

**KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
SISTEMINĖS ANALIZĖS KATEDRA**

Ramūnas Maknickas

**KOMPIUTERINE VAIZDŲ ANALIZĖ
PAGRĮSTOS SISTEMOS, SKIRTOS GALVOS
SMEGENŲ TYRIMAMS, ANALIZĖ IR
ALGORITMŲ PLĖTRA**

Magistro darbas

**Vadovas
dr. V. Punys**

KAUNAS, 2005

**KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
SISTEMINĖS ANALIZĖS KATEDRA**

**TVIRTINU
Katedros vedėjas
prof. habil. dr. R. Barauskas
2005-05-23**

**KOMPIUTERINE VAIZDŲ ANALIZĖ
PAGRĮSTOS SISTEMOS, SKIRTOS GALVOS
SMEGENŲ TYRIMAMS, ANALIZĖ IR
ALGORITMŲ PLĖTRA**

Informatikos mokslo magistro baigiamasis darbas

**Kalbos konsultantė
Lietuvių k. kat. lekt.
dr. J. Mikelionienė
2005-05-19**

**Recenzentas
doc. dr. K. Plukas
2005-05-19**

**Vadovas
dr. V. Punys
2005-05-19**

**Atliko
IFM 9/1 gr. stud.
R. Maknickas
2005-05-19**

KAUNAS, 2005

TURINYS

PAVEIKSLŲ SĄRAŠAS.....	6
SUMMARY.....	7
ĮVADAS	8
1. Žmogaus smegenų vizualizavimas virtualioje trimatėje erdvėje.....	11
1.1. Smegenų modelių koordinačių sistemos.....	11
1.1.1. Talairacho koordinačių sistema	11
1.1.2. MNI koordinačių sistema	13
1.1.3. MNI sistemos transformacija į Talairacho koordinačių sistemą	13
1.2. Atlasų tipai	15
1.2.1. Atlasų klasifikacija pagal duomenų tipus	15
1.2.1.1. MR vaizdų atlasai	15
1.2.1.2. Kriopjūviniai vaizdai	16
1.2.1.3. Daugiamodaliniai atlasai	16
1.2.1.4. Trimačiai anatomiciniai modeliai	17
1.2.2. Atlasų klasifikacija pagal elgseną su jais	17
1.2.2.1. Deformuojami atlasai	17
1.2.2.2. Tikimybinių atlasų sudarymo metodai.....	18
1.3. Segmentacijos algoritmai	19
1.4. Korespondencijos metodai	22
1.4.1. Taškų sulyginimo algoritmų apžvalga	22
1.4.1.1. Nepriklausomi metodai sprendžiantys transformacijos uždavinį	23
1.4.1.2. Nepriklausomi metodai sprendžiantys korespondencijos uždavinį	23
1.4.1.2.1. Aukštesnio lygio savybių naudojimas struktūroms	23
1.4.1.2.2. Lokalių ar globalių figūros atributų naudojimas	24
1.4.1.2.3. Erdvinės atitikties informacijos naudojimas.....	24
1.4.1.3. Jungtiniai metodai sprendžiantys korespondencijos ir transformacijos uždavinį	24
1.4.1.3.1. Metodai traktuojantys korespondenciją kaip dvejetainį kintamąjį.	25
1.4.1.3.2. Metodai traktuojantys korespondenciją kaip tolydujį kintamąjį	25
1.4.2. Stiprus taškų palyginimo algoritmas.....	26
1.4.2.1. Minimizavimo algoritmas.....	26
1.4.2.2. Transformacijos naudojimas.....	28

1.5. Registracijos algoritmai.....	29
1.5.1. Bendra registracijos algoritmo schema.....	29
1.5.2. Vaizdų registracijos algoritmų klasifikacija.....	30
1.5.2.1. Savybių erdvė.....	31
1.5.2.2. Iškraipymo erdvė.....	32
1.5.3. Vaizdų panašumo matas.....	33
1.5.3.1. Vidutinė kvadratinė paklaida.....	33
1.5.3.2. Koreliacijos koeficientas.....	33
1.5.3.3. Abipusė informacija.....	34
1.6. Transformacijos funkcijos.....	35
1.6.1. Globalinės transformacijos.....	35
1.6.1.1. Polinominė transformacija.....	35
1.6.1.2. Paviršiaus splineų transformacija.....	36
1.6.1.3. Multikvadratinė transformacija.....	37
1.6.2. Lokalinės transformacijos.....	38
1.6.2.1. Dalimis tiesinė transformacija.....	38
1.6.2.2. Lokalinė svorinio vidurkio transformacija.....	39
1.6.2.3. Svorinis mažiausių kvadratų metodas.....	41
1.6.2.4. Plonos plokštelės splainas.....	42
1.6.2.5. Kubinis B-splainas.....	43
2. Taškų optimalių padėčių plokštumoje radimas naudojant splainus.....	44
2.1. Struktūrų kontūrų taškų radimas naudojant Overhauzerio kreivę.....	44
2.2. Overhauzerio splaino taškų padėčių plokštumoje optimizacija.....	46
2.3. Splaino fragmentų radimas.....	49
2.4. Splaino taškų padėčių optimizavimo modeliavimo rezultatai.....	51
IŠVADOS.....	55
LITERATŪRA.....	56
SANTRUMPŲ IR TERMINŲ ŽODYNAS.....	58
PRIEDAI.....	59
1 priedas. Kontolinių duomenų pavyzdys, skirtas taškų padėčių optimizacijai rasti.....	59
2 priedas. Trimačių žmogaus smegenų vizualizacija su išvardintomis struktūromis.....	60
3 priedas. Pagrindinių žmogaus smegenų neurostruktūrų ir jų grupių pavadinimai.....	62
4 priedas. „Visible Human Project“ aksialinio pjūvio nuotrauka.....	63

PAVEIKSLŲ SĄRAŠAS

1 pav. Vieno asmens magnetinio rezonanso nuotraukos	9
2 pav. Pagrindiniai Talairacho-Tournouxo atlaso komponentai	12
3 pav. Pasirinkto pjūvio tikslesnis Talairach sistemos vaizdas	12
4 pav. Talairacho ir MNI koordinačių sistemų koronalinio pjūvio vaizdai.....	13
5 pav. Žmogaus smegenų MRI vaizdų segmentavimo algoritmų klasių schema.....	20
6 pav. Netiesinė taškų palyginimo (registracijos) problema.....	22
7 pav. Vaizdų registracijos veiksmų schema.....	30
8 pav. Transformacijos funkcijų klasifikacija	30
9 pav. Gauti tiksliniai vaizdai, atlikus globalines transformacijas.....	37
10 pav. Gauti tiksliniai vaizdai, atlikus globalines transformacijas.....	37
11 pav. Gauti tiksliniai vaizdai.....	39
12 pav. Tiksliniai ir nuorodiniai vaizdai.....	40
13 pav. Overhauzerio kreivių fragmentai	46
14 pav. Didžiausio atstumo nuo atkarpos iki splaino reikšmės radimas	49
15 pav. Funkcijos G parametrų reikšmės	50
16 pav. Kontrolinių taškų pavyzdys ir jų interpoliavimas splainu	51
17 pav. Taškų padėčių optimizacijos pavyzdžiai, esant įvairioms paklaidos R reikšmėms	52
18 pav. Aproximuotų taškų skaičiaus priklausomybė nuo nustatytos paklaidos R	53
19 pav. Bendros atkarpų ilgių sumos priklausomybė nuo nustatytos paklaidos R	53
20 pav. Aproximuotų taškų skaičiaus priklausomybė nuo atstumo R paklaidos	54

KOMPIUTERINE VAIZDŲ ANALIZĖ PAGRĮSTOS SISTEMOS, SKIRTOS GALVOS SMEGENŲ TYRIMAMS, ANALIZĖ IR ALGORITMŲ PLĖTRA

Summary

One of the main problems in neurosurgery is knowledge about human brain. It's very important to see the whole brain with its critical neurostructures in virtual reality. This document is about three dimensional human brain visualization strategies. Review most recently used three dimensional objects building strategies from two dimensional medical MRI images. This task was split into 4 significant problems: image segmentation, point-sets correspondence, image registration and its frequently used transformation functions with image matching measurements. All these problems were addressed reader to show most recently used algorithms with advantages and disadvantages. Atlas types, patterns and maps survey was introduced with widely popular brain model coordinate systems.

In order to find a better correspondence between two point sets it was modeled a new robust and accurate Overhauser spline points location optimization algorithm. Instead of deletion outlier points from overloaded point set, this algorithm generates more points in other set at optimized points locations. Determination of an accurate point location and choosing the correct transformation function are the key steps in registration process. Whereas registration is vital task in precise human brain visualization for neurosurgeries at preoperative and intraoperative process.


ĮVADAS

Vienas iš svarbiausių neurochirurgijos tikslų yra kaukolės ir smegenų pažinimas. Prieš išrandant kompiuterinę tomografiją, tradicinėje neurochirurgijoje chirurgai operuodavo ligonių galvos smegenis remdamiesi savo nuomone apie jų struktūrą ir netiesiogine informacija, gauta iš rentgeno nuotraukų ir neurologinių tyrimų, o rankų judesiai buvo pagrįsti „koordinacija iš akies“. Tokia chirurgijos padėtis buvo labai komplikuluota norint nustatyti pažeistą žmogaus smegenų sritį ir lokalizuoti jos padėtį.

Kompiuterizuoti medicininiai vaizdai – kompiuterinės tomografijos vaizdai (KT) (*CT – Computer Tomography*), o vėliau ir magnetinio rezonanso vaizdai (MR) (*MRI – Magnetic Resonance Imaging*) sukėlė revoliuciją ne vien radiologijoje, bet ir neurochirurgijoje. Chirurgai dabar gali iš nuotraukų matyti pažeidimus, pakitimus ir neurologinių problemų priežastis. Kitas neurochirurgijos aspektas yra neurochirurginių operacijų planavimas. Kompiuteriu gauti vaizdai yra labai svarbūs. Jų pagalba atliekamas gauto vaizdo objekto struktūros bei jo padėties realioje fiziniėje erdve sutapatinimas. Tokių vaizdų naudojimas chirurgijos operacijai vis tiek reikalauja chirurginės patirties, neuronavigacijos įgūdžių. Nors operacijos metu šie vaizdai ir yra kabinami švieslentėje, neuronavigacija (t.y. orientavimasis realioje erdvėje tarp neurostruktūrų) yra gana komplikuluota. Orientavimasis naudojant dvimačius vaizdus ir chirurgijos instrumento judesio trajektorija (t.y. kelias nuo odos iki reikiamos smegenų struktūros) yra retai suderinami, kas ir tapo chirurgų užduotimi nustatyti tikslią padėtį erdvėje naudojantis dvimačiais vaizdais. Dar daugiau komplikuluojant užduotį galima pasakyti, kad smegenų pakitimai, pavyzdžiui, augliai, yra gerai matomi tiek KT, tiek MR vaizduose, tačiau aplinkinės struktūros yra sunkiai įžiūrimos. Tik naudojantis tikslia sveikų aplinkinių struktūrų lokalizacija erdvėje, galima nustatyti reikiamą kelią iki auglio [7]. Toks uždavinys yra keliamas operacijos metu operuojant pacientą bei ikioperacinio pasiruošimo atlikimui. Operacijos metu naudojantis chirurginiais instrumentais ir vadovaujantis magnetinio rezonanso nuotraukomis, galima tiksliau lokalizuoti reikiamą smegenų sritį (*ROI – Region of Interest*) ir instrumento padėtį erdvėje. Esant itin brangiai medicininiai aparatūrai, toks uždavinys praktikoje yra keliamas retai. Taigi chirurgams priešoperacinis pasiruošimas yra būtinas, todėl smegenų trimačio modelio, sudaryto naudojantis diagnostinėmis dvimatėmis nuotraukomis, vizualizavimas virtualioje erdvėje labai palengvintų chirurgų darbą. Daugelis chirurginių procedūrų reikalauja aukšto tikslumo taškų lokalizacijos tam, kad chirurgai galėtų prieiti prie tikslinės struktūros su minimaliu aplinkinių struktūrų pažeidimu.

MR ir KT vaizdai, paprastai, yra gaunami kaip aibė skenuotų smegenų įvairiuose pjūviuose. Dažniausiai skenavimo tankis (atstumas tarp nuotraukų) yra parenkamas nuo 1 iki 3 mm. Skenuojama kas fiksuotą atstumą pagal pasirinktą ašį. Taip gauta aibė dvimačių (2D) vaizdų sudaro

vieną trimatį (3D) vaizdą. Naudosimės tik magnetinio rezonanso nuotraukomis, nes juose yra tiksliau matomos vidinės struktūros.



1 pav. Vieno asmens magnetinio rezonanso nuotraukos: (a), (b), (c) Sveikų smegenų struktūrų nuotraukos; (d), (e), (f) Smegenų struktūrų nuotraukos su augliu; (a), (d) Koronarinis pjūvis; (b), (e) Sagitalinis pjūvis; (c), (f) Aksialinis pjūvis

Kaip matyti, šiuose magnetinio rezonanso nuotraukose yra lengvai matomas auglio dydis ir forma. Tokie vaizdai yra saugomi DICOM (*DICOM – Digital Imaging and Communications in Medicine*) formatu. Turint didesnio formato nuotraukas galima tiksliau pasakyti taškų padėtį erdvėje. Vaizdų skiriamąją gebą lemia ir bitų skaičius, skirtas saugoti kiekvieno taško pilkumos reikšmei. Šis duomenų formatas yra plačiai paplitęs ir yra patogus vaizdų apdorojimui dėl gero archyvavimo algoritmo bei papildomos informacijos apie skenavimą, pacientą, fizikinių, erdvinį skenavimo parametrų gausos saugojimo galimybes.

Turint vieno konkretaus paciento duomenų (vaizdų) aibę galima sudaryti trimatį vaizdą išskiriant reikiamas smegenų struktūras. Tam yra atliekama:

- Vaizdų segmentacija;
- Taškų padėties optimizacija;
- Taškų korespondencija;
- Vaizdų registracija;
- Gautų taškų erdvinė trianguliacija;
- Turimų objektų trimatė vizualizacija.

Norint pasiekti tikslą, reikia įsigilinti į visus minėtus uždavinius ir gautas rezultatas bus tik poodinio sluoksnio, kaukolės, edemos, auglio bei skilvelių trimačių struktūrų vizualizavimas virtualioje erdvėje. Šis rezultatas nėra pakankamas, kad priešoperacinis pasiruošimas būtų išsamus ir būtų nustatytas tikslus neoronavigacijos kelias. Būtina įvertinti ir atskiras vidines smegenų struktūras, kurios yra neaiškiai matomos vaizduose. Chirurgui yra žinoma kiekvienos struktūros funkcinė paskirtis ir jų pažeidimo pasekmės. Prieš atliekant operaciją yra nustatomas tikslus kelias nuo kaukolės iki auglio. Tad norint aiškiai matyti vidines struktūras, lokalizuoti jų padėtis erdvėje, yra pasitelkiamas sveikų smegenų trimačio modelio atlasas su iš anksto lokalizuotomis struktūromis. Vaizdas šiame kontekste tampa gidu deformuojant turimą atlasą. Kadangi atlasas yra apriorinė informacija apie paciento smegenų struktūrų padėtis erdvėje, tai trimačių vaizdų vizualizacija nėra problemiškas uždavinys.

Šio darbo 1-ajame skyriuje bus tiksliau peržvelgti visi keliami uždaviniai ir standartiniai jų sprendimo būdai. Labiau bus orientuojamasi į taškų korespondenciją, vaizdų registraciją, kuri susideda iš vaizdų transformacijos ir vaizdų panašumo palyginimo, ir taškų padėties optimizaciją. Pastaroji bus plačiau nagrinėjama 2-ajame skyriuje. Taškų padėčių optimizacijos pagalba bus surastos tokios taškų padėtys erdvėje, kad minimizavus taškų skaičių, būtų išlaikyta nagrinėjamos neurostruktūros figūra ir forma.

1. Žmogaus smegenų vizualizavimas virtualioje trimatėje erdvėje

1.1. Smegenų modelių koordinačių sistemos

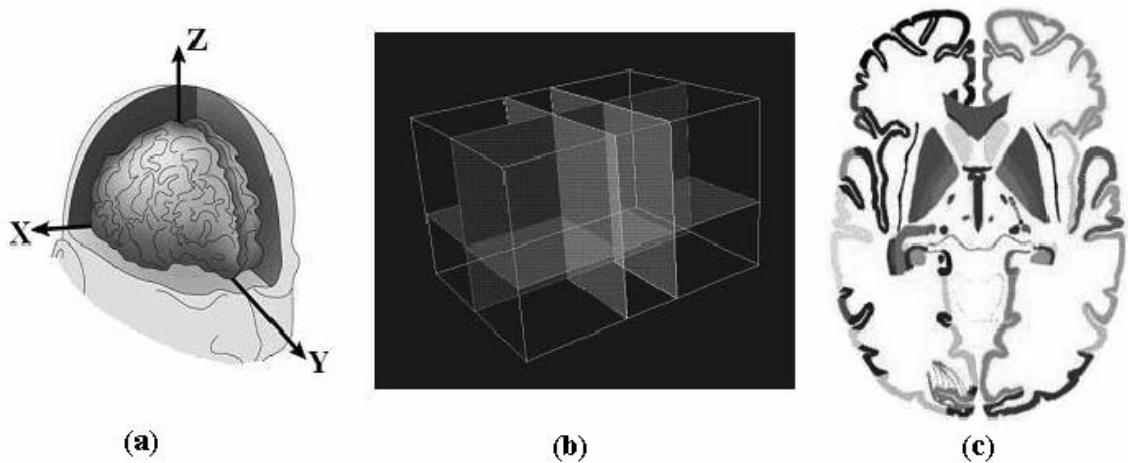
Egzistuojančiose atlasuose, proporcinės matavimo sistemos yra naudojamos nustatyti ryšį tarp duotų smegenų vaizdo ir smegenų atlaso. Tam, kad būtų suvienodintos visų smegenų formos ir kiekvienam taškai erdvėje vienoje smegenyse būtų surastas atitinkamas taškas kitose smegenyse, reikia įsivesti koordinačių sistemą.

1.1.1. Talairacho koordinačių sistema

Didelį poreikį žmogaus pažinimui turi greitas anatominių ir funkcinių vaizdų registracijos, vaizdų sintezės ir vizualizacijos (vaizdavimo) technologijų augimas. Detaliems aukštos skiriamosios gebos vaizdams dabar gali būti atlikta funkcinių vaizdų, gautų iš funkcinio magnetinio rezonanso (*fMRI – functional Magnetic Resonance Images*) ir pozitronų emisijos tomografo (*PET – Positron Emission Tomography*), tiksli registracija. Šie vaizdai teikia svarbią vaizdinę informaciją apie smegenų atskirų sričių aktyvumą [9].

Norint palengvinti kelių asmenų smegenų modelių tarpusavio registraciją, taškų lokalizacija turi būti atlikta standartizuotoje erdvėje. Šiam tikslui pasiekti yra atliekama erdvinė normalizacija (*spatial normalization*). Pastaroji ir sričių žymėjimas yra kritiniai procesai nustatant kelių asmenų vaizdų palyginimo efektyvumą. Koregistruoti (normalizuoti) anatominiai ir funkciniai skenavimai sulyginant su šabloninėmis smegenimis (atlasu) yra transformuojami. Visi taškai yra sužymėti trimis koordinatėmis x - y - z , vadinamomis stereotaksinėmis (*stereotaxic*) koordinatėmis. Makroanatominės struktūros yra didžiosios smegenų struktūros, bei smegenų vingiai (*gyri/sulci*). Mikroanatominės struktūros yra mikroskopinės žievės dalelytės. Talairacho koordinačių sistemos pagalba galima sužymėti tiek makroanatomines, tiek mikroanatomines struktūras.

1988 metais Talairachas(Talairach) ir Tournouxas(Tournoux) suskirstė kas 1 mm. visą smegenų modelį ir sužymėjo struktūras. Autoriai atliko tris svarbius darbus: sudarė standartinę koordinačių sistemą identifikuojančią smegenų struktūrų padėtis erdvėje; atliko erdvinę normalizaciją, kurios pagalba galima sulyginti vieną smegenų modelį su kitu; sužymėjo visiems erdviniams taškams anatomines struktūras, priskirdamas anatominius ir citoarchitektūrinius pavadinimus [11].

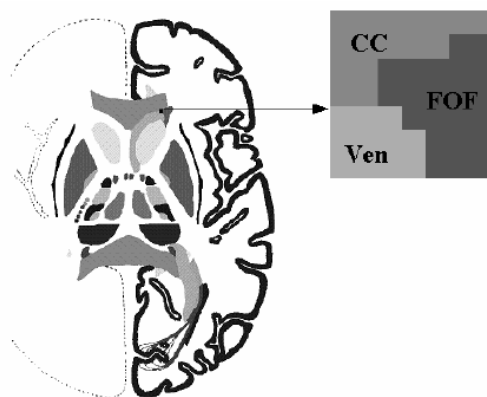


2 pav. Pagrindiniai Talairacho-Tournouxo atlaso komponentai: (a) Koordinacių sistema; (b) Proporcinė gardelė erdvinei normalizacijai atlikti; (c) Sužymėtasis atlasas

Ši koordinacių sistema yra sudaryta pagal priekinę jungtį (PJ) (*AC – Anterior commissure*) ir galinę jungtį (GJ) (*PC – Posterior commissure*) – dvi mažas požievinės struktūras, kurios normalių smegenų atžvilgiu yra santykinai pastovioje vietoje. Koordinacių sistemos pradžia eina per PJ. Oy ašis kerta abi jungtis. Oz ašis yra vertikali ir einanti tarp pusrutulių ir kertanti PJ. Tikslesnę jų kryptį matome 2 pav.(a) dalyje.

Erdvinė normalizacija atliekama taip: smegenų vaizdai yra pervedami į Talairacho koordinacių sistemą, ir tada pakeičiami jų masteliai taip, kad atstumas tarp dviejų jungčių PJ ir GJ sutaptų abiejuose vaizduose. Atstumai nuo PJ iki didžiausios Oy ašies reikšmės, mažiausios Oz reikšmės ir Ox ašies kampinių reikšmių, taip pat atstumai nuo GJ iki smegenų modelio mažiausios Oy ašies reikšmės yra taip pat pakeičiami. Ši transformacija yra žinoma, kaip Talairacho proporcinio tinklelio normalizavimas. Kaip 2 pav.(b) matyti, tinklelio taškai nėra vienodai pasiskirstę.

Talairacho koordinacių sistemos atlasas yra sudarytas naudojantis mirusios moters įstrižų, sagitalinių, koronarinių(vainikinių) vaizdų smegenų pjūvių serijomis. Detalesnį atlaso vaizdą galima matyti 3 pav.




3 pav. Pasirinkto pjūvio tikslesnis Talairacho sistemos vaizdas. CC – Corpus Collosum, Ven – Ventriculus, FOF – Fasciculus occipitio frontalis

1.1.2. MNI koordinacių sistema

Kitas labai svarbus ir plačiai naudojamas yra MNI (*MNI – Montreal Neurological Institute*) smegenų šablonas. Jis nežymiai skiriasi nuo Talairacho atlaso. MNI norėjo aprašyti smegenų modelį, kuris daugiau tiktų žmonių populiacijai. Buvo sudarytas naujas šablonas, kuris buvo apytiksliai sutapatintas su Talairacho sistemos smegenų modeliu (šablonu). Pirma, buvo paimti normalūs 241 asmens MR vaizdai ir rankiniu būdu sužymėtos anatomijos struktūros. Vaizdai buvo sunormalizuoti. Visiems vaizdams buvo pakeistas mastelis, kad struktūros apytiksliai sutaptų su Talairacho atlasu. Tada paimti normalūs 305 (239 vyrai, 66 moterys; amžius: 23.4 ± 4.1 metų) asmenų MR skenavimai ir panaudota automatinė 9 parametru tiesinė transformacija, kuri šiuos skenavimus sulygino su vidutiniu 241 asmens vaizdu [1]. Tokiu būdu turimų 305 asmenų vaizdai buvo transformuoti ir suvidurkinti, ir gautas atlasas pavadintas MNI305. Dėl didelios populiacijos apimties, smulkiose struktūrose gauti dideli variantiškumai. MNI305 buvo pirmasis MNI šablonas. Dabartinis MNI šablonas yra ICBM152, kuris yra gautas 152 normalių asmenų MR smegenų nuotraukas sulyginus su MNI305 šablonu, tam panaudojus 9 parametru afiniją transformaciją.

1.1.3. MNI sistemos transformacija į Talairach koordinacių sistemą

Problema yra ta, kad tiesinė transformacija MNI šablono tiksliai netransformuoja į Talairacho sistemos atlaso modelį. Gaunasi taip, kad MNI šablono smegenų modelis yra didesnis nei Talairacho sistemos smegenų modelis [1]. Skirtumai didėja tolstant nuo smegenų centro iki žievės ir sudaro iki 10 mm. Patys skirtumai nėra ryškūs aksialiniuose pjūviuose, bet aiškiai matomi koronalinuose pjūviuose. Koronalinį pjūvį iliustruoja 4 pav.



4 pav. Talairacho ir MNI koordinacių sistemų koronalinio pjūvio vaizdai. Dešiniajame paveiksle matomas vaizdas yra Talairacho sistemoje, o kairiajame – MNI koordinacių sistemoje

Trumpai peržvelkime algoritmą, kuris Talairacho sistemą transformuoja į MNI sistemą. Aprašome transformacijos parametru vektoriu:

$$\Theta = (\theta_x, \theta_y, \theta_z, \theta_{rot1}, \theta_{rot2}).$$

Pirmi trys parametrai $\theta_x, \theta_y, \theta_z$ yra skirti mastelio keitimui išilgai Ox, Oy, Oz ašių. Pagal kitus du parametrus $\theta_{rot1}, \theta_{rot2}$ yra randamas posūkio kampas. Jie taip pat ištaiso Oy ašies ir koordinatinių pradžių nesutapimą. Posūkis apie Ox ašį yra atliekamas kampu $\phi = \arctan\left(\frac{\theta_{rot2}}{\theta_{rot1}}\right)$, $\theta_{rot1} \neq 0$, išreikštu radianais. MNI koordinatinių pradžių taškas gaunamas atlikus postūmio transformaciją vektoriumi (1.17, -20.68, 10.75). Taigi posūkio matrica turi tokią išraišką:

$$\begin{pmatrix} x' \\ y' \\ z' \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \phi & -\sin \phi \\ 0 & \sin \phi & \cos \phi \end{pmatrix} \begin{pmatrix} x \\ y - \theta_{rot1} \\ z - \theta_{rot2} \end{pmatrix} + \begin{pmatrix} 0 \\ \theta_{rot1} \\ \theta_{rot2} \end{pmatrix}, \quad (1)$$

kur Talairacho koordinatinių sistemos taškui (x, y, z) yra atlikta posūkio transformacija ir gautas taškas (x', y', z'). Mastelio keitimo transformacijos matrica atrodo taip:

$$\begin{pmatrix} x'' \\ y'' \\ z'' \end{pmatrix} = \begin{pmatrix} \theta_x & 0 & 0 \\ 0 & \theta_y & 0 \\ 0 & 0 & \theta_z \end{pmatrix} \begin{pmatrix} x' - 1.17 \\ y' - (-20.68) \\ z' - 10.75 \end{pmatrix} + \begin{pmatrix} 1.17 \\ -20.68 \\ 10.75 \end{pmatrix}, \quad (2)$$

kur x'', y'', z'' yra pasuktos taško (x', y', z') koordinatės. Ši transformacija tiksliai tinka nusakyti arti smegenų centro esančioms smulkios struktūroms. Parametrų vektorius Θ yra skirtas minimizuoti atstumą tarp transformuotų Talairacho sistemos taškų ir lateralinio skilvelio (LS) (*LV – Lateral ventricle*), esančio MNI koordinatinių sistemoje, paviršiaus taškų. Minėtasis atstumas nusakomas šia formule:

$$\bar{d}(\Theta) = \frac{1}{N} \sum_{i=1}^N \min_{LS_j^M \in LS^M} d(LS_i^\Theta, LS_j^M), \quad (3)$$

kur $\bar{d}(a)$ yra vidutinis atstumas, N yra transformuotų Talairacho koordinatinių sistemos taškų skaičius, LS_j^M yra MNI koordinatinių sistemos lateralinio skilvelio taškų aibės j -asis elementas, LS_i^Θ yra transformuotų lateralinio skilvelio paviršiaus taškų aibės i -asis elementas, $d(a, b)$ yra Euklido atstumas tarp taškų a ir b . Kiekvienas sumuojamas elementas yra minimalus atstumas tarp transformuoto Talairacho koordinatinių taško ir visos statinės MNI taškų aibės elementų. Talairacho sistemos lateralinio skilvelio (LS) paviršiaus taškų koordinatės yra gaunamos iš skaitmeninio Talairacho atlaso [2]. Kadangi toks atlasas neegzistuoja tiesiogiai MNI sistemos šablonui gauti, tai MNI sistemos lateralinio skilvelio paviršiaus koordinatės turi būti gautos rankiniu būdu sulyginant MNI MR T2 vaizdų šablonus su smegenų fotografijų vaizdais. Lateraliniai skilveliai yra lengvai atskiriami nuo aplinkinių smegenų struktūrų, nes reikšmingai skiriasi taškų intensyvumo reikšmės. Galutinis Θ įvertis yra gaunamas naudojant standartinį skaitmeninį iteracinį minimizavimą.

1.2. Atlasų tipai

Kiekvieno smegenų atlaso sėkmė priklauso nuo kaip gerai individualaus subjekto anatomija atitinka atlaso teikiamą anatomiją. Stereotaksinė koordinacių sistema palaiko duomenų aktyvavimą, reikalingos srities išskyrimą ir tarpsubjektinius palyginimus. Smegenų atlasai palaiko struktūrinę smegenų modelio sudėtį. Daugelis smegenų atlasų yra paremti detalio vieno subjekto (asmens) anatomija standartizuotoje 3D koordinacių sistemoje ar stereotaksinėje erdvėje. Ankstyvieji atlasai buvo sudaromi remiantis mirusių žmonių smegenimis. Tokie atlasai parodo smegenų anatomines savybes. Jie taip pat gali pateikti smegenų žievės ląstelių išdėstymą, ar net specifinį neurocheminį pasiskirstymą.

Anatominiai duomenys teikia papildomą detalią informaciją tikslioms aktyvacijos sritims nustatyti, taip pat pateikti chemoarhitektūrą. Stereotaksinė 3D koordinacių sistema yra būtina norint turimus kelis vaizdus palyginti kokybiškai ir patikrinti jų koreliaciją. Kadangi nėra nei vieno geriausio smegenų modelio šablono, nei paprasto metodo, kaip sudaryti vidutinės anatomijos modelį ar pateikti sudėtingus variantiškumus apie vidutinę anatomiją, toks uždavinys tapo plačiai nagrinėjamas. Populiariai paremtas atlasas gali būti naudojamas žiniomis paremtiems vaizdų analizės algoritmams skaičiuoti ir gali būti taikomas individualių pacientų ar jų grupių pataloginių savybių nustatymui [15]. Vieno modalumo atlasai gali būti nepakankami dėl anatomijų variantiškumo ir fiziologinių atitikčių nustatymo. Todėl vis dažniau vartojami daugimodaliniai atlasai, apjungiantys struktūrinius žemėlapius, gautus iš įvairių vaizdų gaviklių. Anatomicinės žymės gali būti naudojamos funkcinėms aktyvacijos sritims nustatyti. Dėl individualių normalių žmonių smegenų modelių variantiškumo, ankstyvos registracijos algoritmai kiekvieną duotų smegenų vaizdą keisdavo (didindavo ar mažindavo) proporcingai. Taip buvo sulyginami duotų smegenų duomenys su atlaso smegenų modelio duomenimis. Patobulinius transformacijų funkcijas, vietoj tiesinės transformacijos buvo pradėtos naudoti naujos elastiško, ar paremtos skysčio fizika veikimo transformacijos.

1.2.1. Atlasų klasifikacija pagal duomenų tipus

1.2.1.1. MR vaizdų atlasai

Be anatominių atlasų, sudarytų naudojantis negyvo smegenimis ar histologinėmis medžiagomis, magnetiniu rezonansu gauti vaizdai nusako detalią informaciją apie anatomiją ir gali būti naudojami atlasams sudaryti. Vieni naujausių atlasų yra paremti MR duomenimis ir turi 3D registracijos ar saugojimo erdvinėmis koordinatėmis privalumą. Trūkumas tas, kad šių vaizdų ryškumas, palyginus su kitais vaizdais, yra mažas, nes svarbiose vaizdų dalyse tarpanatomicinėse struktūrose taškų pilkumo lygmenys turi mažą kontrastą. Harvardo universiteto smegenų atlasas yra

sudarytas iš 25 metų vyro skenuotų $1 \times 1 \times 1.5$ mm skiriamosios gebos vaizdų. Sudarant buvo naudotas 3D pakeisto gradiento atstatymo algoritmas (*SPGR – spoiled gradient-recalled acquisition*) [14]. Prieš segmentavimą į 150 rankiniu būdu sužymėtų sričių, normalaus asmens smegenų modelis buvo padidintas naudojant anizotropinės difuzijos filtravimą. Į sritis įėjo baltos medžiagos traktas ir daugelis neuroanatominių struktūrų. Daug aukštos gebos MR vaizdų atlasų, sudarytų iš iki 150 vaizdų, turinčių 2 mm. vokselių plotį ir 256×256 taškų, vis dar turi svarią reikšmę, nors ir nepasižymi geresnėmis savybėmis, nei daugiamodaliniai atlasai. Tobulėjant technologijoms, gerėja ir vaizdų erdvinės ir kontrastinės savybės. Dabartiniai MR vaizdų atlasai yra sudaromi vidurkinant vieno asmens koregistruotų skenavimų (pvz.: $N=27$) vaizdus tam tikslui, kad išvengtų žemo kontrasto ir prasto signalo ir triukšmo santykio (*SNR – Signal to Noise Ratio*).

1.2.1.2. Kriopjūviniai vaizdai

Keletas skaitmeninių atlasų buvo sudaryti naudojant fotografijos vaizdus, gautus iš sušaldytų smegenų bandinių naudojant krioplokštumas. Duomenys turi būti gauti reikiamo vaizdo plokštumoje. Naudojant 1024×1024 taškų su 24 bitų/tašką skiriamosios gebos skaitmeninius fotoaparatus, erdvinė geba gali siekti iki 100 mikronų/vokselį ir daugiau. Kriopjūviniai vaizdai su mikroniniais tikslumais leidžia duomenų kaupimą su aukšta erdvine skiriamąja geba. Vaizdų serijos gavimas tiesiai iš atitinkamai pasuktų krioplokštumų taip pat padeda išvengti serijinės vaizdų registracijos. Serijiniai vaizdai gali būti rekonstruoti į 3D anatomines struktūras naudojamas įvairiomis stebėjimo kryptimis.

1.2.1.3. Daugiamodaliniai atlasai

Objektas yra charakterizuojamas naudojant vaizdus, gautus iš įvairios skirtingos įrangos. „Visible Human Project“ sudarė dviejų mirusių asmenų: vyro ir moters kūno virtualius modelius. Vaizdai buvo gauti kas 1.0 mm. intervalais naudojant krioplokštumas. Visas kūnas nuskenuotas į 5000 KT ir MR vaizdų. Gauti skaitmeniniai duomenys užima virš 15 GB ir turi prieigą per internetą naudojant IDL navigacinę programinę įrangą. Vartotojai gauna duomenis matydami aksialinį, koronarinį ir sagitalinį pjūvį. Segmentavimui bei analizei atlikti gali naudotis žinomais grafiniais formatais. Duomenys tarnauja kaip fondas reikiamiems smegenų žievės sričių atlasams generuoti ir aukštos kokybės smegenų modeliams ir vizualizacijai gauti. Naudojant daugiamodalinius duomenis su lokalizuota patologija, Hehne su kolegomis paruošė komercinį smegenų atlasą pritaikytą neuroanatomijos mokymui (*VOXEL-MAN*) [14]. Naudojant PET ir MR yra sudaryti įvairių ligos stadijų Alzheimerio (Alzheimer) liga sergančių pacientų smegenų modeliai. Šie duomenys apjungti su 3D histologiniais vaizdais.

1.2.1.4. Trimačiai anatominiai modeliai

„Sietle Digital Anatomist“ projekto ir Harvardo chirurginio planavimo laboratorijos sudaryti atlasai buvo papildyti aibe skaitmeninių anatominių modelių, skirtų anatomijos mokymui. Šie modeliai gali būti pasukti ir vizualizuoti norint interaktyviai pailustruoti daug erdvinių sąsajų tarp anatominių struktūrų. Modeliavimo strategijos yra naudojamos siekiant sudaryti sudėtingos formos anatomines struktūras, skirtas vizualizacijai ir analizei. Trimačių objektų paviršiaus generavimo metodai gali būti pritaikyti parametrizuotiems ar trianguluotiems struktūrų modeliams. Kadangi skaitmeniniai modeliai yra toje pačioje stereotaksinėje erdvėje kaip ir atlaso duomenys, paviršiaus modeliai saugomi kaip vektoriaus koordinačių sąrašai ir yra paruošti skaitmeniniai transformacijai, taip pat geometriniais ar statistiniams matavimams. 3D koordinačių sistema yra pagrindinė visoms atlasų sistemoms, nes ji palaiko ryšius tarp struktūrų modelių ir indeksuotų neuroanatominių žymių. Naudojant standartinius 3D modeliavimus, nagrinėjant kraujagyslių struktūras galima sulyginti įvairius populiacijos variantiškumus.

1.2.2. Atlasų klasifikacija pagal elgseną su jais

1.2.2.1. Deformuojami atlasai

Stiprus normalių smegenų žievės variantiškumas buvo rastas pirminėje motorinėje, somatosensorinėje, klausos smegenų srities žievėje, vaizdinėje žievėje, priekinėje srityje ir lateralinėje (šoninėje) žievėje. Kompleksiniame struktūrų variantiškume vieno asmens smegenų atlasas gali neatitikti kiekvieno individo smegenų struktūrų išdėstymą. Smegenys skiriasi ir forma, ir dydžiu, ir vidinių struktūrų išdėstymu, taigi nėra dviejų žmonių, turinčių vienodą smegenų formą. Toks variantiškumas taip pat komplikuoja funkcinių ir anatominių duomenų palyginimą. Patys atlasai yra sudaromi transformuojant kiekvieno individo modelius į Talairacho koordinačių sistemą ir tik tada atliekant vokselių (trimačių grafikos taškų) suvidurkinimą. Pati transformacija negali būti tiesinė, t.y. vien pasukimo, mastelio keitimo ir postūmio nepakanka norint sudaryti tikslų atlasą. Paprastai atliekamos lokali transformacijos funkcijos (pvz.: neproporcingas vienos koordinatės pailgėjimas ar sutrumpėjimas kitų koordinačių atžvilgiu, šlytis).

Sudarius tokį žievės atlasą labai patogu naudoti ligų diagnozavimui, smegenų augimo ar pakitimo procesui stebėti bei tarpsubjektiniams ir tarpgrupiniams palyginimams atlikti. Tam atliekama tokia pati lokali transformacija sulyginant nagrinėjamo subjekto smegenų modelį su atlaso šablonu.

Taip pat dažnai naudojama ir netiesinė transformacija. Tam pirma turi būti rastas 3D deformacijų laukas. Gautas deformacijų laukas vėliau panaudojamas fiziologinių duomenų perkėlimui nuo skirtingų individų prie anatominio atlaso. Vietoj to, kad deformuoti atlasą, kartais iškraipomi (deformuojami) individualaus subjekto vaizdai.

1.2.2.2. Tikimybių atlasų sudarymo metodai

Metodai, skirti sudaryti tikimybinius atlasus, gali būti suskirstyti į 3 stambias kategorijas: tankumu paremti, žymėmis paremti, deformacija paremti metodai. Šie metodai skiriasi tik požymiais, pagal kuriuos nagrinėjamas statistinis pasiskirstymas ir atliekama analizė. Atsitiktiniai vektoriniai laukai (t.y. deformacijos vektorių pasiskirstymas kiekviename taške) yra analizuojami deformacijos metodais gautuose žemėlapiuose. Atsitiktiniai skaliariniai laukai yra naudojami tikimybių atlasų, sudarytų naudojantis MR vaizdų taškų intensyvumo statistika, analizei. Šie laukai naudojami tankumu paremtuose metoduose ir žymėmis paremtuose metoduose [13].

Tankumu paremti metodai

Populiacija paremtuose atlasuose yra saugoma informacija apie anatomijos struktūras, kurie buvo sudaryti suvidurkinus taškų intensyvumo (pilkumo) reikšmes. Vidurkinama daug MR skenavimų tuose pačiose pjūviuose. Skenavimai yra tiesiškai transformuojami į stereotaksinę erdvę, suvidurkinti pagal vokselių pilkumo intensyvumą. Taip gaunamos vidutinių smegenų šablonas. Didžiausias variantiškumas pastebimas žievės plotuose, kur struktūros yra išblukintos dėl ypač didelio populiacijos kintamumo. Šis blukinimas sąlygotai riboja tokio atlaso panaudojimą.

Žymėmis paremti metodai

Taip pat žinomi kaip SPAM (Statistiniai/tikimybiniai anatomijos žemėlapiai) (*SPAM – Statistical/Probabilistic Anatomy Maps*), kuriuose dideli duomenų kiekiai yra rankiniu būdu sužymėti ar automatinio būdu susegmentuojami į substruktūras, prieš tai atlikus pervedimą į stereotaksinę erdvę. Tikimybinis žemėlapis yra sukonstruojamas kiekvienai segmentuotai struktūrai kiekviename vokselėje stereotaksinėje erdvėje. SPAM tikimybiniai žemėlapiai tinka ieškant reikšmingų aktyvacijų PET, SPECT vaizduose. Statistiniai duomenys, gauti iš anatominių žymių ir struktūrų tipų stereotaksinėje erdvėje, teikia svarbią informaciją, kurią naudojami matematiniai algoritmai analizuodami neuroanatominius duomenis.

Deformacija paremti metodai

Kaip anksčiau buvo minėta, pritaikant dviems skirtingiems 3D skenavimams netiesinės registracijos metodus ar iškraipymo algoritmus randamas deformuotas žemėlapis, kuris palygina dviejų smegenų atitinkamas struktūras. Deformacinis žemėlapis pateikia 3D šablonus, sudarytus iš dviejų subjektų skirtumų. Tikimybių atlasų statistinių duomenų pagalba gauti deformaciniai žemėlapiai yra skirti lokalių anatominių struktūrų svarbos ir variantiškumo nustatymui. Lokalaus variantiškumo užkodavimas gali būti naudojamas įvertinti ligos požymius.

1.3. Segmentacijos algoritmai

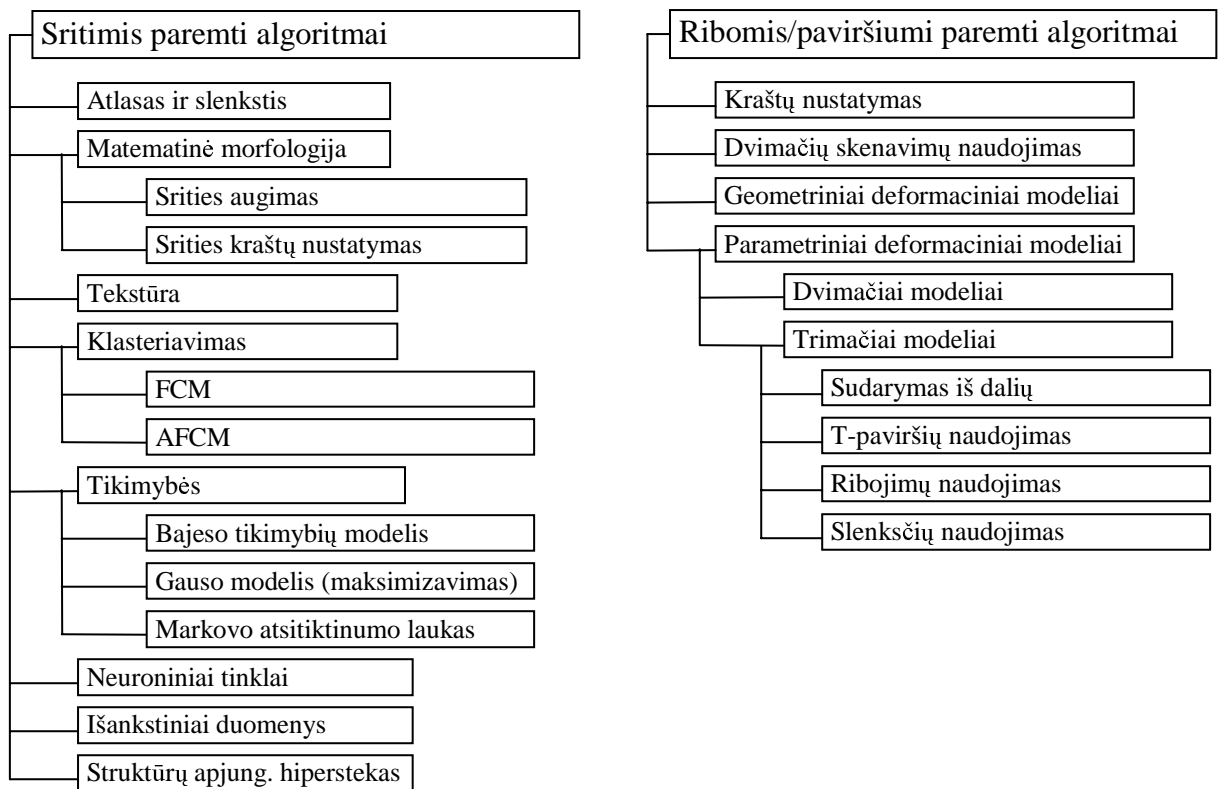
Segmentavimas yra vaizdo sudalinimas į atskiras iš anksto žinomas sritis. Šiandien dienai jau egzistuoja platus spektras įvairiausių smegenų vaizdų segmentavimo algoritmų. Jie skirti tiek KT, tiek MR, tiek fMR vaizdams segmentuoti. Žievės segmentavimo algoritmai yra vieni sudėtingiausių ir reikalauja daug skaičiavimo laiko. Vienos didžiausių segmentavimo problemų yra šios:

- dalinis vaizdų suvidurkinimas,
- medžiagos nehomogeniškumas ir netolydumas,
- netiksli skenavimo įranga,
- triukšmų atsitiktinumas,
- smegenų formų netaisyklingumas ir variantiškumas,
- struktūrų gausa medžiagose,
- smegenų auglių didumas ir tipai,
- stebėjimo kintamumas,
- jautrumas paklaidoms,
- vaizdų charakteristikos ir parametrų kintamumas,
- deformuotų formų (topologijos) stoka.

Kompiuterinė trimačių (3D) vaizdų vizualizacija, šablonų atpažinimas, vaizdų apdorojimas priklauso nuo skenavimo metodo ir tikslų. Vienas segmentavimo algoritmas gali netikti visoms struktūroms segmentuoti ir išskirti. Todėl egzistuoja tokia segmentavimo algoritmų gausa. Minimos medžiagos žmogaus galvos vaizduose yra trys: pilkoji medžiaga (*GM – grey matter*), baltoji medžiaga (*WM – white matter*) ir stuburo ir smegenų skystis (*CSF – cerebro-spinal fluid*). Dažniausiai segmentuojamos struktūros yra minėtoji pilkoji medžiaga, baltoji medžiaga, skystis, lateralinis skilvelis, kaulas ir kartais poodinis sluoksnis [8].

Sritimis paremti algoritmai gali segmentuoti vaizdą į skirtingas sritis. Žmogaus smegenys susideda iš įvairių klasių audinių; sritimis paremtas skaičiavimo būdas gali būti tiek paprastas, tiek sudėtingas klasių segmentavimo būdas. Klasifikuojant tris klases: baltąją medžiagą, pilkąją medžiagą bei stuburo ir smegenų skystį, klasteriavimo algoritmas gali gana greitai atlikti savo darbą, tačiau nėra labai tinkamas suklasifikuojant daugiau nei į tris klases. Tikimybėmis paremti algoritmai yra daugiau tikslesni ir efektyvūs, tačiau reikalauja daugiau skaičiavimo laiko.

Pagrindinės segmentavimo algoritmų klasės, kuriems priklauso šie ir kiti metodai, yra pateiktos 5 pav.



5 pav. Žmogaus smegenų MRI vaizdų segmentavimo algoritmų klasių schema

Slenksčių paremti metodai yra vadovaujami žmogaus ir yra lėti. Tai subjektyvūs, sudėtingi, linkę į klaidas algoritmai ir reikalauja nuo dviejų iki trijų valandų kompiuterinio skaičiavimo laiko apdorojant vieno paciento visus duomenis (vaizdus). Todėl slenkščiu paremti algoritmai yra naudojami kartu su kitais algoritmais [6].

Tikimybėmis paremti algoritmai remiasi iš anksto žinomais klasių skirstiniais. Tai taip pat reikalauja didelių skaičiavimų ir nėra labai praktiški realiems taikymams. Josio algoritmas naudojo žmogaus vadovojamą redagavimą topologijai sudaryti. Metodo rezultatai kartais būdavo klaidingi. Gibso modelis buvo sujungtas su Markovo tikimybiniu lauku. Tai buvo tikimybės maksimizavimo plėtinys. Vaizdo duomenų ir taškų intensyvumo korekcija yra atlikta naudojant išorinį lauką, o vidutinių laiko reikšmių radimo lygtys yra naudojamos gauti vėlesnius audinio tikimybių įverčius. Naudojant Bajeso formulę tikimybės maksimizavimas apjungė klasifikavimą ir įverčių lauką kaip netiesinį optimizavimą. Jų modelyje įverčių (nuokrypių) laukas ir stebėti intensyvumai yra aprašomi Gauso skirstiniu.

Nemažai buvo naudotas ir klasteriavimo algoritmas. Vaizde esančių klasių skaičius yra tas pats kaip ir skirtingų audinių skaičius. Taškas gali priklausyti kelioms klasėms iš karto, nes vidinės smegenų struktūros yra persidengiančios. Skaidžios tarpusavio ryšio funkcijos pagalba randamas ryšys tarp stebėto taško ir kiekvienos klasės centro atskirai. Jei ryšys mažesnis už slenkstinę ribą, tai taškas nepriklauso nagrinėjamai klasei. Centroidų reikšmės yra perskaičiuojamos po kiekvienos iteracijos kiekvienai klasei atskirai. Taigi algoritmas nėra greitas, vykdymo teisingumas priklauso

nuo daugelio parametrų ir iteracijų. Pradinis centroidų dydis turi būti kruopščiai parinktas, kas ir lems tolesnę segmentavimo sėkmę. Jis taip pat yra jautrus triukšmams ir audinio nehomogeniškumui.

3D matematinė morfologija yra naudojama kartu su 3D kraštų nustatymu ir yra atliekama naudojant 3D Marr-Hildreth operatorių. Čia nėra ieškomas 2D vaizdas, o iš karto randamos 3D žievės briaunos. Tokie algoritmai parodė gerus rezultatus, nors veikė ir 93 minutes vykdant visus žingsnius. Minėtas operatorius yra jautrus triukšmams. Beje, briaunų radimas ne visada rasdavo teisingą kontūrą, o kartais net ir prarasdavo glotnumą dėl morfologinių filtrų.

Išankstiniais duomenimis paremti algoritmai taip pat nėra geri. Sistema susideda iš tokių žingsnių: pirma, sudaromas kompiuterinis 3D modelis, gautas su eksperto pagalba bei sveikų smegenų skenavimais. Tai vadinama, globaliomis žiniomis. Po to, paciento vaizdų aibė yra normalizuojama, interpoliuojama, ir pritaikomos globalios žinios žievės/požievės struktūroms sudaryti. Naudojama daugiamodalumo sintezė, t.y. struktūros sudaromos naudojant MR vaizdus, bei PET duomenis. Trūkumas tas, kad išskiriant sritis globaliose žiniose nėra žinių apie geometrinių ar anatominių modelių struktūrą. Taip pat sudarinėjant 3D globalių žinių modelį reikalingos eksperto žinios, kurių pateikimas yra gana lėtas. Tokia segmentavimo metodologija reikalauja vaizdų duomenų registracijos, kuri dažnai teikia klaidingus ar netikslius rezultatus.


Tekstūra paremti algoritmai yra Bajeso klasifikacijos, tekstūros ir K-vidurkio klasteriavimo algoritmų mišinys. Klasteriavimas buvo naudojamas gauti homogeniškų taškų aibę. Bajeso klasifikacija naudojama transformuoti binarines atitiktis į įvairių klasių tikimybes. K-vidurkio klasteriavimas naudojo Euklido atstumą. Algoritmas puikiai įvertindavo BM (baltąją medžiagą), PM (pilkąją medžiagą) ir žievės sritis, tačiau buvo jautrus pradiniam tekstūros savybėms, kurios ir nulemdavo rezultatų sėkmę.

Turbūt geriausias iš sritimis paremtų technologijų, nors ir ilgiausiai veikiantis, yra sričių hipersteko algoritmas. Pirma, yra išblukinamas vaizdas naudojant įvairius gradiento sklaidos formulės parametrus ir gauti vaizdai sudedami į hipersteką. Antra, atliekamas hipersteko vaizdų segmentavimas. Sudaromas hierarchinis medis, kurio pagalba saugomi įvairių vaizdų lygių taškai atitinkantys atskiroms struktūroms (smegenų audiniams). Trečia, atliekama sričių analizė naudojant matematinę morfologiją. Ir galiausiai, sritys yra apdorojamos ir paruošiamos atvaizdavimui vartotojo ekrane. Tai labai tikslus, efektyvus algoritmas su minimalia vartotojo sąveika. Tačiau čia sričių apjungimas naudoja daugiausiai laiko.

1.4. Korespondencijos metodai

Sulyginant atlaso ir paciento vaizdo susegmentuotų struktūrų taškus, kyla taškų korespondencijos problema. Tam yra sprendžiamas skirtingų apimčių taškų aibių sulyginimo uždavinys.

Bazinė netiesinė taškų palyginimo problema gali būti aprašoma taip: duotos dvi taškų aibės (taškų koordinatės) ir yra norima rasti netiesinę transformaciją, kuri geriausiai sujungtų vieną taškų aibę su kita. Kitaip sakant, rasti taškų korespondencijos aibę, t.y. tokią taškų porų atitikčių aibę, kurios elementai yra taškų poros iš skirtingų aibių. Taškai gali būti sujungti naudojant transformaciją, kuri vieną taškų aibę apytiksliai arba tiksliai „perveda“ į kitą taškų aibę. Korespondencija informuoja mus, kuris taškas vienoje aibėje turi atitikti kitoje aibėje.



6 pav. Netiesinė taškų palyginimo (registracijos) problema. (a) Dvi taškų aibės, kurių galios lygios N ; (b) Taškų korespondencija; (c) Taškų transformacija

Išsprendus duotą problemą, nesunku nustatyti reikiamą registraciją, t.y. nesunku parinkti tinkamą transformacijos funkciją, kuri perversių vienus taškus į kitų taškų pozicijas. Antra vertus, galima elgtis ir priešingai: duotai transformacijai galima rasti tinkamą taškų korespondenciją naudojant tinkamą kriterijų. Pasirenkamas pirmasis atvejis ir nagrinėjamas netiesinis taškų palyginimas. Idealiu atveju taškų palyginimas tampa „tikslus“, kai kiekvienas taškas iš vienos aibės tiksliai sutampa su kitos aibės atitinkamu tašku. Realiai, struktūrų savybių, anatomijų taškai yra gaunami su paklaidomis (triukšmais). Tad struktūrų kontūrų taškai nėra tikslūs ir todėl nėra „tiksliai sulyginami“. Pasirinkti algoritmai nevertina triukšmų ir traktuoja taškų koordinates tiksliai tokias, kokios yra gautos. Kita, dažniau kylanti problema, yra ta, kad vienos taškų aibės ne visi elementai turi atitikti kitoje aibėje.

1.4.1. Taškų sulyginimo algoritmų apžvalga

Kaip buvo minėta, galima spręsti du uždavinius: taškų transformaciją ir taškų korespondenciją. Jei sprendžiamas tik vieną uždavinys nepriklausomai nuo kito, tai turimas nepriklausomo įverčio atvejis. Jei sprendžiami abu atvejai kartu, t.y. įvertinami abu gauti rezultatai, tai toks uždavinio formulavimas reikalauja nagrinėti jungtinį įvertį. Bus peržvelgiami abu atvejai.

1.4.1.1. Nepriklausomi metodai sprendžiantys transformacijos uždavinį

Inercijos momento analizė yra klasikinis transformacijos radimo būdas nevertinantis korespondencijos rezultato. Metodas yra remiasi fizikos dėsniais. Randamas masės centras ir duomenų ašis, pagal kurią apjungiami duoti aibių taškai. Algoritmas yra paprastas, tačiau dažnai teikia netikslų sprendinį.

Hugho(Hugh) transformacijos algoritmas yra labiau tobulėsnis nei pastarasis algoritmas. Transformacijos parametrų aibė yra padalinta į mažas „dėžutes“, kurių kiekviena turi tam tikrus transformacijos parametrus. Taškai gali priklausyti visoms „dėžutėms“, ir tos dėžutės, kurios surenka daugiausiai taškų, transformacijos parametrai yra laikomi geriausiai. Deja, dažnai yra priimami su dideliais triukšmais gauti taškai, todėl algoritmas nėra aukštai vertinamas.

Yra žinomi ir kiti algoritmai, kaip paieškos medžio, Hausdofo (Hausdauff) atstumo, geometrinės maišos ir kiti. Visi šie algoritmai gerai veikia su tiesine transformacija. Esant netiesinei transformacijai parametrų gausa nulemia tai, kad minėti algoritmai tampa neefektyvūs [14].

1.4.1.2. Nepriklausomi metodai sprendžiantys korespondencijos uždavinį

1.4.1.2.1. Aukštesnio lygio savybių naudojimas struktūroms

Pirmojo tipo metodai yra savybėmis paremti metodai, kurie naudojant objekto parametrizavimą, bando sujungti savybių taškus į aukštesnio lygio savybių struktūras tokias, kaip segmentai, linijos, kreivės ar paviršiai. Kitais žodžiais tariant, visi savybių segmentai yra išgaunami iš aibių ir yra tarpusavyje sugrupuojami taip, kad palyginimas galėtų būti atliktas su aukštesniu kreivės ar paviršiaus lygiu. Paprastai, kreivės ar paviršiai yra glodūs, kas palengvina sulyginimo procesą. Grupavimas yra atliekamas naudojant kreivės/paviršiaus palyginimo žingsnį. Dažnai parametrizuotas objektas (pvz.: kreivė, lankas) naudojamas įdėti lokalaus konteksto informaciją. Papildoma informacija veikia kaip ribojimas ir aukštesnių matavimų erdvėje korespondencijos paieškos apimtis sumažėja. Norint rasti geriausią korespondenciją dažnai naudojamas dinaminis programavimas [14].

Tačiau papildomas kreivės palyginimo žingsnis reikalauja gero taškų aibės savybių išgavimo. Pirma, kai duomenys yra su dideliais triukšmais ar pačios figūros yra sudėtingos formos, savybių išgavimas yra sudėtingas. Antra, šie metodai yra sunkiai įvertina kreivių segmentų formų kreivumus. Taip pat sunkiai palygina laužytas neglotnias kreives. Netiesinis taškų palyginimas gali būti veiksmingas, jei bus išspręsta aukštesnių matavimų parametrų aibės paieškos problema.

1.4.1.2.2. Lokalių ar globalių figūros atributų naudojimas

Šie metodai taikomi tada, kai taškai yra daugiau išsibarstę plokštumoje. Atributai naudojami korespondencijos radimui [14].

Modalinio palyginimo metodas naudoja sudarytas masės ir standumo matricas remiantis atstumais, pasiskirsčiusiais pagal Gauso dėsnį tarp atskirų aibių taškų porų. Idėja yra ta, kad kol turima forma yra netiesiškai deformuojama, skirtingi taškai gali laisvai judėti nuo vieno taško prie kito. Buvo pastebėta, kad rastos korespondencijos nėra labai tikslios. Jei aibėse yra atmetamų taškų, tai šis algoritmas neįvertina taškų, kuriuos galima atmesti. Tuomet, sujungiami taškai, kurie iš tikro turėtų būti atmesti.

Tikimybinis metodas remiasi, tuo, kad randama formos korespondencija. Kiekvienam pasirinktam taškui brėžiamos linijos, jungiančios su visais kitais taškais. Pagal rastus jų ilgių ir krypčių pasiskirstymą sudaroma histograma. Tuomet tuo pačiu metodu sudaromi skirstiniai visiems kitiems taškams. Korespondencija gali būti rasta palyginant vienos ir kitos aibės atributus. Tai supaprastina paiešką, nes lyginami atributai, o ne atitiktys. Kai korespondencija rasta, taškam atliekama transformacija ir metodas kartojamas. Šis metodas figūrų šablonų palyginime parodė gerus rezultatus.

1.4.1.2.3. Erdvinės atitikties informacijos naudojimas

Performuluojant taškų palyginimo problemą kaip svorinio grafo perrinkimo problemą, erdvinės atitiktys tarp abiejų aibių taškų naudojamos kaip ribojimai. Tarpusavio ryšiai nustatomi naudojant Delone (Delaunay) trianguliacijos grafą. Sprendžiant korespondencijos problemą naudojama netiksli grafo paieška. Erdvinės transformacijos yra afiniosios ar artimos afiniosioms. Taip pat naudojami ir kiti metodai. Suskaidomieji grafai yra naudojami deformuojamų šablonų palyginimui ir paieška yra vykdoma naudojant dinaminį programavimą.

1.4.1.3. Jungtiniai metodai sprendžiantys korespondencijos ir transformacijos uždavinį

Norint įvertinti korespondencijos rezultatus, reikia atlikti transformaciją. Šie metodai yra skirstomi į dvi grupes pagal tai, kaip jie sprendžia korespondencijos problemą.

1.4.1.3.1. Metodai traktuojantys korespondenciją kaip dvejetainį kintamąjį

Korespondencija nustatoma naudojantis binariniais (dvejetainiais) kintamaisiais. Jei atitinkami taškai laikomi sujungtais, jiems priskiriama reikšmė 1, o jei ne – 0. Ankstyvieji metodai korespondenciją modeliuodavo tokiu būdu.

Iteracinis artimiausio taško (ICP – Iterative Closest Point) populiarusis algoritmas priklauso būtent šiai metodų klasei. Jis naudoja artimiausio kaimyno nustatymą atliekant korespondenciją kiekviename žingsnyje. Tarpusavio ryšį nusako tik binariniai kintamieji. Korespondencija su artimiausiu tašku turi reikšmę lygia 1, o korespondencijos su visais kitais taškais lygios 0. Tuomet atliekama transformacija ir metodas kartojamas. Tai greitas ir paprastas algoritmas, garantuojantis artimiausio lokalaus minimumo konvergavimą. Jis gali būti naudojamas tik su tiesinėmis transformacijomis. Esant didelioms deformacijoms ar netiesiniai transformacijai, toks algoritmas taikomas vis rečiau, nes gaunamas didelis lokalių minimumų kiekis ir nėra garantuojama korespondencija, jungianti vienos aibės tašką su vienu kitos aibės tašku [14].

1.4.1.3.2. Metodai traktuojantys korespondenciją kaip tolydųjį kintamąjį

Čia korespondencijai priskiriamos reikšmės iš atkarpos $[0;1]$. Tai gali būti traktuojama kaip galimos atitikties tarp dviejų taškų aibių tikimybė. Šis uždavinys gali būti priimamas ir kaip tiesinės optimizacijos problema. Pagal tai ir išskiriamos dvi metodų klasės: tikimybiniai ir optimizavimo metodai.

Tikimybiniai metodai. Pagal tarpusavio atitikčių tikimybes sudaromas Gauso skirstinys. Čia geriausiai žinomas didžiausio tikėtino (EM – *Expectation-Maximization*) metodas. Tam atliekami du žingsniai: E ir M. E žingsnyje įvertinama korespondencija duotai transformacijai, o M žingsnis – atnaujina transformaciją. Išmetamieji iš aibių elementai yra randami naudojant tolygųjį dėsnį. Kiti panašūs algoritmai yra deformacinio pobūdžio, pvz.: deformuojami B-splainų metodai. Pagrindinė problema tikimybinių metodų, kad jie nenustato vienas su vienu tiesioginio atitikties ryšio ir geriausiai tinka naudoti tik tiesiniai transformacijai.

Optimizaciniai metodai. Du nauji metodai: DA (DA – *Deterministic annealing*) ir lengvo priskyrimo (*softassign*) metodai yra naudojami įverčių pagerinimui ir nustato korespondenciją vienas su vienu. Paminėti algoritmai teikia gana gerus rezultatus atskirdami triukšmus ir atmetinus aibių taškus, ir tinka naudoti su teisine ir netiesine transformacija. Vieną tokių ir panagrinėsime kitame skyriuje – stiprų taškų palyginimo algoritmą.

1.4.2. Stiprus taškų palyginimo algoritmas

Aprašysime stipraus taškų palyginimo (*RPM – Robust Point Matching*) algoritmą. Duotos dvi taškų aibės $V = \{v_a \mid a = 1, 2, \dots, K\}$ ir $X = \{x_i \mid i = 1, 2, \dots, N\}$. Taškų palyginimo problema sprendžiama dvireikšmę tiesinę energijos funkciją minimizuojant mažiausių kvadratų metodu:

$$E(Z, \alpha) = \sum_{i=1}^{N+1} \sum_{a=1}^{K+1} z_{ai} \|x_i - f(v_a, \alpha)\|^2 + \lambda T \|Lf\|^2 - \zeta \sum_{i=1}^N \sum_{a=1}^K z_{ai}, \quad (4)$$

kur λ ir ζ yra konstantos, o Z yra korespondencijos matrica, kurios elementai yra įgyja tik dvi reikšmes: 0 arba 1. Taip pat turi galioti tiesiniai lygybiniai ribojimai:

$$\begin{aligned} \sum_{i=1}^{N+1} z_{ai} &= 1, \quad a \in \{1, 2, \dots, K\}, \\ \sum_{i=1}^{K+1} z_{ai} &= 1, \quad i \in \{1, 2, \dots, N\}. \end{aligned}$$

α yra transformacijos parametras. L yra operatorius ir $\|Lf\|^2$ yra glodumo matas. Funkciją f yra pakeičiama netiesine transformacija – plonos plokštelės splainu (*thin plate spline*). Trečiasis minimizuojamos energijos elementas valdo atmetamų taškų skaičių. Kaip matyti, ši lygybė sukelia optimizacijos sunkumų. Korespondencija yra sveikaskaitinė, transformacija yra tolydinė. Atliekant optimizaciją, sveikaskaitinės reikšmės neleidžia įgyti realių reikšmių, todėl keičiantis sveikoms reikšmėms, energijos reikšmės kinta šuoliškai arba užsilaiko lokaliajame minimumo taške. Problemą spręsti naudosime du metodus: švelnaus priskyrimo (*softassign*) ir DA (*Deterministic annealing*).

1.4.2.1. Minimizavimo algoritmas

Pritaikę pakeitimus, energijos funkciją perrašome taip:

$$\begin{aligned} E(M, \alpha) &= \sum_{i=1}^{N+1} \sum_{a=1}^{K+1} m_{ai} \|x_i - f(v_a, \alpha)\|^2 + \lambda T \|Lf\|^2 + T \sum_{i=1}^N \sum_{a=1}^K m_{ai} \log m_{ai} + \\ &+ T_0 \sum_{a=1}^K m_{a,N+1} \log m_{a,N+1} + T_0 \sum_{i=1}^N m_{K+1,i} \log m_{K+1,i}, \end{aligned} \quad (5)$$

kur λ yra svorinė konstanta ir kintamieji $m_{ai} \in [0; 1]$ tenkina šiuos ribojimus:

$$\begin{aligned} \sum_{i=1}^{N+1} m_{ai} &= 1, \quad a \in \{1, 2, \dots, K\}, \\ \sum_{i=1}^{K+1} m_{ai} &= 1, \quad i \in \{1, 2, \dots, N\}. \end{aligned}$$

Atmestini taškai yra įeina į modelį naudojant konstantas x_{N+1} , v_{K+1} ir T_0 . Reguliavimą rodo temperatūros reikšmė T . Šiame algoritme naudojama sklaidi korespondencija. Šis terminas „sklaidi“ yra paimtas iš sklaidžių (*fuzzy*) aibių teorijos.

Korespondencijos matrica M elementai m_{ai} įgyja sklaidžias reikšmes iš atkarpos $[0;1]$. Taip korespondencija tampa tikimybinu pasiskirstymu tarp aibių taškų. Taigi, taškas priklauso ne vienam, o keliems taškams su atitinkama tikimybe. Yra skiriamas sklaidumo laipsnis. Jei jis labai didelis, tai visos m_{ai} reikšmės tarpusavyje lygios ir korespondencijos problema lieka neišspręsta. Jei jis mažas – uždavinys įgyja dvireikšmės korespondencijos problemą. Taip panaudojama švelnaus priskyrimo sąlyga. Tad reikšmės turi būti tolydžios intervale $[0;1]$.

DA algoritmo panaudojamas paskutiniuose trijuose sumose. Jos pakeistos entropijos reikšmėmis. Čia reikšmė T yra temperatūra. Energijos funkcijos reikšmė yra mažinama mažinant temperatūros reikšmę T . Naudojant entropiją energijos funkcija įgyja iškilos funkcijos pavidalą ir nenusistovi lokaliuose minimumo taškuose. Smarkiai sumažinus temperatūros reikšmę, energijos reikšmė bus maža, tačiau nėra garantuojama, kad tai globalaus minimumo taškas. Parinkus tinkamą temperatūros reikšmę T visas procesas tampa determinuotas. Ši temperatūros reikšmė valdo ir korespondencijos sklaidumo laipsnį. Mažinant T mažėja ir matricos M sklaidumo reikšmės. Perdaug padidinus T reikšmę, turima energijos reikšmė auga ir korespondencijos reikšmės per daug išsisklaido tarp taškų.

Norint išspęsti minėtąją energijos minimizavimo funkciją, pirma turim rasti m_{ai} reikšmes. Kadangi funkcija yra iškyla, tai minimumo radimui taikome būtinąją minimumo sąlygą. Gradiento reikšmė minimumo taške turi būti lygi 0. Kintamumas randamas diferencijuojant minėtąją energijos funkciją pagal kintamuosius m_{ai} ir α ir prilyginus gautąjį rezultatą 0. Tam normalizuojame m_{ai} reikšmes:

$$q_{ai} = e^{-\frac{\|x_i - f(v_a, \alpha)\|^2}{T}}, \quad a = 1, 2, \dots, K, \quad i = 1, 2, \dots, N;$$

$$q_{K+1,i} = e^{-\frac{\|x_i - f(v_{K+1}, \alpha)\|^2}{T_0}}, \quad a = K + 1, \quad i = 1, 2, \dots, N;$$

$$q_{a,N+1} = e^{-\frac{\|x_{N+1} - f(v_a, \alpha)\|^2}{T_0}}, \quad i = N + 1, \quad a = 1, 2, \dots, K.$$

Tada atliekamas Sinkhorno (Sinkhorn) iteracinis algoritmas (iteracinis eilutės ir stulpelio minimizavimas) kol pasiekiamas konvergavimas:

stulpelio normalizavimas:

$$m_{ai} = \frac{q_{ai}}{\sum_{b=1}^{K+1} q_{bi}},$$

eilutės normalizavimas:

$$m_{ai} = \frac{q_{ai}}{\sum_{j=1}^{N+1} q_{aj}}.$$

Kitame žingsnyje yra atnaujinami transformacijos parametrai α gautiems korespondencijų matricos M elementams m_{ai} . Tam reikia išspręsti šį mažiausių kvadratų uždavinį:

$$\min_{\alpha} E(\alpha) = \min_{\alpha} \sum_{a=1}^K \|y_a - f(v_a, \alpha)\|^2 + \lambda T \|Lf\|^2, \quad (6)$$

kur

$$y_a = \frac{\sum_{i=1}^N m_{ai} x_i}{\sum_{i=1}^N m_{ai}}. \quad (7)$$

y_a gali būti traktuojamas kaip nauja tikslinės taškų aibės X koordinatės. Kadangi korespondencija yra žinoma, transformacijos radimas yra interpoliavimo problema. Panaudojus Euklido atstumą, tai tampa mažiausių kvadratų metodo uždaviniu. Kiekvienas aibės X taškas turi atitinkamą tašką aibėje Y .

Pradedant nuo pakankamai didelios T temperatūros reikšmės T mažinama tiesiškai: $T_i = rT_{i-1}$, $r \in (0;1)$, kol pasiekiamas konvergavimas. Paprastai, galutinė T reikšmė parenkama pagal taškų aibės triukšmus. Esant mažam triukšmų skaičiui, galutinė T reikšmė yra artima 0. Norint nustatyti kiekvienam taškui korespondencijos reikšmes iš aibės $\{0,1\}$, kiekvienam i -ajam taškui išrenkama didžiausia m_{ai} reikšmė [14]. Ir i -asis taškas yra sujungiamas su j -uoju tašku, kur $j = \arg \max_{a=1, \dots, K} m_{ai}$.

1.4.2.2. Transformacijos naudojimas

Aprašytasis RPM algoritmas atlieka minimizavimo užduotį, tačiau turi būti parinkta ir tinkama netiesinės transformacijos funkcija f . Dažnai naudojama plonos plokštelės splaino (*TPS – Thin Plate Spline*) funkcija. Kaip ir daugelio kitų splainų, taip ir TPS užduotis yra atlikti erdvinį taškų sulyginimą. Šis ribojimas nurodo, kad abiejų taškų aibės turi glodžiai sutapti viena su kita, t.y. jei nėra būtina, ji neturi per daug išsklaidyti aibės elementų. Viena paprasčiausių formų, kaip įvertinti glodumą, yra rasti transformacijos funkcijos antros eilės dalinių išvestinių kvadratų integralo reikšmę. Tuomet ieškant transformacijos funkcijos reikšmės tarp atitinkamų aibių $\{y_a\}$ ir $\{v_a\}$ elementų, yra minimizuojama tokia energijos funkcija:

$$E_{TPS}(f) = \sum_{a=1}^K \|y_a - f(v_a)\|^2 + \lambda \iint \left[\left(\frac{\partial^2 f}{\partial x^2} \right)^2 + 2 \left(\frac{\partial^2 f}{\partial x \partial y} \right)^2 + \left(\frac{\partial^2 f}{\partial y^2} \right)^2 \right] dx dy, \quad (8)$$

kur λ yra svorinė konstanta. TPS funkcija gali būti parametrizuota dviem parametrais: matricomis d ir c ($\alpha = \{d, c\}$). Kai gaunamas atitinkantis taškas aibėje v_a , TPS funkcija jį perveda į $f(v_a, \alpha)$ padėtį:

$$f(v_a, \alpha) = f(v_a, d, c) = v_a d + \phi(v_a) c, \quad (9)$$

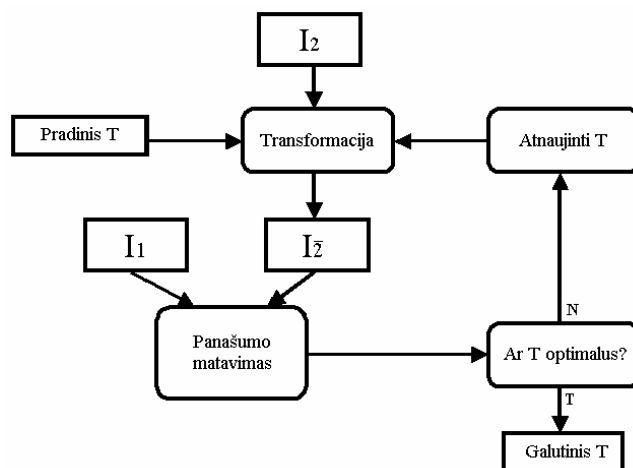
kur d yra matrica $(D+1) \times (D+1)$ atliekanti afiniją transformaciją, c yra $K \times (D+1)$ netiesinės transformacijos koeficientų matrica. $\phi(v_a)$ yra vektorius $1 \times K$ ir $\phi_b(v_a) = \|v_b - v_a\|^2 \log \|v_b - v_a\|$.

1.5. Registracijos algoritmai

Vaizdų registracija yra toks dviejų vaizdų sutapatinimo procesas, kad atitinkamos dviejų vaizdų ypatybės gali būti lengvai nustatytos. Tai svarbus įrankis norint nustatyti nagrinėjamą anatomijos pakitimą esant ligai, keičiantis žmogaus amžiui, lyčiai bei kitiems klinikiškiams ar genetiniams faktoriams. Labai svarbus yra registracijos taikymas serijiniams vaizdams, naudojamiems klinikiškiams tyrimams, apdorojimams. Paciento gautų vaizdų sulyginimas įvairiais ligos laiko momentais gali padėti nustatyti ligos progresiją, padėti parinkti gydymo būdą ir net struktūros pakitimus organų vystymosi eigoje [16]. Deja, paprastai, diagnostiniai vaizdų skenavimai nėra registruojami daugelyje radiologijos skyrių. Įprasta, kad gydytojai žiūri skenuotus pavienius vaizdus ir bando nustatyti ligos pakitimus. Vaizdų registracija gali būti taip sintezuoti informaciją iš daugelio vaizdų gavimo įrangos tuo tikslu, kad susieti skirtingą vaizdų informaciją gautą apie smegenų struktūrą ir funkcionavimą. Registruota aukštos rezoliucijos anatomija naudojant magnetinį rezonansą (MR), ultragarsą, kompiuterinę tomografiją (KT) teikia daug tikslesnę informaciją apie anatomiją nei vienos emisijos kompiuterinė tomografija (*SPECT*), pozitronų emisijos tomografija (PET) ir funkcinis magnetinis rezonansas (fMR). Nenaudojant registracijos, atitinkamoms anatomicinėms struktūroms gauti trimačiai vaizdai būtų mažiau tikslūs. Tokia daugiamodalinė registracija gali padėti priimti kliniškai svarbius gydymo sprendimus. Registracijos algoritmai gali padėti sudaryti anatomijos struktūrų šablonus esant dideliai žmonių populiacijai, taip pat padėti sudaryti ir specifinės ligos ar žmonių anatomijos ypatybių atlasus. Kai sutapatiname skanuotą objektą ir atlasą vienas su kitu, galime pašalinti individualius anatomicinius skirtumus ir perduoti segmentuotą informaciją nuo atlaso prie nagrinėjamo vaizdo. Registracijos pagalba galima nustatyti atitikties tarp priešoperacinių duomenų ir paciento duomenų, taip pat atliekant erdvinę normalizaciją.

1.5.1. Bendra registracijos algoritmo schema

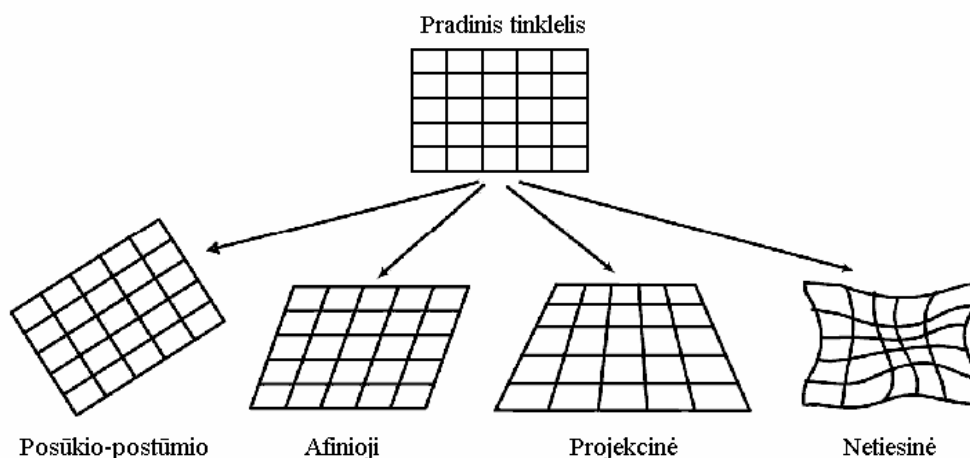
Registracija nustato atitikties tarp dviejų vaizdų vertinant vaizdų atitinkamų taškų intensyvumo panašumo matą. Paveikslėlis rodo registracijos algoritmo struktūrinę schemą. Vaizdas I_1 yra *tikslinis vaizdas* ir I_2 yra *deformuotas vaizdas*. Algoritmas susideda iš trijų pagrindinių etapų: 1) vaizdo I_2 transformacijos į vaizdą I_2 naudojant iškraipymo funkciją T ; 2) vaizdų I_1 ir I_2 tarpusavio panašumo įvertinimo, gaunamo naudojant panašumo kriterijų; 3) optimalios transformacijos radimo optimizacinio etapo.



7 pav. Vaizdų registracijos veiksmų schema

1.5.2. Vaizdų registracijos algoritmų klasifikacija

Vaizdų registracija gali būti suklasifikuota į posūkio-postūmio, afiniąją, projekcinę ir netiesinę registraciją paremtą geometrine transformacija. Trimatės posūkio-postūmio transformacijos išlaiko atstumus ir kampus tarp taškų ir gali būti pateiktos trimis vektoriais ir trimis kampais (6 laisvės laipsniai). Afinioji (tiesinė) transformacija atitinka posūkio-postūmio transformaciją pridėjus tris Dekarto koordinatinių sistemos mastelio keitimo dydžius ir šlytį (12 laisvės laipsnių). Ji nustato atitiktis tarp atitinkamų lygiagrečių linijų, bet neišlaiko kampų tarp šių linijų. Projekcinė transformacija išlaiko linijų tiesiškumą, bet neišlaiko lygiagretumo. Netiesinė transformacija neišlaiko atkarpų tiesiškumo ir sutapatina liniją su kreive. Netiesinės transformacijos užtikrina, kad jungios sritys išlieka sujungtos ir išlaikomas ryšys su kaimyninėmis struktūromis. Tokios transformacijos nėra išreiškiamos parametru (koeficientų) matricomis. Taigi jos laisvės laipsnių skaičius yra didesnis nei posūkio-postūmio ar afiniosios transformacijos.



8 pav. Transformacijos funkcijų klasifikacija

1.5.2.1. Savybių erdvė

Daug įvairių metodų yra paruošta norint išspręsti registracijos problemą. Jos klasifikuojamos į tris tipus: savybėmis paremta registracija, intensyvumu paremta registracija ir mišri registracija. Kiekvienas iš šių būdų turi privalumų ir trūkumų. Trumpai peržvelgsime visus tris.

Savybėmis paremta registracija

Savybėmis paremta registracija stengiasi rasti atitikimą ir transformaciją naudojant gauto vaizdo griežtas anatomines savybes. Šios savybės – tai taškai, kreivės ar anatominių struktūrų paviršiaus modelis. Ši registravimo metodika, paprastai, taikoma tada, kai lokalių struktūros kontūrų taškų informacija yra daugiau reikšminga, nei vaizdo taškų intensyvumo informacija. Jie gali susidoroti su sudėtingais vaizdo iškraipymais ir gali būti greitesni, nes neįvertina sulyginimo kriterijaus kiekviename vaizdo vokselyje (*voxel*), bet remiasi santykinai mažu savybių skaičiumi [3]. Paprasčiausia anatominių savybių aibė yra žymių (*landmarks*) aibė. Vis dėl to, žymių atrinkimas yra laikoma gana sudėtinga problema tiek atliekant automatiškai, tiek rankiniu būdu. Daugeliui vaizdų – tai rimtas trūkumas, nes registracijos tikslumas gali nepagerėti nepriklausomai nuo to, ar žymės atrinktos automatiškai ar rankiniu būdu. Praktiškai, žymių padėtys erdvėje nėra tikslios, t.y. reikšmės su triukšmais. Tuo būdu, erdvinės koordinatės ir geometriniai primityvai būdami per daug išretinti ir netikslūs.

Intensyvumu paremta registracija

Intensyvumu paremti registracijos metodai veikia tiesiogiai remdamiesi vaizdų taškų pilkumo reikšmėmis. Pagrindinis principas – yra transformacijų aibėje rasti tokią transformaciją, kuri maksimizuotų (minimizuotų) lyginamų vaizdų panašumo kriterijaus reikšmę, gaunamą matuojant atitinkamas vokselių reikšmes. Kai kurie panašumo matai yra taškų intensyvumo reikšmių kvadratinių skirtumų suma, kai kurie – srities koreliacija ar abipusė informacija (*mutual information*). Pastaroji parodė nuostabų tarpmodalinės registracijos vaizdų panašumo mato kriterijaus įvertį [3]. Tai įrodo, kad statistinė vokselių intensyvumo priklausomybė maksimali yra tada, kai vaizdai geometriškai sutampa. Intensyvumo panašumo matas, suderintas su struktūriniu integralumu, yra optimizuojamas nustatant deformacijos lauko parametrus. Toks būdas reikalauja daugiau skaičiavimo, bet išvengia savybių išskyrimo sunkumų.

Mišri registracija

Jos gaunamos tarpusavyje derinant savybėmis ir intensyvumu paremtus registracijos metodus, ir apjungia abiejų strategijų privalumus. Toks plačiai žinomas yra hierarchinis registracijos būdas, kai naudojamas skysčio modelis.

1.5.2.2. Iškraipymo erdvė

Skirstant registracijos būdus į kategorijas vienas iš svarbiausių faktorių yra iškraipymo lauko (*warping space*) (erdvės) naudojimas. Ji sudaroma naudojant iškraipymo funkcijas. Pastarosios vaidina svarbiausią vaidmenį vaizdų registracijoje ir buvo plėtojamoms per paskutinius dvidešimt metų. Metodai yra skirstomi į bazinių funkcijų plėtros, fizinių modelių ir optinių srautų metodus.

Bazinių funkcijų plėtros metodai. Netiesinė registracija nustato deformacijų lauką, teikianti atitiktį kiekvienam taškui (vokseliui) deformuojamame vaizde. Deformacija gali būti išreikšta bazinėmis funkcijomis. Specifiniai pavyzdžiai: sinusoidinės, bangelių bei radialinės funkcijos (pvz.: plonos plokštelės splainai (*thin-plate splines*)).

Fiziniais modeliais paremti metodai. Netiesinė vaizdo registracija taip pat gali būti atlikta modeliuojant vieno vaizdo deformaciją į kitą vaizdą kaip elastišką fizikinį procesą. Platus spektras šių metodų yra paremtas Navier-Stokes tiesine elastiška daline skirtumine lygybe:

$$\mu\Delta u(x) + (\mu + \lambda)\nabla(\nabla u(x)) = k(x, u(x)), \quad (10)$$

kur μ ir λ yra Lamé konstantos, nusakančios elastiškumo savybes. $\mathbf{u}=(u_1, u_2, u_3)$ yra poslinkio laukas ir k rodo elastiško kūno poveikio jėgą. $\Delta=\nabla^T\nabla$ yra Laplaso operatorius ir $\nabla(\nabla u)$ yra divergencijos \mathbf{u} gradientas. Paprastai λ yra nustatyta lygi 0 su tikslu užtikrinti, kad deformacijos turėtų tik poveikį tik nustatytų jėgų kryptimis; μ įgyja reikšmę tarp 0 ir 1. Išorinės jėgos gali būti gautos iš panašumo funkcijos lokali optimizacijos. Navier-Stokes lygybė turi svarbų trūkumą: neleidžia atlikti plačiai lokalizuotų deformacijų. Šio trūkumo neturės skysčio modelis. Vietoj to, kad naudoti poslinkius \mathbf{u} tiesiogiai Navier-Stokes lygybėje, naudojamas deformacijos greitis \mathbf{v} .

$$\mu\Delta v(x) + (\mu + \lambda)\nabla(\nabla v(x)) = k(x, u(x)). \quad (11)$$

Greičio naudojimo privalumas tas, kad galime naudoti plačias deformacijas. Tačiau, antra vertus, iš to seka ir trūkumas: didėja neteisingų registracijos rezultatų skaičius [3].

Optinių srautų metodai. Optinių srautų ribojimo lygybė įvertina judesį tarp dviejų kadru vaizdų sekoje. Tai paremta prielaida, kad esant mažiems laiko intervalams taško intensyvumo reikšmė nesikeičia. Ribojimas gali būti išreikštas taip:

$$(\nabla I)^T \vec{v} + I_t = 0, \quad (12)$$

kurioje ∇I , \vec{v} , I_t atitinkamai yra vaizdo intensyvumo gradientas, nežinomas tarp vaizdų judesio vektorius ir darbinis vaizdo darinys. Ši lygybė nėra pakankamai ribota (optikoje problema dar yra žinoma kaip apertūrinė problema) ir daugelis tikslinimo schemų buvo taikytos šiai problemai spręsti.

1.5.3. Vaizdų panašumo matas

Netiesinė vaizdų registracija yra optimizavimo problema, kurios tikslas yra optimizuoti vaizdų panašumo matą atsižvelgiant į transformacijos parametrus. Galima užrašyti taip:

$$\Gamma(I_1, I_2) = \arg \min_T E(I_1, I_2 \circ T), \quad (13)$$

kur E yra kaštų funkcija, T yra geometrinės transformacijos funkcija. Kartais kartu su minimizuojama kaštų funkcija yra pridėdama ir glodumo funkcija. Pridedant glodumą į (13) lygybę gauname:

$$\Gamma(I_1, I_2) = \arg \min_T (E(I_1, I_2 \circ T) + E_{glod}(T)), \quad (14)$$

Trimačiu atveju glodumo terminas aprašomas tokia išraiška:

$$E_{glod} = \frac{1}{V} \int_0^x \int_0^y \int_0^z \left[\left(\frac{\partial^2 T}{\partial x^2} \right)^2 + \left(\frac{\partial^2 T}{\partial y^2} \right)^2 + \left(\frac{\partial^2 T}{\partial z^2} \right)^2 + 2 \left(\frac{\partial^2 T}{\partial x \partial y} \right)^2 + 2 \left(\frac{\partial^2 T}{\partial x \partial z} \right)^2 + 2 \left(\frac{\partial^2 T}{\partial y \partial z} \right)^2 \right] dx dy dz, \quad (15)$$

kur V žymi trimačio vaizdo dydį.

1.5.3.1. Vidutinė kvadratinė paklaida

Vienas iš paprasčiausių vaizdo panašumo matų yra vidutinis kvadratinis nuokrypis (VKP) tarp vaizdų A ir B . VKP yra minimizuojama registracijos metu ir apibūdinama formule:

$$\delta = \frac{1}{N} \sqrt{\sum_{x \in \Omega_{A,B}} |A(x) - B(x)|^2}, \quad (16)$$

kur N yra vaizdų dydis. Įrodyta, kad tai optimalus matas, kai abiejų vaizdų paklaidos yra pasiskirsčiusios pagal normalųjį dėsnį. Šis griežtas reikalavimas retai pasiteisina medicininių vaizdų registracijoje, nes paklaidos ir triukšmai medicininiuose vaizduose dažnai nėra Gauso (normaliojo) skirstinio.

1.5.3.2. Koreliacijos koeficientas

Įrodyta, kad registracijos metu naudojant afiniją transformaciją, optimalus panašumo matas yra koreliacijos koeficientas KK:

$$KK = \frac{\sum_{x \in \Omega_{A,B}^T} (A(x) - \bar{A})(T(B(x)) - \bar{B})}{\sqrt{\sum_{x \in \Omega_{A,B}^T} (A(x) - \bar{A})^2 (T(B(x)) - \bar{B})^2}}, \quad (17)$$

kur \bar{A} ir \bar{B} yra atitinkamai vaizdų A ir B vidutinės taškų intensyvumo reikšmės. Šio panašumo matas įgyja reikšmes iš atkarpos $[-1, 1]$ ir turi būti maksimizuojamas.

1.5.3.3. Abipusė informacija

Paskutiniaisiais metais daug vaizdų panašumo matų yra pagrįsti jungtine entropija (*joint entropy*), abipuse informacija (*MI – Mutual information*) ir normalizuota abipuse informacija (*NMI – Normalized mutual information*). Jos teikia daug vilčių daugiamodalinėje vaizdų registracijoje. Daugiamodalinių vaizdų registracija yra sudėtingas uždavinys, bet dažnai yra būtinas spresti. Paciento kūno anatominių ir funkcinių vaizdų palyginimas su atlaso vaizdais yra būtinas uždavinys diagnozuojant ligą ar pakitimą. Abipusė informacija (AI) yra dviejų vaizdų statistinės priklausomybės matas. Turint du atsitiktinius dydžius A ir B , abipusė informacija apibrėžiama taip:

$$AI(A, B) = H(B) - H(B | A) = H(A) + H(B) - H(A, B), \quad (18)$$

$$H = -\sum_i p_i \log p_i,$$

$$H(A, B) = -\sum_{a \in A} \sum_{b \in B} p_{AB}(a, b) \log p_{AB}(a, b),$$

kur H yra vidutinė informacija gaunama iš n taškų intensyvumo reikšmių, kurių tikimybės yra p_1, p_2, \dots, p_n . $H(A, B)$ yra jungtinė (dvimačio atsitiktinio dydžio (A, B)) entropija ir kiekvieno elemento reikšmės rodo tikimybę, kad taškų pora abiejuose vaizduose turi tą pačią reikšmę [3, 12]. $p_{AB}(a, b)$ yra labai priklausomas nuo jungtinės sankirtos $\Omega_{A, B}^T$, kas yra nepageidaujama. Norint sumažinti vaizdų sankirtos priklausomybę, turime normalizuoti informaciją persidengiančioje (sankirtos) srityje. Ši formulė aprašo normalizuotą abipusę informaciją (NAI):

$$NAI(A, B) = \frac{H(A) + H(B)}{H(A, B)}. \quad (19)$$

1.6. Transformacijos funkcijos

Transformacijos funkcijos yra skirtos vieną vaizdą transformuoti į kitą taip, kad jie abu taptų maksimaliai panašūs. Nurodžius taško koordinates viename vaizde, transformacijos funkcija nustatys koordinates kitame vaizde. Vieną vaizdą vadinsime **nuorodiniu**, o kitą – **tiksliniu (nukreipiamuoju)** vaizdu. Paprastai, nuorodinis vaizdas yra duotas ir nekeičiamas. Tikslinis vaizdas taip pat yra duotas, tačiau turi būti deformuotas, kad išlaikytų nuorodinio vaizdo duotų taškų geometriją. Yra skiriami du panašūs procesai: **vaizdo iškraipymas** (*image warping*) ir **vaizdo registracija** (*image registration*). Abiejuose procesuose gali būti naudojamos tos pačios transformacijų funkcijos. Skirtumas tas, kad pirmuoju atveju yra iškraipomas duotasis nuorodinis vaizdas ir gaunamas tikslinis vaizdas. Tokių uždavinių problema yra žinoti, kaip ir kuriuos taškus deformuoti, kad gautą iškraipytą vaizdą būtų galima segmentuoti, pridėti prie tikimybinio atlaso turimų vaizdų, saugoti vaizdų duomenų bazėje ir pan. Mes naudosimės vaizdo registracija.

Vaizdo registracija – tai toks procesas, kai naudojantis turimu nuorodiniu vaizdu yra deformuojamas nukreipiamasis (tikslinis) vaizdas. Kitaip sakant, turimą “blogą” vaizdą reikia deformuoti taip, kad jis kuo galima labiau sutaptų su nuorodiniu vaizdu. Tiksliniai vaizdai – tai konkretaus paciento galvos smegenų kiekvienu pjūviu gauti magnetinio rezonanso vaizdai. Dėl 1.3. skyriuje aprašytų segmentavimo algoritmų sunkumų, gautuose konkrečiuose vaizduose bus atliekama dalinė segmentacija. Segmentuojama tik galvos kaukolė, smegenų ir stuburo skystis, lateralinis skilvelis ir smegenų žievė. Norint rasti smulkesnių vidinių smegenų struktūrų ribas, bus naudojama vaizdų registracija, deformuojant paciento tikslinį vaizdą naudojantis atlaso nuorodiniu vaizdu.

1.6.1. Globalinės transformacijos

Tai viena pirmųjų transformacijos funkcijų klasių. Šių funkcijų pagalba yra transformuojamas visas vaizdas, o ne atskirai paimta vaizdo dalis. Dėl jų išraiškų paprastumo ir didelio skaičiavimo poreikio, funkcijos turi daigiau teorinę nei praktinę vertę. Paskutiniu metu jos vis rečiau yra naudojamos medicininių vaizdų registracijoje.

1.6.1.1. Polinominė transformacija

Tai vienas seniausiai iš žinomų netiesinės transformacijos metodų. M -ojo laipsnio polinominė transformacija formaliai užrašoma taip:

$$\begin{aligned}
x &= \sum_{j=0}^M \sum_{k=0}^j a_{jk} X^k Y^{j-k}, \\
y &= \sum_{j=0}^M \sum_{k=0}^j b_{jk} X^k Y^{j-k}.
\end{aligned}
\tag{20}$$

Paprastai, aukštesnės nei antros eilės polinomai nėra taikomi vaizdų geometrinei transformacijai, nes tampa sunku prognozuoti jų elgseną [5]. Polinominė transformacija yra taikoma, kai reikia transformuoti visą vaizdą. Taip būna retai, tačiau galvos smegenų 2D skenuotiems vaizdams apdoroti jos taip pat gali būti naudojamos. Vieno koeficiento pakeitimas turi įtakos visam vaizdai, o ne vienai jos daliai. Parametrai a ir b yra randami išsprendus dvi tiesinių lygčių sistemas, sudarytas iš nuorodinio ir tikslinio vaizdo kontrolinių taškų koordinatų. Antrojo laipsnio polinomas turės 6 X ir 6 Y reikšmes. Vadinasi, parametrams rasti reikia 6 kontrolinių taškų.

1.6.1.2. Paviršiaus splineų transformacija


Tai plačiausiai naudojama žmogaus galvos smegenų dvimačių vaizdų transformacija, kuri užrašoma taip:

$$\begin{aligned}
x &= a_0 + a_1 X + a_2 Y + \sum_{i=1}^n F_i r_i^2 \ln r_i^2, \\
y &= b_0 + b_1 X + b_2 Y + \sum_{i=1}^n G_i r_i^2 \ln r_i^2,
\end{aligned}
\tag{21}$$

kur $r_i^2 = (X - X_i)^2 + (Y - Y_i)^2$ ir (X_i, Y_i) yra i -asis kontrolinis taškas tiksliniame vaizde. Jei duota n kontrolinių taškų, turėsime $2n+6$ nežinomų parametru. n taškų pateikia $2n$ lygčių, tad reikia dar 6 lygčių, kad būtų galima nustatyti visus parametru reikšmes. Likusios 6 konstantos randamos iš šių lygčių:

$$\begin{aligned}
\sum_{i=1}^n F_i &= 0, & \sum_{i=1}^n G_i &= 0, \\
\sum_{i=1}^n X_i F_i &= 0, & \sum_{i=1}^n X_i G_i &= 0, \\
\sum_{i=1}^n Y_i F_i &= 0, & \sum_{i=1}^n Y_i G_i &= 0.
\end{aligned}$$

Paviršiaus splineas pateikia paviršiaus koordinates, priklausomas nuo užduotų taškų. F ir G koeficientai rodo atitinkamų kontrolinių taškų svarbą. Pirmosios nuliui lygios lygtys užtikrina, kad paviršius nepajudės nei aukštyn, nei žemyn. Likusios keturios lygtys garantuoja, kad paviršius nebus pasuktas. Priešingai nei polinominės transformacijos, ši transformacija yra jautriausia lokalinei vaizdo daliai. Tuo tarpu polinominės transformacijos daro įtaką visam vaizdai [5].




9 pav. Gauti tiksliniai vaizdai, atlikus globalines transformacijas: (a) Globalinė polinominė transformacija; (b) Globalinė paviršiaus splineų transformacija

1.6.1.3. Multikvadratinė transformacija

Ji aprašoma tokia išraiška:

$$\begin{aligned} x &= \sum_{i=1}^n a_i h_i(X, Y), \\ y &= \sum_{i=1}^n b_i h_i(X, Y), \end{aligned} \tag{22}$$

kur $h_i = \sqrt{(X - X_i)^2 + (Y - Y_i)^2 + R^2}$. R – yra vartotojo nustatomas parametras, kontroliuojantis funkcijos lokalumą. Koefficientai a ir b yra randami nustačius $x=x_i, y=y_i, X=X_i, Y=Y_i$, kai $i=0, \dots, n$ ir išsprendus dvi tiesinių lygčių sistemas. Tai rečiau taikomas galvos smegenų vaizdų transformacijų metodas.




10 pav. Gauti tiksliniai vaizdai, atlikus globalines transformacijas: (a) Svorinio vidurkio transformacija; (b) Multikvadratinė transformacija


1.6.2. Lokalinės transformacijos

Lokalioms transformacijoms funkcijos lokaliai mažame plote randa atitikties tarp dviejų vaizdų. Tai suteikia didesnę transformacijos veikimo greitį ir daugiau funkcionalumo pačiam vartotojui. Svarbiausios yra šios transformacijų funkcijos: dalimis tiesinė funkcija (*piecewise linear*), dalimis kubinė funkcija (*piecewise cubic*) ir lokalaus svorinio vidurkio funkcija (*local weighted mean*).

1.6.2.1. Dalimis tiesinė transformacija

Transformacija yra gaunama trianguliuojant kontrolinius taškus nuorodiniame vaizde, identifikuojant atitinkamus trikampius tiksliniame vaizde ir pritaikant tiesinę transformaciją, kuri suvienodintų vieno trikampio struktūrą su kito vaizdo trikampio struktūromis. Tiesinės transformacijos koeficientai yra randami sulyginant atitinkamų trikampio viršūnių koordinates ir sprendžiant gautas tiesinių lygčių sistemas. Kai vartotojas nurodo tašką tiksliniame vaizde, yra nustatomas atitinkamas taškas nuorodiniame vaizde. Taško poslinkis turės tik tiems trikampiams įtakos, kurie yra prijungti prie šio taško kaip bendros trikampio viršūnės. Kadangi funkcionalas kinta pagal x ir pagal y koordinatę, trikampio sandūros taškų pilkumo lygmenų reikšmės kinta gana smarkiai [5]. Perėjimas nuo vieno trikampio prie kito nėra glodus. Taškai gana yra „aštriai“ išsidėstomi vienas kito atžvilgiu. Norint turėti glodų taškų perėjimą nuo vieno trikampio prie kito, reikia naudoti dalimis kubinę transformaciją.





11 pav. Gauti tiksliniai vaizdai: (a) Taškų poslinkiai. Mėlyni taškai rodo taškus, kurie nepasislinko nuorodiniame ir tiksliniame vaizde. Taškas a pasislinko į taško b poziciją; (b) Sutrianguliuotas nuorodinis vaizdas; (c) Gautas po tiesinės transformacijos tikslinis vaizdas; (d) Sutrianguliuotas tikslinis vaizdas

1.6.2.2. Lokalinė svorinio vidurkio transformacija

Tegul turimi du n -ojo laipsnio polinomiali, aprašantys abiejų duotų vaizdų kontrolinius taškus. Tegul tiksliniame vaizde turimas i -asis kontrolinis taškas ir $n-1$ jam artimiausių kontrolinių taškų. Atliekamas pažymėjimas atitinkamų i -ųjų taškų nuorodiniame vaizde (x_i, y_i) , o tiksliniame vaizde – (X_i, Y_i) . Polinomų koeficientai yra randami įsistatant duotų taškų koordinates į polinominės išraiškas ir išsprendžiant dvi tiesinių lygčių sistemas, susidedančias iš n tiesinių lygčių. Taip randamos polinomų išraiškos. Norint, kad šie polinomiali veiktų lokalinėje vaizdo dalyje, kiekvieno polinomo koeficientui suteikiamas svoris taip, kad polinomo reikšmė taptų lygi nuliui, esant dideliems atstumams nuo nagrinėjamo kontrolinio taško. Svoriai randami tokiu būdu:

$$W_i(R) = \begin{cases} 1 - 3R^2 + 2R^3, & 0 \leq R \leq 1, \\ 0, & R > 1. \end{cases} \quad (23)$$

kur $R = \frac{\sqrt{(X - X_i)^2 + (Y - Y_i)^2}}{R_n}$, ir R_n yra taško (X_i, Y_i) atstumas iki $(n-1)$ -ojo artimiausio taško

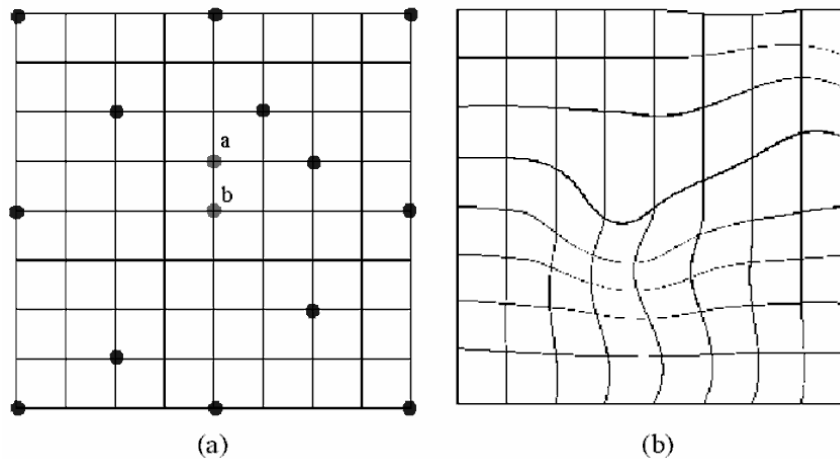
tiksliniame vaizde. Svoriai $W_i(R)$ užtikrina, kad i -asis polinomas neturės įtakos taškams, kurie yra toliau nei R_n reikšmė tiksliniame vaizde. Pastebint, kad

$$\left[\frac{dW}{dR} \right]_{R=0} = \left[\frac{dW}{dR} \right]_{R=1} = 0$$

reiškia, kad polinomų svorinė suma yra glodi visame plote. Taigi taškų reikšmės glodžiai pereina tarp skirtingų polinomų reikšmių ir nelieka prieš tai aprašyto algoritmo trūkumų. Naudojant aprašytus svorius, sudaroma transformacijų funkcija, jungianti nuorodinio vaizdo taškus su tikslinio vaizdo taškais:

$$\begin{aligned}
 x &= \frac{\sum_{i=1}^n W \left(\frac{\sqrt{(X - X_i)^2 + (Y - Y_i)^2}}{R_n} \right) P_i(X, Y)}{\sum_{i=1}^n W \left(\frac{\sqrt{(X - X_i)^2 + (Y - Y_i)^2}}{R_n} \right)}, \\
 y &= \frac{\sum_{i=1}^n W \left(\frac{\sqrt{(X - X_i)^2 + (Y - Y_i)^2}}{R_n} \right) Q_i(X, Y)}{\sum_{i=1}^n W \left(\frac{\sqrt{(X - X_i)^2 + (Y - Y_i)^2}}{R_n} \right)}.
 \end{aligned}
 \tag{24}$$

$P_i(X, Y)$ ir $Q_i(X, Y)$ yra lokalinės transformacijos funkcijų komponentės, kurios jungia i -ąjį ir $(n-1)$ -ąjį kontrolinį tašką tiksliniame vaizde su atitinkamais taškais nuorodiniame vaizde.



12 pav. Tiksliniai ir nuorodiniai vaizdai: (a) Nuorodinio ir tikslinio vaizdo taškai. Mėlyni taškai žymi nepaslinktus taškus. Taškas a pereina į taško b poziciją; (b) Transformuotas tikslinis vaizdas panaudojus antros eilės polinomus

Vaizdo deformacija labai priklauso ir nuo naudojamo polinomo eilės. Taikant svorinius vidurkius rekomenduojama naudoti ne aukštesnės kaip 2 eilės polinomų išraiškas, nes santykinai maži kontrolinių taškų poslinkiai gali smarkiai pakeisti tarpinių (ieškomų) taškų koordinatas. Tuomet vaizdas gali atrodyti „nebe natūraliai“. Esant mažam kontrolinių taškų skaičiui, galima naudoti 3 eilės polinomus arba naudoti didesnio nagrinėjamo vaizdo ploto taškus. Tokiu būdu bus gaunama didesnė R_n reikšmė. Norint rasti polinomų koeficientų reikšmes, kada kontrolinių taškų skaičius yra didesnis negu pakankamas, naudojamas mažiausių kvadratų metodas.

1.6.2.3. Svorinis mažiausių kvadratų metodas

Kai naudojamas mažiausių kvadratų metodas tikslesniam polinomų koeficientų nustatymui, paklaidos, gautos lokalinėje vaizdo dalyje, yra paskirstomos po visą vaizdą. Norint sumažinti šių paklaidų įtaką tolimesniems nei lokalinio vaizdo taškams, yra naudojamas svorinis mažiausių kvadratų metodas. Atsižvelgiant į kontrolinių taškų pozicijas nuorodinio vaizdo taškams svoriai yra priskiriami tokiu būdu:

$$W_i(x, y) = \frac{1}{\sqrt{\delta + (x - x_i)^2 + (y - y_i)^2}}. \quad (25)$$

Parametro δ reikšmės palyginus su atstumais tarp taškų santykinai nėra didelės ir siekia apie 1.0. Kuo mažesnė δ reikšmė, tuo mažesnę įtaką turi polinomų reikšmės smarkiai nutolusiems taškams [5]. Esant tikslioms kontrolinių taškų reikšmėms, δ reikšmė turi būti parenkamai arti 0. Skaičiuojant svoriniu kvadratų metodu polinomų koeficientai yra randami minimizuojant šias dvi paklaidų reikšmes:

$$\begin{aligned} E_x^2(x, y) &= \sum_{i=1}^n [f_x(x_i, y_i) - X_i]^2 W_i(x, y), \\ E_y^2(x, y) &= \sum_{i=1}^n [f_y(x_i, y_i) - Y_i]^2 W_i(x, y), \end{aligned} \quad (26)$$

kur $f_x(x, y)$ ir $f_y(x, y)$ yra polinomai. Minimizavimas atliekamas išsprendus šias lygčių sistemas:

$$\begin{aligned} \sum_{j=0}^M \sum_{k=0}^j a_{jk} [W_i(x, y) x_i^l y_i^{m-1} x_i^k y_i^{j-k}] &= \sum_{i=1}^N W_i(x, y) X_i x_i^l y_i^{m-kl}, \\ \sum_{j=0}^M \sum_{k=0}^j b_{jk} [W_i(x, y) x_i^l y_i^{m-1} x_i^k y_i^{j-k}] &= \sum_{i=1}^N W_i(x, y) Y_i x_i^l y_i^{m-kl}, \end{aligned} \quad (27)$$

kai $l = 0, \dots, M$ ir $m = 0, \dots, l$

1.6.2.4. Plonos plokštelės splainas

Plonos plokštelės splainas turi fizikinę prasmę. Jie interpoliuoja duotus taškus minimizuodami dvimatės funkcijos reikšmę

$$\int \left(\frac{\partial^2 z}{\partial x^2} \right)^2 + 2 \left(\frac{\partial^2 z}{\partial x \partial y} \right)^2 + \left(\frac{\partial^2 z}{\partial y^2} \right)^2 \quad (28)$$

ir suteikdami glotnią deformaciją be netikėtų vingių ir iškraipymų. Fundamentalios bazės [3] funkcija, naudojama 2D plonos plokštelės splaino, yra išreiškiama funkcija:

$$z(x, y) = -U(r) = -r^2 \log r^2, \quad (29)$$

kur r yra atstumas nuo Dekarto koordinatų pradžios taško. Funkcija $U(r)$ tenkina kitą nelybę:

$$\delta^2 U = \left(\frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} \right) U \propto \delta_{0,0}, \quad (30)$$

kur U yra biharmoninės lygybės $\Delta^2 = 0$ fundamentalus sprendinys. Plonos metalinės plokštelės funkcija $z(x, y)$ yra vertikalčiai paslinkta virš xOy plokštumos. 3D atveju biharmoninės lygybės fundamentalus sprendinys yra $U(r) = |r|$. Plonos plokštelės splaino poslinkio lauko komponentė x arba y gali būti išreikšta kaip

$$f(x, y) = a_1 + a_x x + a_y y + \sum_{i=1}^n w_i U(|P_i - (x, y)|), \quad (31)$$

kur a_1, a_x, a_y aprašo afiniją transformaciją. Nežinomi parametrai $W = [w_1, w_2, \dots, w_n]$ yra nustatomi sprendžiant tiesinių lygčių sistemą, sudaromą žymių vietose fiksuojant poslinkio lauko reikšmes. Tegul $P_1 = (x_1, y_1), P_2 = (x_2, y_2), \dots, P_n = (x_n, y_n)$ yra n taškų Euklido erdvėje. $r_{ij} = |P_i - P_j|$ yra atstumas tarp taškų i ir j . Sudarome matricas:

$$L = \begin{bmatrix} K & P \\ P^T & O \end{bmatrix}, \quad (32)$$

$$K = \begin{bmatrix} 0 & U(r_{12}) & \dots & U(r_{1n}) \\ U(r_{21}) & 0 & \dots & U(r_{2n}) \\ \dots & \dots & \dots & \dots \\ U(r_{n1}) & U(r_{n2}) & \dots & 0 \end{bmatrix}, \quad (32)$$

$$P = \begin{bmatrix} 1 & x_1 & y_1 \\ 1 & x_2 & y_2 \\ \dots & \dots & \dots \\ 1 & x_n & y_n \end{bmatrix}, \quad (33)$$

kur O yra 3×3 nulinė matrica. Aprašome žymių poslinkius $D = [d_1, d_2, \dots, d_n, 0, 0, 0]^T$. Lygybė, suformuota pakeičiant žymių ribojimus, gali būti užrašyta matrica forma $D = LW$. Šios matricos

sprendinys W yra apskaičiuojamas mažiausių kvadratų metodu, nes matrica K gali ir nebūti pilno rango.

1.6.2.5. Kubinis B-splainas

3D kubinio B-splaino iškraipymo metodams transformacija T yra aprašoma gardele Φ , sudaryta iš $n_x \times n_y \times n_z$ kontrolinių taškų, tarp kurių tarpai yra vienodai pasiskirstę [3]. Tarpai tarp kontrolinių taškų x , y ir z kryptimis yra atitinkamai pažymėti δ_x , δ_y ir δ_z . Kiekviename taške $X = (x, y, z)$ yra suskaičiuojama deformacija priklausomai nuo supančių $4 \times 4 \times 4$ kaimyninių kontrolinių taškų

$$T(X) = \sum_{l=0}^3 \sum_{m=0}^3 \sum_{n=0}^3 B_l(u) B_m(v) B_n(w) \phi_{i+l, j+m, k+n}, \quad (34)$$

kur i, j, k žymi kontrolinio taško celės indeksus, kuriai priklauso taškas $X = (x, y, z)$. u, v, w yra atitinkamų taškų koordinačių x, y ir z pozicijos.

$$i = \left\lfloor \frac{x}{\delta_x} \right\rfloor - 1, \quad j = \left\lfloor \frac{y}{\delta_y} \right\rfloor - 1, \quad k = \left\lfloor \frac{z}{\delta_z} \right\rfloor - 1, \quad u = \frac{x}{\delta_x} - \left\lfloor \frac{x}{\delta_x} \right\rfloor, \quad v = \frac{y}{\delta_y} - \left\lfloor \frac{y}{\delta_y} \right\rfloor, \quad w = \frac{z}{\delta_z} - \left\lfloor \frac{z}{\delta_z} \right\rfloor.$$

Funkcijos nuo B_0 iki B_3 yra trečios eilės bazinės B-splaino funkcijos. Jų išraiškos yra šios:

$$\begin{aligned} B_0(t) &= \frac{(1-t)^3}{6}, \\ B_1(t) &= \frac{(3t^3 - 6t^2 + 4)}{6}, \\ B_2(t) &= \frac{(-3t^3 + 3t^2 + 3t + 4)}{6}, \\ B_3(t) &= \frac{t^3}{6}. \end{aligned} \quad (35)$$

Priešingai nei plonos plokštelės splainas, kubinis B-splainas, aprašantis geometrinę transformaciją, turi dvi matematinės savybes: jis yra lokaliai valdomos (t.y. keičiant kontrolinio taško poziciją, yra įtakojama tik $4 \times 4 \times 4$ kaimyninių kontrolinių taškų transformacija) ir yra apksimuojanči, o ne interpoliuojanti funkcija [10].

2. Taškų optimalių padėčių plokštumoje radimas naudojant splainus

Kadangi žmogaus smegenų vidinių neurostruktūrų kontūrų taškai sudaro glotnią kreivę, šis glodinimo skaičiavimo etapas yra pageidautinas. Juo labiau segmentavimo algoritmų rezultatas yra gaunami atskiri taškai, kurie ne visada sudaro pakankamai glotnią kreivę. Todėl norint vizualizuoti glotnų struktūros paviršių, jį suglodiname naudojant Overhauzerio splaino išraišką. Detaliau ši funkcija bus aptariama kitame skyriuje, kol kas trumpai peržvelgiame tokio skaičiavimo tikslai.

z_1 pjūvio dvimačių taškų apjungimas su kito pjūvio z_2 taškais vykdomas naudojant trimatę Delone(Delaunay) trianguliaciją. Šis algoritmas nereikalauja kiekviename pjūvyje saugoti vienodo taškų skaičiaus, tačiau, savaime suprantama, kad norint pavaizduoti keletą svarbiausių ar visas struktūras trimatėje erdvėje, susidarys šimtai tūkstančių trikampių. Delone trianguliacija vykdoma naudojant Voronojaus(Voronoi) diagramą, ir apjungia į trikampį artimiausius kaimyninius duotus taškus. Norint sumažinti trikampių skaičių, reiktų mažinti viršūnių skaičių, o tai priklauso nuo mūsų poreikio matyti tikslią figūros formą. Tad taškus optimizuosime: kur reikia įvesime naujus naudojant Overhauzerio kreivę, kur nereikia – atmesime senus turimus taškus.

Atlase yra saugomi tankiai susegmentuoti struktūrų kontūrų taškai. Natūralu, kad atlase saugomų taškų yra per daug, ir parinkus norimą paklaidą, kai kuriuos jų galima atmesti. Taip bus gaunami vienos taškų aibės elementai. Kita tos pačios neurostruktūros taškų aibė yra gaunama naudojantis paciento vaizdo segmentavimo algoritmu. Paprastai, šie taškai neturi tokio pat tikslumo padėčių, kaip atlaso taškai. Todėl bus glodinamos abi struktūros ir bus nustatyta taškų korespondencija tarp šių taškų. Paprastai, taškų skaičius abiejuose aibėse yra skirtingas. Kad neprarasti struktūros formos tikslumo ir sumažinti taškų skaičių, reikia rasti optimalias taškų padėtis plokštumoje. Tokiu būdu, atsižvelgus į didelio taškų kiekio saugojimo operatyviojoje atmintyje problemą, su kuria susiduria trimačių objektų vizualizacija, atliksime šių splainų taškų padėčių optimizaciją.

2.1. Struktūrų kontūrų taškų radimas naudojant Overhauzerio kreivę

Overhauzerio(Overhauser) kreivė buvo išrasta ir naudojama kompanijos „Ford Motor Company“. Ji taip pat gerai žinoma kaip kubinis Catmull-Rom splainas. Paprastai, Bezje kreivės neinterpoliuoja visų kontrolinių taškų. Overhauzerio kreivė interpoliuoja visus kontrolinius taškus ir susideda iš kreivės segmentų. Jos visos lygtys užrašomos taip:

$$\begin{aligned}
f_0(t) &= -\frac{1}{2}t + t^2 - \frac{1}{2}t^3, \\
f_1(t) &= 1 - \frac{5}{2}t^2 + \frac{3}{2}t^3, \\
f_2(t) &= \frac{1}{2}t + 2t^2 - \frac{3}{2}t^3, \\
f_3(t) &= -\frac{1}{2}t^2 + \frac{1}{2}t^3,
\end{aligned}$$

kuriose $t \in [0,1]$. Vienas Overhauzerio kreivės segmentas interpoliuoja \mathbf{P}_1 ir \mathbf{P}_2 taškus. Kreivės nuožulnumas ties tašku \mathbf{P}_1 priklauso nuo taškų \mathbf{P}_0 ir \mathbf{P}_2 , o kreivės nuožulnumas ties tašku \mathbf{P}_2 priklauso nuo taškų \mathbf{P}_1 ir \mathbf{P}_3 padėčių. Gauname, kad $P'(0) = \frac{1}{2}(P_2 - P_0)$ ir $P'(1) = \frac{1}{2}(P_3 - P_1)$ [17].

Tai reiškia, kad antrojo kreivės segmento pirmasis taškas turės tą pačią reikšmę kaip ir pirmojo segmento paskutinis taškas ir perėjimas bus glodus.

Šios funkcijos pagalba sugeneruojama glodi kreivė, einanti tarp taškų \mathbf{P}_1 ir \mathbf{P}_2 . Pagal duotą funkcijos išraišką dalimis ir pasirinkus reikiamą t parametą iš atkarpos $[0,1]$, randama tik viena koordinatė. Norint sužinoti daugiau funkcijos taškų, yra parenkama aibė t reikšmių iš duoto uždaro intervalo. Analogiškai randamos ir kitos koordinatės. Dvimačiu atveju:

$$\mathbf{F}(t) = \sum_{i=0}^3 f_i(t) \mathbf{P}_i; \Rightarrow \begin{cases} x(t) = \sum_{i=0}^3 f_i(t) P_{xi}, \\ y(t) = \sum_{i=0}^3 f_i(t) P_{yi}. \end{cases}, t = \frac{i}{n-1}, i = 0, \dots, n-1, n > 1, n \in \mathbb{N}.$$

Tokiu būdu randamos n taškų glodžios kreivės koordinatės. Pagal turimą užduotį keliamas tikslas interpoliuoti m kontrolinių taškų. Kadangi neurostruktūrų kontūrai sudaro uždara kreivę, tai taškai turi būti parinkti taip, kad būtų sugeneruota uždara glodi kreivė. Tam prie turimų m taškų dar pridedamas 1-asis ir 2-asis taškas. Jei tarp kiekvienų dviejų kontrolinių taškų bus sugeneruojama po n tarpinių taškų, tai bus gauta glotni kreivė, kurios išraiška atrodys taip:

$$\begin{cases} x(j,t) = \sum_{i=0}^3 f_i(t) P_{x,k}, & t = \frac{i}{n-1}, i = 0, \dots, n-1, n > 1, n \in \mathbb{N}; \\ y(j,t) = \sum_{i=0}^3 f_i(t) P_{y,k}. & k = \begin{cases} i+j, i+j < m, \\ i+j-m, i+j \geq m. \end{cases}; \\ & j = 0, \dots, m-1, m > 2, m \in \mathbb{N}. \end{cases}$$


Pasirinkama ši funkcija dėl jos paprastumo, greitaveikos, nesudėtingos analizinės išraiškos bei nereikalaujamo tiesinių lygčių sprendimo, ir jos pagalba suglodinamas atskirų struktūrų paviršius. Tegul yra duota m taškų, kuriuos norima suglodinti. Tam parenkama n tarpinių taškų ir minėtu būdu gaunamas glodus paviršius, turintis $m^*(n-1)$ taškų. Neurostruktūros yra netaisyklingos formos ir įvairiuose taškuose išlinkio kampas skiriasi. Taigi norint sumažinti taškų skaičių, galima rasti tik

„svarbius“ taškus. Nurodžius norimą paklaidą (t.y. Euklido atstumą nuo tikrosios splaino reikšmės iki optimizuotų taškų tiesės), galima gauti tik reikšmingus taškus. Tam panaudojama taškų padėčių optimizacija.

2.2. Overhauzerio splaino taškų padėčių plokštumoje optimizacija

Gautų optimizuotų padėčių taškai sumažina trimačio objekto elementų (pvz.: trikampių) viršūnių skaičių reikšmingai neprarandant objekto figūros formos. Tam tikslui pasiekti randami tokie splaino taškai, tarp kurių, išvedus tiesę, atstumas (statmuo) nuo tiesės iki labiausiai nutolusio splaino kreivės reikšmės neviršytų užduotos paklaidos ε . Tegu turime Overhauzerio funkcijos splaino parametrinę analizinę išraišką:

$$\begin{aligned} \mathbf{F}(t) &= \sum_{i=0}^3 f_i(t) \mathbf{P}_i, \quad t \in [0,1]; \\ x &= F_x(t) = \sum_{i=0}^3 f_i(t) P_{xi} = \\ &= \left(-\frac{t}{2} + t^2 - \frac{1}{2}t^3\right) P_{x0} + \left(1 - \frac{5}{2}t^2 + \frac{3}{2}t^3\right) P_{x1} + \left(\frac{t}{2} + 2t^2 - \frac{3}{2}t^3\right) P_{x2} + \left(-\frac{t^2}{2} + \frac{1}{2}t^3\right) P_{x3} = \\ &= t^3 \left(\frac{3}{2} P_{x1} - \frac{1}{2} P_{x0} - \frac{3}{2} P_{x2} + \frac{1}{2} P_{x3}\right) + t^2 \left(P_{x0} - \frac{5}{2} P_{x1} + 2 P_{x2} - \frac{1}{2} P_{x3}\right) + t \left(-\frac{1}{2} P_{x0} + \frac{1}{2} P_{x2}\right) + P_{x1} = \\ &= A_x t^3 + B_x t^2 + C_x t + D_x, \\ y &= F_y(t) = \sum_{i=0}^3 f_i(t) P_{yi} = A_y t^3 + B_y t^2 + C_y t + D_y. \end{aligned}$$



13 pav. Overhauzerio kreivių fragmentai. (a) Dekarto ir (b) transformuotoje Dekarto koordinatėse sistemoje

Atlikus Dekarto koordinačių posūkį apie koordinačių pradžią kampu $-\beta$, gaunama transformuotos kreivės ir transformuotos tiesės išraiška. Naudojama afiniosios transformacijos išraiška ir sukant kampu $-\beta$ bus gauta:

$$\begin{cases} X = x_t = x \cos(-\beta) - y \sin(-\beta) = F_x(t) \cos(-\beta) - F_y(t) \sin(-\beta) = F_x(t) \cos \beta + F_y(t) \sin \beta, \\ Y = y_t = y \cos(-\beta) + x \sin(-\beta) = F_y(t) \cos(-\beta) + F_x(t) \sin(-\beta) = F_y(t) \cos \beta - F_x(t) \sin \beta. \end{cases}$$

kurioje taškas (x,y) yra senosiose koordinačių ašyse, o (x_t, y_t) – naujosiose koordinačių ašyse. Ieškant atstumo ε ir tuo tikslu randama funkcijos $y_t = G(F_y(t), F_x(t))$ ekstremumo taško reikšmė.

Remiantis būtinają minimumo sąlyga taške ir funkcijos, apibrėžtos parametrinėmis lygtimis diferencijavimu, randama, kad

$$Y'_x = \frac{Y'_t}{X'_t} = 0, X'_t \neq 0 \Rightarrow Y'_t = 0 \Rightarrow G'_t(F_y(t), F_x(t)) = 0.$$

Vadinasi

$$y_t^* = G'_t(F_y(t^*), F_x(t^*)) = 0 \Rightarrow t^* = \arg G'_t(F_y(t^*), F_x(t^*)) = 0.$$

Čia G – funkcija, kurios reikšmė priklauso nuo parametro t reikšmės. Atkreipkime dėmesį, kad ieškoma nebūtinai maksimumo, gali būti ir minimumas. Svarbu, kad būtų rastas didžiausias atstumas nuo kreivės iki tiesės absoliutiniu didumu. Toliau išsamiau nagrinėjama lygtis

$$y_t^* = G'_t(F_y(t^*), F_x(t^*)) = 0.$$

$$\begin{aligned} y_t = G'_t(F_y(t), F_x(t)) &= (F_y(t) \cos \beta - F_x(t) \sin \beta)'_t = F'_y(t) \cos \beta - F'_x(t) \sin \beta = \\ &= (A_y t^3 + B_y t^2 + C_y t + D_y)'_t \cos \beta - (A_x t^3 + B_x t^2 + C_x t + D_x)'_t \sin \beta = \\ &= (3A_y t^2 + 2B_y t + C_y) \cos \beta - (3A_x t^2 + 2B_x t + C_x) \sin \beta = \\ &= t^2 (3A_y \cos \beta - 3A_x \sin \beta) + t(2B_y \cos \beta - 2B_x \sin \beta) + (C_y \cos \beta - C_x \sin \beta). \end{aligned}$$

Pasižymima:

$$A = A_y \cos \beta - A_x \sin \beta;$$

$$B = B_y \cos \beta - B_x \sin \beta;$$

$$C = C_y \cos \beta - C_x \sin \beta.$$

Išsprendus kvadratinę lygtį:

$$y_t = G'_t(F_y(t), F_x(t)) = 3At^2 + 2Bt + C = 0,$$

randamos dvi t reikšmės:

$$t_{1,2} = \frac{-B \pm \sqrt{B^2 - 3AC}}{3A}.$$

Priimama, kad $t^* = t_1$ arba $t^* = t_2$. Gauta reikšmė priklauso atkarpai $[0,1]$. Teoriškai gaunamos t reikšmės yra iš intervalo $(-\infty, +\infty)$. Todėl pasirenkamos tos reikšmės, kurios priklauso $[0,1]$. Tokios reikšmės gali būti dvi, gali būti viena, arba nei vienos. Pastaruoju atveju, nėra rastas ekstremumo taškas. Vadinasi, didžiausia reikšmė bus įgyta viename iš fragmento kraštinių taškų ir $t^* = 0$ arba $t^* = 1$. Sužinojus t^* reikšmę, paskaičiuojama $y_t^* = F_y(t^*) \cos \beta - F_x(t^*) \sin \beta$. Taip yra transformuojama splaino išraiška ir randama y_t^* .

Toliau bus randama ir transformuotos tiesės reikšmė y_{tp} . Tačiau prieš tai tarkime, kad žinoma du tos tiesės taškai (x_1, y_1) ir (x_2, y_2) senosiose koordinatinių ašyse. Tuomet tiesės lygtis bus tokia:

$$y = f(x) = \frac{(y_2 - y_1)}{(x_2 - x_1)} x + y_1 - x_1 \frac{(y_2 - y_1)}{(x_2 - x_1)} = x \operatorname{tg} \beta + (y_1 - x_1 \operatorname{tg} \beta). \quad \text{Transformuota tiesė (pasukta}$$

kampu lygiu $-\beta$) tampa lygiagreti senųjų koordinatinių sistemos Ox ašiai. Todėl galima transformuoti tiek (x_1, y_1) , tiek (x_2, y_2) tašką. Ir, įsistačius jį į transformacijos lygtį, gaunama transformuotos tiesės reikšmė:

$$\begin{aligned} y_{tp} &= y \cos(-\beta) + x \sin(-\beta) = y \cos \beta - x \sin \beta = (x \operatorname{tg} \beta + (y_1 - x_1 \operatorname{tg} \beta)) \cos \beta - x \sin \beta = \\ &= x \sin \beta + (y_1 - x_1 \operatorname{tg} \beta) \cos \beta - x \sin \beta = (y_1 - x_1 \operatorname{tg} \beta) \cos \beta = y_1 \cos \beta - x_1 \sin \beta. \end{aligned}$$

Taigi turimi du taškai y_t^* ir y_{tp} . Galiausiai, randama paklaida (atstumas tarp šių taškų):


$$\begin{aligned} \varepsilon &= |y_t^* - y_{tp}| = |F_y(t^*) \cos \beta - F_x(t^*) \sin \beta - (y_1 \cos \beta - x_1 \sin \beta)| = \\ &= |\cos \beta (F_y(t^*) - y_1) + \sin \beta (x_1 - F_x(t^*))|. \end{aligned}$$

Lygiai taip pat analogiškai buvo galima atlikti pasukimą ir pagal Oy ašį. Tuomet būtų skaičiuojamas atstumas nuo vertikalios tiesės iki splaino reikšmės, turinčios didžiausią x reikšmę. Kadangi nėra iš anksto žinoma, su kuria: t_1 ar t_2 reikšme bus įgytas didžiausias atstumas, tai lygiai taip pat nėra žinoma, ar šis atstumas bus mažesnis ar didesnis už ε reikšmę. Tam yra naudojamas splainų fragmentų perrinkimas. Jų pagalba nustatomas toks splaino fragmentas, kuriame bus rasta norima ε reikšmė. Šis fragmentų perrinkimo strategija nagrinėjama kitame poskyryje.

2.3. Splaino fragmentų radimas

Apeinant visus kontrolinius taškus reikia nustatyti pirmąjį tašką, su kuriuo bus viršytas leistinas atstumas. Paimamas pirmasis taškas kaip atkarpos pradžia ir einama paeiliui per kitus taškus brėžiant atkarpas. Pagal turimą vieną atkarpą transformuojami (pasukami apie koordinatinių pradžios tašką) tarp šių taškų esantys splainų fragmentai (lokalieji splainai) ir randamas didžiausias atstumas iki atkarpos. Jei jis yra mažesnis už leistiną paklaidą, imamas kitas kontrolinis taškas, transformuojami tarp taškų esantys fragmentai ir vėl randamas didžiausias atstumas.

Nubrėžus atkarpą nuo pradinio taško iki nagrinėjamo fragmento galinio taško, yra nustatoma koordinatinių pasukimo kryptis. Nustačius kontrolinį tašką, su kuriuo yra viršijama paklaida, atliekamas parametro t nustatymo etapas naudojant dalybos pusiau metodą. Bandoma surasti tokią t^* parametro reikšmę, su kuria atstumas neviršija nustatytos paklaidos ε . Detaliau šiuos veiksmus iliustruoja 14 paveikslėlis.



14 pav. Didžiausio atstumo nuo atkarpos iki splaino reikšmės radimas

Kiekviename i -ajame fragmente yra randamas maksimalus atstumas ε_i iki tiesės segmento. Veiksmai vykdomi transformuotoje koordinatinių sistemoje. Atstumai ε_1 ir ε_2 atitinkamai iki pirmojo ir antrojo splainų toliausiai nutolusių taškų sutampa. ε_5 yra rasta tokia t parametro reikšmė, su kuria nustatytas didžiausias atstumas.

Toliau nagrinėjamas parametro t^* radimas. Kaip matyti, parametras t^* priklauso ne toliausiai nutolusiam fragmentui, bet aktyviajam fragmentui. Perrinkimo būdu (dalybos pusiau metodu) yra nustatoma tiksli t^* reikšmė:

$$t^* = \begin{cases} t_0 + dt, & R < \varepsilon, \\ t_0 - dt, & R \geq \varepsilon. \end{cases}$$

kur $t_0 = 0$, o dt kiekvienoje iteracijoje yra mažinama pusiau. R yra vartotojo nustatytas atstumas nuo splaino iki atkarpos. ε yra tikrasis rastas atstumas. Studijuojama visa algoritmo schema detaliai:

$$t_0 = 0; t_2^* = 0.5; (x_1, y_1); R; \varepsilon = 0;$$

Kol nerasta pakankamai tiksli paklaida ($R - \varepsilon$):

$$\sin \beta = \frac{(F_y^i(t_2^*) - y_1)}{\sqrt{(F_y^i(t_2^*) - y_1)^2 + (F_x^i(t_2^*) - x_1)^2}};$$

$$\cos \beta = \frac{(F_x^i(t_2^*) - x_1)}{\sqrt{(F_y^i(t_2^*) - y_1)^2 + (F_x^i(t_2^*) - x_1)^2}};$$

$$t_1^* = \arg G_t'(F_y^j(t), F_x^j(t));$$


$$y_t^* = F_y^j(t_1^*) \cos \beta - F_x^j(t_1^*) \sin \beta;$$

$$y_{tp} = y_1 \cos \beta - x_1 \sin \beta;$$

$$\varepsilon = |y_t^* - y_{tp}|;$$

$$t_2^* = \begin{cases} t_0 - dt, & R < \varepsilon, \\ t_0 + dt, & R \geq \varepsilon. \end{cases}$$

Šioje schemeje F_x^i ir F_y^i yra aktyviojo fragmento, kuriame norima rasti t_2^* reikšmę, funkcijos. F_x^j ir F_y^j yra fragmento, kuriame rastas didžiausias atstumas, charakteringos funkcijos. Nuo šios reikšmės tikslumo gali labai priklausyti tai, ar tiksliai nustatysime ε reikšmę. Pagal algoritmą $\varepsilon \rightarrow R$ ir jis yra baigiamas tada, kai yra randama pakankamai tiksli ε reikšmė su vartotojo nustatyta paklaida. Kitas svarbus etapas yra t^* reikšmės radimas. Kaip buvo minėta praeitame poskyryje, $y_t = G_t'(F_y(t), F_x(t))$. Radus funkcionalo G išvestinę t atžvilgiu, gaunamas antros eilės polinomas (parabolė), turintis dvi šaknis t_1 ir t_2 . Norint pasakyti, kuri iš šių reikšmių yra tinkama, nagrinėjami atskiri atvejai. Reikšmė t^* priimama lygi tai t reikšmei, kuri priklauso intervalui $[0,1]$ ir jame įgyja didesnę reikšmę. Kelis atskirus galimus atvejus matome 16 pav.



15 pav. Funkcijos G parametrų reikšmės. (a) $t_{1,2} \notin [0,1]$; (b) $t_{1,2} \in [0,1]$.

2.4. Splaino taškų padėčių optimizavimo modeliavimo rezultatai

Duoti taškai:

X	43	44	44	45	45	45	45	45	45	45	46	47	51	57	62
Y	0	10	30	54	80	100	124	152	176	194	216	228	240	246	248


X	70	78	83	86	87	87	87	85	80	76	69	63	65	71	76
Y	248	246	238	224	212	198	188	180	172	168	166	164	172	170	166

X	80	84	88	91	93	94	94	92	88	84	78	74	67	62	58
Y	162	154	148	136	124	110	98	84	74	64	58	56	56	58	62

X	53	49
Y	68	72

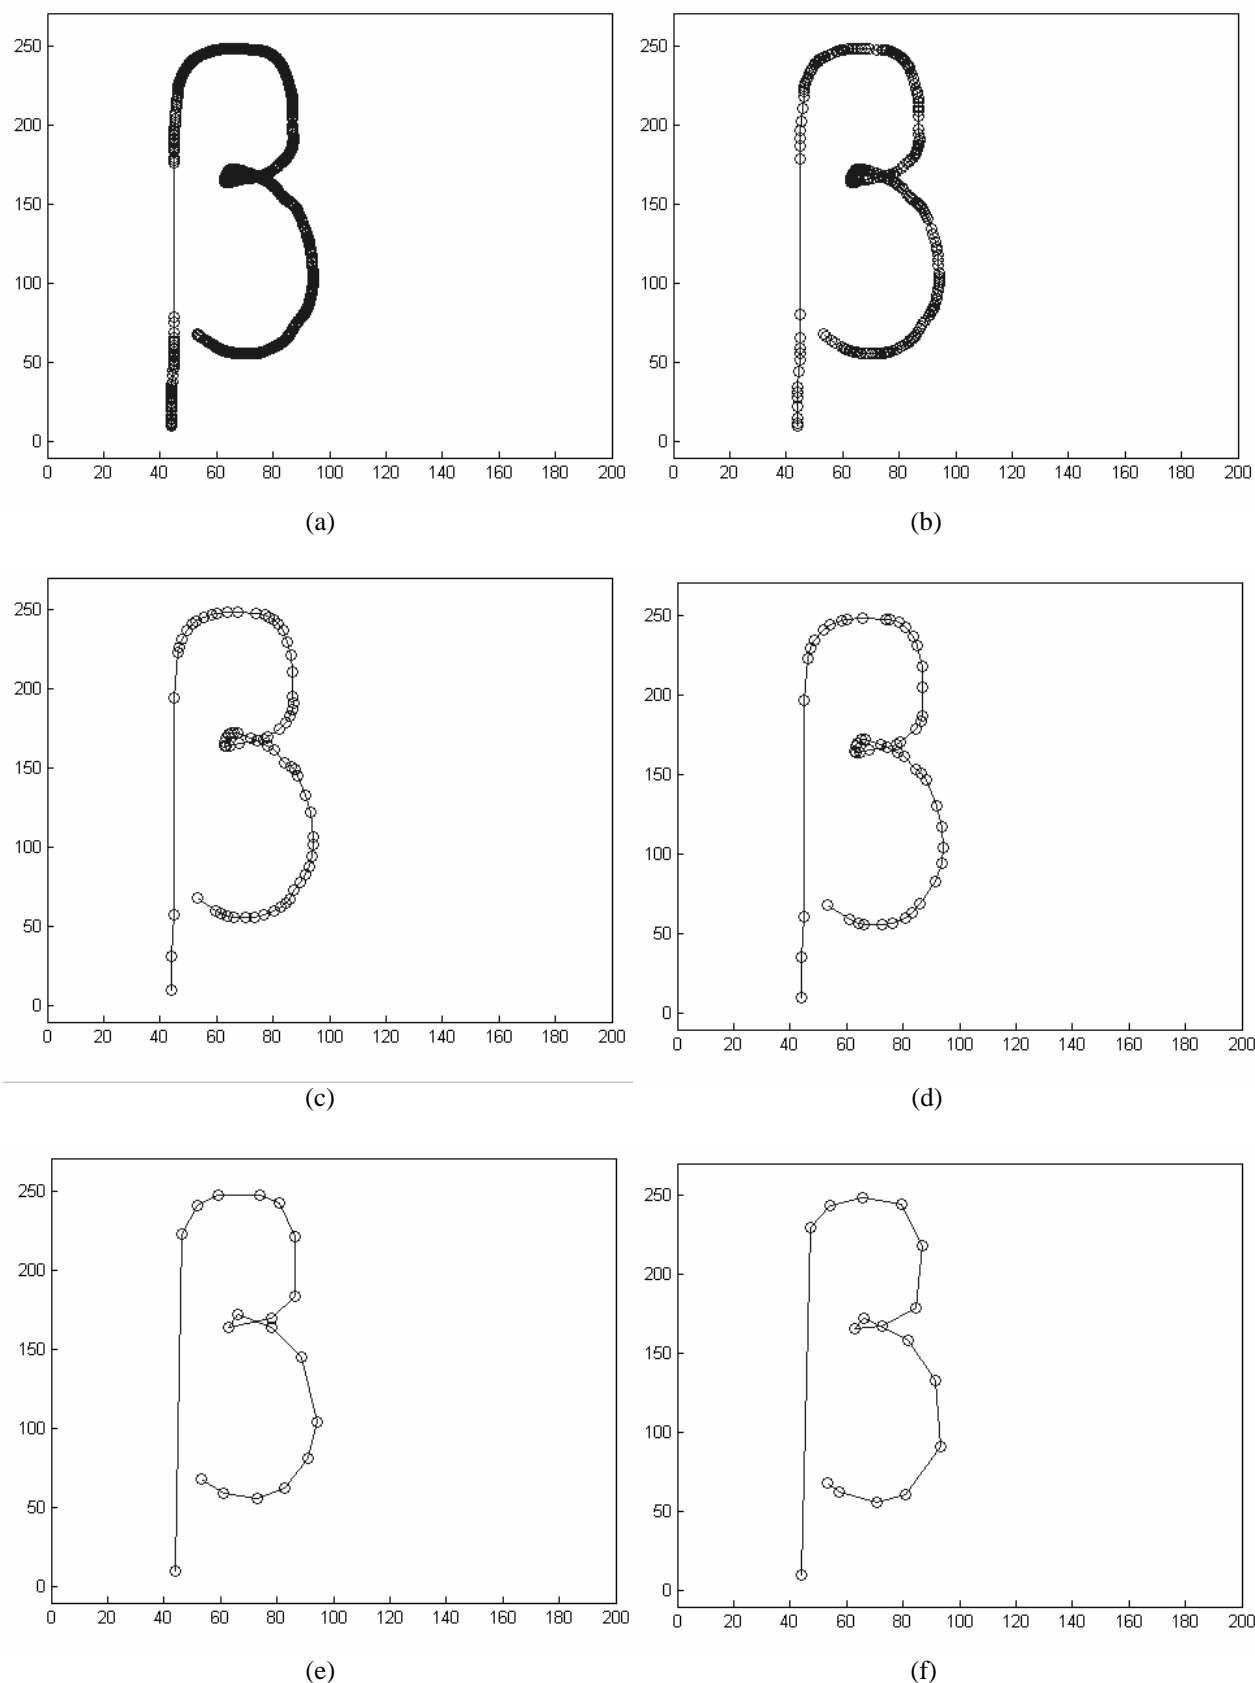
Panagrinėti: kaip duotiems taškams optimizuotų padėčių taškų skaičius priklauso nuo paklaidos R .

Pirma grafiškai 16 pav. (a) dalyje pavaizduojami duoti taškai. Šiuos taškus interpoliuosime Overhauzerio splainu. Pasirenkame žingsnį $dt = 0.1$ ir 16 pav. (b) dalyje pavaizduojame splainus.



16 pav. Kontrolinių taškų pavyzdys ir jų interpoliavimas splainu. (a) Duotų kontrolinių taškų pavyzdys; (b) Taškų interpoliavimas Overhauzerio splainu

Naudojantis programiniu paketu MATLAB 6.5 modeliuojame taškų padėčių optimizavimo algoritmą. Patekiamia keltą modeliavimo rezultatų iliustruodami grafiškai.




17 pav. Taškų padėčių optimizacijos pavyzdžiai, esant įvairioms paklaidos R reikšmėms. (a) kai $R=0.001$, $\epsilon=0.0001$; (b) kai $R=0.01$, $\epsilon=0.0001$; (c) kai $R=0.1$, $\epsilon=0.001$; (d) kai $R=0.1$, $\epsilon=0.1$; (e) kai $R=1$, $\epsilon=0.1$; (f) kai $R=2$, $\epsilon=0.1$

Parinkus įvairias paklaidas (atstumus nuo splaino reikšmės iki optimalios atkarpos), sudaroma lentelė. Į lentelę įtraukiame ir bendrą optimizuotų atkarpų ilgių sumą. Naudojantis gautais rezultatais bus nubrėžiami grafikai ir matysis parametru priklausomybės.


1 lentelė. Modeliavimo rezultatų lentelė

<i>R</i>	Optim. padėčių taškų sk.	Bendras atkarpų ilgis
10.0000	477.8433	8
5.0000	508.3470	10
2.5000	517.0383	15
1.2500	522.1823	19
0.6250	524.8877	27
0.3125	525.9380	40
0.1563	526.5945	58
0.0781	526.8458	81
0.0391	526.9542	118
0.0195	527.0564	175
0.0098	527.1276	252
0.0049	527.1416	351
0.0024	527.1499	511
0.0012	527.1541	721
0.0006	527.1561	996

Pavaizdavus gautus rezultatus grafiškai, matome aiškia parametru kitimo tendencija.



18 pav. Aproksimuotų taškų skaičiaus priklausomybė nuo nustatytos paklaidos R .




19 pav. Bendros atkarpų ilgiu sumos priklausomybė nuo nustatytos paklaidos R .

Kaip matyti, 18 pav. pavaizduotas grafikas turi atvirkštinio logaritmo kitimo savybę. Paėmus mažai taškų, gaunamos didelios paklaidos nuo splaino reikšmės plokštumoje, o paėmus mažą paklaidos vertę, gaunamas didelis kiekis optimizuotų taškų. Natūralu trimatėje erdvėje

atvaizduojant duotus taškus, t.y. raidę „ β “, paklaidą R parinkti taip, kad taškų skaičius būtų tarp 20 ir 60. Trimatės struktūros tikslesnė paklaidos vertė yra pasirenkama pagal tikslumo poreikį ir priklausomai nuo taškais pavaizduoto objekto matavimo vienetų.

Labai informatyvus yra 19 pav. Atvaizdavas bendrą atkarpų, jungiančių taškus optimizuotose padėtyse, ilgio priklausomybę nuo minėtos paklaidos, gaunamas grafikas apytikslis tiesei. Pasirinkus kitus duotus kontrolinius taškus būtų gaunamas kitas grafikas. Tačiau visada yra apytiksliai vaizduojama tiesė. Vadinasi, galima teigti, kad vaizduojamos figūros tikslumą apibūdina nustatyta paklaida. O nuo paklaidos tiesiškai priklauso ir figūros paviršiaus plotas. Taigi apibūdinant figūros formos tikslumą, galima nustatyti ir figūros kreivės ilgį, tačiau toks uždavinys būtų žymiai sudėtingesnis spręsti.

Nustatant paklaidą R yra randami taškai, kurie aproksimuoja splaino taškų reikšmes. Tačiau, paprastai, nėra apskaičiuojamos tikslios taškų koordinatės taip, kad atstumas būtų lygus R . Taip gaunama dar viena paklaida – paklaidos (atstumo) R paklaida. Panagrinėkime, kaip ji įtakoja taškų skaičių ir figūros formą.



20 pav. Aproksimuotų taškų skaičiaus priklausomybė nuo atstumo R paklaidos.

Iš grafikų matyti, kad aproksimuotų taškų skaičiui ε įtaka yra labai panaši į R skaičiaus įtaką. Natūralu, šie du parametrai turi panašią prasmę. Abu nurodo atstumą nuo aproksimuotos atkarpos iki splaino. Tik ε dar rodo R atstumo paklaidą. Taigi derinant šių dviejų parametru reikšmes galima gauti visai optimalų taškų skaičių. Nepamirštant tai, kad svarbiausia yra nustatyti mažiausią taškų skaičių tokiose optimaliose plokštumos padėtyse, kad būtų išsaugota priimtina figūros forma. Pastarąją įtakoja bendras atkarpų ilgis. Fiksavus pastovią R reikšmę, ε taip pat apytiksliai tiesiškai įtakoja minėtąjį ilgį.

IŠVADOS

Apžvelgus galvos smegenų tyrimams skirtų kompiuterine vaizdų analize paremtų sistemų problemų ratą ir jų sprendimo metodus nustatyta, kad algoritmų plėtros kryptių gali būti daug: smegenų modeliai bei jų koordinačių sistemos, kompiuterinių atlasų sudarymas, vaizdų segmentacija, charakterinių taškų radimas ir sutapatinimas, vaizdus sutapatinančios transformacijos ir t.t. Šiame darbe gilintasi į sutapatinančios transformacijos charakterinių taškų radimą panaudojant splainus:

1. Geriausius rezultatus parodė mišrūs registracijos metodai, įvertinantys taškų (žymių) korespondenciją ir abipusės informacijos vaizdų panašumo matą;
2. Splainai atlieka tiksliausią netiesinę transformaciją geriausiai tinkančią žmogaus galvos smegenų vaizdų registracijai atlikti;
3. Daugumoje interpoliacinių splainų ar polinomų koeficientų radimui naudojami iteraciniai metodai, nes esant dideliame kontrolinių taškų skaičiui tikslaus sprendinio radimas truktų gana ilgai;
4. Lokalūs Overhauzerio splainas dėl nesudėtingos analizinės išraiškos ir paprastos realizacijos gerai tinka neurostruktūrų glodinimui ir taškų padėčių optimizacijai;
5. Taškų padėčių optimizacija nustato būtinus vaizdų transformacijos kontrolinius taškus;
6. Overhauzerio splainas gali būti naudojamas tiksliai taškų korespondencijai nustatyti;
7. Tikslus optimizuotos taško padėties radimo uždavinys yra logaritminio sudėtingumo.

LITERATŪRA

1. Brett M. The MNI brain and the Talairach atlas. Cambridge Imagers, 2002. Prieiga per internetą: <www.mrc-cbu.cam.ac.uk/Imaging/Common/mnispace.shtml>.
2. Carmack P. S., Spence J., Gunst R. F., Schucany W. R., Woodward W. A., Haley R. W. Improved Agreement Between Talairach and MNI Coordinate Spaces in Deep Brain Regions. Department of Statistical Science, Southern Methodist University, Dallas, 2003-09-19, 14 p. Prieiga per internetą: <[http://www.smu.edu/statistics/TechReports/Carmack et al_NI.pdf](http://www.smu.edu/statistics/TechReports/Carmack%20et%20al_NI.pdf)>.
3. Chou, Yi-Yu. Transitive and Symmetric Nonrigid Image Registration. School of Biomedical Engineering, Georgia Institute of Technology, balandis 2004, 72 p. etd-04082004-122026. Prieiga per internetą: <<http://etd.gatech.edu/theses/available/etd-04082004-122026>>.
4. Chui H. Non-Rigid Point Matching: Algorithms, Extensions and Applications. Faculty of Graduate School, Yale University, USA, 2001-01, 151 p. Prieiga per internetą: <<http://noodle.med.yale.edu/thesis/chui.html>>.
5. Goshtashby A. A. Transformation Functions. Paskaitų konspektai, 1999, 19 p. Prieiga per internetą: <<http://citeseer.ist.psu.edu/update/407549>>.
6. Kaus M. Contributions to the Automated Segmentation of Brain Tumors in Magnetic Resonance Images. Der Technischen Fakultät der Universität Erlangen-Nürnberg, 2000, 130 p. Prieiga per internetą: <<http://splweb.bwh.harvard.edu:8000/pages/papers/kaus/phd.pdf>>.
7. Schiffbauer H. Neuronavigation In Brain Tumor Surgery. Clinical beta-phase of the Oulu Neuronavigator System, Department of Neurosurgery, University of Oulu, Oulu Finland, 1999, 159 p. ISBN 951-42-5128-8, ISSN 0355-3221. Prieiga per internetą: <<http://herkules oulu.fi/isbn9514252543/isbn9514252543.pdf>>.
8. Suri, Jasjit S., Kamaleddin Setarehdan, S., Singh, Sameer. Advanced Algorithmic Approaches to Medical Image Segmentation. Springer, 2002. 668 p. ISBN 1-85233-389-8
9. Rajagopalan S., Robb R. High Resolution Three Dimensional Talairach Labels For Human Brain Mapping Using Shape-based Interpolation. Biomedical Imaging Resource, Mayo Clinic/Foundation, Rochester, Minnesota, USA. 2004, 9 p. Prieiga per internetą: <http://www.mayo.edu/bir/PDF/rajagopalan2-MI_04-pap.pdf>.
10. Rohlfing T., Brandt R., Maurer C. R., Menzel R. Bee Brains, B-Splines and Computational Democracy: Generating an Average Shape Atlas. Image Guidance Laboratories, Department of Neurosurgery, Stanford University, Stanford, CA, USA, 2001, 8 p. Prieiga per internetą: <http://www.stanford.edu/~rohlfin/publications/2001-rohlfin-mmbia-bee_brain_average_atlas.pdf>.

11. Rorden C., Brett M. Stereotaxic display of brain lesions. University of Nottingham, Nottingham, UK, MRC Cognition and Brain Sciences Unit, Cambridge, UK. 2001, 191-200 p. ISSN 0953-4180. Prieiga per internetą:
<<http://www.psychology.nottingham.ac.uk/staff/cr1/mricro01.pdf>>.
12. Russakoff D. B., Tomasi C., Rohlfing T., Maurer C. R. Image Similarity Using Mutual Information of Regions. Department of Computer Science and Image Guidance Laboratories, Stanford University, Stanford CA, USA, 2004, 12 p. . Prieiga per internetą:
<http://www.stanford.edu/~rohlfig/publications/2004-russakoff-eccv-mutual_information_regions.pdf>.
13. Thompson P. Probabilistic Brain Atlases. Brain Research Institute, Los Angeles. Prieiga per internetą: <http://www.loni.ucla.edu/~thompson/prob_atlas.html>.
14. Toga A. W., Thompson P. Brain Atlases And Registration. Laboratory of Neuro Imaging, Dept. of Neurology, Division of Brain Mapping, UCLA School of Medicine, Los Angeles, 2000, 19 p. Prieiga per internetą: <<http://citeseer.ist.psu.edu/update/498548>>.
15. Toga A. W., Thompson P. Multimodal Brain Atlases. Laboratory of Neuro Imaging, Dept. of Neurology, Division of Brain Mapping, UCLA School of Medicine, Los Angeles, CA. Prieiga per internetą: <http://www.loni.ucla.edu/~thompson/whole_atlas.html>.
16. Toga A. W., Thompson P. The Role Of Image Registration In Brain Mapping. Laboratory of Neuro Imaging, Dept. of Neurology, Division of Brain Mapping, UCLA School of Medicine, Los Angeles, 2001, 24 p. Prieiga per internetą:
<http://www.loni.ucla.edu/~thompson/IVCJ_99.html>.
17. Sederberg T. W. Computer Aided Geometric Design. 2003-03-24, 200 p.

SANTRUMPŲ IR TERMINŲ ŽODYNAS

AC – Anterior commissure

CSF – Cerebro-spinal fluid

CT – Computer Tomography

DA – Deterministic Annealing

DICOM – Digital Imaging and Communications in Medicine

EM – Expectation-Maximization

fMRI – functional Magnetic Resonance Images

GM – Grey matter

ICP – Iterative Closest Point

LV – Lateral ventricle

MI – Mutual information

MNI – Montreal Neurological Institute

MRI – Magnetic Resonance Imaging

NMI – Normalized mutual information

ROI – Region of Interest

RPM – Robust Point Matching

PC – Posterior commissure

PET – Positron Emission Tomography images

SNR – Signal to Noise Ratio

SPAM – Statistical/Probabilistic Anatomy Maps

SPECT - Single Photon Emission Computerized Tomography

SPGR – Spoiled gradient-recalled acquisition


TPS – Thin Plate Spline

WM – White matter


PRIEDAI

1 priedas. Kontrolinių duomenų pavyzdys, skirtas taškų padėčių optimizacijai rasti


(a) Duotų kontrolinių taškų aibė; (b) Paklaidos R priklausomybė nuo atkarpų ilgių sumos; (c) R priklausomybė nuo optim. taškų skaičiaus; (d) $R=0.03125$; (e) $R=0.05$; (f) $R=0.0625$; (g) $R=0.125$




(a)




(b)




(c)




(d)



(e)

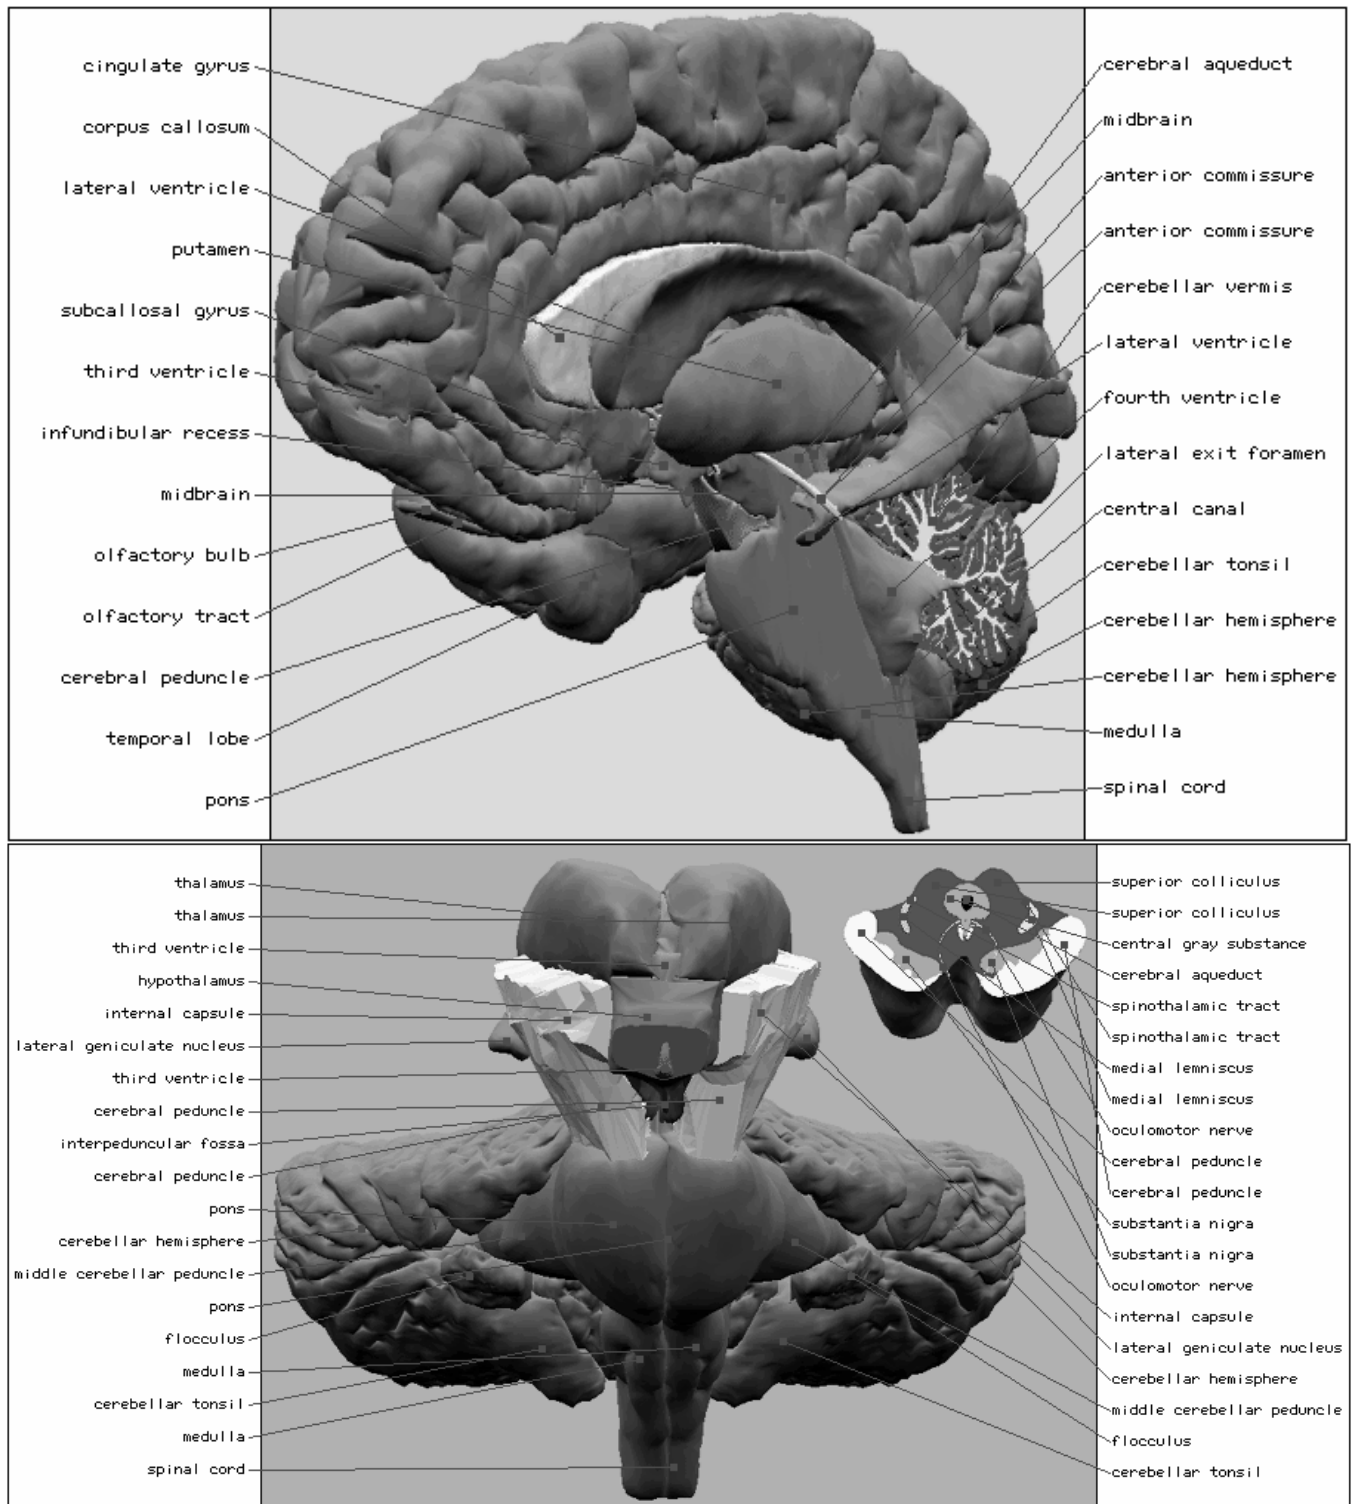





(f)



(g)

2 priedas. Trimačių žmogaus smegenų vizualizacija su išvardintomis struktūromis





3 priedas. Pagrindinių žmogaus smegenų neurostruktūrų ir jų grupių pavadinimai

abducens nerve	medulla
ambient cistern	midbrain
amygdala	midbrain tegmentum
anterior cerebral artery	middle cerebral artery
anterior commissure	middle cerebral artery branches
anterior limb of internal capsule	middle cerebellar peduncle
atrium (trigone) of lateral ventricle	occipital horn of lateral ventricle
base of pons	occipital lobe
basilar artery	occipito-temporal gyrus
caudate nucleus	optic chiasm
calcarine sulcus	optic nerve
central sulcus	optic tract
cerebellar hemisphere	parahippocampal gyrus
cerebellar tonsil	parieto-occipital sulcus
cerebellar vermis	pineal body
cerebellum	pituitary fossa
cerebral aqueduct	pons
cingulate gyrus	pontine tegmentum
choroid plexus	pontomedullary junction
choroidal fissure	postcentral gyrus
corpus callosum	posterior cerebral artery
dentate nucleus	posterior choroidal artery
eyeball	posterior commissure
inferior cerebellar peduncle	posterior communicating artery
inferior colliculi	posterior inferior cerebellar artery
inferior colliculus	posterior limb of internal capsule
infundibulum	precentral gyrus
insula	putamen
internal carotid artery	red nucleus
internal cerebral vein	quadrigeminal cistern
interpeduncular fossa	septal nuclei
isthmus of cingulate gyrus	septum pellucidum
gyrus rectus	splenium of corpus callosum
hippocampal formation	substantia innominata
hypothalamus	substantia nigra
facial nerve	subthalamus
fimbria of hippocampus	superior cerebellar artery
flocculus	superior cerebellar peduncle
fourth ventricle	superior colliculus
fornix	superior sagittal sinus
frontal lobe	stria medullaris of thalamus
genu of corpus callosum	temporal horn of lateral ventricle
globus pallidus	temporal lobe
great cerebral vein	thalamostriate vein
lamina terminalis	thalamus
lateral exit foramen	third ventricle
lateral sulcus	transverse temporal gyrus
lateral ventricle	transverse sinus
lateral geniculate nucleus	trigeminal nerve
lingual gyrus	vertebral artery
mammillary nuclei	vestibulocochlear nerve

4 priedas. „Visible Human Project“ aksialinio pjūvio nuotraukos

