{ns} odvisen od vrste sosednosti vokslov, tako da z razdaljo med središči vokslov utež k_{ns} pada. Vrednost k_l je prosti parameter filtra, s katerim določamo prožnost modela. Impulzni odziv uporabljenega filtra je prikazan na sliki 4.7.



Slika 4.7: Impulzni odziv elastičnega filtra \mathbf{G} .

Gaussov filter je dober približek elastičnosti. Sicer slabše opisuje elastičnost kot diskretni model elastičnosti, vendar pa zaradi upoštevanja premikov bolj

oddaljenih vokslov dopušča večjo togost modela deformacij. Impulzni odziv Gaussovega filtra je določen z enačbo

$$\mathbf{G}(\mathbf{x}) = \exp\left(\frac{|\mathbf{x}|^2}{2\sigma^2}\right). \quad (4.13)$$

Filtriranje sil \mathbf{F}

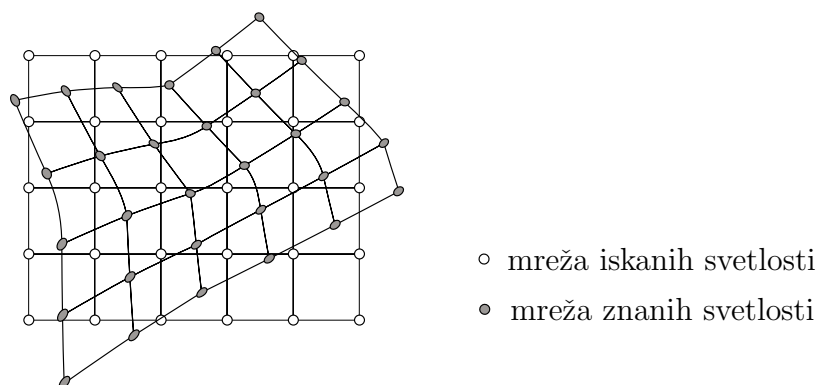
Točke z večjimi zunanji silami $\mathbf{F}(\mathbf{x})$ se nahajajo v glavnem na tistih delih slik, ki pripadajo robovom objektov predstavljenih na slikah. Kot je bilo omenjeno, je hitrost poravnave odvisna od največje zunanje sile, tako da ta povzroči premik velikosti $|\mathbf{u}_{max}|$. Ker je število točk z večjimi silami relativno majhno, hkrati pa so te točke zelo razpršene, je smiselno te sile nekoliko zmanjšati. S tem se poravnava teh točk ne poslabša, saj največja sila še vedno povzroči premik velikosti \mathbf{u}_{max} , izboljša pa se poravnava ostalih točk. Prav tak učinek dobimo s prostorskim filtriranjem sil $\mathbf{F}(\mathbf{x})$ z Gaussovimi filtrom. Če želimo, da filtriranje sil ne povzroči spremembe lastnosti deformacij, mora biti filtriranje sil manjše od filtriranja premikov \mathbf{U}' . S povečevanjem širine Gaussovega filtra za sile, se lastnosti deformacij začnejo spreminjati. V ekstremnem primeru lahko filtriranje premikov povsem ukinemo. S tem dobimo model deformacij, ki je najbolj podoben inkrementalnim deformacijam, kjer vsako novo stanje predstavlja novo začetno stanje za nadaljnjo poravnavo. Takšne deformacije se po svojih lastnostih približujejo lastnostim viskoznosti.

4.3 Izračun deformirane slike

Izračun deformirane slike je končni korak poravnave. Z njim iz poravnane slike B in izračunane matrike premikov \mathbf{U} določimo poravnano sliko B' . Želimo torej določiti vrednost slike B' v točkah \mathbf{x} na nedeformirani mreži, pri tem pa imamo podane vrednosti v točkah $\mathbf{x}' = \mathbf{x} + \mathbf{U}(\mathbf{x})$ na deformirani mreži. Gre torej za operacijo, ki je nasprotna običajni interpolaciji slik (slika 4.8). Vrednosti v iskani točki ni enostavno določiti iz znanih vrednosti sosednih točk, saj te ne tvorijo geometrijsko pravilnega lika. Zato raje ugotavljamo kakšen vpliv ima posamezna znana točka na okoliške neznane točke pravilne mreže. Vsaka poznana točka leži v trodimenzionalnem prostoru med osmimi neznanimi točkami. Z metodo linearne interpolacije (poglavje 3.2.1) določimo uteži w_{kl} , ki podajajo utež točke k na pravokotni mreži za izračun točke l na deformirani mreži. S pomočjo teh uteži lahko izračunamo svetlosti v točkah pravokotne mreže

$$i_k = \frac{\sum_l w_{kl} i_l}{\sum_l w_{kl}}, \quad (4.14)$$

kjer i_k predstavlja svetlost točke k na pravokotni mreži, i_l pa svetlost točke l na deformirani mreži. Opozoriti je potrebno, da s tem postopkom ne moremo



Slika 4.8: Ilustracija problema izračuna deformirane slike (2D).

določiti svetlosti točk, za katere so vse uteži w_{kl} enake nič. Do tega pride na robovih slik, če so prisotne velike deformacije pa se lahko pojavi tudi drugje.

4.4 Večločljivostni pristop

Odpravljanje lokalnih neskladij ni smiselno, če prej niso odpravljena globalna neskladja. Tudi elastično poravnavo je primerno izvesti postopno, tako da najprej odpravimo večja neskladja, nato pa vse bolj lokalna neskladja in nazadnje še vse detajle. Pri opisanem postopku večmodalne elastične poravnave lahko nivo poravnavanih detajlov nastavimo na dva načina:

- z uporabo podvzorčenih slik,
- z uporabo različnih parametrov elastičnosti.

Poravnavanju detajlov se najlažje izognemo, če teh detajlov na slikah ni. Detajle lahko iz slik izločimo z uporabo skalirnih postopkov ali s podvzorčenjem. Skalirni postopki za večmodalno poravnavo slik niso primerni, saj temeljijo na filtriranju. To v slike uvaja nove sivinske vrednosti, kar močno pokvari vezano verjetnostno porazdelitev in poslabša večmodalno poravnavo. Podvzorčenje je bolj primerno, saj gre na prvi pogled le za upoštevanje vsakega drugega vzorca slik (vsakega osmega voksla v 3D). Kljub temu pa je po Shannonovem teoremu vzorčenja pred podvzorčenjem potrebno zagotoviti, da v sliki niso prisotne visoke frekvence. To dosežemo s filtriranjem, vendar pa vsak filter z znanim frekvenčnim potekom spet ustvarja nove svetlostne vrednosti, kar spet negativno vpliva na rezultate poravnave. Zato smo za filtriranje pred podvzorčenjem uporabil nelinearen filter, medianino sito. Ta filter ne ustvarja novih svetlostnih vrednosti in je po tej strani zelo primeren. Deluje tako, da vsakemu vokslu filtrirane slike

priređi tisto svetlost, kot jo ima srednji vokal njegove, po svetlosti razvrščene, okolice na originalni sliki. V našem primeru je zadostna uporaba okolice velikosti $3 \times 3 \times 3$ voksele. Na ta način filtrirane in podvzorčene slike nato uporabimo v večnivojskem postopku poravnave, kot je prikazano na sliki 3.12. Pri vsakem prehodu iz višjega v nižji nivo je potrebno interpolirati matriko premikov \mathbf{U} s čimer rezultate enega nivoja uporabimo kot začetno stanje novega nivoja poravnave. Podvzorčenje tudi zelo pohitri poravnavo, saj se v vsakem višjem nivoju poravnave količina podatkov zmanjša za 87%, približno v razmerju 8 : 1 pa se tudi zmanjša čas ene iteracije. Poleg tega pa je zaradi večjih dimenzij vokslor v višjih nivojih učinek ene iteracije poravnave v vsakem višjem nivoju $2 \times$ večji.

Pri elastični poravnavi lahko nivo poravnanih detajlov spreminjamo tudi s spreminjanjem parametrov elastičnosti. Bolj tog model materiala ustreza bolj togi poravnavi, ki odpravi manj detajlnih slikovnih neskladij. V našem primeru togost poravnave raste z manjšanjem uteži k_l pri elastičnem filtru, oziroma z večanjem širine filtra σ pri Gaussovem filtru. Ker s podvzorčenjem povečamo velikost vokslor, se razmerje med širino filtra in velikostjo poravnanih struktur podvoji. S tem postane poravnavo bolj toga. Spreminjanje parametrov elastičnosti je torej že implicitno vključeno v večločljivostni pristop poravnave.

4.5 Izbira postopkov predobdelave

Celotna večmodalna poravnavo se od enomodalne razlikuje predvsem zaradi potrebe po uporabi večmodalnih mer podobnosti. Zaradi občutljivosti teh mer na filtriranje, podvzorčenje in interpolacijo je zelo pomembna tudi izbira vseh ostalih postopkov. Pozornost je potrebna tudi pri izbiri postopkov predobdelave.

Elastična poravnavo zahteva neko togo predporavnavo. Rezultat predporavnave se običajno poda kot nova, poravnana slika, določena s postopkom interpolacije. Ker interpolacija lahko škoduje natančnosti nadaljne elastične poravnave se ji je zaželeno izogniti. To lahko dosežemo tako, tako da namesto interpolirane slike in ničelne začetne matrike premikov elastične poravnave $\mathbf{U} = 0$ za elastično poravnavo raje uporabimo originalno poravnano sliko, začetno matriko \mathbf{U} pa določimo iz rezultatov predporavnave.

Pogosto poravnani sliki nimata enake velikosti vokslor. Običajno se takšne slike pred poravnavi prevzorči, tako da je velikost vokslor na obeh slikah enaka. To pri večmodalni elastični poravnavi ni zaželeno, zelo enostavno pa se temu lahko izognemo. Boljša rešitev je neposredno upoštevanje velikosti vokslor. Edina razlika, ki pri elastični poravnavi slik nastane zaradi različne velikosti vokslor, je namreč dodaten skalirni faktor pri interpolaciji referenčne slike ob določanju točkovnih podobnosti.

Če sliki vsebujeta svetlostne nehomogenosti, lahko to zelo vpliva na točnost poravnave. Zato je zaželeno odpravljanje svetlostnih nehomogenosti slik pred vsako poravnavo. Postopki za odpravljanje svetlostnih nehomogenosti [65] nimajo stranskih učinkov, ki bi škodili večmodalni elastični poravnavi.

Seveda so možni tudi drugi postopki predobdelave slik. Vedno se je dobro prepričati, če so zares potrebni, saj lahko vnesejo več napak kot koristi. Tudi postopke, ki vsebujejo nezaželeno filtriranje, interpolacijo, podvzorčenje ali prevzorčenje, se običajno da prirediti za uporabo z večmodalno elastično poravnavo slik.

5. Rezultati

Ocena rezultatov večmodalne elastične poravnave je zelo težavna. Ker so rezultati odvisni od zahtevanih deformacij in od napak, ki so prisotne na slikah, bi bilo oceno sistema potrebno podati glede na rezultate poravnave realnih medicinskih slik. Vendar pa pravih rezultatov takšne poravnave nikoli ne poznamo vnaprej. Kako torej ocenjevati? Pomagamo si lahko s simuliranimi slikami, kjer predvidimo realna neskladja slik in napake, ki se na slikah lahko pojavijo.

Rezultate smo razdelili v tri skupine. V prvi ugotavljamo katere mere podobnosti so bolj primerne za večmodalno elastično poravnavo slik, v drugi pa ugotavljamo vpliv različnih elastičnih modelov in različnih parametrov modela deformacij. Glede na rezultate v teh dveh skupinah lahko ocenimo, katere postopke je primerno uporabiti pri reševanju realnih problemov. Ocena rezultatov realnih poravnav je najbolj težavna in ji je namenjena zadnja skupina rezultatov.

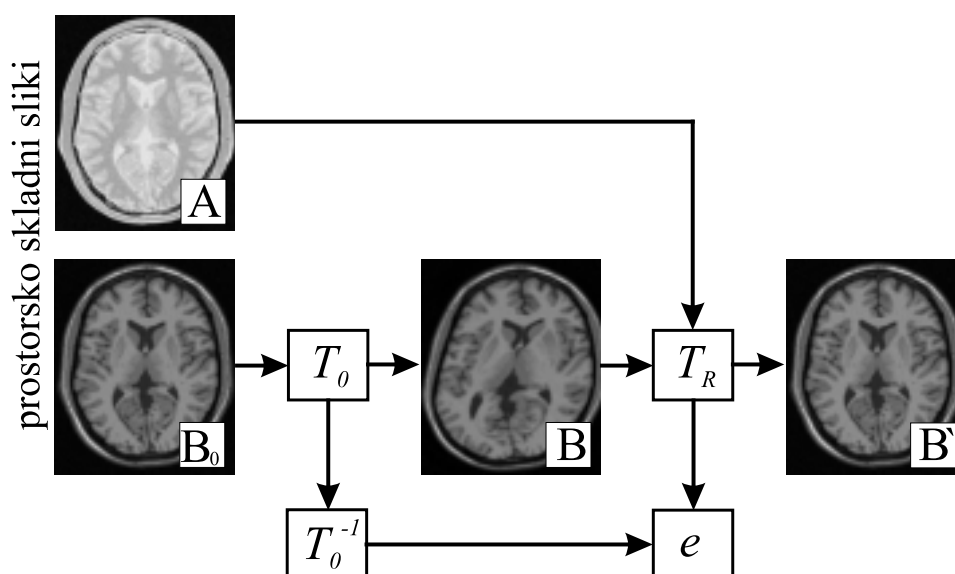
5.1 Primerjava lokalnih mer podobnosti

Primerjava globalnih mer podobnosti poteka tako, da se primerja njihove funkcije podobnosti glede na parametre transformacije slik. Pri tem se ocenjuje gladkost, število lokalnih ekstremov, položaj globalnega ekstrema, področje delovanja in podobno. Primerjava lokalnih in še posebej točkovnih večmodalnih mer podobnosti je bolj problematična, saj vsaka transformacija področij velikosti enega voksla povzroči drastično spremembo prekrivanja teh področij. Ker pravzaprav ugotavljamo, katera mera podobnosti da boljše rezultate poravnave, menimo, da teh mer ne moremo primerjati neodvisno od uporabljenega sistema poravnave. Primerjavo točkovnih mer podobnosti je torej po naši oceni smiselno izvesti kot primerjavo sicer enakih sistemov poravnave, ki pa temeljijo na različnih merah podobnosti.

Za primerjavo mer podobnosti smo uporabili dve popolnoma skladni simulirani BrainWeb sliki glave [66–69]. Prva slika (MRI-PD) je bila uporabljena kot referenca A , medtem ko smo drugo sliko B_0 (MRI-T1) prostorsko transformirali v poravnavano sliko B z znano transformacijo T_0 . Potem smo sliko B večkrat poravnali na sliko A z večmodalno elastično poravnavo, pri tem pa vedno uporabili isti postopek in drugo točkovno mero podobnosti. Rezultate

poravnnav smo nato ocenili s korenem srednje kvadratične napake premikov e (angl. *RMS*, *Root mean square*), ki smo ga izračunali iz razlike med znano transformacijo poravnave T_R in inverzom znane začetne transformacije T_0 (5.1). Voksle, ki so na poravnnavani sliki predstavljali ozadje, nismo upoštevali pri oceni poravnave, saj vsako poravnnavo ozadja lahko štejeemo za pravilno. Točke poravnave smo zato odstranili s poznano masko Ω . N_Ω je število vokslov maske, ki ne pripada ozadju.

$$e = \sqrt{\frac{1}{N_\Omega} \sum_{\mathbf{x} \in \Omega} (T_{0\mathbf{x}}^{-1} - T_{R\mathbf{x}})^2} \quad (5.1)$$



Slika 5.1: Shema postopka za ocenjevanje kvalitete poravnave.

Rezultati poravnnav so tabelirani v tabeli 5.1. Prvi stolpec prikazuje točkovne večmodalne mere podobnosti, ki smo jih primerjali. Prvih šest mer podobnosti so mere, izpeljane iz vezane entropije (poglavje 3.3), sledi mera podobnosti na osnovi segmentacije, zadnje štiri mere pa so izpeljanke obeh prej omenjenih mer, tako da je vezana porazdelitev najprej predobdelana (poglavje 3.5.2), nato pa uporabljena za izračun točkovne mere. Vsaka mera podobnosti je bila preizkušena na običajnih slikah, slikah z dodanim šumom, slikah s svetlostno nehomogenostjo, nazadnje pa smo mere primerjali tudi ob uporabljenem predhodnem zanjju vezane porazdelitve, ki smo jo določili iz začetnih slik. Pri poravnnavi smo uporabili razmeroma majhno število iteracij, 2 pri originalni ločljivosti, 2 v polovični ločljivosti in 10 za nadaljne tri nižje ločljivosti. Uporabljena začetna transformacija T_0 je bila sestavljena iz šestih Gaussovih funkcij, tako da je bila začetna napaka e enaka 6.9 voksla.

Tabela 5.1: Primerjalni rezultati točkovnih mer podobnosti


S_v	običajne slike	dodan šum	svetl. nehomog.	predh. znanje
$p(\mathbf{i})$	6,74	6,91	7,45	7,90
$p(i_A i_B)$	2,63	2,66	3,73	2,18
$p(i_A - i_B)$	6,57	6,65	6,86	7,06
$\log(p(\mathbf{i}))$	2,56	2,58	2,80	1,20
$\log(p(i_A i_B))$	2,82	2,83	3,00	1,40
$\log(p(i_A - i_B))$	3,89	4,05	4,23	3,29
$p(\mathcal{C}_S \mathbf{i})$	1,26	1,25	2,12	0,94
$p(i_A i_B)p(i_B i_A)$	2,63	2,66	3,74	2,18
$\log(p(i_A i_B)p(i_B i_A))$	2,14	2,14	2,42	0,89
$(p(i_A i_B)p(i_B i_A)) i_B$	1,63	1,72	2,77	1,19
$\log((p(i_A i_B)p(i_B i_A)) i_B)$	2,33	2,35	2,61	0,99

Rezultati primerjave točkovnih večmodalnih mer podobnosti kažejo, da je za vse vrste slik najboljša mera podobnosti na osnovi segmentacije $S_v = p(\mathcal{C}_S|\mathbf{i})$. Med merami, ki so izpeljane iz entropije, je najboljša originalna entropijska mera $S_v = \log(p(\mathbf{i}))$, zelo dobro pa se obnesejo tudi mere, ki temeljijo na produktu $p(i_A|i_B)p(i_B|i_A)$. Najboljši meri, ki ne zahtevata segmentacije, sta tako meri $S_v = \log(p(i_A|i_B)p(i_B|i_A))$ in $S_v = (p(i_A|i_B)p(i_B|i_A))|i_B$. Mere podobnosti, ki uporabljajo verjetnost slike razlik $p(i_A - i_B)$ in mera $S_v = p(\mathbf{i})$ nista primerne za elastično poravnavo slik.

Opazimo lahko nizko občutljivost mer podobnosti na šum. Občutljivost na svetlostne nehomogenosti je večja, posebno velika je za mero podobnosti na osnovi segmentacije. To je pričakovano, saj v primeru svetlostnih nehomogenosti porazdelitev svetlostnih razredov ni mogoče zanesljivo modelirati z Gaussovimi funkcijami.

Po pričakovanjih uporaba predhodnega znanja izboljša rezultate poravnave. Ker mera podobnosti na osnovi segmentacije $S_v = p(\mathcal{C}_S|\mathbf{i})$ že sama ocenjuje kateri razredi pripadajo istemu tkivu na obeh slikah, pri njej predhodno znanje povzroči le manjše izboljšanje rezultatov.

Zanimiva je tudi primerjava izračunanih vezanih podobnosti različnih mer podobnosti, izpeljanih iz iste vezane verjetnosti (slika 5.2). Uporaba vezane verjetnosti $p(\mathbf{i})$ kot mere podobnosti S_v , ni primerna zaradi majhnih verjetnosti slabše zastopanih tkiv. Tako se v glavnem poravnava le tkiva, ki so najbolj pogosta, medtem ko manj pogosta tkiva ostanejo nepravilno poravnana. To izboljša uporaba logaritemske funkcije. Vsi ekstremi vezane podobnosti so tako bolj podobnih amplitud, hkrati pa so velike tudi amplitude ekstremov, ki



Slika 5.2: Vezane podobnosti različnih točkovnih mer podobnosti.


pripadajo napačno poravnanim področjem slik. Razmeroma velike podobnosti dobimo tudi za področja ki pripadajo mešanim vokslom in to ne le na črtah, ki ustrezajo njihovi pravilni poravnavi. Amplitude ekstremov, ki pripadajo napačno poravnanim področjem slik se zelo zmanjšajo pri uporabi mere podobnosti na osnovi segmentacije $S_v = p(\mathcal{C}_S|\mathbf{i})$. Ker mešani vokslji pri tej meri podobnosti niso posebej modelirani, ti tudi ne vplivajo na poravnavo. Mere podobnosti, ki temeljijo na produktu $p(i_A|i_B)p(i_B|i_A)$, kljub temu, da ne potrebujejo segmentacije, bolje ločijo med razredi, ki pripadajo pravilno, oziroma napačno poravnanim področjem slik, kot ostale mere podobnosti brez segmentacije. Vidimo, da te mere razmeroma dobro ocenijo tudi pravilne položaje mešanih voksljov. Mere podobnosti, ki uporabljajo verjetnost slike razlik $p(i_A - i_B)$ zaradi enodimenzionalne statistike mnogo slabše določijo podobnosti svetlostnih parov.

Glede na rezultate primerjave mer podobnosti predlagamo uporabo točkovne večmodalne mere podobnosti na osnovi segmentacije $S_v = p(\mathcal{C}_S|\mathbf{i})$. V posebnih primerih, ko sliki vsebujeta preveč svetlostnih nehomogenosti pa predlagamo uporabo mere $S_v = \log(p(i_A|i_B)p(i_B|i_A))$.

5.2 Primerjava elastičnih modelov

Primerjava elastičnih modelov je zelo težavna. Vsak elastični model najbolje odpravlja takšna slikovna neskladja, za katera lahko transformacijo opišemo kot vsoto njegovih premaknjenih in skaliranih odzivov na enotin impulz. Primernost modela je torej odvisna od pričakovanih slikovnih neskladij. Če bi želeli podati primerjavo primernosti različnih modelov za poravnavo medicinskih slik, bi morali poznati deformacije, ki se pri tem lahko pojavljajo. Deformacije lahko spoznamo le s poravnavo, vendar pa tako dobljena ocena ni verodostojna, saj je odvisna od elastičnega modela, ki je bil pri tem uporabljen. Določitev možnih deformacij moramo zato prepustiti strokovnjakom.

Zaradi nepoznavanja resničnih medicinskih slikovnih neskladij, smo primerjavo modelov izvršili na zahtevni poravnavi dveh umetnih slik (slika 5.3). Gre za sliki valja (poravnavana slika) in kvadra (referenčna slika) velikosti $99 \times 99 \times 99$ voksljov. Sliki imata širok spekter različnih slikovnih neskladij. Na mestu stranic kvadra so potrebne velike visokofrekvenčne deformacije, v točkah večje razdalje od stranic pa vse bolj nizkofrekvenčne deformacije. Zmožnost odpravljanja takšnih neskladij smo preizkusili za elastični filter pri uporabi različnega parametra k_l in za Gaussov filter različnih širin σ . Uporabili smo večločljivostni pristop z dvema iteracijama v prvem nivoju poravnave, sedmimi v drugem in po 20 iteracijami v tretjem in četrtem nivoju. Rezultati poravnave so prikazani na slikah 5.4 in 5.5. Opazimo lahko, da je Gaussov filter zelo primeren za bolj toge modele. Z manjšanjem parametra σ pa se prožnost hitro povečuje. Pri $\sigma = 0.5$ je model že preveč prožen, premiki voksljov slike so med



Slika 5.3: Prerez testne poravnavane slike (levo) in referenčne slike (desno).

seboj skoraj neodvisni, s tem pa poravnava postane nestabilna [27, 37]. Elastičen filter ne omogoča velike togosti poravnave, vendar pa pri njem lažje kontroliramo prožnost modela. Za nastavitve parametra $k_l > 10$ lahko opazimo gubanje slike, kar je fizikalno nedopustno in je tudi posledica prevelike neodvisnosti premikov posameznih vokslov.

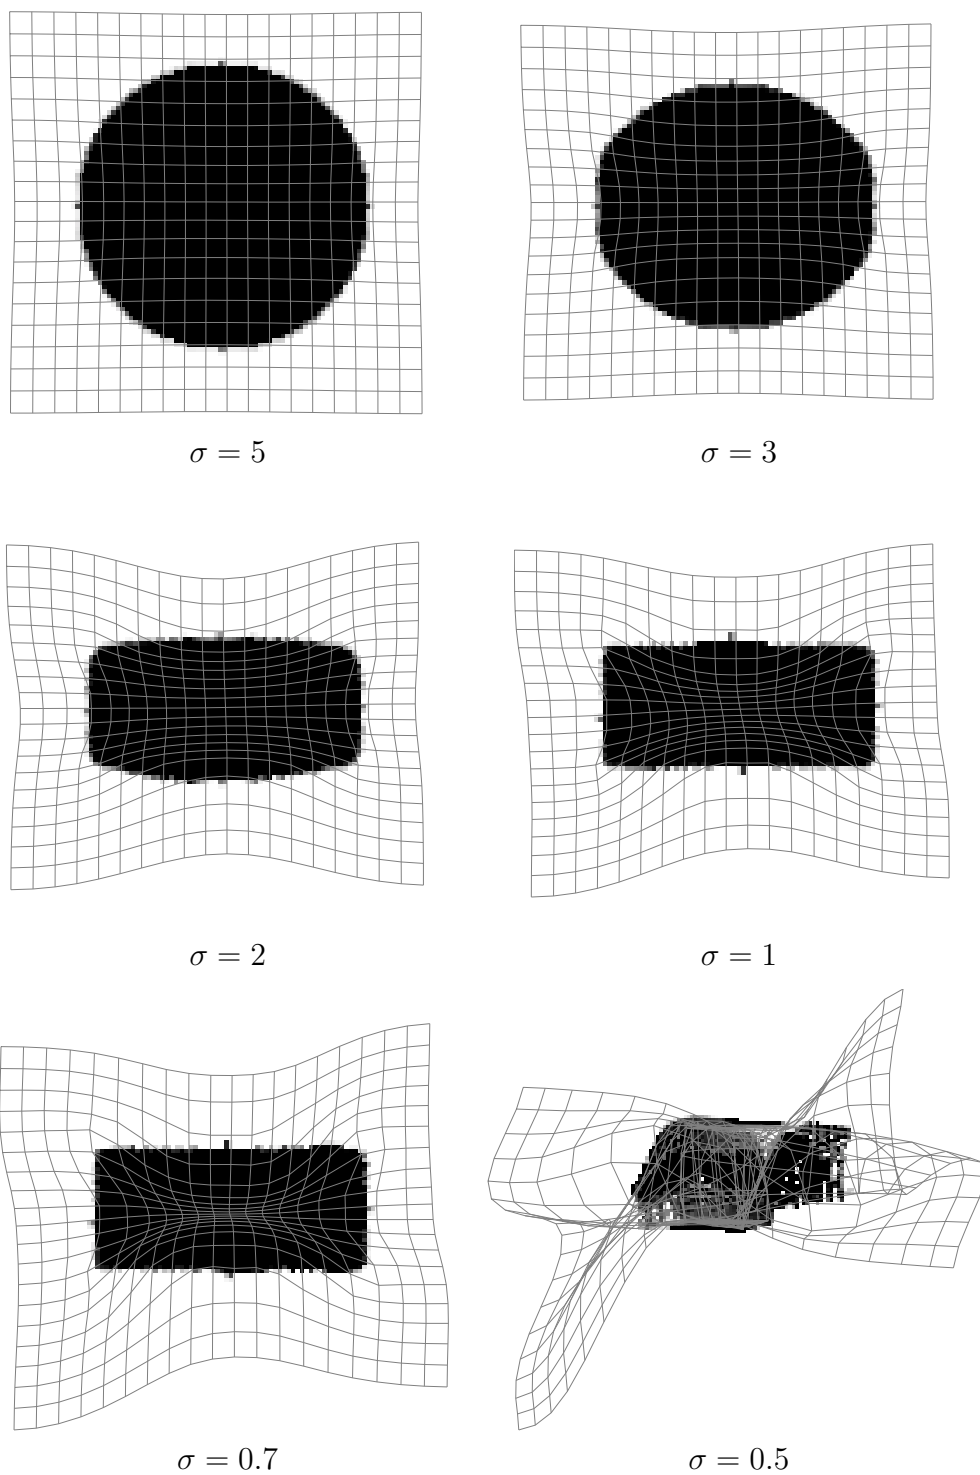
V splošnem je Gaussov filter primernejši za bolj toge, elastični filter pa za bolj prožne modele. Iz impulznih odzivov filtrov je tudi razvidno, da je elastični filter bolj primeren za poravnavanje detajlov, saj ima bolj izrazit ekstrem (slika 5.6). To se pri testni poravnavi kaže v zmožnostih odpravljanja neskladij na stranicah kvadra.

Napake zaradi prevelike prožnosti modela nastajajo predvsem v višjih nivojih poravnave, pri manjši ločljivosti in več še neodpravljenih deformacijah. Zato predlagamo uporabo bolj togih modelov v višjih nivojih, pri nižjih nivojih pa so modeli lahko bolj prožni (slika 5.7).

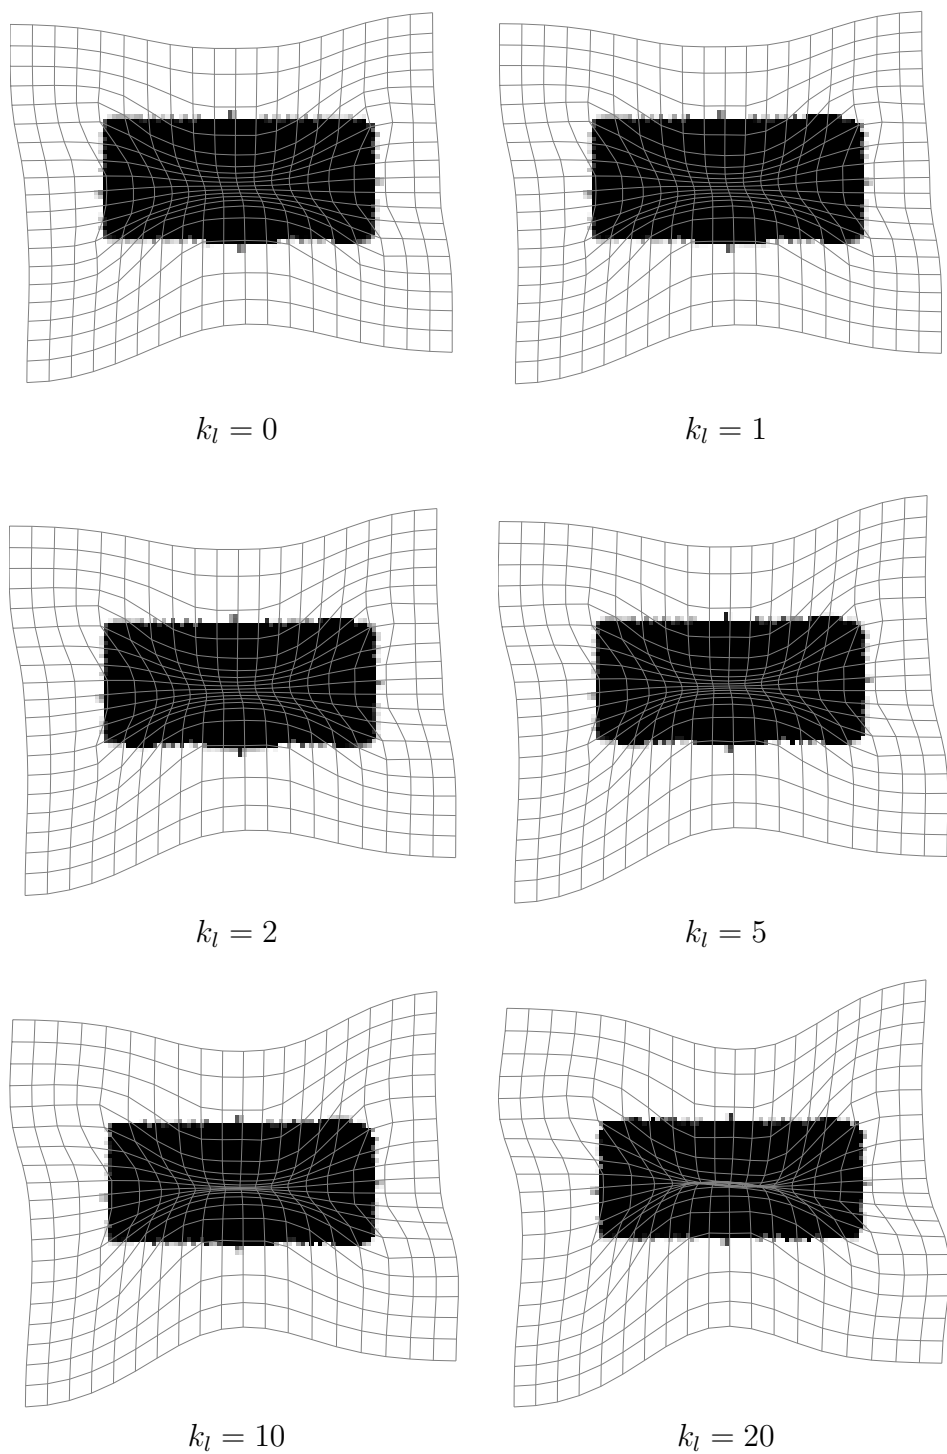
5.3 Izbira uporabljenih metod in ocena sistema

Za večmodalno elastično poravnavo medicinskih slik na osnovi izvedenih poskusov ugotavljamo, da je najprimernejša uporaba mere podobnosti s segmentacijo $S_v = p(\mathcal{C}_S|\mathbf{i})$. Le v posebnih primerih, ko svetlostnih razredov ni mogoče modelirati z Gaussovimi funkcijami, je primernejša mera $S_v = \log(p(i_A|i_B)p(i_B|i_A))$. Prostorska modela deformacij na osnovi elastičnega in Gaussovega filtra se med seboj dopolnjujeta. Za začetne iteracije poravnave, ko je zahtevana večja togost, je primernejši Gaussov filter, za končne iteracije poravnave pa elastični filter.


Celotni sistem je bil preizkušen na dveh primerih poravnave slik glave. Prvi




Slika 5.4: Rezultati poravnave testnih slik pri uporabi Gaussovega filtra.



Slika 5.5: Rezultati poravnave testnih slik pri uporabi elastičnega filtra.




Slika 5.6: Enodimenzionalna impulzna odziva Gaussovega filtra (levo) in elastičnega filtra (desno).



Slika 5.7: Rezultati poravnave testnih slik pri uporabi Gaussovega filtra za višje nivoje poravnave ($\sigma_4 = 2$, $\sigma_3 = 1$) in elastičnega filtra za nižje nivoje poravnave ($k_{l2} = 1$, $k_{l1} = 10$).


primer je poravnava simuliranih slik, kot je opisano v poglavju 5.1. Poravnava je bila izvedena v petih nivojih s po 20 iteracijami. V prvem in drugem nivoju je bil uporabljen uporabili elastičen filter ($k_{l1} = 5, k_{l2} = 0$), v ostalih pa Gaussov filter ($\sigma_3 = \sigma_4 = \sigma_5 = 2$). Uporabljena je mera podobnosti na osnovi segmentacije. Poravnava je potekala brez predhodnega znanja o vezani porazdelitvi svetlosti. Zečetno in končno odstopanje od idealno poravnane slike sta prikazana na sliki 5.8. Izračunana napaka poravnave (5.1) je $e = 0.96$ voksla. To je dober rezultat, vendar pa kaže na nezmožnost sistema za poravnavo z natančnostjo manjšo od velikosti enega voksla.

Poravnavo smo preizkusili tudi na realnih slikah. Na sliki 5.9 je prikazano




Slika 5.8: Razlika med poravnavano sliko in idealno poravnano sliko pred poravnavo (levo) in po poravnavi (desno).

začetno in končno prekrivanje slik različnih oseb. Numerične ocene poravnave zaradi nepoznavanja pravilne transformacije ne moremo podati. Sliki predhodno nista bili toga poravnani, niti jima niso bile odpravljene svetlostne nehomogenosti. Kljub temu lahko opazimo dobro poravnano slik po poravnavi. Deformacija, potrebna za poravnavo, je prikazana na sliki 5.10.



Slika 5.9: Poravnano slik pred poravnavo (levo) in po poravnavi (desno), prikazani po principu šahovnice.



Slika 5.10: Deformacija poravnane slike.

6. Zaključek

V tem magistrskem delu smo se posvetili perečemu problemu večmodalne elastične poravnave medicinskih slik. Glavni problem tovrstne poravnave predstavlja določanje poravnosti majhnih področij slik, kar ocenjujemo z merami podobnosti. Kot rešitev tega problema predlagamo večmodalne točkovne mere podobnosti, ki lokalno poravnost ocenjujejo na osnovi globalnih lastnosti slik. Posebno mesto pripada meri podobnosti na osnovi segmentacije, ki združuje postopka poravnave in segmentacije v sočasen proces in s tem izkoristi prednosti obeh postopkov. Rezultati poravnave, dobljeni s to mero podobnosti so boljši, hkrati pa je rezultat poravnave tudi segmentirana slika.

Velika prednost točkovnih večmodalnih mer podobnosti je izločitev vpliva merjenja podobnosti na lastnosti deformacij, ki so tako odvisne le od prostorskega modela deformacij. Pri tem se je potrebno zavedati, da je neodvisna poravnava posameznih vokslov slike nestabilna, zato mora model deformacij vedno podajati povezavo med položajem sosednjih vokslov in ne sme dopuščati prevelikih prožnosti materiala.

Postopek poravnave je enostaven iterativni proces, kjer zunanje sile v vsaki iteraciji poravnave delujejo v smeri zmanjšanja preostalih slikovnih neskladij. Naš pristop, v katerem zunanje sile odpravljajo le preostala neskladja, izboljša rezultate poravnave, saj so tako potrebne manjše zunanje sile v ravnovesnem stanju, zaradi česar so nepopravljena neskladja manjša. Kljub temu deformacije v vsakem trenutku ustrezajo istemu modelu deformacij, kar je posledica filtriranja celotnih premikov in ne le sprememb, kot je to pri inkrementalnih deformacijah. Kadar so lastnosti inkrementalnih deformacij zaželeno, jih lahko dosežemo tako, da zmanjšamo filtriranje premikov \mathbf{U} ter dodamo filtriranje delnih premikov \mathbf{U}_F .

Posebno pozornost je pri večmodalnih poravnava potrebnost posvetiti uporabljenim metodam predobdelave. Izogibati se je potrebno filtriranjem, interpolaciji in prevzorčenju, saj lahko ti postopki zelo spremenijo vezano porazdelitev svetlosti slik in tako poslabšajo večmodalno poravnavo.


Poravnava, kot je opisana v tem magistrskem delu, je razmeroma enostavna, tudi razmeroma hitra, njeni rezultati pa so obetavni. Za boljšo oceno sistema bi bilo potrebno izvesti večje število poravnave realnih večmodalnih slik, rezultate pa dati v presojo strokovnjakom z medicinskega področja.

6.1 Smernice nadaljnjega dela

Kljub temu, da se pri večmodalni elastični poravnavi srečamo s številnimi problemi, od izbire mere podobnosti do izbire postopkov predobdelave, verjamemo, da bi bilo mogoče doseči točnost poravnave boljše od velikosti enega voksla. V tem primeru bi bilo potrebno upoštevati tudi informacijo, ki jo nosijo mešani vokslji. V prihodnosti nameravamo zato izboljšati mero podobnosti na osnovi segmentacije, tako da bo na osnovi ocene deleža posameznih vsebovanih tkiv pravilno določala tudi podobnost mešanih vokslov. Tako pričakujemo, da bo mešane vokse mogoče natančno poravnali in to celo z večjo gotovostjo kot ostale vokse slike.

Ker na merjenje podobnosti na osnovi segmentacije zelo vplivajo svetlostne nehomogenosti slik, bi bilo odpravljanje svetlostnih nehomogenosti smiselno vključiti v postopek poravnave slik. Tovrstne korekcije slik dajo namreč boljše rezultate, če pri tem uporabimo rezultate segmentacije slik. Tako bi vse tri postopke (poravnavo, segmentacijo in odpravljanje svetlostnih nehomogenosti) združili v en proces in jih izvedli istočasno.

Pri možnih izboljšavah postopka elastične poravnave bi izpostavili problem določanja razmerja k_E med velikostjo zunanjih sil \mathbf{F} in velikostjo posledičnih premikov \mathbf{U}_F . Za različne že dosežene stopnje poravnosti slik ali delov slik bi namreč želeli različno hitrost poravnave. Želeli bi, da se z izboljševanjem medsebojne poravnosti slik zmanjšuje korak poravnave, to je velikost premikov \mathbf{U}_F . Menimo, da bi bilo poravnavo smiselno preučiti tudi z regulacijskega vidika in zato razmerje k_E nadomestili z regulatorjem (slika 6.1). Položaj vsakega voksla slike bi tako regulirali z ločenim regulatorjem. Preučiti bi bilo potrebno vpliv različnih regulatorjev. Pričakujemo, da bi v primeru uporabe PID regulatorja I člen vplival na zmanjšanje napake v ustaljenem stanju, D člen pa bi poravnavo pohitril.



Slika 6.1: Elastična poravnava kot regulacijsku proces.

Za obsežnejše testiranje in praktično uporabo elastične poravnave bo potrebno realizirati tudi togo predporavnavo slik. Rezultat te poravnave ne bo togo poravnana slika, ampak začetna matrika premikov \mathbf{U} elastične poravnave.

Literatura

- [1] K.K. Shung, M.B. Smith, and Tsui B.M.W. *Principles of Medical Imaging*. Academic Press, San Diego, 1992.
- [2] *Basic Principles of MR Imaging*. Philips Medical Systems.
- [3] J. P. Hornak. *The Basics of MRI*. Rochester Institute of Technology, <http://www.cis.rit.edu/htbooks/mri/>, 1997.
- [4] J.B.A. Maintz and M.A. Viergever. A survey of medical image registration. *Medical Image Analysis*, 2(1):1–36, 1998.
- [5] P. A. Van den Elsen, E. J. D. Pol, and M. A. Viergever. Medical image matching - a review with classification. *IEEE Engineering in Medicine and Biology*, 12(1):26–39, 1993.
- [6] C.R. Maurer and J.M Fitzpatrick. A review of medical image registration. In R.J. Maciunas, editor, *Interactive image-guided neurosurgery*, pages 17–44, Park ridge, IL, 1993. American Association of neurological surgeons.
- [7] L.G. Brown. A survey of image registration techniques. *ACM Comput. Surveys*, 24(4):325–376, December 1992.
- [8] B. Klaus and P. Horn. *Robot Vision*, pages 278–285. The MIT Electrical Engineering and Computer Science Series. The MIT Press, Boston, 1986.
- [9] B. Likar and F. Pernus. Automatic extraction of corresponding points for the registration of medical images. *Medical Physics*, 26:1678–1686, 1999.
- [10] K. Rohr. Extraction of 3d anatomical point landmarks based on invariance principles. *Pattern Recognition*, 32(1):3–15, 1999.
- [11] R. Szeliski and S. Lavallee. Matching 3-d anatomical surfaces with non-rigid deformations using octree-splines. *International Journal of Computer Vision*, 18(2):171–186, May 1996.
- [12] Boštjan Likar. Avtomatska poravnava medicinskih slik. Master's thesis, Univerza v Ljubljani, Fakulteta za elektrotehniko, Januar 1998.

-
- [13] C. Broit. *Optimal registration of deformed images*. PhD thesis, University of Pennsylvania, 1981.
- [14] H. Lester and S. R. Arridge. A survey of hierarchical non-linear medical image registration. *Pattern Recognition*, 32(1):129–149, 1999.
- [15] P. Thompson and Toga A. W. Warping strategies for intersubject registration. In I. Bankman, editor, *Handbook of Medical Image Processing*. Academic Press, 1999.
- [16] R. Bajcsy and S. Kovačič. Multiresolution elastic matching. *Computer Vision, Graphics and Image Processing*, 46:1–21, April 1989.
- [17] G.E. Christensen, R.D. Rabbitt, and M.I. Miller. Deformable templates using large deformation kinematics. *IEEE Transactions on Image Processing*, 5(10):1435–1447, 1996.
- [18] M. Bro-Nielsen and C. Gramkow. Fast fluid registration of medical images. *Springer Lecture Notes in Computer Science*, 1131:267–276, 1996.
- [19] C. Gramkow and M. Bro-Nielsen. Comparison of three filters in the solution of the navier-stokes equation in registration. In *Proceedings of the Scandinavian Conference on Image Analysis – SCIA ’97*, pages 795–802, 1997.
- [20] J. C. Gee, L. Le Briquer, C. Barillot, and D. R. Haynor. Probabilistic matching of brain images. In Y. Bizais, C. Barillot, and R. Di Paola, editors, *Information Processing in Medical Imaging*, pages 113–125, 1995.
- [21] James C. Gee. *Probabilistic matching of deformed images*. PhD thesis, Computer and Information Science, University of Pennsylvania, 1996.
- [22] James C. Gee. On matching brain volumes. *Pattern Recognition*, 32(1):99–111, 1999.
- [23] X. Pennec, P. Cachier, and N. Ayache. Understanding the demon’s algorithm. In C.J. Taylor and A. Colchester, editors, *Proceedings of the 2nd International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI’99*, volume 1679 of *Lecture Notes in Computer Science*, pages 597–605. Springer, 1999.
- [24] P. J. Kostelec, J. B. Weaver, and D. M. Healy Jr. Multiresolution elastic image registration. *Medical Physics*, 25(9):1593–1604, September 1998.
- [25] B. Likar and F. Pernuš. A hierarchical approach to elastic registration based on mutual information. *Image and Vision Computing*, 19:33–44, 2001.

-
- [26] B. Likar and F. Pernus. Registration of serial transverse sections of muscle fibers. *Cytometry*, 37(2):93–106, 1999.
- [27] J. B. A. Maintz, H. W. Meijering, and M. A. Viergever. General multimodal elastic registration based on mutual information. *Medical Imaging*, 3338:144–154, 1998.
- [28] I. S. Sokolnikoff. *Mathematical theory of elasticity*. McGraw-Hill, 1977.
- [29] Andrej Umek. *Mehanika deformabilnih teles*. Didakta, 1998.
- [30] Marjan Stanek and Goran Turk. *Osnove mehanike trdnih teles*. Fakulteta za gradbeništvo in geodezijo, Ljubljana, 1998.
- [31] J. C. Gee and Haynor D. R. Numerical methods for high-dimensional warps. In Arthur W. Toga, editor, *Brain warping*, pages 45–65, San Diego, 1999. Academic Press.
- [32] M. Bro-Nielsen. *Medical Image Registration and Surgery Simulation*. PhD thesis, Department of Mathematical Modelling, Technical University of Denmark, 1981.
- [33] F. Maes, A. Collignon, D. Vandermeulen, G. MArchal, and P. Suetens. Multimodality image registration by maximization of mutual information. *IEEE Transactions on Medical Imaging*, 16(2):187–198, April 1997.
- [34] C. Studholme, D.L.G. Hill, and D.J. Hawkes. Automated 3d registration of mr and ct images of the head. *Medical Image Analysis*, 1(2):163–175, 1996.
- [35] G. K. Rohde, A. Aldroubi, and B. M. Dawant. Adaptive free-form deformation for inter-patient medical image registration. In *The Proceedings of the SPIE Symposium on Medical Imaging 2001*, 2001.
- [36] D. Mattes, D. R. Haynor, H. Vesselle, Lewellen T. K., and W. Eubank. Nonrigid multimodality image registration. In *The Proceedings of the SPIE Symposium on Medical Imaging 2001*, 2001.
- [37] T. Gaens, F. Maes, D. Vandermeulen, and Suetens P. Non-rigid multimodal image registration using mutual information. In W.M. Wells, A. Colchester, and S. Delp, editors, *Proceedings of the 1st International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI’98*, number 1496 in Lecture Notes in Computer Science, pages 1099–1106, MIT, Cambridge, MA, USA, October 1998. Springer-Verlag.
- [38] M.E. Leventon and W.E.L. Crimson. Multi-modal volume registration using joint intensity distributions. In W.M. Wells, A. Colchester, and S. Delp, editors, *Proceedings of the 1st International Conference on Medical Image*

-
- Computing and Computer-Assisted Intervention – MICCAI’98*, number 1496 in Lecture Notes in Computer Science, pages 1057–1066, MIT, Cambridge, MA, USA, October 1998. Springer-Verlag.
- [39] J. Weese, P. Rosch, T. Netsch, T. Blaffert, and M. Quist. Gray-value based registration of ct and mr images by maximization of local correlation. In C.J. Taylor and A. Colchester, editors, *Proceedings of the 2nd International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI’99*, volume 1679 of *Lecture Notes in Computer Science*, pages 656–663. Springer, 1999.
- [40] N. Hata, T. Dohi, S.K. Warfield, W.M. Wells, R. Kikinis, and F.A. Jolesz. Multimodality deformable registration of pre- and intraoperative images for mri-guided brain surgery. In W.M. Wells, A. Colchester, and S. Delp, editors, *Proceedings of the 1st International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI’98*, number 1496 in Lecture Notes in Computer Science, pages 1067–1074, MIT, Cambridge, MA, USA, October 1998. Springer-Verlag.
- [41] A. Roche, X. Pennec, L. M. Auer, M. Rudolph, D. P. Auer, G. Malandain, S. Ourselin, and N. Ayache. Generalized correlation ratio for rigid registration of 3d ultrasound with mr images. In S. L. Delp, A. M. DiGioia, and B. Jaramaz, editors, *Proceedings of the 3rd International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI 2000*, volume 1935 of *Lecture Notes in Computer Science*, pages 567–577. Springer, 2000.
- [42] M. Holden, D. L. G. Hill, E. R. E. Dent, J. M Jarosz, T. C. S. Cox, T. Rohlfing, Goodey J., and D. J. Hawkes. Voxel similarity measures for 3-d serial mr brain image registration. *IEEE Transactions on Medical Imaging*, 19(2):94–102, February 2000.
- [43] D. L. G. Hill and D. J. Hawkes. Across-modality registration using intensity-based cost functions. In I. Bankman, editor, *Handbook of Medical Image Processing*, pages 537–553. Academic Press, 1999.
- [44] E.H.W. Meijering, W.J. Niessen, and M.A. Viergever. Retrospective motion correction in digital subtraction angiography: a review. *IEEE Transactions on Medical Imaging*, 18(1):2–21, 1999.
- [45] P. Rogelj and S. Kovacic. Mere podobnosti pri poravnavi slik. In B. Zajc, editor, *Zbornik devete Elektrotehniške in računalniške konference ERK 2000*, volume B, pages 237–240. IEEE Region 8, Slovenska sekcija IEEE, 2000.

-
- [46] N. Ritter, R. Owens, J. Cooper, R.H. Eikelboom, and P.P. Van Saarloos. Registration of stereo and temporal images of the retina. *IEEE Transactions on Medical Imaging*, 18(5):404–418, 1999.
- [47] P. Viola and W. Wells III. Alignment by maximization of mutual information. In *Proceedings of the 5th International Conference on Computer Vision*, pages 16–23, 1995.
- [48] P.A. Viola. *Alignment by maximization of mutual information, Ph.D. thesis*. MIT, MA Cambridge, 1995.
- [49] I. J. Taneja. On generalized information measures and their applications. *Advances in Electronics and Electron Physics*, 67:327–413, 1989.
- [50] C. Studholme, D.L.G. Hill, and D.J. Hawkes. An overlap invariant entropy measure of 3d medical image alignment. *Pattern Recognition*, 32:71–86, 1999.
- [51] P. Rogelj and S. Kovacic. Local similarity measures for multimodal image matching. In S. Loncaric, editor, *Proceedings of the first International Workshop on Image and Signal Processing and Analysis – IWISPA 2000*, pages 81–86. University Computing Center, University of Zagreb, 2000.
- [52] J. P. W. Pluim, J. B. A. Maintz, and M. A. Viergever. Interpolation artefacts in mutual information based image registration. *Computer Vision and Image Understanding*, 77(2):211–232, 2000.
- [53] F. Maes, D. Vandermeulen, and P. Suetens. Comparative evaluation of multiresolution optimization strategies for multimodality image registration by maximization of mutual information. *Medical Image Analysis*, 3(4):373–386, 1999.
- [54] S. Kovačič and R. Bajcsy. Multiscale/multiresolution representations. In Arthur W. Toga, editor, *Brain warping*, pages 45–65, San Diego, 1999. Academic Press.
- [55] J. P. W. Pluim, J. B. A. Maintz, and M. A. Viergever. A multiscale approach to mutual information matching. In K.M. Hanson, editor, *Medical Imaging: Image Processing*, volume 3338 of *Proc. SPIE*, pages 1334–1344. SPIE Press, Bellingham, WA, 1998.
- [56] B. M. ter Haar Romeny. Introduction to scale-space theory: Multiscale geometric image analysis. In *Conf. on Visualization in Biomedical Computing VBC’96*, July 1999.
- [57] A. Roche, G. Malandain, N. Ayache, and S. Prima. Towards a better comprehension of similarity measures used in medical image registration. In C.J. Taylor and A. Colchester, editors, *Proceedings of the 2nd*

-
- International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI’99*, volume 1679 of *Lecture Notes in Computer Science*, pages 555–566. Springer, 1999.
- [58] B. Likar and F. Pernus. A hierarchical approach to elastic registration based on mutual information. In F. Pernus, S. Kovačič, H. S. Stiehl, and M. A. Viergever, editors, *Proceedings of the Workshop on Biomedical Image Registration - WBIR’99*, pages 24–45, August 1999.
- [59] T. M. Buzug, J. Weese, C. Fassnacht, and C. Lorenz. Elastic matching based on motion vector fields obtained with a histogram based similarity measure for dsa-image correction. *Computer Assisted Radiology and Surgery*, pages 139–144, 1997.
- [60] C. Studholme, Hill. D.L.G., and D.J. Hawkes. Using voxel similarity as a measure of medical image registration proc. In E. Hancock, editor, *Proceedings of the British machine vision conference – BMV’94*, pages 235–244, 1994.
- [61] D.H. Laidlaw, K.W. Fleischer, and A.H. Barr. Partial-volume bayesian classification of material mixtures in mr volume data using voxel histograms. *IEEE Transactions on Medical Imaging*, 17(1):74–86, 1998.
- [62] J. C. Rajapakse, J. N. Giedd, and J. L. Rapoport. Statistical approach to segmentation of single-channel cerebral mr images. *EEE Transactions on Medical Imaging*, 16(2):176–186, April 1997.
- [63] P. Rogelj and S. Kovacic. Similarity measures for non-rigid registration. In *The Proceedings of the SPIE Symposium on Medical Imaging 2001*, 2001.
- [64] P. Rogelj and S. Kovacic. Similarity measures for non-rigid registration. In B. Likar, editor, *Proceedings of Sixth Computer Vision Winter Workshop CVWW’01*, pages 82–91. Slovenian Pattern Recognition Society, 2001.
- [65] B. Likar, J. B. A. Maintz, M.A. Viergever, and F. Pernus. Retrospective shading correction based on entropy minimisation. *Journal of Microscopy*, 197(3):285–295, 2000.
- [66] <http://www.bic.mni.mcgill.ca/brainweb/>.
- [67] C. A. Cocosco, V. Kollokian, R.K.-S. Kwan, and A.C. Evans. Brainweb: Online interface to a 3d mri simulated brain database. In *NeuroImage*, volume 5, May 1997.
- [68] R.K.-S. Kwan, A.C. Evans, and G. B. Pike. *An Extensible MRI Simulator for Post-Processing Evaluation*, volume 1131 of *Lecture Notes in Computer Science*, pages 135–140. Springer-Verlag, May 1996.

- [69] 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. In *IEEE Transactions on Medical Imaging*, volume 17, pages 463–468, June 1998.

Izjava

Izjavljam, da sem magistrsko delo izdelal samostojno pod vodstvom mentorja prof. dr. Stanislava Kovačiča univ. dipl. inž. el. Izkazano pomoč drugih sodelavcev sem v celoti navedel v zahvali.

Ljubljana, april 2001

Peter Rogelj

Strokovni življenjepis avtorja

Peter Rogelj se je rodil 26.1.1975. Po končani osnovni šoli na Vačah se je vpisal na Srednjo šolo za elektrotehniko in računalništvo v Ljubljani, ki jo je končal z odličnim uspehom. Na Fakulteto za elektrotehniko se je vpisal leta 1993. Izbral je študijsko smer elektrotehnika-avtomatika-procesna avtomatika in leta 1998 diplomiral na področju računalniškega vida. Od novembra 1998 je zaposlen na Fakulteti za elektrotehniko kot mladi raziskovalec, kjer se ukvarja z obdelavo biomedicinskih slik in z računalniškim vidom.

Objavljena dela

- [1] Peter Rogelj, Stanislav Kovačič. Odčitavanje serijske številke električnih števecov. V: Baldomir Zajc (ur.). *Zbornik sedme Elektrotehniške in računalniške konference ERK '98, 24. - 26. september 1998, Portorož, Slovenija*. Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 1998, zv. B, str. 301-304.
- [2] Peter Rogelj, Simon Dobrišek, France Mihelič. Govorni uporabniški vmesnik v industrijskem okolju. V: Baldomir Zajc (ur.). *Zbornik osme Elektrotehniške in računalniške konference ERK '99, 23. - 25. september 1999, Portorož, Slovenija*. Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 1999, zv. B, str. 233-236.
- [3] Peter Rogelj, Stanislav Kovačič. Local similarity measures for multinodal image matching. V: Sven Lončarić (ur.). *IWISPA 2000 : proceedings of the first international workshop on image and signal processing and analysis in conjunction with 22nd international conference on information technology interfaces, Pula, Croatia, June 14-15, 2000*. Zagreb: University Computing Center, University of Zagreb, 2000, str. 81-86.
- [4] Peter Rogelj, Stanislav Kovačič. Mere podobnosti pri poravnavi slik. V: Baldomir Zajc (ur.). *Zbornik devete Elektrotehniške in računalniške konference ERK 2000, 21. - 23. september 2000, Portorož, Slovenija*. Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2000, zv. B, str. 237-240.
- [5] Peter Rogelj, Stanislav Kovačič. Similarity measures for multimodal elastic matching. V: Ida Eržen (ur.), Draga Štiblar-Martinčič (ur.). *Life sciences 2000, Gozd Martuljek, September 28th to October 1st, 2000 : programme, abstracts*. Ljubljana: Slovenian Society for Stereology and Quantitative Image Analysis, 2000, str. 35.
- [6] Peter Rogelj, Stanislav Kovačič. Similarity Measures for Non-Rigid Registration. V: Boštjan Likar (ur.). *Proceedings of Sixth Computer Vision Winter Workshop CVWW'01, Bled, Slovenija, February 7-9, 2001*. Ljubljana: Slovenian Pattern Recognition Society, 2001, str. 82-91.
- [7] Peter Rogelj, Stanislav Kovačič. Similarity Measures for Non-Rigid Registration. V: *The Proceedings of the SPIE Symposium on Medical Imaging 2001, San Diego, California, USA, February 17-23, 2001*.