

VILNIAUS UNIVERSITETAS

MYKOLAS JURGIS BILINSKAS

MATEMATINIO MODELIO SUKŪRIMAS IR TAIKYMAS  
KRŪTINĖS LAŠTOS KOMPIUTERINĖS TOMOGRAFIJOS  
VAIZDAMS PARAMETRIZUOTI IR REGISTRUOTI

Daktaro disertacija  
Fiziniai mokslai, informatika (09 P)

Vilnius, 2018

Disertacija rengta 2013–2017 metais Vilniaus universiteto Matematikos ir informatikos institute.

Mokslinis vadovas:

prof. habil. dr. Gintautas Dzemyda (Vilniaus universitetas, fiziniai mokslai, informatika – 09 P).

# Padėka

*Nuoširdžiai dėkoju darbo vadovui prof. habil. dr. Gintautui Dzemydai už nuoseklų vadovavimą, nuolatinį motyvavimą, neišsenkančią kantrybę ir didelę pagalbą, ypač tais momentais, kuriais tos pagalbos labiausiai reikėjo.*

*Esu dėkingas disertacijos recenzentams prof. habil. dr. Romualdai Baušiui ir prof. dr. (HP) Juliui Žilinskui, pateikusiems vertingų pastabų ir patarimų bei padėjusiems pagerinti šio darbo kokybę.*

*Už pagalbą ir bendradarbiavimą norėčiau padėkoti Vilniaus universiteto Duomenų mokslo ir skaitmeninių technologijų instituto Kognityvinių skaičiavimų grupės bei Vaizdų ir signalų analizės grupės darbuotojams ir doktorantams, o labiausiai – dr. Aurimui Rapečkai ir dr. Martynui Sabaliauskui.*

*Nuoširdžiai dėkoju šeimos nariams, artimiesiems ir draugams už supratingumą, paramą ir kantrybę.*

*Taip pat dėkoju dr. Mantui Trakymui už konsultacijas medicinos klausimais, kalbos redaktorėms Jorūnei Rimeisytei ir Janinai Kazlauskaitei bei visiems kitiems, kurie tiesiogiai ar netiesiogiai prisidėjo prie šio darbo rengimo.*

*Mykolas Bilinskas*

# Santrauka

Didelę dalį pastaruoju metu kaupiamų ir apdorojamų duomenų sudaro vaizdiniai duomenys. Ypač daug vaizdinės medžiagos generuojama medicinoje.

Šiame darbe nagrinėjami kompiuterinės tomografijos (CT) vaizdai ir jų analizės metodai efektyviai paciento stebėsenai ir diagnostikai, taikant daugkartinę tomografiją, pasiekti. Darbe ypač daug dėmesio skiriama vaizdų registravimui. Vaizdų registravimu įvardijamas procesas, kai skirtingi vaizdai transformuojami į vieną koordinačių sistemą. Medicinoje vaizdų registravimas yra svarbus, kai atliekami kompiuterinės tomografijos tyrimai prieš ir po gydymo. Siekiant įvertinti gydymo efektyvumą, lyginami šių tyrimų vaizdai ar atskiri jų sluoksniai.

Darbo tikslas – atskleisti galimybę registruoti krūtinės srities kompiuterinės tomografijos vaizdų sluoksnius pagal šonkaulių fragmentų išsidėstymą.

Disertacijoje sukurtas matematinis modelis, aproksimuojantis šonkauliais ribojamą sritį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame anatominei žmogaus skersinei plokštumai. Modelio parametrams nustatyti suformuluotas optimizavimo uždavinys ir sukurtas algoritmas jam spręsti. Parodyta galimybė krūtinės ląstos CT vaizdų sluoksnius registruoti pagal šonkaulių fragmentų išsidėstymą, aprašomą šiuo matematiniu modeliu. Pasiūlytas registravimo metodas yra invariantiškas poslinkiui, posūkiui ir mastelio pokyčiui, todėl sluoksnius galima registruoti nepriklausomai nuo paciento pozicijos lovos atžvilgiu ir tomografo parametrų, lemiančių pikselių dydį.

Disertaciją sudaro 5 skyriai ir literatūros sąrašas. Visa disertacijos apimtis yra 120 puslapių, pateikti 37 paveikslai ir 13 lentelių.

Tyrimų rezultatai publikuoti 3 periodiniuose recenzuojamuose leidiniuose, pristatyti ir aptarti 10 nacionalinių ir tarptautinių konferencijų.

## Paveikslų sąrašas

1 pav. Skenuojančiu elektroniniu mikroskopu gauto vaizdo pavyzdys.....	10
2 pav. Magnetinio rezonanso vaizdo sluoksnio pavyzdys.....	10
3 pav. Ultragarsu gauto vaizdo pavyzdys.....	10
4 pav. Fotoakustinio vaizdo pavyzdys.....	12
5 pav. Termovizinio vaizdo pavyzdys.....	12
6 pav. Akies dugno nuotrauka.....	12
7 pav. Pedobarografijos vaizdo pavyzdys.....	12
8 pav. Bangos lūžis.....	13
9 pav. Rentgeno aparato vakuuminė lempa.....	13
10 pav. Pilvo srities rentgeno nuotraukos negatyvas.....	13
11 pav. Kompiuterinės tomografijos vaizdo sluoksnių pavyzdžiai.....	14
12 pav. Kompiuterinės tomografijos skeneris.....	15
13 pav. Anotominės žmogaus plokštumos.....	15
14 pav. Dviejų magnetinio rezonanso vaizdų registravimo pavyzdys.....	18
15 pav. Optinės tėkmės aproksimavimas vienmačiu atveju.....	22
16 pav. Skirtingai suglontintų vaizdų skirtumas:.....	25
17 pav. Duomenų aproksimavimas tiese su skirtingais slenksčiais.....	29
18 pav. Skirtingų metodų paklaidos funkcija.....	29
19 pav. SIFT taškų deskriptorius.....	32
20 pav. Tikrinimas, ar taškas yra kampas.....	33
21 pav. Penki skirtingi būdai sugeneruoti binarinių testų aibę.....	34
22 pav. rBRIEF metodo binariniai testai.....	35
23 pav. Kompiuterinės tomografijos ir echoskopijos vaizdų registravimas.....	36
24 pav. Septynių parametų šonkaulio matematinis modelis plokštumoje.....	40
25 pav. Šešių parametų šonkaulio matematinis modelis plokštumoje.....	40
26 pav. Piramidinis branduolys iš 25-ių regionų.....	42
27 pav. Vaizdo suskaidymas pagal spindulius.....	42
28 pav. Sluoksnių turinys.....	48
29 pav. Kaulinio audinio segmentavimas.....	52
30 pav. Kardioidės.....	53
31 pav. Funkcijos $\rho$ + priklausomybė nuo $\varphi$ .....	55
32 pav. CT sluoksnio pavyzdys ir norimas gauti šonkauliais apriboto kontūro modelis.....	59
33 pav. Modelio įtaikymas be ribojimų.....	60
34 pav. Optimizavimo rezultatų pavyzdžiai.....	63
35 pav. Kreivių sugretinimas, naudojant atitinkamų taškų palyginimą.....	75
36 pav. Sluoksnių lyginimas, naudojant pilną mažiausių kvadratų metodą.....	75
37 pav. Kreivės dalijimas į viršutinę ir apatinę dalis.....	77

## Lentelių sąrašas

1 lentelė. Medžiagų radiotankio pavyzdžiai .....	15
2 lentelė. Transformacijos modelių klasifikavimas .....	19
3 lentelė. Vieno ir dviejų žingsnių optimizavimo rezultatai.....	63
4 lentelė. Optimizavimo rezultatai, išvestines įvertinant skaitiniu ir analiziniu būdais.....	67
5 lentelė. Registravimo rezultatai, gauti naudojant (51).....	81
6 lentelė. Registravimo rezultatai, gauti naudojant (52).....	81
7 lentelė. Registravimo rezultatai, gauti naudojant (53).....	81
8 lentelė. Registravimo rezultatai, gauti naudojant (54).....	82
9 lentelė. Skirtingo storio sluoksnių registravimo rezultatai .....	83
10 lentelė. Registravimas, kai invariantiškumui transformacijoms nenaudojamas matematinis modelis.....	83
11 lentelė. Registravimo paklaida priklausomai nuo optimizavimo tikslumo .	84
12 lentelė. Optimizavimo trukmė .....	85
13 lentelė. Registravimo trukmė.....	85

# Žymėjimai

Šiame skyriuje pateikti tik tie simboliai ir santrumpos, kurie šiame darbe naudojami daugiau kaip viename punkte ar papunktyje.

## Simboliai

---

$*$	Sąsūkos (angl. <i>convolution</i> ) operatorius
$A$	Kompiuterinės tomografijos vaizdas
$A_i$	$i$ -asis kompiuterinės tomografijos vaizdo sluoksnius
$B$	Vieno sluoksnio kaulinį audinį vaizduojančių pikselių aibė
$b_i$	$i$ -asis kaulinį audinį vaizduojantis pikselis ( $B$ aibėje)
$[b_{1i} \ b_{2i}]^T$	$i$ -ojo kaulinį audinį vaizduojančio pikselio taško koordinatės
$B^*$	Transformuota kaulinį audinį vaizduojančių pikselių aibė
$\beta$	Matematinio modelio (toliau – m. m.) parametras, kontroliuojantis papildomos funkcijos veikimo sritį
$c$	M. m. parametras, kontroliuojantis papildomos funkcijos stiprumą
$C_i^*$	M. m. pagrindinės dalies $i$ -asis taškas
$C^*$	M. m. pagrindinės dalies taškų seka
$C_i^{**}$	M. m. papildomos atkarpos $i$ -asis taškas
$C^{**}$	M. m. papildomos atkarpos taškų seka
$C_i$	Viso m. m. $i$ -asis taškas (5-ame skyriuje tik pagrindinės dalies, nes papildymas nenaudojamas)
$C$	Viso m. m. taškų seka (5-ame skyriuje tik pagrindinės dalies)
$dist(A_i, A_j)$	Sluoksnių lyginimo kriterijus
$\varepsilon$	Paklaida
$f(\cdot)$	Optimizuojama funkcija modelio įtaikymui
$H$	<i>Hessian</i> matricos aproksimacija
$I$	Dvimatis vaizdas, diskreti funkcija su dviem argumentais

---

---

$l$	M. m. parametras, kontroliuojantis papildančios funkcijos statumą
$\lambda$	Tikrinė reikšmė ar jos aproksimacija
$m$	Vieno sluoksnio kaulinį audinį vaizduojančių pikselių kiekis
$M$	M. m. parametrų rinkinys
$\mu$	Vidurkis
$n$	M. m. kreivės taškų (angl. <i>sample</i> ) kiekis
$n_t$	M. m. papildomos atkarpos taškų kiekis
$p$	Viršutinio stuburo taško sluoksnyje ordinatė
$\mathbf{p}$	Vieno taško optinės tėkmės vektorius
$\varphi$	Kampas polinėje koordinačių sistemoje
$\psi(\varepsilon)$	Paklaidos funkcija
$\rho$	Matematinis modelis polinėje koordinačių sistemoje
$\rho^+$	M. m. papildoma funkcija tinkamam krūtinkaulio aproksimavimui
$s$	M. m. parametras, kontroliuojantis bendrą kreivės formą
$\sigma$	Standartinis nuokrypis
$T$	Transformacijos matrica
$\theta$	M. m. posūkis sluoksnyje
$\mathbf{v} = [x \ y]^\top$	Taškas Dekarto koordinačių sistemoje
$[x_0 \ y_0]^\top$	M. m. kreivės pradžios taško koordinatės
$[x_i \ y_i]^\top$	$i$ -ojo m. m. kreivės taško koordinatės
$[\Delta x \ \Delta y]^\top$	Dviejų m. m. kreivių poslinkio skirtumas
$w_i$	M. m. kreivės $i$ -ojo taško svoris
$\mathbf{W}$	M. m. kreivės taškų svoriai

---

Mažosiomis paryškintomis raidėmis, pavyzdžiui,  $\mathbf{v}$ , žymimi vektoriai. Didžiosiomis paryškintomis raidėmis, pavyzdžiui,  $\mathbf{B}$ , žymimos aibės, sąrašai ir pan.



Visi simboliai, žymimi vienu apostrofu ', priklauso pirminiam vaizdui (tomografiniam vaizdui ar sluoksniui), o simboliai, žymimi dviem apostrofais'', priklauso tiksliniam vaizdui, pavyzdžiui,  $M'$  yra pirminio sluoksnio matematinio modelio parametrų rinkinys, o  $M''$  – tikslinio sluoksnio matematinio modelio parametrų rinkinys.

## Santrumpos

---

ATP	Atitinkamų taškų palyginimas
CT	Kompiuterinė tomografija (angl. <i>computed tomography</i> )
DICOM	Medicininį vaizdų saugojimo ir perdavimo standartas (angl. <i>Digital Imaging and Communications in Medicine</i> )
HU	<i>Hounsfield</i> matavimo vienetas
ICP	Taškų atitikmenų paieškos algoritmas (angl. <i>Iterative Closest Point</i> )
OpenCV	Atviro kodo kompiuterinės regos biblioteka
PMK	Pilnas mažiausių kvadratų metodas
RANSAC	Atsitiktinių mėginių konsensusas (angl. <i>random sample consensus</i> ) – algoritmas, skirtas įvertinti geometrinę transformaciją
SIFT	Vaizdų registravimo algoritmas „mastelio pokyčiui invariantiška požymių transformacija“ (angl. <i>Scale-Invariant Feature Transform</i> )
SMK	Svorinis mažiausių kvadratų metodas
SPMK	Svorinis pilnas mažiausių kvadratų metodas

---

# Turinys

1 Įvadas.....	1
1.1 Tyrimų sritis.....	1
1.2 Darbo aktualumas .....	2
1.3 Darbo tikslas ir uždaviniai .....	3
1.4 Mokslinis naujumas .....	4
1.5 Ginamieji teiginiai .....	4
1.6 Darbo rezultatų apibavimas .....	5
1.7 Disertacijos struktūra .....	7
2 Medicininių vaizdų analizės metodų ir technologijų apžvalga.....	9
2.1 Medicininių vaizdų šaltiniai.....	9
2.2 Radiografija.....	12
2.2.1 Projekcinė radiografija.....	12
2.2.2 Kompiuterinė tomografija .....	14
2.2.3 DICOM standartas .....	16
2.3 Vaizdų registravimas .....	17
2.3.1 Transformacijos modeliai .....	18
2.3.2 Ryškumu grįstas registravimas .....	20
2.3.3 Spektrinis registravimas.....	23
2.3.4 Požymiais grįstas registravimas.....	24
2.4 Medicininių vaizdų registravimas .....	35
2.4.1 Kaulų segmentavimas.....	38
2.4.2 Šonkaulių aproksimavimas matematinio modeliu.....	39
2.4.3 Sluoksnių registravimas su atlasu.....	41
2.5 Antro skyriaus išvados .....	44
3 Šonkauliais apriboto kontūro aproksimavimas matematinio modeliu .....	47
3.1 Šonkaulių, krūtinkaulio ir stuburo segmentavimas.....	48

3.2	Šonkauliais apriboto kontūro aproksimavimas .....	53
3.2.1	Matematinio modelio sudarymas .....	53
3.2.2	Modelio įtaikymas .....	60
3.3	Trečio skyriaus išvados .....	67
4	Sluoksnių registravimas .....	69
4.1	Registravimo invariantiškumo užtikrinimas .....	70
4.1.1	Invariantiškumas posūkiui .....	70
4.1.2	Invariantiškumas mastelio pokyčiui .....	71
4.1.3	Invariantiškumas poslinkiui .....	72
4.1.4	Invariantiškumo užtikrinimas nenaudojant matematinio modelio .....	77
4.2	Sluoksnių palyginimo kriterijai .....	77
4.3	Ekspperimentai .....	80
4.3.1	Sluoksnių palyginimo kriterijų įvertinimas .....	80
4.3.2	Sluoksniu storio įtaka registravimo paklaidai .....	82
4.3.3	Sluoksnių registravimas piramidiniu Lucas-Kanade algoritmu .....	83
4.3.4	Optimizavimo tikslumo įtaka registravimo paklaidai .....	84
4.4	Ketvirto skyriaus išvados .....	86
5	Išvados .....	87
5.1	Analitinės apžvalgos rezultatai .....	87
5.2	Disertacinio darbo išvados .....	88
6	Bibliografija .....	91
6.1	Autoriaus publikacijų sąrašas disertacijos tema .....	101
6.1.1	Straipsniai recenzuojamuose periodiniuose moksliniuose leidiniuose .....	101
6.1.2	Straipsniai kitose konferencijų medžiagose .....	102
A	Priedas Šonkaulių, krūtinkaulio ir stuburo segmentavimo C# programinis kodas .....	103



# 1

## Ivadas

### 1.1 Tyrimų sritis

Šiuolaikinėmis technologijomis galima rinkti ir kaupti milžiniškus kiekius duomenų. Šablonų, tendencijų ir anomalijų paieška šiuose duomenyse ir jų apibendrinimas yra vieni svarbiausių šių laikų uždavinių: iš duomenų reikia gauti informaciją, o iš informacijos – žinių [1]. Vaizdai yra vienas iš informacijos šaltinių [2]. Ypač daug vaizdinės medžiagos generuojama medicinoje. Vaizdinę medžiagą generuoja elektroninis mikroskopas, magnetinio rezonanso vaizdinimas, echoskopija, fotoakustinis vaizdinimas, termovizija, oftalmoskopija, pedobarografija, projekcinė radiografija, kompiuterinė tomografija. Kiekvienu atveju reikalingi specialūs vaizdų analizės metodai, priklausomi nuo sprendžiamo uždavinio, ieškomos patologijos ir kt. Tai sritis, kurioje informatikos metodai gali būti įtraukti į medicininės diagnostikos uždavinių sprendimą.

Šiame darbe nagrinėjami kompiuterinės tomografijos vaizdai ir jų analizės metodai efektyviai paciento stebėsenai ir diagnostikai, taikant daugkartinę tomografiją, pasiekti. Ypač daug dėmesio skirta šonkauliais ribojamos srities vaizdų registravimui. Vaizdų registravimu įvardijamas procesas, kai skirtingi vaizdai transformuojami į vieną koordinačių sistemą. Vaizdų registravimo taikymas yra itin platus, jis yra būtinas norint palyginti ar sujungti vaizdus, gautus skirtingu metu, skirtingais įrenginiais ar skirtingais įrenginių nustatymais. Medicinoje vaizdų registravimas yra svarbus, kai atliekami

kompiuterinės tomografijos tyrimai prieš ir po gydymo, ir siekiant įvertinti gydymo efektyvumą reikia palyginti šių tyrimų vaizdus ar atskirus jų sluoksnius. Šiame darbe lyginami sluoksniai siekiant įvertinti jų padėtį žmogaus vertikaliajoje ašyje.

## 1.2 Darbo aktualumas

Tam tikros ligos gali būti diagnozuotos ir jų gydymas stebimas naudojant kompiuterinę tomografiją (CT), kuri leidžia pamatyti objektų vidų rentgeno spinduliais. Tomografiniai vaizdai yra trimačiai rastriniai vaizdai: dvimačių rastrinių vaizdų – sluoksnių – rinkinys. Sluoksnis vaizduoja kūno skerspjūvį pagal plokštumą, lygiagrečią skersinei žmogaus plokštumai. Tomografiniai vaizdai daromi tam pačiam pacientui įvairiais gydymo laikotarpiais, taip pat su kontrastinėmis medžiagomis ir be jų. Tai leidžia be chirurginės intervencijos stebėti žmogaus organizmo pokyčius ir pasirinkti tinkamą gydymo strategiją. Dažnas kompiuterinės tomografijos objektas yra krūtinės sritis, ji ypatinga tuo, kad turi daug svarbių vidinių organų: skrandis, širdis, plaučiai, kepenys, kasa ir kt., o juos saugo šonkauliai.

Medikai susiduria su uždaviniu surasti vieno tomografinio vaizdo sluoksnio poziciją kitame tomografiniame vaizde. Sluoksnių registravimas turi nepriklausyti nuo paciento pozicijos lovos atžvilgiu ar kontrastinės medžiagos. Ši problema galėtų būti išspręsta trivialiai pagal DICOM meta duomenis, tačiau [3] parodyta, kad šie metaduomenys yra netikslūs arba išvis klaidingi, todėl reikia ieškoti naujų tomografinių vaizdų sluoksnių registravimo būdų.

Reikalingi vaizdų analizės metodai, leidžiantys pastebėti pokyčius vaizdų sekoje, taip pat palyginti vaizdus. Tokiems vaizdams apdoroti reikia ir specialių metodų. Pavyzdžiui, norint didelėje duomenų bazėje surasti tik nedidelės kūno srities sluoksnius, jie turi būti automatiškai identifikuoti. Tam tomografiniai vaizdai registruojami su žmogaus atlasu [4], [5], [6]. Dažnai registruojami ir tik tam tikri objektai vaizduose, pavyzdžiui, [7] darbe sukurtu metodu ieškomi plaučių navikų atitikmenys CT vaizduose, gautuose tam tikrais laiko intervalais.

---

Metodas naudoja šonkaulių vidurio linijas pradiniam navikų registravimui. Tai nėra vienintelis atvejis, kai šonkaulių anatomija yra naudojama kaip atskaitos taškas tomografinių vaizdų analizėje. Pavyzdžiui, [8] straipsnyje buvo pasiūlytas šešių parametrų matematinis modelis, aprašantis šonkaulio vidurio liniją logaritminėmis spiralėmis. Toks modelis parodo, kad tikslus šonkaulių geometrijos charakterizavimas yra itin svarbus biomechanikos mokslo literatūroje.

Analizuojant CT sluoksnius, lygiagrečius žmogaus skersinei plokštumai, kylanti savita problema yra ta, kad viename sluoksnyje paprastai matomas daugiau kaip vienas šonkaulis. Todėl šiuo atveju tokie modeliai kaip [8], kuriame sudaromas konkretaus šonkaulio modelis, yra netinkami. Taigi tikslinga tam tikru būdu nusakyti šonkaulių konfigūraciją jų fragmentais viename sluoksnyje. Šie fragmentai yra kaulų skerspjūvis, lygiagretus skersinei žmogaus plokštumai. Sluoksniai gali būti lyginami tarpusavyje naudojant šonkaulių fragmentus.

Sluoksnių registravimo problema dar galėtų būti laikoma turiniu pagrįstos vaizdų paieškos problema (angl. *content-based image retrieval* [9]) arba vaizdų indeksavimo problema (angl. *image indexing*), tačiau literatūroje dažniau vartojamas terminas „registravimas“, tad šis terminas ir vartojamas šiame darbe.

### 1.3 Darbo tikslas ir uždaviniai

Darbo tikslas – atskleisti galimybę registruoti krūtinės srities kompiuterinės tomografijos vaizdų sluoksnius pagal šonkaulių fragmentų išsidėstymą.

Tikslui pasiekti sprendžiami šie uždaviniai:

1. Atlikti analitinę medicininių vaizdų analizės metodų ir technologijų apžvalgą, išskirtinį dėmesį skiriant kompiuterinei tomografijai ir medicininių vaizdų registravimui.

2. Sukurti matematinį modelį, aproksimuojantį šonkauliais ribojamą sritį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame žmogaus skersinei plokštumai.
3. Suformuluoti optimizavimo uždavinį modelio parametrų reikšmėms nustatyti pagal kaulinio audinio pikselių išsidėstymą kompiuterinės tomografijos vaizdo sluoksnyje ir pasiūlyti algoritmus tam uždaviniui spręsti.
4. Sukurti krūtinės srities CT vaizdų sluoksnių registravimo pagal šonkaulių fragmentų išsidėstymą metodą, kuris remtųsi matematiniu modeliu, aproksimuojančiu šonkauliais ribojamą sritį.
5. Atlikti eksperimentinį naujo registravimo metodo ir jo atskirų etapų tyrimą.

#### 1.4 Mokslinis naujumas

1. Sukurtas matematinis modelis, aproksimuojantis šonkauliais ribojamą sritį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame žmogaus skersinei plokštumai.
2. Suformuluotas optimizavimo uždavinys pasiūlyto modelio parametrų reikšmėms nustatyti.
3. Įrodyta galimybė krūtinės ląstos CT vaizdų sluoksnius registruoti pagal šonkaulių fragmentų išsidėstymą, aprašomą matematiniu modeliu, aproksimuojančiu šonkauliais ribojamą sritį.

#### 1.5 Ginamieji teiginiai

1. Krūtinės ląstos CT vaizdų sluoksnius galima registruoti pagal šonkaulių fragmentų išsidėstymą, aprašomą matematiniu modeliu, aproksimuojančiu šonkauliais ribojamą sritį.
2. Pasiūlytas registravimo metodas yra invariantiškas poslinkiui, posūkiui ir mastelio pokyčiui, todėl sluoksnius galima registruoti



---

nepriklausomai nuo paciento pozicijos lovos atžvilgiu ir tomografo parametrų, lemiančių pikselio dydį.

3. Modelio papildymas atkarpa, lygiagrečia žmogaus sagitalinei ašiai, užtikrina gerą šonkaulių sistemos aproksimaciją ir stuburo aplinkoje.
4. Piramidinio Lucas-Kanade algoritmo teikiamos galimybės nėra pakankamos kompiuterinės tomografijos vaizdams registruoti.
5. Sluoksnių registravimui įtaką daro ne tik šonkauliais apriboto kontūro forma, o ir kaulinį audinį vaizduojančių pikselių tankis modelio kreivės taškų aplinkoje.

## 1.6 Darbo rezultatų aprobavimas

Tyrimų rezultatai publikuoti 3 periodiniuose recenzuojamuose leidiniuose:

1. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Approximation of the Ribs-Bounded Contour in a Tomography Scan Slice. *International Journal of Information Technology & Decision Making*, 2017, ISSN 0219-6220. Priimta, [10.1142/S0219622017500298](https://doi.org/10.1142/S0219622017500298). (IF 2016: 1,664).
2. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Martynas Sabaliauskas. Speeding-up the Fitting of the Model Defining the Ribs-bounded Contour. *Applied Computer Systems*, **21**(1), 2017, ISSN 2255-8691, p. 66–70.
3. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Feature-Based Registration of Thorax CT Scan Slices. *Informatica*, **28**(3), 2017, ISSN 0868-4952, p. 439-452. [10.15388/Informatica.2017.137](https://doi.org/10.15388/Informatica.2017.137). (IF 2016: 1,056).

Tyrimų rezultatai pristatyti ir aptarti 10 nacionalinių ir tarptautinių konferencijų:

1. **Mykolas J. Bilinskas**, Povilas Treigys, Gintautas Dzemyda, Mantas Trakymas. Cross-section of ablative margin calculation from fused

- DICOM images using implanted fiducial markers. 5-asis tarptautinis seminaras „*Duomenų analizės metodai programų sistemoms*“. Druskininkai, Lietuva. 2013 m. gruodžio 5–7 d.
2. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Objekto išskyrimo iš fono Graph Cut algoritmu problemos. 55-oji Lietuvos matematikų draugijos konferencija. Vilnius, Lietuva. 2014 m. birželio 26–27 d.
  3. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. An approach to tumor location and treatment results evaluation by CT images. 6-oji tarptautinė konferencija „*Duomenų analizės metodai programų sistemoms*“. Druskininkai, Lietuva. 2014 m. gruodžio 4–6 d.
  4. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Computed tomography image analysis: the model of ribs-bounded contour. „*23rd International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision*“, WSCG 2015. Pilzenas, Čekija. 2015 m. birželio 8–12 d.
  5. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Nonlinear optimization problems in computed tomography scan analysis. 56-oji Rygos Technikos Universiteto tarptautinė mokslinė konferencija. Ryga, Latvija. 2015 m. spalio 14 d.
  6. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Registration of computed tomography scan slices using mathematical model for ribs-bounded contour approximation. 7-oji tarptautinė konferencija „*Duomenų analizės metodai programų sistemoms*“. Druskininkai, Lietuva. 2015 m. gruodžio 3–5 d.
  7. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. Kompiuterinės tomografijos nuotraukos sluoksnių registravimas naudojant šonkaulių kontūrą aproksimuojantį matematinį modelį. 6-oji LMA Jaunųjų mokslininkų konferencija „*Fizinių ir technologijos mokslų tarpdalykiniai tyrimai*“. Vilnius, Lietuva. 2016 m. vasario 10 d.

- 
8. Gintautas Dzemyda, **Mykolas J. Bilinskas**, Mantas Trakymas. Optimization in modelling the ribs-bounded contour in computer tomography scan slices. *„Numerical computations: theory and algorithms“*, NUMTA-2016. Pizzo Calabro, Italija. 2016 m. birželio 19–25 d.
  9. Gintautas Dzemyda, **Mykolas J. Bilinskas**. Modelling the ribs-bounded contour in computer tomography images. *„Международный конгресс по информатике: Информационные системы и технологии“*. Minskas, Baltarusija. 2016 m. spalio 24–27 d.
  10. **Mykolas J. Bilinskas**, Gintautas Dzemyda, Mantas Trakymas. The registration of computed tomography scan slices using the model of the ribs-bounded contour. 8-oji tarptautinė konferencija *„Duomenų analizės metodai programų sistemoms“*. Druskininkai, Lietuva. 2016 m. gruodžio 1–3 d.

## 1.7 Disertacijos struktūra

Disertaciją sudaro 5 skyriai ir literatūros sąrašas. Disertacijos skyriai: Įvadas, Medicininių vaizdų analizės metodų ir technologijų apžvalga, Šonkauliais apriboto kontūro aproksimavimas matematinio modeliu, Sluoksnių registravimas ir Išvados. Be to, disertacijoje pateikti paveikslų, lentelių, naudotų žymėjimų ir santrumpų sąrašai. Visa disertacijos apimtis yra 120 puslapių, pateikti 37 paveikslai ir 13 lentelių. Disertacijoje remtasi 100 literatūros šaltinių.



# 2


## Medicininiių vaizdų analizės metodų ir technologijų apžvalga

### 2.1 Medicininiių vaizdų šaltiniai


Šablonų, tendencijų ir anomalijų paieška milžiniškuose kiekiuose duomenų, pastaruoju metu renkamuose ir kaupiamuose įvairiose žmogaus veiklos srityse, taip pat jų apibendrinimas yra vieni svarbiausių šių laikų uždavinių – reikia iš duomenų gauti informaciją, o iš informacijos gauti žinių [1]. Vaizdai yra vienas geriausių būdų gauti žinias apie mus supantį pasaulį [2]. Todėl reikia ieškoti naujų arba tobulinti esamus duomenų tyrybos įrankius, norint rasti šablonų duomenyse. Galimi įvairūs medicininiių vaizdų šaltiniai, pavyzdžiui, elektroninis mikroskopas (angl. *electron microscope*), magnetinio rezonanso vaizdinimas (angl. *magnetic resonance imaging, MRI*), echoskopija (angl. *sonography, ultrasonography*), fotoakustinis vaizdinimas (angl. *photo acoustic imaging*), termovizija (angl. *thermovisual imaging*), oftalmoskopija (angl. *ophthalmoscopy, funduscopy*), pedobarografija (angl. *pedobarography, plantar pressure*), projekcinė radiografija (angl. *projectional radiography*), kompiuterinė tomografija (angl. *computed tomography, CT*).

Elektroniniais mikroskopais galima tirti kur kas smulkesnius objektus nei optiniais mikroskopais. Taip yra todėl, kad elektrono bangos ilgis yra žymiai mažesnis už regimos šviesos fotonų bangos ilgį.

Iš esmės yra du elektroninių mikroskopų tipai – transmisiniai ir skenuojantys elektroniniai mikroskopai [10]. Paprastai optinis mikroskopas susideda iš šviesos šaltinio, kondensoriaus, fokusuojančio šviesą į tiriamą objektą, objekto laikiklio, lęšių ir okuliario. Visi šie komponentai turi atitikmenis elektroniniame mikroskope, tik jame šviesos šaltinis pakeistas elektronų patranka, optiniai lęšiai pakeisti elektrostatiniais ir elektromagnetiniais lęšiais [11]. Skenuojančiais elektroniniais mikroskopais gaunami mažesni vaizdai, tad jie leidžia tirti objektus tik iki 15 centimetrų dydžio. Tačiau abu mikroskopų tipai neleidžia tirti gyvų organizmų, nes abu veikia tik vakuume. Elektroniniu mikroskopu gauto vaizdo pavyzdys yra pateiktas 1 pav.



1 pav. Skenuojančiu elektroniniu mikroskopu gauto vaizdo pavyzdys [12].



2 pav. Magnetinio rezonanso vaizdo slauksnio pavyzdys [13].



3 pav. Ultragarsu gauto vaizdo pavyzdys [14].

Magnetinio rezonanso vaizdinimas pagrįstas atomo branduolių magnetiniu rezonansu, t. y. atomo branduolys gali sugerti ir vėl išspinduliuoti radijo bangas, kai yra išorinis magnetinis laukas [15]. Šią ypatybę turi vandenilio branduolys, o vandenilio branduolių visuose biologiniuose organizmuose yra daug, ypač vandenyje ir riebaluose. Todėl magnetinio rezonanso vaizduose geriausiai išryškėja būtent vanduo ir riebalai. Magnetinio rezonanso tomografinio vaizdo pavyzdys pateiktas 2 pav.

Echoskopija remiasi ultragarsinėmis bangomis, paprastai nuo 1 iki 18 megahercų. Garso banga atsimuša į audinių sandūras arba yra išsklaidoma. Vaizdai sukuriama fokusuojant bangas viena kryptimi, ir skaičiuojant aido grįžimo laiką ir stiprumą [16]. Kuo vėliau aidas sugrįžta, tuo didesnis atstumas. Kuo didesnis aido stiprumas, tuo ryškesnis taškas gaunamas galutiniame vaizde.

---

Ultragarsu gauto vaizdo pavyzdys – sonograma (angl. *sonogram*) – pateikta 3 pav.


Fotoakustinis vaizdinimas yra pakankamai nauja vaizdinimo technologija, apimanti tiek optinio, tiek ultragarsinio vaizdinimo fiziką [17]. Fotoakustinis vaizdinimas yra stipriai pagerina įprastą echoskopiją, nes suteikia galimybę gauti geresnio kontrasto vaizdus srityse, kurios skirtingai sugeria šviesą. Ypač gerai gali būti nustatytos sritys, turinčios daugiau kraujo, o tai labai pravartu vaskuliarizacijai stebėti ir nustatyti ankstyvai vėžio stadijai [18].

Fotoakustinis vaizdinimas remiasi fotoakustiniu efektu, dėl kurio šviesą sugerianti medžiaga gali skleisti garso bangas. Medicininio fotoakustinio vaizdinimo metu tiriami audiniai yra apšviečiami nejonizuojančio lazerio spinduliu ir matuojamas ateinantis ultragarsas. Matuojant, per kiek laiko ateina ultragarso pulsas, galima nustatyti, kaip buvo sugerti šviesos spinduliai. Fotoakustinio vaizdo pavyzdys pateiktas 4 pav.


Termovizija remiasi ypatybe, kad kiekvienas šiltas objektas spinduliuoja infraraudonosius spindulius. Šiuos spindulius matuoja infraraudonųjų spindulių kamera, tad gaunamas vaizdas, kurio kiekvieno taško spalva nusako atitinkamo tiriamo kūno taško temperatūrą [19]. Termovizinio vaizdo pavyzdys pateiktas 5 pav.

Oftalmoskopija yra procedūra, kurios metu specialia oftalmoskopijos kamera gaunamas akies dugno vaizdas. Oftalmoskopija yra itin svarbi, norint nustatyti akies tinklainės, optinio disko ar stiklakūnio būklę [19]. Akies dugno nuotraukos pavyzdys pateiktas 6 pav.

Pedobarografija yra spaudimo tarp pėdos ir grindų paviršiaus pasiskirstymo tyrimas, dažniausiai naudojamas biomechaninei eisenos ir laikysenos analizei [20]. Pedobarografas dažniausiai būna sudarytas iš tinkleliu išsidėsčiusių spaudimo sensorių. Pagal iš šių sensorių gaunamus duomenis sudaromas vaizdas, pavyzdys pateiktas 7 pav.




4 pav. Fotoakustinio vaizdo pavyzdys [21].



5 pav. Termovizinio vaizdo pavyzdys [19].



6 pav. Akies dugno nuotrauka [19].



7 pav. Pedobarografijos vaizdo pavyzdys<sup>1</sup>.

Projekcinė radiografija ir kompiuterinė tomografija, taip pat medicininių vaizdų registravimo problematika apžvelgti tolesniuose poskyriuose, nes jie glaudžiai susiję su šios disertacijos tyrimais.

## 2.2 Radiografija

### 2.2.1 Projekcinė radiografija


Procesas, kai objektas yra apšviečiamas didelės energijos elektromagnetinės bangos ir jį perskrodžiantys spinduliai užfiksuojami detektoriuje, įvardijamas projekcine radiografija [22]. Dažniausiai kaip elektromagnetinis spinduliavimas naudojami rentgeno spinduliai (angl. *X-rays*). Rentgeno spindulių bangos ilgis yra nuo 0,01 iki 10 nanometrų, o regimosios šviesos bangų ilgis yra nuo 380 iki 750 nanometrų, taip pat rentgeno spindulių lūžis (8 pav.; angl. *refraction*) yra daug silpnesnis nei ilgesnių bangų. Todėl naudojant šiuos spindulius galima tirti žmogaus vidaus organus be pjūvio.

<sup>1</sup> Creative Commons licencija [commons.wikimedia.org/wiki/File:Example\\_foot\\_pressure.png](https://commons.wikimedia.org/wiki/File:Example_foot_pressure.png)




Rentgeno spinduliai gaunami vakuomo vamzdyje sukuriant aukštą įtampą tarp katodo ir anodo (20 – 600 kV), tada iš kaitinamo katodo elektronai lekia link šalto anodo, į kurią atsitrenkę išspinduliuoja nedidelę dalį energijos pertekliaus (0,1 – 5 %) kaip rentgeno spindulius [23]. 9 pav. pavaizduota Rentgeno aparato vakuomo vamzdžio schema, joje  $X$  žymi rentgeno spindulius,  $K$  – katodą,  $A$  – anodą,  $W_{in}$  – įeinantis vanduo aušinimui,  $W_{out}$  – išeinantis karštas vanduo,  $C$  – aušintuvas,  $U_h$  – katodo kaitintuvo įtampa,  $U_a$  – įtampa tarp katodo ir anodo. Rentgeno spinduliai nukreipiami į tiriamą objektą, už kurio pastatomas spindulių detektorius. Kaip detektorius dažniausiai naudojama fotojuosta arba puslaidininkių pokštelės. Dalį spindulių objektas sugeria; kuo didesnis tankis medžiagos, kurią spindulys skrodžia, tuo daugiau spindulių ji sugeria. Kuo mažiau spindulių sugeria medžiaga, tuo ryškesnį pėdsaką spinduliai palieka detektoriuje. Taip detektoriuje sukuriamas vaizdas, įvardijamas rentgeno nuotrauka, kurioje šviesesnė spalva reiškia didesnę spindulių patekimą atitinkamame detektoriaus taške. Paprastai naudojami negatyvai (10 pav.).


Radiotankis priklauso nuo medžiagos tankio ir ją sudarančių atomų numerio [24]. Pavyzdžiui, žmogaus kaulai turi didesnę radiotankį už riebalus, raumenis ar orą, nes kauluose yra daug kalcio.



8 pav. Bangos lūžis, kur  $S$  yra dviejų aplinkų riba<sup>2</sup>.



9 pav. Rentgeno aparato vakuuminė lempa<sup>3</sup>.



10 pav. Pilvo srities rentgeno nuotraukos negatyvas.

Kartais į kūną tyčia įterpiami rentgeno spindulius sugeriantys objektai (pvz., titaniniai strypeliai), kuriais pažymimos tam tikros vietos [25], arba į

<sup>2</sup> Creative Commons licencija [commons.wikimedia.org/wiki/File:Refracao.png](https://commons.wikimedia.org/wiki/File:Refracao.png)


<sup>3</sup> Viešo naudojimo kūriny [commons.wikimedia.org/wiki/File:Roentgen-Roehre.svg](https://commons.wikimedia.org/wiki/File:Roentgen-Roehre.svg)

kraują suleidžiama radio-kontrastinė medžiaga (dar kartais vadinama tiesiog kontrastine medžiaga; angl. *radiocontrast agent*), kad būtų išryškintos kraujagyslės [26, p. 152]. Radio-kontrastinės medžiagos dažniausiai turi daug jodo, kartais bario.

### 2.2.2 Kompiuterinė tomografija

Kitas radiografijos metodas yra kompiuterinė tomografija. Jos rezultatas yra trimatis rastrinis (tomografinis) vaizdas, kuris Radon rekonstrukcija [27] gautas iš daug dvimačių projekcinės radiografijos vaizdų, darytų apie vieną ašį. Dažniausiai CT vaizdai yra sluoksnių, lygiagrečių skersinei plokštumai, seka. Šiame darbe būtent tokie CT vaizdai ir bus analizuojami. Keli tokio vaizdo sluoksnių pavyzdžiai parodyti 11 pav., kur *(a)* ir *(b)* – yra sluoksniai iš tomografijos, darytos be kontrastinės medžiagos (angl. *precontrast, native-phase*), *(c)* ir *(d)* – su kontrastine medžiaga (angl. *postcontrast image*); pastaruosiuose sluoksniuose galima aiškiai matyti ryškesnę aortą (šalia stuburo) ir šiek tiek ryškesnius inkstus. 12 pav. pavaizduotas tomografas.


13 pav. pavaizduotos anatomicinės plokštumos, pagal kurių skerspjuvius galima lengviau nusakyti organų vietą ar judesių kryptį. Yra trys principinės plokštumos: sagitalinė (dar vadinama vidurine arba medialine), pavaizduota raudonai, vertikali (dar vadinama frontaliąja), pavaizduota mėlynai, ir skersinė (dar vadinama horizontaliąja), pavaizduota žaliai. Sagitalinės ir vertikalios plokštumų sankirta nurodo vertikalią ašį, sagitalinės ir skersinės plokštumų – sagitalinę ašį, o vertikalios ir skersinės – skersinę ašį.



11 pav. Kompiuterinės tomografijos vaizdo sluoksnių pavyzdžiai: *(a)* – sluoksnis ties širdimi, *(b)* ir *(d)* – sluoksniai ties inkstais, *(c)* – sluoksnis ties kepenimis; *(a)* ir *(b)* sluoksniai yra iš tomografijos, darytos be kontrastinės medžiagos, *(c)* ir *(d)* – su pastarąja.



12 pav. Kompiuterinės tomografijos skeneris<sup>4</sup>.



13 pav. Anatinės žmogaus plokštumos [28].

Kompiuterinėje tomografijoje radiotankis yra standartizuotas pagal *Hounsfield* skalę [29], matavimo vienetai žymimi HU (angl. *Hounsfield units*). Skalė apibrėžta taip, kad distiliuoto vandens radiotankis yra 0 HU, o oro –1000 HU. Daugiau medžiagų radiotankio reikšmių pateikta 1 lentelėje.

1 lentelė. Medžiagų radiotankio pavyzdžiai.

<b>Medžiaga</b>	<b>Radiotankis, HU</b>
Oras	–1000
Plaučiai	nuo –700 iki –600
Vanduo	0
Limfmazgiai	nuo +10 iki +20
Kraujas	nuo +30 iki +45
Kaulai	nuo +200 iki +3000

Kompiuterinės tomografijos vaizduose naudojama *Hounsfield* skalė turi labai platų dinaminį diapazoną (angl. *dynamic range*), šis turi būti sumažintas norint vaizdą parodyti įprastu monitoriumi. Tai paprastai daroma lango (angl. *window*) procesu: mažesnis pikselių reikšmių intervalas prilyginamas pilkai

<sup>4</sup> *Creative Commons* licencija [commons.wikimedia.org/wiki/File:UPMCEast\\_CTscan.jpg](https://commons.wikimedia.org/wiki/File:UPMCEast_CTscan.jpg)

skalei (paprastai intervalui [0; 255]). Pavyzdžiui, nagrinėjant pilvo sritį dažnai svarbus intervalas (langas) tik nuo  $-135$  iki  $+215$  HU. Tada pikselių reikšmės, turinčios reikšmę  $-135$  HU ir mažiau, rodomos juodai, o pikselių reikšmės, turinčios reikšmę  $+215$  HU ir daugiau, rodomos baltai. Radiotankio reikšmės, patenkančios į intervalą (langą), yra tiesiškai normalizuojamos.

### 2.2.3 DICOM standartas

Paprastai kompiuterinės tomografijos vaizdai saugomi DICOM<sup>5</sup> formatu. Jį sudaro failų formatas ir perdavimo tinklu protokolai. Iš esmės visas failas sudarytas iš žymių (angl. *tags*), nurodančių paciento duomenis, tyrimo duomenis, tyrimo prietaiso nustatymus, paciento poziciją, ir, svarbiausia, žymėje laikomas pats tomografinis vaizdas. Žymę sudaro grupė, elemento numeris, reikšmės tipas (angl. *Value Representation, VR*), ilgis baitais (*LengthInByte*), reikšmė. Žymės grupė ir elemento numeris turi savo aprašą, daug jų apibrėžta DICOM standarte, pvz., (0010,0010) yra paciento vardas. Šios žymės vadinamos standartiniais duomenų elementais (angl. *Standard Data Elements*), dažnai skirtingi gamintojai turi savo specifines žymes, kurias vadinamos privačiais duomenų elementais (angl. *Private Data Element*, arba *Private Creator Data Element, PCDE*).

Vieno DICOM objekto (t. y. vieno DICOM failo) vaizdas gali būti dvimatis, trimatis ar net keturių dimensijų (trimačiai duomenys, besikeičiantys laike). Tačiau dažniausiai vieną DICOM objektą sudaro vienas dvimatis vaizdas, trimatį vaizdą sudaro daug DICOM objektų, o žymės prie kiekvieno objekto užtikrina, kad objektas nepasimes ar nesusimaišys su kitais.

Pats standartas yra gana universalus, jis tinka ne tik kompiuterinei tomografijai, bet ir magnetinio rezonanso vaizdams, įprastoms rentgeno nuotraukoms, ultragarsu gautiems vaizdams, pozitronų emisijos tomografijai (angl. *positron emission tomography, PET*) ir kt.

---

<sup>5</sup> [dicom.nema.org/](http://dicom.nema.org/)

---

Standartą 1985 metais sukūrė Amerikos Radiologų Kolegija (angl. *American College of Radiology, ACR*) ir Nacionalinė Elektronikos Gamintojų Asociacija (angl. *National Electrical Manufacturers Association, NEMA*), kuriai priklauso autorių teisės, tuo metu standartas vadinosi ACR/NEMA 300. Tada jis nesulaukė didesnio pasisekimo, ir 1988 metais standartas buvo atnaujintas, jis gavo pavadinimą ACR/NEMA V2.0. 1993 metais buvo išleista trečia standarto versija, tada ji ir buvo pavadinta DICOM (angl. *Digital Imaging and Communications in Medicine*). Dabartinė versija vis dar laikoma trečia, nors nuolat šiek tiek atnaujinama, tačiau suderinama su ankstesnėmis.


DICOM standartu aprašytų vaizdų metaduomenys kartais būna netikslūs, todėl jais negalima remtis sluoksniams lyginti [3]. Dažniausia netikslumo priežastis yra ta, kad radiologai dažnai nepakeičia įrangos numatytųjų parametru, neatsižvelgdami į tyrimo specifiką.

## 2.3 Vaizdų registravimas

Vaizdų registravimu (angl. *image registration*, dar kartais *image alignment*) vadinamas procesas, kai skirtingi vaizdai transformuojami į vieną koordinačių sistemą. Jo taikymas yra itin platus, jis yra būtinas norint lyginti ar sujungti vaizdus, gautus skirtingu metu, skirtingais įrenginiais ar skirtingais įrenginių nustatymais.

Paprastai registravimo procese vienas iš vaizdų yra vadinamas tiksliniu (angl. *target*, *subject* arba *destination*), kitas – pirminiu (angl. *source* arba *reference*), nors gali būti ir keli pirminiai vaizdai. Vaizdų registravimo esmė yra transformuoti pirminį vaizdą ir sulygtinti jį su tiksliniu vaizdu, t. y. tikslinio vaizdo koordinačių sistema nesikeičia, o pirminio vaizdo transformuojama taip, kad sutaptų su tikslinio vaizdo koordinačių sistema (14 pav. pateiktas pavyzdys, kuriame tikslinio vaizdo koordinačių sistemos abscisių ašis yra horizontali, pirminio vaizdo – pasukta taip, kad vaizdai kuo labiau sutaptų). Taip pat gali būti, kai nėra nė vieno tikslinio vaizdo, o galutinę koordinačių sistemą reikia parinkti registravimo metu, pavyzdžiui, jungiant panoramas iš atskirų vaizdų

siekama, kad galutinės nuotraukos  $x$ -ašis sutaptų su žemės plokštuma, kitaip tariant, kad  $x$ -ašis būtų statmena gravitacijos ašiai [30].



14 pav. Dviejų magnetinio rezonanso vaizdų registravimo pavyzdys<sup>6</sup>.

Vaizdų registravimo metodų įvairovės ypatumai:

- transformacijos modelių pasirinkimas,
- metodai, grįsti ryškumu (angl. *intensity-based*) arba požymiais (angl. *feature-based*),
- erdviniai ar spektriniai metodai,
- vienmodaliai ar daugiamodaliai metodai.

Vienmodaliais (angl. *single-modality*) metodais registruojami to paties šaltinio vaizdai (t. y. gauti tokiu pačiu metodu), daugiamodaliais (angl. *multi-modality*) – registruojami skirtingu būdu gauti vaizdai. 2.4 poskyryje pateiktas daugiamodalio registravimo pavyzdys, tačiau plačiau šiame darbe bus nagrinėjami tik vienmodaliai registravimo metodai. Toliau šiame poskyryje nagrinėjami transformacijos modeliai, ryškumu, spektru ir požymiais grįsti metodai.

### 2.3.1 Transformacijos modeliai

Pirmiausia registravimas klasifikuojamas pagal ryšio pobūdį tarp pirminio ir tikslinio vaizdo. Transformacija gali būti tiesinė ir netiesinė. Tiesinėmis







---

<sup>6</sup> Viešo naudojimo kūriny [commons.wikimedia.org/wiki/File:Mni-autoreg\\_03-registered.png](https://commons.wikimedia.org/wiki/File:Mni-autoreg_03-registered.png)

transformacijomis įvardijamos tokios, kur pirminio vaizdo taško koordinatų vektorių  $\mathbf{v}' = [x', y']^T$ <sup>7</sup> padauginus iš transformacijos matricos  $T$  gaunamas taškas tikslinio vaizdo koordinatų sistemoje  $\mathbf{v}''$ , t. y.  $\mathbf{v}'' = T\mathbf{v}'$ . Transformacijos matrica yra kvadratinė matrica, skirta optimaliai tiesiškai transformuoti pirminį vaizdą tikslinio vaizdo atžvilgiu.

Transformacijos dar klasifikuojamos pagal laisvės laipsnius, jos išvardytos 2 lentelėje.

2 lentelė. Transformacijos modelių klasifikavimas.

Tipas	Pavadinimas	Laisvės laipsniai	Pikto-grama
Standi (angl. <i>rigid</i> ) / tiesinė	Paslinkimo	2	
Standi / tiesinė	Posūkio	3	
Nestandi (angl. <i>nonrigid</i> ) / tiesinė	Panašumo	4	
Nestandi / tiesinė	Afininė	6	
Nestandi / tiesinė	Projekcinė	8	
Nestandi / netiesinė	Elastinga (angl. <i>elastic</i> )	–	

Paslinkimo transformacijos modeliai išlaiko orientaciją (t. y. jeigu vaizde buvo linija, kuri su  $Ox$  ašimi sudarė kažkokį kampą, po transformacijos tas kampas išliks nepakitęs), atstumą (t. y. jeigu vaizde buvo kažkokio ilgio atkarpa, po transformacijos tas ilgis išliks nepakitęs), kampus (t. y. jeigu vaizde buvo dvi atkarpos, kurios tarpusavyje sudarė kažkokį kampą, tas kampas po transformacijos išliks nepakitęs), lygiagretumą (t. y. jeigu vaizde buvo dvi lygiagrečios linijos, po transformacijos šios linijos ir išliks lygiagrečios) ir tiesias linijas (jeigu vaizde buvo tiesi linija, ji po transformacijos išliks tiesi). Posūkio transformacijos modeliai nebeišlaiko orientacijos, panašumo – atstumo, afininė – kampų, projekcinė – lygiagretumo, elastingi – tiesių linijų.

<sup>7</sup> Norint tiesinę transformaciją žymėti viena matrica, reikia naudoti homogenines koordinates, kuriomis dvimatis taškas žymimas  $\mathbf{v} = (x, y, 1)$ , tačiau dėl paprastumo šiame darbe paskutinis narys praleidžiamas.

Transformacijos modelio tipas pasirenkamas priklausomai nuo užduoties specifikos, o tada ieškomi modelio parametrai.

### 2.3.2 Ryškumu grįstas registravimas

Registravimo metodai, veikiantys lyginant kiekvieną pirminiame ir tiksliniame vaizduose persidengiantį pikselį, yra vadinami ryškumu grįstu arba tiesioginiu metodu (angl. *direct method*). Pikseliams palyginti reikia pasirinkti paklaidos matmenį (angl. *error metric*) ir paieškos būdą.

Paprasčiausias paklaidos matmuo yra skirtumų kvadratų suma (angl. *sum of squared differences, SSD*):

$$E_{SSD}(T) = \sum_i [I'(T \cdot \mathbf{v}_i) - I''(\mathbf{v}_i)]^2 = \sum_i \varepsilon_i^2, \quad (1)$$

kur  $I'$  yra pirminis vaizdas (vaizdą galima traktuoti kaip dvimatę funkciją  $I(\mathbf{v}) = I([x \ y]^T)$ ),  $I''$  – tikslinis vaizdas,  $\sum_i \varepsilon_i^2$  – likutinė paklaida (angl. *residual error*),  $i$  kinta per visus indeksus, kur paveikslėliai persidengia,  $T$  yra transformacijos matrica, kuri ieškoma optimizuojant  $E_{SSD}$  funkciją.  $E_{SSD}$  funkcijos minimizavimas gali turėti tendenciją mažinti vaizdų persidengiantį plotą; tai galima išspręsti padalijant sumą iš vaizdų sankirtos ploto.

Skirtumų kvadratų suma yra labai jautri triukšmui, todėl dažnai skirtumų kvadratai keičiami robastiška (angl. *robust*) funkcija  $\psi(\varepsilon)$ :

$$E(T) = \sum_i \psi(I'(T \cdot \mathbf{v}_i) - I''(\mathbf{v}_i)) = \sum_i \psi(\varepsilon_i). \quad (2)$$

Funkcija  $\psi(\varepsilon)$  turi būti diferencijuojama, taip pat jos reikšmės toliau nuo nulio turi augti ne taip greitai kaip kvadratinės funkcijos. Tokia galėtų būti *Geman-McClure* funkcija [31]:

$$\psi_{GM}(\varepsilon) = \frac{\varepsilon^2}{1 + \varepsilon^2/\xi^2}, \quad (3)$$

kur  $\xi$  yra konstanta, nusakanti slenkstį.



Vietoj paklaidos matmens galima naudoti ir kryžminę koreliaciją (angl. *cross-correlation*), tik ją reikia maksimizuoti:

$$E_{CC}(T) = \sum_i I'(T \cdot \mathbf{v}_i) I''(\mathbf{v}_i). \quad (4)$$

Paprasciausias būdas minimizuoti paklaidos matmens funkciją yra išbandyti visas galimas  $T$  reikšmes pasirinktame intervale pasirinktu žingsniu, t. y. atlikti visą paiešką (angl. *full search*). Nors ji gali atrodyti visiškai neracionali, paieška iš tikrųjų dažnai atliekama, kai žinoma, kad transformacijos modelis turi nedaug laisvės laipsnių ir paieškos intervalas yra labai mažas, pavyzdžiui, registruojant video kadrus [32].


Pagreitinti minimizavimo procesui dažnai naudojamas hierarchinis judesio įvertinimas (angl. *hierarchical motion estimation*). Pirmiausia sudaroma vaizdo piramidė – vaizdas suspaudžiamas 2, 4, 8 ir t. t. kartų iki nustatyto dydžio. Tada paieška atliekama stambiausiame lygyje su mažu pikselių kiekiu. Judesio įvertinimas viename lygyje naudojamas inicializuoti lokaliai paieškai kitame smulkesniame lygyje. Nors tai negarantuoja tokio paties rezultato kaip ir visa paieška, toks sprendimas yra kur kas greitesnis, tačiau transformacijos modeliams su daug laisvės laipsnių vis dar per lėtas. Todėl ryškumu grįsti metodai dažniau naudojami tik registravimui patikslinti [33].

### 2.3.2.1 Optinė tėkmė

Optinė tėkmė (angl. *optical flow*) skaičiuoja ne bendrą vaizdo transformaciją, o poslinkio (angl. *displacement*) vektorių kiekvienam vaizdo taškui [34]. Dažniausiai taip registruojami du labai panašūs vaizdai, pavyzdžiui, vienas po kito einantys video kadrai.

Vienmačiu atveju yra ieškomas skirtumas  $\eta$  tarp dviejų funkcijų argumentų, kad funkcijų  $I'$  ir  $I''$  reikšmės sutaptų (žr. 15 pav.; šiuo atveju laikykime, kad funkcijos  $I'$  ir  $I''$  yra vienmatės). Kadangi mažiems  $\eta$  galioja  $\frac{dI''}{dx} \approx \frac{(I''(x+h) - I''(x))}{\eta} \approx \frac{(I'(x) - I''(x))}{\eta}$ , tai  $\eta \approx \frac{(I'(x) - I''(x))}{\left. \frac{dI''}{dx} \right|_x}$ . Kaip parodė [34]

autorių atlikti eksperimentai su sinusoidėmis, iteruojančiu algoritmu galima rasti  $\eta$  iki pusės sinusoidės periodo.



15 pav. Optinės tėkmės aproksimavimas vienmačiu atveju [30].

Optinės tėkmės apskaičiavimo algoritmą galima aprašyti šiais žingsniais [35]:

1. Apskaičiuoti tikslinio vaizdo gradientą  $I_x(\mathbf{v}) = I_x(x, y) = \frac{\partial I''}{\partial x}$  ir  $I_y(\mathbf{v}) = \frac{\partial I''}{\partial y}$ ,
2. Kiekvienam taškui jo aplinkoje  $(2W_x + 1) \times (2W_y + 1)$  apskaičiuoti matricą  $H(\mathbf{v}) = H(x, y)$  pagal (5) formulę,
3. Inicializuoti pradinę optinę tėkmę  $\mathbf{p}_0 = [0 \ 0]^T$ ,
4. Gauti vaizdų skirtumą  $\delta I_k(\mathbf{v}) = I''(\mathbf{v}) - I'(\mathbf{v} + \mathbf{p}_{k-1})$ ,
5. Gauti vaizdų neatitikimo vektorius  $\mathbf{z}_k$  pagal (6) formulę,
6. Optinės tėkmės artinys  $\boldsymbol{\eta}_k = H^{-1}(\mathbf{v})\mathbf{z}_k(\mathbf{v})$ ,
7. Kitos iteracijos artinys  $\mathbf{p}_k = \mathbf{p}_{k-1} + \boldsymbol{\eta}_k$ .

4–7 žingsniai kartojami, kol  $\boldsymbol{\eta}_k$  tampa nykstamai mažas (pagal nustatytą tikslumą). 3–7 žingsniai dėl žymėjimo paprastumo pateikti vienam taškui, tačiau skaičiavimai atliekami visiems taškams.

$$H(x, y) = \sum_{p_x=x-W_x}^{x+W_x} \sum_{p_y=y-W_y}^{y+W_y} \begin{bmatrix} I_x^2(p_x, p_y) & I_x(p_x, p_y)I_y(p_x, p_y) \\ I_x(p_x, p_y)I_y(p_x, p_y) & I_y^2(p_x, p_y) \end{bmatrix}, \quad (5)$$

$$\mathbf{z}_k(x, y) = \sum_{p_x=x-W_x}^{x+W_x} \sum_{p_y=y-W_y}^{y+W_y} \begin{bmatrix} \delta I_k(p_x, p_y)I_x(p_x, p_y) \\ \delta I_k(p_x, p_y)I_y(p_x, p_y) \end{bmatrix}. \quad (6)$$

Funkcijos  $H(x, y)$  reikšmė yra matrica,  $\mathbf{z}_k(x, y)$  – vektorius.

Yra sukurta įvairių šio algoritmo modifikacijų, ne tik registruojančių pakankamai skirtingus vaizdus, bet ir leidžiančių gauti vieną transformacijos matricą visam vaizdui.

### 2.3.3 Spektrinis registravimas

Ne visada įmanoma pritaikyti hierarchinius intensyvumu grįstus metodus, nes kuo labiau spaudžiamas vaizdas, tuo daugiau reikšmingų požymių susilieja. Kai transformacijos modelis yra nesudėtingas (pvz., tik poslinkis), problema išsprendžiama Furjė transformacija grįstu (angl. *Fourier-based*) registravimu.

Spektrinis registravimas paremtas Furjė transformacijos ypatybe, kad paslinkto signalo spektro stiprumas (angl. *magnitude*) išlieka toks pats, tik turi tiesiškai besikeičiančią fazę [36, p. 57]:

$$\mathcal{F}\{I(\mathbf{v} + \mathbf{u})\} = \mathcal{F}\{I(\mathbf{v})\}e^{-2\pi j\mathbf{u}\cdot\mathbf{f}}, \quad (7)$$

kur  $\mathbf{f}$  yra vektorinis dažnis, o  $\mathcal{F}\{I(\mathbf{v})\}$  yra vaizdo Furjė transformacija.

Kita svarbi Furjė transformacijos ypatybė yra Furjė sąsūkos teorema, teigianti, kad vaizdo sąsūkos (angl. *convolution*) spektras yra lygus vaizdo ir branduolio spektrų sandaugai [36, p. 58]. Kryžminė koreliacija (4) iš esmės ir yra sąsūka, todėl ją galima suskaičiuoti naudojant Furjė transformaciją:

$$\mathcal{F}\{E_{CC}\} = \mathcal{F}\{I'(\mathbf{v}) * I''(\mathbf{v})\} = \mathcal{F}\{I'(\mathbf{v})\}\mathcal{F}\{I''(\mathbf{x})\}, \quad (8)$$

kur  $*$  yra sąsūkos operatorius. Taigi norint efektyviai įvertinti kryžminę koreliaciją  $E_{CC}$  visoms įmanomoms poslinkio reikšmėms  $\mathbf{u}$ , reikia atlikti vaizdų  $I'(\mathbf{v})$  ir  $I''(\mathbf{v})$  Furjė transformaciją, rezultatus sudauginti ir atlikti atvirkštinę Furjė transformaciją  $E_{CC}(\mathbf{v}) = \mathcal{F}^{-1}\{\mathcal{F}\{I_0(\mathbf{v})\}\mathcal{F}\{I_1(\mathbf{v})\}\}$ . Gaunamas dvimatis vaizdas  $E_{CC}$ , kuriame ryškiausio pikselio koordinatės nurodo geriausią poslinkį  $\mathbf{u}$ , juo ir turi būti paslinktas pirminis vaizdas. Bendras sprendimo sudėtingumas  $N_x \times N_y$  dydžio vaizdui yra  $\mathcal{O}(N_x N_y \log(N_x N_y))$ , o štai įprastas kryžminės koreliacijos sprendimo sudėtingumas būtų  $\mathcal{O}(N_x^2 N_y^2)$ .

Furjė sąsūkos teorema teisinga tik tada, kai sumuojami visi paveikslėlių pikseliai  $v$ ; šią problemą galima išspręsti išplečiant (angl. *padding*) vaizdus reikiamu kiekiu juodų pikselių (nulinėmis reikšmėmis).

Furjė transformaciją įmanoma pritaikyti ir skirtumų kvadrato sumą imant kaip paklaidos matmenį, tačiau reikia įvesti svorius ir formulės tampa gana sudėtingos.

Deja, spektrinį registravimą labai sunku taikyti su panašumo registravimo ir sudėtingesniais modeliais.

### 2.3.4 Požymiais grįstas registravimas

Intensyvumu grįsti metodai turi labai daug trūkumų – yra arba lėti, arba turi kitų ribojimų. Kitas svarbus metodų tipas – požymiais grįstas registravimas. Jo esmė yra iš pradžių surasti skiriamuosius vaizdo bruožus (požymius; angl. *feature detection*), surasti kiekvieno iš jų atitikmenis abiejuose registruojamuose vaizduose ir įvertinti geometrinę transformaciją. Skiriamieji bruožai gali būti taškai ([37], [38]), linijos ([39], [40]) ar netgi regionai ([41]). Literatūroje taškai, pagal kuriuos registruojama, vadinami įvairiai: į kampus panašūs taškai (angl. *corner-like*), raktiniai taškai (angl. *keypoints*), svarbūs taškai (angl. *interest points*), iškilūs taškai (angl. *salient points*), kontroliniai taškai (angl. *control points*), orientyrai (angl. *landmarks*) arba sekti tinkami požymiai (angl. *good features to track*).

#### 2.3.4.1 Požymių radimas

Skiriamieji bruožai turi būti aiškūs, išsidėstę tolygiai, randami abiejuose registruojamuose vaizduose ir iš tų pačių objektų, matomų vaizduose, turi būti gaunami tokie patys požymiai. Dažniausiai skiriamieji bruožai yra taškai, o jie gali būti suprantami ir kaip linijų sankirtos, ir kaip kampai – kontūro vietos su dideliu kreivumu [42].

Kreivumą geriausiai parodo vaizdo taško Hessian matricos tikrinės reikšmės, tačiau jas skaičiuoti kiekvienam pikseliui užtruktų per ilgai, todėl

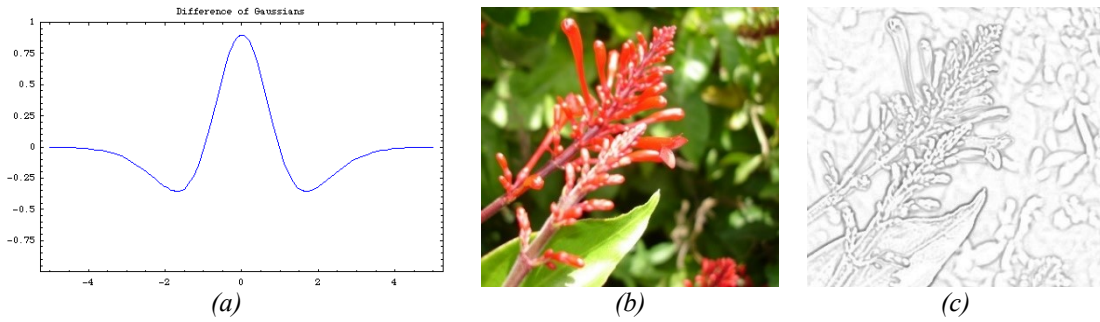
naudojamos įvairios aproksimacijos. Pavyzdžiui, kiek supaprastintas Harris kampų nustatymo metodas [43] kiekvienam vaizdo pikseliui skaičiuoja  $H$  matricą pagal (5) formulę,  $\lambda_0$  ir  $\lambda_1$  pagal (9) formulę, tada  $R$  pagal (10) formulę. Tas pats metodas taikomas ir pirminiam  $I'$ , ir tiksliniam  $I''$  vaizdams.

$$\lambda_0(\mathbf{v}) = \frac{H_{00}(\mathbf{v}) + H_{11}(\mathbf{v}) - \sqrt{(H_{00}(\mathbf{v}) - H_{11}(\mathbf{v}))^2 + H_{01}(\mathbf{v})H_{10}(\mathbf{v})}}{2}, \quad (9)$$

$$\lambda_1(\mathbf{v}) = \frac{H_{00}(\mathbf{v}) + H_{11}(\mathbf{v}) + \sqrt{(H_{00}(\mathbf{v}) - H_{11}(\mathbf{v}))^2 + H_{01}(\mathbf{v})H_{10}(\mathbf{v})}}{2},$$

$$R(\mathbf{v}) = \lambda_0(\mathbf{v})\lambda_1(\mathbf{v}) - q(\lambda_0(\mathbf{v}) + \lambda_1(\mathbf{v}))^2, \quad (10)$$

kur  $H_{yx}(\mathbf{v})$  yra  $H$  matricos elementas  $y$  eilutėje ir  $x$  stulpelyje,  $q$  – konstanta, pavyzdžiui,  $q = 0,06$ ,  $R$  yra naujas vaizdas, kurio lokalūs maksimumai nusako kontrolinius taškus.



16 pav. Skirtingai suglontintų vaizdų skirtumas: (a) vienmatis Gauso branduolių skirtumas<sup>8</sup>; (b) pradinis vaizdas<sup>9</sup>; (c) vaizdas po sąsūkos su dvimačiu branduoliu<sup>10</sup>.

Paskui pasiūlyti mažiau nuo mastelio nepriklausomi metodai, pavyzdžiui, skirtingai suglontintų vaizdų skirtumo (angl. *Difference of Gaussian*, *DoG*; 16(b) ir (c) pav.) ekstremumų metodas [44]. Kontroliniai taškai yra lokalūs maksimumai  $I_{t\sigma,\sigma}(\mathbf{v})$  vaizde, kuris gaunamas pagal (11).

$$\begin{aligned} I_{t\sigma,\sigma}(\mathbf{v}) &= I(\mathbf{v}) * \Gamma_{t\sigma} - I(\mathbf{v}) * \Gamma_{\sigma} \\ &= I(\mathbf{v}) * (\Gamma_{t\sigma} - \Gamma_{\sigma}), \end{aligned} \quad (11)$$

<sup>8</sup> Viešo naudojimo kūriny [en.wikipedia.org/wiki/File:DOG\\_vs\\_MHF.png](http://en.wikipedia.org/wiki/File:DOG_vs_MHF.png)

<sup>9</sup> *Creative Commons* licencija [en.wikipedia.org/wiki/File:Flowers\\_before\\_difference\\_of\\_gaussians.jpg](http://en.wikipedia.org/wiki/File:Flowers_before_difference_of_gaussians.jpg)

<sup>10</sup> *Creative Commons* licencija [en.wikipedia.org/wiki/File:Flowers\\_after\\_difference\\_of\\_gaussians\\_grayscale.jpg](http://en.wikipedia.org/wiki/File:Flowers_after_difference_of_gaussians_grayscale.jpg)

kur  $\Gamma_\sigma$  yra Gauso skirstinio branduolys  $\Gamma_\sigma(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}}$ . Dėl sąsūkos operatoriaus asociatyvumo skirtingai suglotnintų vaizdų skirtumą galima gauti ir taikant sąsūką vieną kartą su branduoliu, lygiu dviejų Gauso branduolių skirtumui (11). 16(a) pav. pavaizduotas toks vienmatis branduolys (dvimačio branduolio skerspjūvis per centrą).

#### 2.3.4.2 Požymių atitikmenų radimas

Suradus požymius pirminiame ir tiksliniuose vaizduose, reikia surasti tų požymių atitikmenis (angl. *feature match, point correspondences*).

Jeigu žinomos tik kontrolinių taškų koordinatės, atitikmenys ieškomi pagal erdvinį taškų išsidėstymą. Pavyzdžiui, [45] metodas bando sutapatinti iš pirminio ir tikslinio vaizdų kontrolinių taškų gautus minimalius jungiamuosius medžius (angl. *minimum spanning trees*), tačiau jeigu taškų yra labai daug, šis metodas veikia itin lėtai.

Naujesnis ir greitesnis metodas – [46]. Jo žingsniai yra tokie:

1. Nustatomi pirminio ir tikslinio vaizdų kontrolinių taškų iškilieji apvaskalai (angl. *convex hull*)  $Y_1$  ir  $Y_2$ ,
2. Nustatomi transformacijos parametrai, susiejantys porą taškų iš  $Y_1$  ir porą taškų iš  $Y_2$ ,
3. Kiekvienai gautai transformacijai suskaičiuojama, kiek su ja pirminio vaizdo kontrolinių taškų transformuojama į tikslinio vaizdo taškus su paklaida  $\varepsilon$ ,
4. Pagal šį kiekį surandama geriausia transformacija,
5. Pagal taškus, kurie tenkina šią transformaciją su paklaida  $\varepsilon$ , surandama transformacija mažiausių kvadratų metodu.

Ir [45], ir [46] tinka nesudėtingesnėms nei panašumo transformacijoms, be to, yra gana lėti.

ICP (angl. *Iterative Closest Point*) [47] algoritmas, ieškodamas taškų atitikmenų, iškart vertina ir geometrinę transformaciją. Algoritmą galima pritaikyti bet kokios dimensijos duomenims bet kokiam transformacijos

---

modeliui rasti. Duomenys gali būti taškų, atkarpų, trikampių aibės, taip pat parametrinės kreivės ar parametriniai paviršiai. Algoritmo žingsniai šie:

1. Kiekvienam pirminio vaizdo kontroliniui taškui randamas artimiausias (pagal Euklidinį atstumą) taškas tikslinio vaizdo kontrolinių taškų aibėje,
2. Įvertinami transformacijos modelio parametrai mažiausių kvadratų metodu, atmetant išsišokėlius (angl. *outlier*),
3. Tikslinio vaizdo taškai transformuojami pagal gautą transformaciją.

1–3 žingsniai kartojami, kol transformacija konverguoja. Taip pat pravartu žinoti pradinę transformaciją, pagal kurią transformuojami pirminio vaizdo taškai dar prieš pirmą iteraciją. ICP autoriai pasiūlė poslinkį apskaičiuoti pagal taškų masių centrus, o posūkį – naudojant kvaternijonų aritmetiką.

Visiškai kitokia strategija yra ieškoti taškų atitikmenų pagal jų aprašus (angl. *descriptor*). Taško aprašas turi tenkinti kelias ypatybes: invariantiškumą transformacijai (atitinkamo taško pirminiame ir tiksliniame vaizduose aprašas turi būti toks pat), unikalumą (skirtingi taškai turi turėti skirtingus aprašus), stabilumą (nežymiai deformuoto taško aprašas turi būti panašus į originalų) ir nepriklausomumą (jeigu aprašas yra vektorius, jo elementai turi būti nepriklausomi) [48]. Suprantama, šios ypatybės yra siektinos, vieni aprašymo būdai geriau tenkina vieną ypatybę, kiti – kitą. Ieškant taškų atitikmenų pagal aprašus taško erdvinė vieta paprastai ignoruojama.

Paprasčiausias taško aprašas gali būti vaizdo pikselių intensyvumas artimoje aplinkoje, tokiu atveju galima taikyti kryžminę koreliaciją ([49], [50]). N. Vujovic ir D. Brzakovic naudojo monotoniškumo operatorių [51] išskirti vertikaliai ir horizontaliai ištišusias struktūras (angl. *elongated structures*), jų sankirtos buvo naudojamos kaip kontroliniai taškai, o jų aprašai sudaryti iš kampų tarp sankirtoje dalyvaujančių struktūrų [52]. Dažnai kontroliniai taškai ir jų aprašai sudaromi iš vaizde surastų uždarų kontūrų, pavyzdžiui, [53] kontroliniai taškai yra kontūro masės centras, o jo aprašas yra vektorius, į kurį

įeina kontūro perimetras, mažiausias ir didžiausias atstumai nuo masės centro iki kontūro, pirmas ir antras momentai.

Kai taško aprašas yra vektorius, atitikmenys dažniausiai ieškomi įvairiais artimiausių kaimynų paieškos algoritmais. Šiuo metu dažnai naudojamas FLANN (angl. *Fast Library for Approximate Nearest Neighbors*) [54], [55], kuris pagal pateiktus pradinius vektorius automatiškai parenka geriausią algoritmą ir jo parametrus.

#### 2.3.4.3 Geometrinės transformacijos įvertinimas

Sukurtas 1981 metais, tačiau vis dar labai plačiai naudojamas metodas yra atsitiktinių mėginių konsensusas (angl. *Random Sample Consensus, RANSAC*) [56]. Šis metodas gali būti pritaikytas įvertinti bet kokio matematinio modelio parametrus iš duomenų, turinčių išsišokėlių. Metodas yra nedeterministinis, jis duoda rezultatus su tam tikra tikimybe, didėjančia, kai didinamas algoritmo iteracijų skaičius. Viena iteracija susideda iš dviejų žingsnių:

1. Atsitiktinai pasirenkama po tris (jeigu ieškoma panašumo transformacija, arba mažiausiai tiek, kiek reikia nustatyti norimai transformacijai) kontrolinius taškus iš abiejų vaizdų ir pagal juos nustatoma transformacija  $T$ ,
2. Skaičiuojama, kiek kontrolinių taškų porų atitinka šią transformaciją su iš anksto nustatyta paklaida (slenksčiu)  $t_r$ .


Iteracijų kartojimas gali būti nutrauktas, jeigu transformacija surenka pakankamą procentą atitikmenų (angl. *inliers*).

RANSAC metodas skaičiuoja transformacijos atitikmenų kiekį, kitaip tariant, vertina kiekvieno atitikmens paklaidą 0 arba 1, kuri priklauso tik nuo iš anksto pasirinkto slenksčio, o slenksčio parinkimas gali iš esmės lemti gaunamą modelį. 17 pav. parodyta, kad globalus minimumas priklauso nuo slenksčio parinkimo, todėl slenksčio parinkimas gali būti suprantamas kaip problemos apibrėžimas. 17 pav. punktyrinėmis linijomis parodytos paklaidos, o atitinkamos spalvos linija – įtaikytą modelį. MSAC (angl. *M-estimator sampling consensus*) metodui [57] taip pat reikalingas slenkstis  $h$ , tik kiekvienam

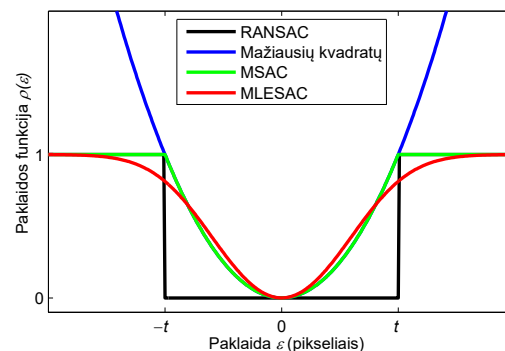


atitikmeniui  $i$  suteikiama paklaida  $\psi(\varepsilon_i) = \begin{cases} \varepsilon_i^2, & \varepsilon_i^2 < h^2 \\ h^2, & \varepsilon_i^2 \geq h^2 \end{cases}$ , kur  $\varepsilon_i = |T\mathbf{v}'_i - \mathbf{v}''_i|$ ,

$\mathbf{v}'$  yra pirminio vaizdo kontrolinis taškas,  $\mathbf{v}''$  yra tikslinio vaizdo atitinkamas kontrolinis taškas, paprasčiau tariant,  $\varepsilon$  yra realios ir išmatuotos verčių skirtumas. Kur kas sudėtingesnis MLESAC (angl. *Maximum Likelihood Estimation Sample Consensus*) metodas [58] paklaidą modeliuoja iš Gauso ir tolygiojo skirstinių: kiekvienam atitikmeniui  $i$  priskiria paklaidą  $\psi(\varepsilon) = \gamma \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\varepsilon^2}{2\sigma^2}} + (1 - \gamma) \frac{1}{v}$ , čia  $v$  yra konstanta (paieškos langas), o  $\gamma$  reikia įvertinti algoritmo skaičiavimo metu. 18 pav. parodyti paklaidos funkcijų grafikai (paslinkti, kad būtų lengviau palyginti): mažiausių kvadratų metodas (mėlyna linija) priskiria dideles baudas didelėms klaidoms, RANSAC (juoda) tiesiog skaičiuoja modelį tenkinančius vienetus, MSAC (žalia) yra nukirsta mažiausių kvadratų funkcija, MLESAC (raudona) apskaičiuojamas kaip logaritminė tikimybė.



17 pav. Duomenų aproksimavimas tiese su skirtingais slenksčiais<sup>11</sup>.



18 pav. Skirtingų metodų paklaidos funkcija.

RANSAC algoritmas sukurtas pritaikyti bet kokią matematinę modelį eksperimentiniams duomenims. Juo galima netgi surasti požymių atitikmenis, tačiau tokiu atveju reikėtų sujungti pirminio ir tikslinio vaizdų koordinates [58], t. y. iš dviejų dvimačių koordinatinių sistemų gauti vieną keturmatę. Tokie skaičiavimai užtruktų labai ilgai, todėl praktikoje naudojami kiti metodai.

<sup>11</sup> [https://dspace.cvut.cz/bitstream/handle/10467/14636/masters\\_thesis\\_Lebeda\\_2013.pdf](https://dspace.cvut.cz/bitstream/handle/10467/14636/masters_thesis_Lebeda_2013.pdf)

#### 2.3.4.4 Piramidės pritaikymas optinės tĕkmės algoritmui

J.-y. Bouguet modifikavo optinės tĕkmės algoritmą vaizdams su dideliu skirtumu registruoti, pritaikydami piramidę [35]. Kiekviename piramidės lygmenyje optinė tĕkmė skaičiuojama iteratyviai, taip pat tikslinama ankstesniame lygmenyje apskaičiuota optinė tĕkmė. 4-tas žingsnis 2.3.2.1 punkte pateiktame algoritme tampa  $\delta I_k(\mathbf{v}) = I_L''(\mathbf{v}) - I_L''(\mathbf{v} + \mathbf{p}^L + \mathbf{p}_{k-1})$ , kur  $L$  yra einamasis piramidės lygmuo (kinta nuo  $L_m$  iki 0, t. y. iki pradinio vaizdo),  $I_L'$  ir  $I_L''$  yra pirminio ir tikslinio vaizdų piramidžių  $L$ -asis lygmuo, t. y. vaizdas, suspaustas  $2^L$  kartų,  $\mathbf{p}^L$  yra optinė tĕkmė, suskaičiuota aukštesniame lygmenyje,  $\mathbf{p}^{L_m} = [0 \ 0]^T$ .

Tame pačiame straipsnyje [35] buvo pasiūlyta optinę tĕkmę skaičiuoti ne visiems vaizdo pikseliams, o tik kontroliniams taškams. Algoritmas yra toks:

1. Suskaičiuojama  $H$  matrica pagal (5) formulę ir mažiausia tikrinė reikšmė  $\lambda$  kiekvienam vaizdo pikseliui,
2. Randama  $\lambda_{max}$  – didžiausia  $\lambda$  iš visų taškų,
3. Paliekami tik tie pikseliai, kurių  $\lambda \geq t_p \lambda_{max}$ , kur  $t_p$  yra iš pradžių pasirenkamas slenkstis, pavyzdžiui, 0,95,
4. Iš pastarųjų pikselių paliekami tik lokaliai didžiausią  $\lambda$  reikšmę turintys pikseliai (lokalūs maksimumai ieškomi  $3 \times 3$  aplinkoje),
5. Iš pastarųjų paliekamas poaibis tų pikselių, kurie išlaiko ne mažesnę kaip nustatytą atstumą tarp bet kurios poros.

Pirmas šio algoritmo žingsnis yra labai panašus į Harris kampų nustatymo algoritmą, aprašytą 2.3.4.1 punkte, tik pastarajame tikrinių reikšmių skaičiavimas vardan greitumo yra aproksimuojamas.

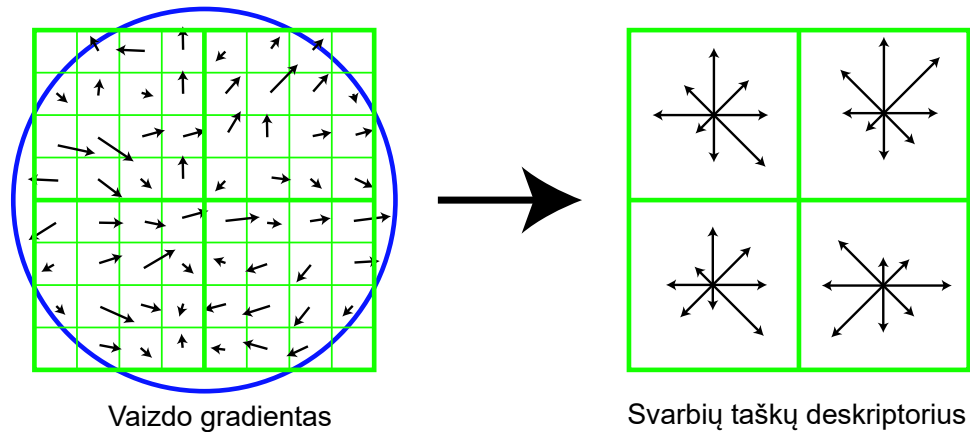
Ieškant sekti tinkančių taškų,  $H$  matrica gali būti skaičiuojama mažoje taškų aplinkoje, pavyzdžiui,  $3 \times 3$ , o optinė tĕkmė skaičiuojama nustačius didesnę aplinką (nors pradinio optinės tĕkmės algoritmo autoriai [34] čia siūlė taip pat naudoti  $3 \times 3$  dydžio aplinką).

---

#### 2.3.4.5 SIFT metodas

Dabartiniai metodai dažnai požymius aprašo vektoriais, tada jų ieško kitame paveikslėlyje naudojant įvairias artimiausių kaimynų paieškas (angl. *nearest neighbour search*). Pavyzdžiui, SIFT (angl. *Scale-Invariant Feature Transform*) metodas [44] iš pradžių taiko skirtingai suglotnintų vaizdų skirtumą, iš jo pašalina kontūrus, kurie nėra kampai (tikrindami principinį kreivumą, kurį rodo Hessian matrica taške), tada kiekvienam ekstremumui sudaro deskriptoriaus vektorius, kaip parodyta 19 pav. SIFT taškų aprašas yra gaunamas apskaičiuojant gradiento vektorius kiekviename taške aplink kontrolinį tašką. Gradientų vektorius ilgiai padauginami iš Gauso branduolio (apibrėžtas mėlynu apskritimu) svorių, taškų gradiento vektoriai kiekvienam  $4 \times 4$  subregionui apibendrinami krypties histogramomis, kaip parodyta dešinėje, kur rodyklių ilgiai nurodo atitinkamos krypties gradiento vektorius sumą tame subregione. Algoritme galima keisti Gauso branduolio standartinį nuokrypį, subregiono dydį, subregionų kiekį (šiuo atveju  $2 \times 2$ ) ir krypties histogramoje kiekį (šiuo atveju 8, t. y. kas  $45^\circ$ ). Kiekvienas pirminio vaizdo kontrolinio taško aprašo vektorius ieškomas tarp tikslinio vaizdo kontrolinių taškų aprašų vektorius. Kadangi ieškomi vektoriai, turintys daug dimensijų ([44] darbe buvo naudojami 128 dimensijų vektoriai), o standartinis  $k-d$  medis nepajėgus dirbti su daugiau kaip 10 dimensijų, sukurtas specialus artimiausių kaimynų paieškos algoritmas *best-bin-first* [59], naudojantis maišos funkcijomis (angl. *hash*) grįstas prioritetingas eiles. Taip pat paieška nutraukiama, kai patikrinamas tam tikras artimiausių kaimynų kandidatų skaičius. Suradus artimiausią kaimyną gaunama požymių pora, iš kurios galima prognozuoti vaizdo transformaciją – poslinkį, posūkį ir mastelio pokytį, iš viso 4 parametrai. Galiausiai renkama geriausia transformacija.

SIFT metodas yra patentuotas, jo teisės priklauso Britų Kolumbijos Universitetui. Metodas prieinamas tik individualiam tyrinėjimui, bet kokiam jo komerciniam naudojimui reikia įsigyti licenciją.



19 pav. SIFT taškų deskriptorius [44].


### 2.3.4.6 ORB metodas

OpenCV<sup>12</sup> bibliotekos autoriai sukūrė nemokamą ir greitai veikiančią metodą ORB [60]. Iš pradžių jis randa kontrolinius taškus naudodamas FAST (angl. *Features from Accelerated Segment Test*) ([61], [62]) metodo papildymą oFAST, kiekvienam kontroliniui taškui sukuria aprašo vektorius, naudodamas BRIEF (angl. *Binary Robust Independent Elementary Features*) metodo [63] papildymą rBRIEF, tada aprašų vektoriai ieškomi tarp tikslinio vaizdo aprašų vektorius vietai jautria maiša (angl. *Locality Sensitive Hashing*) [64].

FAST algoritmas iš pradžių atrenka galimus taškus – kandidatus į kampus – tikrindamas šešiolikos pikselių apskritimą aplink kiekvieną tašką. Taškas  $\mathbf{v}$  yra kampas, jeigu egzistuoja bent 9 (šis parametras gali būti keičiamas, tačiau 9 duoda geriausių rezultatų) iš eilės apskritimu einančių pikselių, kurių visų ryškumas yra arba didesnis už  $I(\mathbf{v}) + d$ , arba mažesnis už  $I(\mathbf{v}) - d$ , kur  $d$  yra slenkstis (algoritmo parametras). 20 pav. pateiktas tikrinimo, ar taškas yra kampas, pavyzdys. 16 paryškintų kvadratų yra pikseliai, kurie naudojami kampui nustatyti;  $x$  yra kampas kandidatas. Šiame pavyzdyje punktyrine linija pažymėta arka nurodo 12 iš eilės einančių pikselių, kurie yra šviesesni už tašką  $x$ , ir tas skirtumas yra didesnis nei slenkstis.

<sup>12</sup> [opencv.org](http://opencv.org)

Naudojant ID3 algoritmą [65] paliekami tik tie kampai, kurie turi didžiausią entropiją. Po to kiekvienam taškui-kampui priskiriama reikšmė, lygi minimaliam  $d$ , su kuriuo taškas vis dar gali būti laikomas kampu. Tada gautu vaizdu slenkamas  $3 \times 3$  dydžio langas, ir šalinami visi kampai, kurių reikšmė yra ne maksimali tame lange.



20 pav. Tikrinimas, ar taškas yra kampas [61].

Kadangi FAST metodas niekaip nenusako kampų krypties, ORB autoriai išplėtė šį metodą pridėdami krypties komponentę ir pavadindami jį oFAST (angl. *oriented FAST*). Naudojant intensyvumo masės centrą (angl. *intensity centroid*) [66] apskaičiuojama kampo kryptis, kuri lygi:

$$\vartheta = \text{atan2} \left( \sum_{x,y} y \cdot I(x,y), \sum_{x,y} x \cdot I(x,y) \right), \quad (12)$$

kur  $\text{atan2}(x, y)$  yra ketvirčiams jautri arktangento versija.

BRIEF metodas sukuria binarinį  $u$  ilgio vektorių iš vaizdo intensyvumo palyginimų:

$$\tau(I_\sigma, \mathbf{v}^*, \mathbf{v}^{**}) = \begin{cases} 1, & I_\sigma(\mathbf{v}^*) < I_\sigma(\mathbf{v}^{**}) \\ 0, & I_\sigma(\mathbf{v}^*) \geq I_\sigma(\mathbf{v}^{**}), \end{cases} \quad (13)$$


kur  $I_\sigma(\mathbf{v})$  yra suglotnintas paveikslėlis; sudarant vieno kontrolinio taško požymių vektorių naudojama aplinka  $S \times S$  dydžio aplink tą tašką.  $u$  dydžio  $(\mathbf{v}^*, \mathbf{v}^{**})$  porų rinkinys vienareikšmiai nusako binarinių testų aibę. Galutinis BRIEF vektorius sudaromas taip:

$$f_u(I_\sigma) = \sum_{1 \leq i \leq u} 2^{i-1} \tau(I_\sigma, \mathbf{v}_i^*, \mathbf{v}_i^{**}). \quad (14)$$

BRIEF autoriai pateikė penkis būdus, kaip galima sudaryti binarinių testų aibę [63] (21 pav. parodytos atkarpos tarp taškų  $\mathbf{v}^*$  ir  $\mathbf{v}^{**}$ ):

- I)  $\mathbf{v}^*$  ir  $\mathbf{v}^{**}$  yra atsitiktinai sugeneruojami pagal tolygų skirstinį intervale  $\left[-\frac{S}{2}, \frac{S}{2}\right]$ ,
- II)  $\mathbf{v}^*$  ir  $\mathbf{v}^{**}$  yra atsitiktinai sugeneruojami pagal Gauso skirstinį  $\mu = 0$  ir  $\sigma = \frac{1}{25} S^2$ ,
- III)  $\mathbf{v}^*$  sugeneruojamas pagal Gauso skirstinį  $\mu = 0$  ir  $\sigma = \frac{1}{25} S^2$ , o  $\mathbf{v}^{**}$  yra sugeneruojamas pagal Gauso skirstinį  $\mu = \mathbf{v}^*$  ir  $\sigma = \frac{1}{100} S^2$  (taip gaunami lokalesni testai),
- IV)  $\mathbf{v}^*$  ir  $\mathbf{v}^{**}$  yra sugeneruojami pagal tolygų skirstinį polinėse koordinatėse,
- V)  $\forall i: \mathbf{v}_i^* = [0 \ 0]^T$ , o  $\mathbf{v}^{**}$  yra sugeneruojamas taip, kad kuo tolygiau užpildytų  $S$  skersmens apskritimą polinėse koordinatėse.

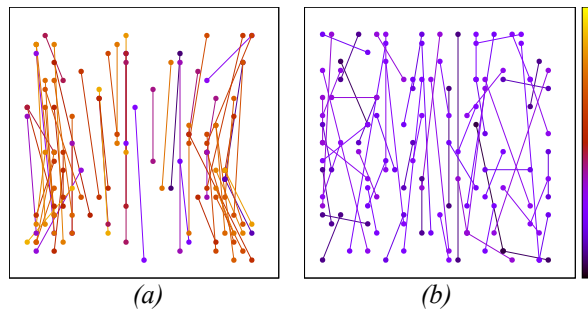
Straipsnyje parodyta [63], kad V būdas veikia prasčiausiai, o kitų būdų atpažinimo rodiklis (angl. *recognition rate*) skiriasi vos keliais procentais. ORB metodas naudoja antro būdo plėtinį. Kad BRIEF metodas būtų jautrus kryptčiai, ORB autoriai sugeneruotą testų aibę pritaiko skirtingoms kryptims, t. y. padaroma daug testų aibių, sukant tą pačią aibę 30 kartų kas  $12^\circ$ . Kas kartą sudaromas kontrolinio taško, surasto oFAST metodu, aprašo vektorius, pasirenkama testų aibė pagal to kontrolinio taško kampą  $\vartheta$ .



21 pav. Penki skirtingi būdai sugeneruoti binarinių testų aibę [63].

---

Taip pat ORB autoriai ieškojo tokios testų aibės, kuri užtikrintų kuo didesnę gaunamų vektorių dispersiją ir kuo mažesnę koreliaciją. Jie sugeneravo virš 200 tūkstančių testų aibių (anksčiau aprašytu II būdu), o iš jų išrinko geriausias naudodami PASCAL 2006 [67] duomenų bazės vaizdus, kuriuose rasta apie 300 tūkstančių kontrolinių taškų. Didžiausią dispersiją duodanti testų aibė pavaizduota 22(a) pav., kur atkarpos spalva rodo maksimalią testo koreliaciją. 22(b) pav. pavaizduota testų aibė su maža koreliacija.



22 pav. rBRIEF metodo binariniai testai: (a) su didžiausia dispersija; (b) su didele dispersija ir maža koreliacija [60].

Gavus pirminio ir tikslinio vaizdų kontrolinius taškus aprašančius vektorius rBRIEF metodu, jų atitikmenys randami LSH metodo plėtiniu [68], kuris dar tikrina ir grupės, į kurią patenka aprašo vektorius, kaimynus.


## 2.4 Medicininių vaizdų registravimas

Dažniausiai medicinoje vaizdų registravimas reikalingas norint palyginti skirtingomis priemonėmis arba skirtingu laiku gautus vaizdus tiriant tą patį pacientą (angl. *intrasubject registration*).

Pirmo atvejo pavyzdys gali būti kompiuterinės tomografijos ir echoskopijos vaizdų registravimas, kai iš pradžių padaroma geros kokybės kompiuterinė tomografija, paskui atliekant radijo-dažninę abliaciją ar kitokią procedūrą naudojami ultragarsu realiu laiku gaunami vaizdai [69]. Tai yra sudėtinga, nes tie patys kompiuterinės tomografijos ir echoskopijos audiniai vaizduojami visiškai kitaip, be to, ultragarsas itin sunkiai atkuria vaizdą, esantį už kaulo ([70], [69]). 23 pav. iliustruotas kompiuterinės tomografijos ir

echoskopijos vaizdų registravimas: (a) CT stuburo vaizdas (juoda linija pažymėtas kaulo paviršius iš vienos pusės); (b) tos pačios vietos ultragarsu gautas vaizdas; (c) ultragarsu gautas vaizdas, kur juoda linija nurodo iš CT vaizdo įvertintą kaulo paviršių.

Antruoju atveju registracija reikalinga palyginti prieš ir po gydymo gautiems vaizdams siekiant įvertinti gydymo sėkmingumą ar stebėti ligos progresą.



23 pav. Kompiuterinės tomografijos ir echoskopijos vaizdų registravimas [70].

Dar yra registruojami paciento duomenys su atlasu, paprastai kai norima automatiškai nustatyti vaizdo vietą kūno atžvilgiu.

Taip pat yra skirtingų dimensijų registravimas, dar vadinamas 2D / 3D registravimu, t. y. dvimatis vaizdas registruojamas su trimačiu (tomografiniu) vaizdu. Toks registravimas dar skirstomas į du tipus – projekcinės (dvimatės) nuotraukos ir trimačio vaizdo registravimas bei sluoksnio su tūriu (angl. *slice-to-volume*) registravimas [71]. Pirmuoju atveju vienas dvimatės nuotraukos pikselis rodo, kiek spindulių, einančių atitinkama kryptimi, sugeria audiniai, antruoju atveju vienas pikselis atitinka vieną vokselį (angl. *voxel*) trimačiame vaizde [72].

Medicininis vaizdų registravimas yra sudėtingesnis nei įprastų nuotraukų, nes medicininiai vaizdai turi mažiau išsiskiriančios tekstūros [71], todėl kai taikomi standartiniai požymiais grįsti registravimo metodai paprastai gaunami netikslūs rezultatai, nes kontrolinių taškų aprašų vektoriai per daug panašūs, kad



---

pavyktų surasti jų atitikmenis. Dėl to itin dažnai taikomas intensyvumu grįstas registravimas, pavyzdžiui, [71] apžvalgoje iš 87 aptartų straipsnių tik 8 naudoja požymiais grįstą registravimą.

R. Dalvi ir R. Abugharbieh [13] kontroliniams taškams rasti naudoja fazės kongruenciją (angl. *phase congruency*) [73], o taškų atitikmenų ieško ICP algoritmu.

Yra bandymų pritaikyti SIFT metodą medicininiam vaizdams iš pradžių juos segmentuojant, o tada taikant SIFT metodą segmentams atskirai – taip sumažinama atitikmenų paieškos sritis [74]. Apskritai segmentavimas dažnai taikomas prieš registravimą, nes segmento kontūrai gali būti naudojami ir registruojant, pavyzdžiui, [75] straipsnyje registruojami segmentų kontūrai, o segmentavimą atlieka radiologas rankiniu būdu, t. y. pažymi (apveda) norimą organą vaizde. Registruojant segmentų kontūrus galima rasti netgi elastingą transformaciją [76]. Be to, dvimates kreives įmanoma registruoti su trimačiu paviršiumi [77].

Vaizdų analizėje segmentavimas yra procesas, kai vaizdas dalijamas į segmentus (pikselių ar vokselių aibes). Pagrindiniai segmentavimo metodai yra morfologinės operacijos ([78]), slenksčio funkcija ([79]), „gyvačių“ metodai ([80], [81]), grafo pjūvio metodas ([82], [83]) ir kt.

J. Shi ir kiti pasiūlė plaučių navikų registravimo pagal šonkaulių išsidėstymą metodą [7]: pirmiausia segmentuojami šonkauliai, surandamos jų vidurio linijos, tada jie registruojami nustatant kiekvieno šonkaulio transformacijos matricą, galiausiai pagal poziciją šonkaulių atžvilgiu registruojami navikai. Šiuo atveju šonkauliai yra kaip stabilus atskaitos pagrindas. Apskritai kaulai dažnai naudojami registruojant vaizdus, pavyzdžiui, kontroliniams taškams rasti [84], todėl svarbus ir kaulų segmentavimas. Toliau detalizuota kaulų segmentavimo problema, taip pat šonkaulių formos modeliavimo galimybės.

### 2.4.1 Kaulų segmentavimas

Y. Kang ir kiti pasiūlė trijų žingsnių kaulų trimačio segmentavimo algoritmą [85]:

1. Taikomas globalaus ir adaptyvaus slenksčio mišinys, t. y. visi vokseliai, kurių reikšmė mažesnė už nustatytą žemutinį slenkstį, laikomi minkštaisiais audiniais, visi vokseliai, kurių reikšmė didesnė už nustatytą viršutinį slenkstį, laikomi kaulais, o vokselių, kurių reikšmės yra tarp žemutinio ir viršutinio slenksčių, audinys nustatomas pagal adaptyvų slenkstį:  $I(x) \begin{cases} < \mu - \alpha \cdot \sigma \Rightarrow \text{minkšt. a.} \\ \geq \mu + \alpha \cdot \sigma \Rightarrow \text{kaulas} \end{cases}$ , kur  $\mu$  ir  $\sigma$  yra vokselių intensyvumo vidurkis ir standartinis nuokrypis, atitinkamai,  $x$  aplinkoje (iš 26 kaimynų),  $\alpha$  yra konstanta, paprastai lygi 1. Žemutinis slenkstis nustatomas pagal CT vaizdo intensyvumo histogramą, viršutinis slenkstis lygus 400 HU.
2. Taikomas morfologinis uždarymas (angl. *morphological close*), tik tarp išplėtimo (angl. *dilate*) ir sutraukimo (angl. *erosion*) taikomas kontūro užpildymas, t. y. skylės, esančios kaule, pažymimos kaip kaulas. Morfologinės operacijos atliekamos trimatėje erdvėje, kontūro užpildymas – dvimatėje, t. y. visuose sluoksniuose.
3. Gauti segmentai trianguliuojami, randama 50 % intensyvumo vieta (slenkstis) suglotnintame intensyvumo profilyje, einančiame palei trikampio normalę, pagal surastą slenkstį pakoreguojamas trikampių paviršius.

Tame pačiame straipsnyje aprašytas dar ir kaulo segmentavimas į žievę (kietąją dalį) ir čiulpus [85].

Yra darbų, kur aprašomas vien tik šonkaulių segmentavimas, pavyzdžiui, [86]. Kadangi straipsnyje buvo nagrinėti kompiuterinės tomografijos vaizdai, kurių sluoksniai yra lygiagretūs skersinei žmogaus plokštumai, o jų dydis buvo  $512 \times 512$  pikselių, tad 256-ame (viduriniame, nes jų yra 512) tomografinio vaizdo skerspjuvyje pagal vertikalią plokštumą matomi tik šonkauliai, nėra

---

matomi nei stuburas, nei krūtinkaulis. Toliau šonkauliai sekami sluoksniuose pagal vertikalią plokštumą tiek viena, tiek kita kryptimi. Pereinant iš vieno sluoksnio į kitą šonkaulių ieškoma 50 pikselių atstumu, taip pat taikomas 20 pikselių atstumo ribojimas nuo plaučių, kurių vokselių intensyvumas yra nuo  $-900$  iki  $-500$  HU (segmentuojama taikant slenksčius). Kaulams surasti taikomas vienas 110 HU slenkstis. Reikėtų pastebėti, kad tokio segmentavimo neįmanoma pritaikyti vienam tomografinio vaizdo sluoksniui, lygiagrečiam skersinei žmogaus plokštumai.

#### 2.4.2 Šonkaulių aproksimavimas matematiniais modeliais

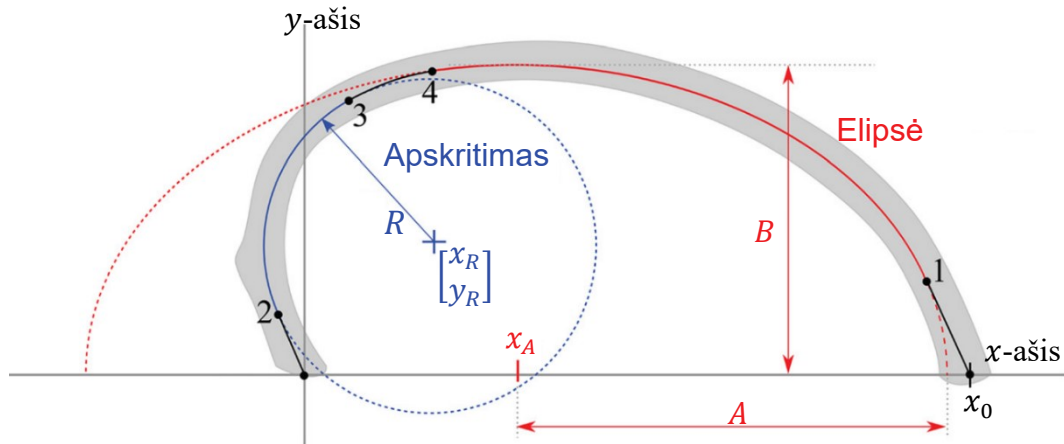
M. W. Kindig ir R. W. Kent pasiūlė vieno šonkaulio septynių parametru matematinį modelį, pagrįstą apskritimo ir elipsės dalimi [87]. Modelis yra dvimatis, todėl šonkaulis turi būti projektuojamas į plokštumą.

Iš pradžių randama šonkaulio centrinė linija, projekcinės plokštumos  $Ox$  ašis eina nuo proksimalinio (esančio arčiau stuburo) iki distalinio (esančio toliau nuo stuburo) šonkaulio galų, o  $Oy$  ašis parenkama taip, kad centrinės linijos taškų nuokrypis nuo plokštumos būtų kuo mažesnis. Centrinė šonkaulio linija projektuojama į šią plokštumą.

Modelį sudaro apskritimo dalis ir elipsės dalis, tarpusavyje sujungtos parabolės dalimi, o su abscisių ašimi – atkarpomis (žr. 24 pav.). Elipsės ilgoji ašis (angl. *major axis*) sutampa su projekcinės plokštumos  $Ox$  ašimi. Modeliui vienareikšmiai nusakyti reikalingi 7 parametrai:


- $x_0$  nurodo atstumą nuo proksimalinio iki distalinio šonkaulio galų,
- Taškas  $[x_R \ y_R]^T$  yra apskritimo centras,
- $R$  yra apskritimo spindulys,
- $x_A$  nurodo elipsės centro tašką  $[x_A \ 0]^T$ ,
- $A$  ir  $B$  nurodo elipsės dydį:  $A$  yra didysis pusašis (angl. *semi-major axis*),  $B$  yra trumpoji ašis (angl. *semi-minor axis*).

Šių septynių parametrų pakanka vienareikšmiai nusakyti matematinį modelį, nes taškai  $[x_1 \ y_1]^T$ ,  $[x_2 \ y_2]^T$ ,  $[x_3 \ y_3]^T$  ir  $[x_4 \ y_4]^T$  randami taip, kad juose išvestinės sutaptų.



24 pav. Septynių parametrų šonkaulio matematinis modelis plokštumoje [87].

S. A. Holcombe ir kiti pasiūlė vieno šonkaulio šešių parametrų matematinis modelį, pagrįstą logaritminėmis spiralėmis [8]. Modelis yra dvimatis, todėl šonkaulis turi būti projektuojamas į plokštumą. Koordinačių sistema pasirenkama taip pat kaip ir [87] straipsnyje.



25 pav. Šešių parametrų šonkaulio matematinis modelis plokštumoje [8].

Modelį sudaro du logaritminių spiralių segmentai (žr. 25 pav.) – proksimalinė dalis ir distalinė dalis. Modelio parametrai:

- 
- $S_x$  parametras yra atstumas tarp šonkaulio galų, šis parametras nusako ir bendrą mastelį. Visi kiti parametrai normalizuojami taip, kad šonkaulio distalinio taško (galo, esančio toliau nuo stuburo) koordinatės yra (1; 0),
  - $X_{Pk}$  ir  $Y_{Pk}$  nurodo šonkaulio aukščiausią tašką modelio koordinačių sistemoje (25 pav. pažymėtas žaliu trikampiu),
  - $\phi_{pia}$  yra kampas, kurį šonkaulio proksimalinis galas sudaro su  $x$  ašimi,
  - $B_p$  yra proksimalinės dalies spiralės laipsnis,
  - $B_d$  yra distalinės dalies spiralės laipsnis.


Gaunamas matematinis modelis gerai nusako šonkaulį plokštumoje, kuri eina per šį šonkaulį, bet nėra lygiagreti žmogaus skersinei plokštumai. Todėl kompiuterinės tomografijos vaizdams lyginti jis nėra tiesiogiai taikytinas.

### 2.4.3 Sluoksnių registravimas su atlasu

Emrich ir kiti bandė nustatyti bet kokio kompiuterinės tomografijos vaizdo sluoksnio, lygiagretaus žmogaus skersinei plokštumai, poziciją žmogaus vertikalioje ašyje [4]. Metodas parametrizuoja sluoksnį vektoriumi, sudaroma sistema, kuri apmokoma su turimais duomenimis, t. y. daugiau nei 10 tūkstančių sluoksnių su savo pozicija. Ši sistema, veikianti artimiausių kaimynų principu, sluoksnio vektoriui suteikia poziciją žmogaus vertikalioje ašyje, t. y. apmokyta sistema veikia kaip žmogaus atlasas.


Prieš parametrizavimą vaizdas suskaidomas į 25 dalis, kaip parodyta 26(a) pav., toliau parametrizuojami 26 vaizdai – pats vaizdas ir 25 jo dalys atskirai. Taip pat iš pradžių dar galima išskirti dominančią sritį (angl. *range of interest, ROI*) ir tada suskaidyti vaizdą, kaip parodyta 26(b) pav. Taip gaunamas dar kitoks parametrizavimas. [4] straipsnyje pasiūlyti du vaizdo dalių parametrizavimo būdai. Pirmasis išskiria Haralick tekstūros požymius (angl. *Haralick texture features*) [88] su 5 skirtingais atstumais tarp pikselių, taip

gaunamas  $(25 + 1) \cdot 13 \cdot 5 = 1690$  ilgio vektorius. Antras vaizdo dalių parametrizavimo būdas yra gradiento kampų histograma iš 8 intervalų, kur gradientas skaičiuojamas tik kontūrų pikseliuose, išskirtuose Canny kraštų nustatymo algoritmu [89] su slenksčiais, lygiais 0. Taip gaunamas  $(25 + 1) \cdot 8$  ilgio vektorius.



26 pav. Piramidinis branduolys iš 25-ių regionų: (a) pritaikytas visam slauksnio vaizdui; (b) pritaikytas tik dominančiai sričiai [4].

Straipsnyje [4] eksperimentiškai tirti keturi atvejai – du parametrizavimo būdai su ir be dominančios srities nustatymu, taip pat tirtos šių atvejų kombinacijos. Visais atvejais taikyta pagrindinių komponentių analizė (angl. *principal component analysis, PCA*) [90]. Nustatyta, kad geriausi rezultatai (mažiausia paklaida) gaunami su jungtiniu vektoriumi, nustatytu iš kampų histogramos, Haralick tekstūros požymių su dominančios srities nustatymu ir Haralick tekstūros požymių be dominančios srities nustatymo. Taip gauta vidutinė 2,83 cm paklaida, kai žmogaus ūgis normalizuotas į 180 cm.



27 pav. Vaizdo suskaidymas pagal spindulius [5].

Straipsnyje [4] aprašytas algoritmas buvo pirmasis, kuriame buvo sprendžiama vieno slauksnio pozicijos paieškos problema. Ankstesniuose darbuose, pavyzdžiui, [91], aprašyti metodai galėjo rasti tik tam tikro tūrio, t. y.

---

visos eilės sluoksnių, poziciją. Būtent gebėjimas dirbti tik su vienu sluoksniu pabrėžiamas ir [4], ir [5] straipsniuose. Vėlesniame darbe [5] ši problema sprendžiama panašiu principu – vaizdas suskaidomas į dalis, tada jos atskirai parametrizuojamos. Pirmiausia vaizdo mastelis unifikuojamas pagal DICOM metaduomenis, kad pikselio dydis būtų 1,5 mm. Tada sluoksnyje randama dominantanti sritis (27 pav. pavaizduota raudonu stačiakampiu) ir nustatomas jos apibrėžtinis apskritimas. Vaizdas suskaidomas apskritimais (į kiautus) ir kampais (į sektorius), kaip parodyta 27 pav., geriausias (duodantis mažiausią paklaidą) kiautų ir sektorių kiekis nustatytas eksperimentais.

Vaizdų dalys parametrizuojamos skaičiuojant kaulinio ir minkštųjų audinių pasiskirstymą (kiautų ir sektorių kiekis skiriasi abiem atvejais). Pirmuoju atveju skaičiuojamas pikselių, kurių ryškumas yra didesnis nei 500 HU, kiekis, antruoju atveju – pikselių, kurių ryškumas yra mažesnis už –300 HU, kiekis. Pagal kaulų išsidėstymą išoriniai kiautai yra svarbesni už vidinius, todėl kaulinio audinio pikselių kiekis dauginamas iš kiauto indekso kvadrato (kiautai indeksuojami nuo vidurio pradedant 1). Minkštuosius audinius vaizduojančių pikselių kiekis yra dauginamas iš konstantos, lygios kiautų kiekio kvadratumui. Taigi viena vaizdo dalis aprašoma dviem skaičiais; viso sluoksnio aprašas yra visų vaizdo dalių, aprašančių vektorių, junginys. Galiausiai bendro vektoriaus dimensijų skaičius sumažinamas iki 50 naudojant pagrindinių komponentų analizę.

Lokalizuojant sluoksnį ieškomas tam tikras skaičius artimiausių įrašų tarp mokomųjų duomenų taip, kad kiekvienas įrašas būtų vis iš kito paciento, iš gautų reikšmių išvedamas vidurkis.

Vidutinė šiuo metu pasiekta paklaida yra  $\varepsilon_{mean} = 1,8$  cm, paklaidos standartinis nuokrypis  $\sigma = 2,81$  cm. Straipsnyje nėra minima, kokia yra registravimo paklaida, kai tomografija atliekama suleidus pacientui kontrastingę medžiagą.

Sluoksnių deskriptoriai, gauti [5], įdėti į Kalifornijos universiteto mašininio mokymosi talpyklą [92]. [6] buvo tirti šie duomenys naudojant difuzinius metodus (angl. *diffusion methods* [93]), tačiau straipsnyje gauta paklaida pateikta procentais  $0,9146 \% \pm 0,6314 \%$ .

## 2.5 Antro skyriaus išvados

1. Projekcinė radiografija ir kompiuterinė tomografija – ypač populiarios diagnostikos priemonės, leidžiančios be chirurginės intervencijos stebėti žmogaus organizmo pokyčius ir pasirinkti tinkamiausią gydymo strategiją. Kompiuteriniu tomografu gaunamos tiriamosios srities trimatės rekonstrukcijos, t. y. skersinio pjūvio dvimačiai vaizdai, todėl lengvai diferencijuojami pacientų audiniai ir organai.
2. Analizuojant projekcinės radiografijos 2D vaizdus ar kompiuterinės tomografijos 3D vaizdus susiduriama su vaizdų segmentavimo problema. Segmentavimas leidžia išskirti objektus, esančius vaizde. Tinkamo segmentavimo metodo pasirinkimą lemia sprendžiamas vaizdo analizės uždavinys ir kiek yra laiko sprendimui priimti. Segmentavimas dažnai taikomas prieš registravimą, nes segmento kontūrai gali būti naudojami registruojant. Sudėtingesniais atvejais segmentavimą atlieka radiologas rankiniu būdu, t. y. pažymi (apveda) norimą organą vaizde.
3. Medicininiuose vaizduose kontūrų paieška yra paprastesnė nei įprastose nuotraukose, nes medicininiai vaizdai gaunami dažniausiai stacionaria ar pusiau stacionaria įranga, kur pašaliniai faktoriai daro mažesnę įtaką atskiro pikselio ar vokselio reikšmei.
4. Norint palyginti ar sujungti vaizdus, gautus skirtingu metu, skirtingais įrenginiais ar skirtingais įrenginių nustatymais taikomi vaizdų registravimo metodai. Tai procesas, kai skirtingi vaizdai transformuojami į vieną koordinačių sistemą. Medicininiai vaizdai



---

paprastai turi mažiau išsiskiriančios tekstūros, todėl daug dažniau taikomi intensyvu grindžiami registravimo metodai.

5. Siekiant tikslių analizės rezultatų segmentuoti ir atskiriems organams aprašyti naudojami ir matematiniai modeliai. Matematiniai modeliai leidžia gan paprastomis kreivėmis aproksimuoti kontūrus, nusakančius tiriamus vidaus organus. Matematiniai modeliai – tai tematika, kuriai plėtoti dabar atsiranda daugiau skaičiuojamųjų galimybių, nes sprendžiami aproksimavimo uždaviniai, kurie kartais būna gana sudėtingi.
6. Didėjant kompiuterinės tomografijos prieinamumui, kyla kompiuterinės tomografijos vaizdų saugojimo ir paieškos problemos. DICOM standartu aprašytų vaizdų metaduomenys kartais būna netikslūs ir jais negalima remtis vaizdams lyginti. Tikslesni sprendimai gaunami lyginant sluoksnius, lygiagrečius žmogaus skersinei plokštumai, skirtinguose kompiuterinės tomografijos vaizduose ir ieškoma tų sluoksnių vieta žmogaus vertikaloje ašyje.



# 3

## Šonkauliais apriboto kontūro aproksimavimas matematiniais modeliais

Šiame skyriuje pasiūlytas matematinis modelis, aproksimuojantis šonkauliais ribojamą sritį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame žmogaus skersinei plokštumai. Taip pat jis leidžia įvertinti paciento posūkį pagal vertikalią ašį tomografijos atlikimo metu.

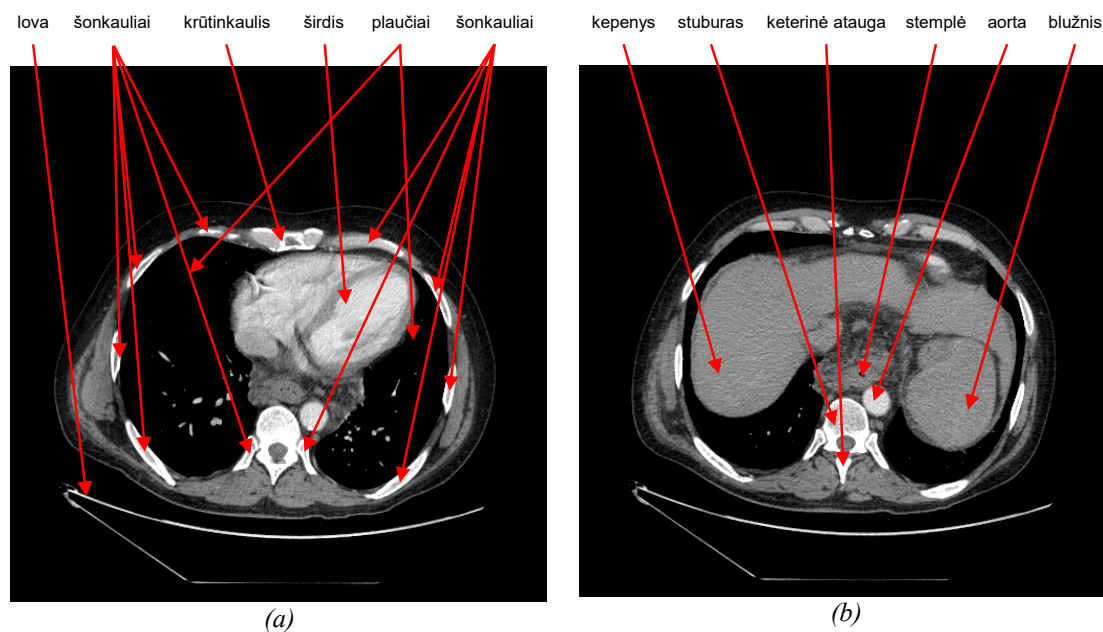
Sluoksnyje galima pastebėti nekintančią struktūrą (28 pav.), į kurią turi būti atsižvelgta sudarant modelį:

- šonkaulių simetrija žmogaus sagitalinės plokštumos atžvilgiu,
- krūtinės skersinis pjūvis yra labiau „suspaustas“ vertikaliai nei horizontaliai,
- kūno posūkis lovos atžvilgiu,
- aorta prie stuburo,
- didelis pikselių, vaizduojančių kaulus, intensyvumas,
- lova,
- šviesios kraujagyslės (jeigu pacientui suleista kontrastinė medžiaga).

Modelio aproksimavimas susideda iš dviejų etapų:

1. Šonkaulių, krūtinkaulio ir stuburo segmentavimo vaizde,
2. Šonkauliais apriboto kontūro aproksimavimo matematine funkcija.

Disertacijoje nagrinėjami  $512 \times 512$  pikselių dydžio sluoksniai, gauti GE LightSpeed Pro 32 tomografu<sup>13</sup>. Juo gaunami 16 bitų DICOM pilkos skalės vaizdai. Vaizdai automatiškai tiesiškai normalizuoti į intervalą  $[0; 255]$  pagal lango centrą 40 HU ir lango plotį 350 HU (Hounsfield matavimo vienetų).



28 pav. Sluoksnių turinys: (a) skerspjūvis ties širdimi, (b) skerspjūvis ties kepenimis.

### 3.1 Šonkaulių, krūtinkaulio ir stuburo segmentavimas

Dažniausiai literatūroje, kurioje aptariami CT vaizdų analizės metodai, minimi trimačiai kaulų segmentavimo metodai. Šiame darbe siekiama registruoti dvimačius sluoksnius. Trimačio kaulų segmentavimo metodą pritaikyti dvimačiams vaizdams yra labai problemiška. Taip pat retai literatūroje aptariami metodai, galintys segmentuoti kaulus vaizduose, gautuose suleidus pacientams kontrastinę medžiagą. Tai labai apsunkina segmentavimą, nes kontrastinė medžiaga taip išryškina kraujagysles ir širdį, kad jos atrodo ryškesnės už kaulų čiulpus.

Sluoksnyje gali matytis lova, ant kurios guli pacientas. Ją būtina pašalinti iš vaizdo pačioje segmentavimo pradžioje. Lova visada yra apačioje, ji atrodo

<sup>13</sup>[http://www3.gehealthcare.com/en/products/categories/goldseal\\_-\\_refurbished\\_systems/goldseal\\_computed\\_tomography/goldseal\\_vct\\_series](http://www3.gehealthcare.com/en/products/categories/goldseal_-_refurbished_systems/goldseal_computed_tomography/goldseal_vct_series)

---

kaip siaura linija, aplink ją visada yra juodo fono. Todėl pirmiausia taikomas slenkstis – parenkami visi ne juodi pikseliai (kurių reikšmė yra didesnė už 0), gaunamas binarinis vaizdas išplečiamas (morfologine operacija išplėtimu, angl. *dilation* [94]) su branduoliu, kurio spindulys yra 2, nes lovos linija gali atrodyti nerišli kampuose. Tada surandamas žemiausias vaizdo pikselis, kurio reikšmė lygi 1, ir surandamas jam rišlus baltas vaizdo komponentas (angl. *blob*). Jeigu šis komponentas nėra pats didžiausias rišlus komponentas sluoksnyje, jis pašalinamas iš pradinio sluoksnio – pradiniam vaizde toje srityje pikselių reikšmės prilyginamos nuliui. Rišlus vaizdo komponentas yra pikselių grupė, kurios visi pikseliai yra tokios pačios spalvos ir kiekvienas jo pikselis kaimynystėje turi bent vieną tokios pačios spalvos pikselį. Kaimynystė yra grupė pikselių, turinčių bendrą briauną.

Kadangi CT vaizduose vokselio reikšmė tiesiogiai priklauso nuo medžiagos, kurią vokselis vaizduoja, ypatybių, tankias medžiagas, tokias kaip kaulai, galima segmentuoti taikant slenkstį. [85] pateiktas kaulų segmentavimo metodas (aprašytas 2.4.1 punkte) su adaptyviu slenkščiu. Taip gaunamas binarinis vaizdas, kurio kiekvieno pikselio ar vokselio reikšmė yra 0 arba 1 ir kuris vaizduojamas juoda ir balta spalvomis: balta spalva atitinka 1.

Tiesiogiai taikant slenkstį CT vaizdams gaunama daug triukšmo (ypač jeigu tiriami prastos kokybės vaizdai) – daug mažų baltų taškų arba dryžių 29(a) pav. Šį triukšmą paprasčiausia panaikinti suglotninant vaizdą dar prieš taikant slenkstį. Kad būtų išsaugoti kontūrai, naudojamas bilateralinis filtras (angl. *bilateral filter*, [95]).

Pritaikius slenkstį vaizde dar gali likti baltų pikselių, vaizduojančių kraują, jeigu tomografija atlikta pacientui suleidus kontrastinę medžiagą, ar bet kokie metaliniai implantai, jeigu tokių buvo žmogaus kūne, o kaulų, turinčių korėtosios medžiagos, vidus gali likti juodas. Kaulo korėtosios dalies segmentavimo problema trimačiu atveju [85] straipsnyje išspręsta morfologinių operacijų seka: išplėtimas, kontūro užpildymas ir sutraukimas. Kontūro užpildymo metu juodų pikselių, esančių rišlaus balto komponento viduje (t. y.

juodi pikseliai, apsupti baltų pikselių iš visų pusių), reikšmės priskiriamos 1 (nuspalvinami baltai). Kitaip tariant, kontūro užpildymas yra skylių nuspalvinimas. Dvimačiu atveju toks metodas nėra tinkamas, nes užpildomos natūralios skylės, pavyzdžiui, stuburo kanalas. Stuburui, šonkauliams ir krūtinkauliui šią problemą galima išspręsti taikant dvigubą slenkstį: gaunamas binarinis vaizdas su aukštesniu slenksčiu, jo skylės užpildomos, tada tarp jo ir kito binarinio vaizdo, gauto su žemesniu slenksčiu, taikomas IR loginis operatorius [96]. Loginio operatoriaus IR rezultato vaizde pikselio reikšmė yra 1 tada ir tik tada, kai abiejų operandų-vaizdų pikselių reikšmės atitinkamose vietose yra 1. Šiame darbe darytuose eksperimentuose žemesnis slenkstis nustatytas 130 lygiu (atitinka 95 HU), o aukštesnis – 170 (atitinka 165 HU), gauto rezultato pavyzdys pateiktas 29(b) pav.

Po šių operacijų dar reikia binariniame vaizde atpažinti ir paslėpti kraujagysles. Pirmiausia vaizdas stipriai sutraukiamas, naudojant branduolį, kurio spindulys yra 7 – taip vaizde lieka tik objektai, storesni kaip 14 pikselių (12,5 – 14 mm), t. y. stuburas (jeigu sluoksnio skerspjūvis yra ne tarp stuburo slankstelių), aorta, širdis ir krūtinkaulis. Surandama dominanti sritis – viršus ir apačia. Širdies vaizdą sudaro balti komponentai, rišlūs su sritimi, esančia 40 pikselių žemiau dominančios srities (*ROI*) viršaus, bet virš *ROI* vidurio (vaizde gali būti matomi atskiri skilveliai). Šie rišlūs komponentai pašalinami iš nesutraukto binarinio vaizdo.

Aortą atpažinti sunku, ji dažnai gali atrodyti prilipusi prie stuburo. Ji surandama skaičiuojant anksčiau sutraukto vaizdo atstumo transformaciją (angl. *distance transform*, [78], 29(c) pav. pateiktas sutraukto vaizdo atstumo transformacijos pavyzdys, kai širdis paslėpta) ir ieškant lokalių maksimumų, kurių reikšmės didesnės už 3 ir mažesnės už 9, o rišlauso komponento, kuriame yra atitinkamas maksimumas, plotas ne didesnis kaip 200 pikselių. Jeigu tokio maksimumo nėra, tai nėra ir matomos aortos arba ji yra siaura tame sluoksnyje, todėl negali būti prie pat stuburo. Lokalus maksimumas, esantis arčiausiai atitinkamo rišlauso komponento masės centro, nurodo aortos centrą. Atstumo

---


transformacijos maksimumo reikšmės 3 ir 9 reiškia 6 – 18 pikselių skersmens komponentą ir atitinka 20 – 32 pikselių skersmens komponentą nesutrauktame vaizde, o šis atitinka 18 – 29 mm objektą. Jeigu atstumo transformacijos lokalus maksimumas yra arti rišlaus komponento masės centro, tai komponentas yra simetriškas taško atžvilgiu.

Jeigu aorta matoma, ją reikia atskirti nuo stuburo (jei ji neprilipusi prie šio). Iš naujo skaičiuojama nesutraukto vaizdo (gauto po širdies paslėpimo) atstumo transformacija. Atstumo transformacijoje 40 pikselių spinduliu nuo aortos centro (bet ne pačioje aortoje, nes aorta gali turėti kelis lokalius maksimumus) ieškoma lokalių maksimumų – didžiausias nurodo stuburo centrą. Tada skaičiuojama vidurio ašies transformacija (angl. *medial axis transform*; 29(d) pav. parodytas sluoksnio vidurio ašies transformacijos pavyzdys [97]), ieškomas kelias nuo aortos centro iki stuburo centro. Jeigu tokio kelio nėra, aorta nėra prigludusi prie stuburo. Jeigu toks kelias yra, surandamas jo taškas su mažiausia vidurio ašies transformacijos reikšme  $r$  (jeigu yra keli taškai su mažiausia reikšme, pasirenkamas tas, kuris arčiau aortos) ir nuo to taško atstumu  $r$  visi pikseliai binariniame vaizde nuspalvinami juodai (t. y. nupiešiamas juodas skritulys). Taip atskiriama aorta nuo stuburo. Atskyrus aortą, patikrinama jos forma, t. y. didžiausias spindulys nuo jos vidurio (atstumo transformacijos maksimumo). Jeigu jis  $\sqrt{2}$  ar daugiau kartų didesnis už minimalų aortos spindulį, pakitimai ( $r$  spindulio skritulys) atstatomi atgal. Šis patikrinimas reikalingas todėl, kad jeigu sluoksnyje nėra matomos aortos, gali būti pasirinkta ir atskirta kita niekuo nesusijusi su aorta vieta.

Galiausiai lieka šonkauliai, išsidėstę pagal vaizdo išorinį apvaskalą (angl. *convex hull*; [98]), stuburas ir krūtinkaulis, o visi kiti matomi objektai turi būti viduje. Taigi galutiniame binariniame vaizde paliekami tik tie balti komponentai, kurie yra rišlūs su:

- išoriniu apvaskalu,
- 15 pikselių juosta *ROI* viršuje (krūtinkauliui) ir

- 80 pikselių aukščio ir pusė *ROI* pločio lygiašonių trikampių *ROI* apačioje (stuburui).



29 pav. Kaulinio audinio segmentavimas: (a) slenkstis pritaikytas nesuglotnintai funkcijai, (b) dvigubas slenkstis pritaikytas suglotnintai funkcijai, (c) sutraukto binarinio vaizdo atstumo transformacija, (d) nesutraukto binarinio vaizdo vidurio ašies transformacija, (e) binarinis vaizdas, kuriam rišlūs komponentai paliekami galutiniame rezultate, (f) galutinis rezultatas.

Visi šie komponentai pavaizduoti 29(e) pav. Galutinis rezultatas pavaizduotas 29(f) pav. A priede pateiktas viso algoritmo programinis kodas C# kalba su paaiškinimais.

Algoritmas nėra itin jautrus savo parametrų (morfologinių operacijų branduolio spinduliams ir pan.), pakeitus juos  $\pm 30\%$  jis vis dar veikia patikimai su suaugusiųjų pacientų tomografiniais vaizdais ir yra pritaikytas vaizdams, kurių pikselių dydis yra nuo 0,9 – 1 mm. Pateiktame algoritme išskirtinai nenumatyta mentės paieška sluoksnyje.

Dėl paprastumo formulėse toliau šiame darbe sluoksnio indeksas praleistas, o vieno sluoksnio kaulinį audinį vaizduojančių pikselių aibė žymima  $\mathbf{B} = \{\mathbf{b}_i = [b_{1i} \quad b_{2i}]^T, i = \overline{1, m}\}$ , kur  $m$  yra šių pikselių kiekis sluoksnyje.




## 3.2 Šonkauliais apriboto kontūro aproksimavimas

### 3.2.1 Matematinio modelio sudarymas

Šonkaulių skersinis pjūvis sudaro formą (28 pav.), panašią į kardioidę:

$$\rho(\varphi) = 1 + \cos(\varphi - \pi/2), \quad \varphi \in \left[-\frac{\pi}{2}; \frac{3\pi}{2}\right), \quad (15)$$

čia  $\rho(\varphi)$  yra spindulys, o  $\varphi$  yra kampas polinėje koordinačių sistemoje. (15) kreivė yra pavaizduota 30 pav. (mėlyna linija). Kardioidė atrodo panaši, nes turi įdubą, ši gali būti panaudota aproksimuoti šonkaulių formą šalia stuburo. (15) kreivė yra pasukta  $\pi/2$  lyginant su standartinė kardioidė, nes pastarosios įduba yra iš dešinės pusės.



30 pav. Kardioidės: mėlyna linija – standartinė, raudona ir žalia linijos – kreivės su  $s = 0,5$  ir  $s = 0,3$  atitinkamai.

28 pav. galima matyti, kad šonkauliais apribotas kontūras yra labiau suspaustas vertikaliai nei standartinės kardioidės. Problema išsprendžiama, kai pridedamas optimizuojamas parametras – laipsnis  $s$ :

$$\rho(\varphi) = \left(1 + \cos\left(\varphi - \frac{\pi}{2}\right)\right)^s. \quad (16)$$

Parametras  $s$  daro įtaką ne tik vertikaliam kreivės masteliui, bet ir bendrai formai (30 pav. parodytos kreivės su skirtingais  $s$  laipsniais).

CT sluoksnyje dar matoma kontūro įduba ties krūtinkauliu, (16) kreivė šioje srityje yra išgaubta. Prie (16) modelio pridedamas  $\rho^+$ , kurio forma gali kisti priklausomai nuo įdubos:

$$\rho(\varphi) = \left(1 + \cos\left(\varphi - \frac{\pi}{2}\right)\right)^s - \rho^+(\varphi). \quad (17)$$

Šis narys suformuoja įdubą atimdamas tam tikrą reikšmę iš (16) modelio pradedant  $\varphi = \pi/2 - \beta$  ir baigiant  $\varphi = \pi/2 + \beta$ .  $\beta$  yra kampas, nurodantis atėmimo intervalą.

Funkcijos  $\rho^+(\varphi)$  apibrėžimo sritis yra  $[\pi/2 - \beta; \pi/2 + \beta]$ , taip pat funkcija privalo pasižymėti šiomis ypatybėmis:

1. Būti unimodali neneigiama funkcija nuo  $\varphi$  ir pasiekti maksimalią reikšmę, kai  $\varphi = \pi/2$ ,
2. Būti simetrine funkcija  $\varphi = \pi/2$  atžvilgiu,
3. Būti lygi 0, kai  $\varphi \leq \pi/2 - \beta$  ir  $\varphi \geq \pi/2 + \beta$ ,
4. Turėti pirmo ir antro laipsnio išvestines pagal  $\varphi$ , lygias 0, kai  $\varphi = \pi/2 - \beta$  ir  $\varphi = \pi/2 + \beta$ .


Pirmos dvi ypatybės užtikrina, kad modelis yra simetriškas, antros dvi – kad modelis yra tolydus.

Funkcija  $\rho^+(\varphi)$  galėtų būti tokia:

$$\rho^+(\varphi) = \begin{cases} c \sin^l(\pi(\varphi - \pi/2 + \beta)/2\beta), & \text{kai } \beta > |\varphi - \pi/2| \\ 0, & \text{kitu atveju.} \end{cases} \quad (18)$$

(18) funkcijoje yra trys parametrai, kontroliuojantys įdubos ties krūtinkauliu formą:  $\beta$  yra kampas, nurodantis atėmimo intervalą,  $l$  yra kreivės, nusakančios įdubą, statusas,  $c$  yra neneigiamas daugiklis, nurodantis atėminio dydį; jeigu  $c = 0$ , gaunamas toks pat kaip ir (16), t. y. be įdubos ties krūtinkauliu.

31 pav. pateikti  $\rho^+$  pavyzdžiai su skirtingomis  $\beta$  ir  $l$  reikšmėmis.



31 pav. Funkcijos  $\rho^+$  priklausomybė nuo  $\varphi \in [-\pi/2; 3\pi/2)$ , abiem atvejais  $c = 1$ .

Toliau pateikiami įrodymai, kad (18) tenkina aukščiau išvardytas keturias ypatybes.

**Teiginys 1.** Tegul  $l \geq 2$  ir  $\beta \geq 0$ .  $\rho^+(\varphi)$  yra unimodali neneigiama funkcija nuo  $\varphi$  ir jos reikšmė pasiekia maksimumą, kai  $\varphi = \pi/2$ .

**Įrodymas.** Funkcija  $\rho^+(\varphi)$  turi būti monotoniškai didėjanti, kai  $\varphi < \pi/2$ , ir monotoniškai mažėjanti, kai  $\varphi > \pi/2$ , taip pat išvestinė taške  $\varphi = \pi/2$  turi būti lygi 0.

$$\frac{d\rho^+}{d\varphi} = \begin{cases} cl \sin^{l-1} \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) \cos \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) \frac{\pi}{2\beta}, & \text{kai } \beta \geq |\varphi - \pi/2| \\ 0, & \text{kitu atveju.} \end{cases} \quad (19)$$

Lygybė  $\frac{d\rho^+}{d\varphi} = 0$  galioja keturiais atvejais:

1.  $\sin^{l-1} \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) = 0$  tada, kai  $\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} = t\pi, t \in \mathbb{Z} \rightarrow \varphi = \frac{\pi}{2} - \beta + 2t\beta, t \in \mathbb{Z}$ ,
2.  $\cos \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) = 0$  tada, kai  $\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} = \frac{\pi}{2} + t\pi, t \in \mathbb{Z} \rightarrow \varphi = \frac{\pi}{2} + 2t\beta, t \in \mathbb{Z}$ ,
3.  $\varphi > \frac{\pi}{2} + \beta$ ,
4.  $\varphi < \frac{\pi}{2} - \beta$ .

Iš šių atvejų gaunama: jei  $\beta \geq \left| \varphi - \frac{\pi}{2} \right|$ , t. y.  $\varphi \in \left[ \frac{\pi}{2} - \beta; \frac{\pi}{2} + \beta \right]$ , tai  $\frac{d\rho^+}{d\varphi} = 0$  tik tada, kai  $\varphi = \frac{\pi}{2} - \beta$ ,  $\varphi = \frac{\pi}{2}$  ir  $\varphi = \frac{\pi}{2} + \beta$ .

$\rho^+(\varphi)$  yra monotoniškai didėjanti funkcija intervale  $\varphi \in \left(\frac{\pi}{2} - \beta; \frac{\pi}{2}\right)$ , nes šiame intervale  $\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \in \left(0; \frac{\pi}{2}\right) \rightarrow \sin\left(\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta}\right) \in (0; 1)$  ir  $\cos\left(\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta}\right) \in (0; 1)$ , todėl  $\frac{d\rho^+}{d\varphi} > 0$ , kai  $\varphi \in \left(\frac{\pi}{2} - \beta; \frac{\pi}{2}\right)$ .  $\rho^+(\varphi)$  yra monotoniškai mažėjanti funkcija intervale  $\varphi \in \left(\frac{\pi}{2}; \frac{\pi}{2} + \beta\right)$ , nes šiame intervale  $\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \in \left(\frac{\pi}{2}; \pi\right) \rightarrow \sin\left(\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta}\right) \in (0; 1)$  ir  $\cos\left(\frac{\pi(\varphi - \pi/2 + \beta)}{2\beta}\right) \in (-1; 0)$ , todėl  $\frac{d\rho^+}{d\varphi} < 0$ , kai  $\varphi \in \left(\frac{\pi}{2}; \frac{\pi}{2} + \beta\right)$ .

Kadangi  $\rho^+(\varphi) = 0$ , kai  $\beta < |\varphi - \pi/2|$ , t. y.  $\varphi \notin \left[\frac{\pi}{2} - \beta; \frac{\pi}{2} + \beta\right]$ , tai  $\rho^+(\varphi)$  yra unimodali ir jos reikšmė pasiekia maksimumą, kai  $\varphi = \pi/2$ . ■

**Teiginys 2.** Tegul  $l \geq 2$  ir  $\beta \geq 0$ .  $\rho^+(\varphi)$  yra simetriška funkcija taško  $\varphi = \frac{\pi}{2}$  atžvilgiu.

**Įrodymas.** Simetriška funkcija taško  $\varphi = \frac{\pi}{2}$  atžvilgiu reiškia, kad  $\rho^+\left(\frac{\pi}{2} - \varphi\right) = \rho^+\left(\frac{\pi}{2} + \varphi\right)$ .

Reikšmė  $\rho^+\left(\frac{\pi}{2} - \varphi\right)$  gali būti suprastinta:

$$\begin{aligned} \rho^+\left(\frac{\pi}{2} - \varphi\right) &= \begin{cases} c \sin^l\left(\frac{\pi(\pi/2 - \varphi - \pi/2 + \beta)}{2\beta}\right), & \beta \geq \left|\frac{\pi}{2} - \varphi - \frac{\pi}{2}\right| \\ 0, & \text{kitu atveju} \end{cases} \\ &= \begin{cases} c \sin^l\left(\frac{\pi(\beta - \varphi)}{2\beta}\right), & \beta \geq |-\varphi| \\ 0, & \text{kitu atveju} \end{cases} = \begin{cases} c \sin^l\left(\frac{\pi}{2} - \frac{\pi\varphi}{2\beta}\right), & \beta \geq |-\varphi| \\ 0, & \text{kitu atveju} \end{cases} \\ &= \begin{cases} c \cos^l\left(-\frac{\pi\varphi}{2\beta}\right), & \beta \geq |-\varphi| \\ 0, & \text{kitu atveju} \end{cases} = \begin{cases} c \cos^l\left(\frac{\pi\varphi}{2\beta}\right), & \beta \geq |\varphi| \\ 0, & \text{kitu atveju,} \end{cases} \end{aligned}$$

o tokia pati reikšmė gaunama ir suprastinant reiškinį

$$\begin{aligned}
\rho^+ \left( \frac{\pi}{2} + \varphi \right) &= \begin{cases} c \sin^l \left( \frac{\pi(\pi/2 + \varphi - \pi/2 + \beta)}{2\beta} \right), & \beta \geq \left| \frac{\pi}{2} + \varphi - \frac{\pi}{2} \right| \\ 0, & \text{kitu atveju} \end{cases} \\
&= \begin{cases} c \sin^l \left( \frac{\pi(\beta + \varphi)}{2\beta} \right), & \beta \geq |\varphi| \\ 0, & \text{kitu atveju} \end{cases} = \begin{cases} c \sin^l \left( \frac{\pi}{2} + \frac{\pi\varphi}{2\beta} \right), & \beta \geq |\varphi| \\ 0, & \text{kitu atveju} \end{cases} \\
&= \begin{cases} c \cos^l \left( \frac{\pi\varphi}{2\beta} \right), & \beta \geq |\varphi| \\ 0, & \text{kitu atveju.} \end{cases} \quad \blacksquare
\end{aligned}$$

**Teiginys 3.** Tegul  $l \geq 2$  ir  $\beta \geq 0$ .  $\rho^+(\varphi)$  yra lygi 0, kai  $\varphi \leq \pi/2 - \beta$  ir  $\varphi \geq \pi/2 + \beta$ .

Irodyta kartu su pirmu teiginiu.

**Teiginys 4.** Tegul  $l \geq 2$  ir  $\beta \geq 0$ .  $\rho^+(\varphi)$  pirmo ir antro laipsnio išvestinės pagal  $\varphi$  yra lygios 0, kai  $\varphi = \frac{\pi}{2} - \beta$  ir  $\varphi = \frac{\pi}{2} + \beta$ .

**Irodymas.** Iš (19) gaunama:

$$\begin{aligned}
\left. \frac{d\rho^+}{d\varphi} \right|_{\varphi = \frac{\pi}{2} - \beta} &= cl \sin^{l-1} \left( \frac{\pi(\pi/2 - \beta - \pi/2 + \beta)}{2\beta} \right) \cos \left( \frac{\pi(\pi/2 - \beta - \pi/2 + \beta)}{2\beta} \right) \frac{\pi}{2\beta} \\
&= cl \sin^{l-1}(0) \cos(0) \frac{\pi}{2\beta} = 0,
\end{aligned}$$

$$\begin{aligned}
\left. \frac{d\rho^+}{d\varphi} \right|_{\varphi = \frac{\pi}{2} + \beta} &= cl \sin^{l-1} \left( \frac{\pi(\pi/2 + \beta - \pi/2 + \beta)}{2\beta} \right) \cos \left( \frac{\pi(\pi/2 + \beta - \pi/2 + \beta)}{2\beta} \right) \frac{\pi}{2\beta} \\
&= cl \sin^{l-1}(\pi) \cos(\pi) \frac{\pi}{2\beta} = 0.
\end{aligned}$$

Antros eilės išvestinė nuo  $\varphi$  yra:

$$\begin{aligned}
\frac{d^2\rho^+}{d\varphi^2} &= \\
cl \left( \frac{\pi}{2\beta} \right)^2 &\left( (l-1) \sin^{l-2} \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) \cos^2 \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) - \sin^l \left( \frac{\pi(\varphi - \pi/2 + \beta)}{2\beta} \right) \right). \quad (20)
\end{aligned}$$

Jos reikšmės taškuose  $\varphi = \frac{\pi}{2} - \beta$  ir  $\varphi = \frac{\pi}{2} + \beta$  yra

$$\begin{aligned}
\left. \frac{d^2\rho^+}{d\varphi^2} \right|_{\varphi = \frac{\pi}{2} - \beta} &= \\
= cl \left( \frac{\pi}{2\beta} \right)^2 &\left( (l-1) \sin^{l-2} \left( \frac{\pi(\frac{\pi}{2} - \beta - \frac{\pi}{2} + \beta)}{2\beta} \right) \cos^2 \left( \frac{\pi(\frac{\pi}{2} - \beta - \frac{\pi}{2} + \beta)}{2\beta} \right) - \sin^l \left( \frac{\pi(\frac{\pi}{2} - \beta - \frac{\pi}{2} + \beta)}{2\beta} \right) \right) \\
= cl \left( \frac{\pi}{2\beta} \right)^2 &\left( (l-1) \sin^{l-2}(0) \cos^2(0) - \sin^l(0) \right) = 0,
\end{aligned}$$

$$\begin{aligned}
& \left. \frac{d^2 \rho^+}{d\varphi^2} \right|_{\varphi=\frac{\pi}{2}+\beta} \\
&= cl \left( \frac{\pi}{2\beta} \right)^2 \left( (l-1) \sin^{l-2} \left( \frac{\pi(\frac{\pi}{2}+\beta-\frac{\pi}{2}+\beta)}{2\beta} \right) \cos^2 \left( \frac{\pi(\frac{\pi}{2}+\beta-\frac{\pi}{2}+\beta)}{2\beta} \right) - \sin^l \left( \frac{\pi(\frac{\pi}{2}+\beta-\frac{\pi}{2}+\beta)}{2\beta} \right) \right) \\
&= cl \left( \frac{\pi}{2\beta} \right)^2 \left( (l-1) \sin^{l-2}(\pi) \cos^2(\pi) - \sin^l(\pi) \right) = 0. \quad \blacksquare
\end{aligned}$$

### 3.2.1.1 Matematinis modelis Dekarto koordinatų sistemoje

Taip pat reikalingi parametrai  $a$  ir  $b$ , atitinkamai nusakantys horizontalų ir vertikalų mastelius. (17) kreivė turi būti priderinta prie kaulinio audinio sluoksnyje, todėl dar reikia nurodyti vietą, kur ši kreivė prasidės (17) (kreivė prasideda nuo  $\varphi = -\pi/2$ ). Pažymėkime šios vietos tašką  $(x_0; y_0)$ . 28 pav. galima pastebėti, kad šonkauliais apribotas kontūras yra pasisukęs lovos atžvilgiu. Todėl įvedamas dar vienas parametras – posūkio kampas  $\theta$ .

Jeigu parametru  $s, \beta, c, l, a, b, x_0, y_0$  ir  $\theta$  reikšmės fiksuotos, galima nubrėžti parametrinę kreivę  $[x \ y]^T = [x(\varphi) \ y(\varphi)]^T$ , aproksimuojančią šonkauliais apribotą kontūrą:

$$\begin{aligned}
x(\varphi) &= x_0 + a\rho(\varphi) \cos \varphi \cos \theta - b\rho(\varphi) \sin \varphi \sin \theta \\
y(\varphi) &= y_0 + a\rho(\varphi) \cos \varphi \sin \theta + b\rho(\varphi) \sin \varphi \cos \theta,
\end{aligned} \tag{21}$$

kur  $\rho(\varphi)$  yra apibrėžtas (17) lygtyje.

### 3.2.1.2 Modelio papildymas atkarpa, lygiagrečia žmogaus sagitalinei ašiai


Nors šonkauliai yra simetriški žmogaus sagitalinės plokštumos atžvilgiu, jų skerspjuvis, lygiagretus skersinei žmogaus plokštumai, gali atrodyti asimetriškas dėl paciento pozicijos ant lovos. Taip pat sluoksnyje yra labai daug baltų pikselių, vaizduojančių stuburą, o tai gali paveikti modelio įtaikymą (angl. *fit*). Be to, įtaką kreivės įtaikymo procesui gali daryti ir keterinė atauga (angl. *spinous process*). Paveika ne tokia didelė, jei pridedama atkarpa, lygiagreti žmogaus sagitalinei ašiai. Ši atkarpa turi apimti bent stuburą: nuo  $(x_0; y_0)$  iki nepasukto modelio (kai  $\theta = 0$ ) apačios, t. y. atkarpos taškai turi būti (32 pav.):

1.  $[x_0 \ y_0]^T$ ,
2.  $[x_0 + (y_0 - \min_y) \sin \theta \quad y_0 - (y_0 - \min_y) \cos \theta]^T$ ,

(22)

kur  $\min_y$  yra minimali  $y$  reikšmė, gauta pagal (21). Jeigu  $\theta = 0$ ,  $\min_y$  gaunamas paprastai:

$$\min_y = \min_{\varphi} (y_0 + b\rho(\varphi) \sin \varphi). \quad (23)$$



32 pav. CT sluoksniu pavyzdys ir norimas gauti šonkauliais apriboto kontūro modelis.


### 3.2.1.3 Parametrų ribojimai

(17) modelio parametrų reikšmių hipotetiniai ribojimai:

1.  $0 < s \leq 1$ ,
2.  $-\pi/6 < \theta < \pi/6$ ,
3.  $a > 0$ ,
4.  $b > 0$ ,
5.  $0 \leq \min_{\varphi} (x_0 + a\rho(\varphi) \cos \varphi \cos \theta - b\rho(\varphi) \sin \varphi \sin \theta) < \max_{\varphi} (x_0 + a\rho(\varphi) \cos \varphi \cos \theta - b\rho(\varphi) \sin \varphi \sin \theta) \leq 512$ ,
6.  $0 \leq \min_{\varphi} (y_0 + a\rho(\varphi) \cos \varphi \sin \theta + b\rho(\varphi) \sin \varphi \cos \theta) < \max_{\varphi} (y_0 + a\rho(\varphi) \cos \varphi \sin \theta + b\rho(\varphi) \sin \varphi \cos \theta) < 512$ ,
7.  $y_0 \geq p + \omega$ , kur  $p$  yra stuburo viršutinio taško sluoksnyje ordinatė ( $p \in \{b_{2i}\}, i = \overline{1, m}$ ),  $\omega$  yra konstanta,
8.  $0 \leq \beta \leq \pi$ ,
9.  $0 \leq c < 1$ ,
10.  $l \geq 2$ ,
11.  $\max_{\varphi} (2a\rho(\varphi) \cos \varphi) > \max_{\varphi} (b\rho(\varphi) \sin \varphi) - \min_{\varphi} (b\rho(\varphi) \sin \varphi)$ .

Pirmas ribojimas užtikrina, kad modelio pagrindas būtų suspausta standartinė kardioidė, antras – kad modelis nebūtų apverstas (jei pacientas guli ant nugaros per tyrimą), trečias ir ketvirtas – taip pat užtikrina, kad modelis nebūtų apverstas (atspindys), penktas ir šeštasis – kad išliktų vaizdo ribose (čia tiriami  $512 \times 512$  pikselių dydžio vaizdai), septintasis – kad kreivės pradžios taškas būtų stabilus, aštuntasis ir devintasis – kad nesusidarytų kilpa kreivės pradžioje, dešimtas – kad krūtinkaulio įdubą modeliuojančios funkcijos apibrėžimo srities galuose antrosios eilės išvestinės būtų lygios 0, vienuoliktas – kad plotis būtų didesnis už aukštį.

Modelio kreivė be ribojimų gali būti netinkamos formos, pavyzdžiui, 33(a) pav., kur  $c > 2^s$ . Iš tikrųjų  $c$  neturėtų išvis priartėti prie  $2^s$ , nes taip gaunamas sparnų formos modelis (33(b) pav.), todėl naudojamas ribojimas  $c < 1$ . Šonkauliais apriboto kontūro aproksimacija pavaizduota raudona linija. Jeigu pažeidžiamas antras ribojimas, kreivė gali būti apversta (33(c) pav.). Jeigu neužtikrinami nei šeštasis, nei vienuoliktas ribojimai, įtaikyto modelio kreivė gali kirsti tik keturis šonkaulius (33(d) pav.).



33 pav. Modelio įtaikymas be ribojimų: (a)  $c > 2^s$ , (b)  $c = 2^s$ , (c) pažeistas antras ribojimas, (d) pažeisti vienuoliktas ir šeštasis ribojimai.

### 3.2.2 Modelio įtaikymas

Jeigu  $\varphi$  kinta intervale  $[\pi/2; 3\pi/2]$  su žingsniu  $2\pi/n$ , gaunama kreivės taškų seka  $\mathbf{C}^* = (\mathbf{c}_i^* = [x_i \ y_i]^\top, i = \overline{0, n-1})$ ,  $x_i = x\left(\frac{2\pi}{n}i - \frac{\pi}{2}\right)$  ir  $y_i = y\left(\frac{2\pi}{n}i - \frac{\pi}{2}\right)$ , kur  $x(\varphi)$  ir  $y(\varphi)$  yra apibrėžti (21). (22) atkarpa yra padalijama į  $n_t$  taškus  $\mathbf{C}^{**} = \left(\mathbf{c}_i^{**} = \left[x_0 + \frac{(y_0 - \min_y) \sin \theta}{n_t} \cdot i \quad y_0 - \frac{(y_0 - \min_y) \sin \theta}{n_t} \cdot i\right]^\top, i = \right.$



$\overline{1, n_t}$ ). Abi sekos sujungiamos į vieną seką  $\mathbf{C} = (\mathbf{C}^*, \mathbf{C}^{**})$ , kurios ilgis yra  $n + n_t$ .

$\min_y$  buvo aproksimuotas  $\min_{i=0, n-1} \left( y_0 + b\rho \left( \frac{2\pi}{n} i - \frac{\pi}{2} \right) \sin \left( \frac{2\pi}{n} i - \frac{\pi}{2} \right) \right)$  siekiant išvengti analizinio  $\frac{d\rho}{d\varphi}$  sprendimo.

Vieno kompiuterinės tomografijos vaizdo sluoksnio šonkauliais apriboto kontūro modelis turi devynis parametrus –  $s, \beta, c, l, a, b, x_0, y_0$  ir  $\theta$ , – kurių reikšmės turi būti rastos siekiant parinkti geriausią kontūro aproksimaciją. Optimalios parametrų reikšmės turi būti surastos pagal kaulinį audinį vaizduojančių pikselių koordinatų aibę  $\mathbf{B} = \{\mathbf{b}_i = [b_{1i} \ b_{2i}]^T, i = \overline{1, m}\}$ , gautą segmentuojant CT vaizdo sluoksnį. Modelio įtaikymo problema – optimalių parametrų  $s, \beta, c, l, a, b, x_0, y_0$  ir  $\theta$  reikšmių radimo – formuluojama kaip mažiausių kvadratų problema:

$$\min_{s, \beta, c, l, a, b, x_0, y_0, \theta} f(s, \beta, c, l, a, b, x_0, y_0, \theta),$$

$$f(\cdot) = \frac{1}{m} \sum_{i=1}^m \|\mathbf{b}_i - \mathbf{c}_{k_i}\|^2, \quad k_i = \arg \min_{j=0, n+n_t-1} \|\mathbf{b}_i - \mathbf{c}_j\|. \quad (24)$$

### 3.2.2.1 Modelio supaprastinimas

Pastebėta, kad optimalios  $\beta$  reikšmės arba siekia ribojimą  $\pi$ , arba yra arti jo. Todėl pabandyta fiksuoti  $\beta = \pi$ , jis tampa neoptimizuojamu parametru. Tai reiškia:

- krūtinkaulio įdubą modeliuojanti funkcija taikoma visai apibrėžimo sričiai  $\varphi \in \left[ -\frac{\pi}{2}; \frac{3\pi}{2} \right]$ ,
- krūtinkaulio įduba modeliuojama keičiant parametrus  $c$  ir  $l$ .

Taip vietoj 9 parametrų optimizuojami tik 8:

$$\min_{s, c, l, a, b, x_0, y_0, \theta} f(s, \pi, c, l, a, b, x_0, y_0, \theta). \quad (25)$$

(17) modelis polinėse koordinatėse tampa:

$$\rho(\varphi) = \left(1 + \cos\left(\varphi - \frac{\pi}{2}\right)\right)^s - c \sin^l\left(\frac{\varphi + \pi/2}{2}\right). \quad (26)$$

### 3.2.2.2 Dviejų žingsnių optimizavimas

Nors (24) funkcija nėra separabili, lokalus optimizavimas vyksta stabiliau vykdomas dviem etapais:

1. Modelis įtaikomas be krūtinkaulio įdubą aproksimuojančios funkcijos, t. y. ieškomi tik parametrai  $s$ ,  $a$ ,  $b$ ,  $x_0$ ,  $y_0$  ir  $\theta$ , o parametrai  $c$  ir  $l$  yra fiksuoti,
2. Modelis pakoreguojamas su krūtinkaulio įdubą aproksimuojančia funkcija, t. y. ieškomi visi parametrai  $s$ ,  $c$ ,  $l$ ,  $a$ ,  $b$ ,  $x_0$ ,  $y_0$  ir  $\theta$ .

Pirmo žingsnio optimizavimas yra paprastesnis nei (24), nes turi mažiau parametrų:

$$\min_{s,a,b,x_0,y_0,\theta} f(s, \pi, 0, 2, a, b, x_0, y_0, \theta). \quad (27)$$

Taip gaunamos  $s$ ,  $a$ ,  $b$ ,  $x_0$ ,  $y_0$  ir  $\theta$  parametrų reikšmės, naudojamos kaip pirminės reikšmės antram žingsnio lokaliajam optimizavimui, kuris aprašytas (24). Antrame žingsnyje  $c$  ir  $l$  pradinės reikšmės nustatomos  $c = 0$ ,  $l = 2$ .


Buvo 500 kartų išbandytas lokalus optimizavimas aštuoniems sluoksniams pradėdant nuo atsitiktinai sugeneruotų pradinųjų taškų, kiekvienam pradiniam taškui taikant tiek vieno, tiek dviejų žingsnių optimizavimą. Pastebėta, kad optimizavimas stabilesnis, jeigu pasirenkamos pradinės parametrų reikšmės yra tokios, kad būtų sudaroma mažesnė kreivė nei tikras šonkauliais apribotas kontūras; tolimesnis optimizavimas lemia šios kreivės išsiplėtimą. Dėl šios priežasties pradiniai taškai generuojami tokiuose intervaluose:  $s \in [0; 1]$ ,  $c \in [0; 2]$ ,  $l \in [2; 8]$ ,  $a \in [100; 150]$ ,  $b \in [100; 150]$ ,  $x_0 \in [231; 281]$ ,  $y_0 \in [150; 250]$ ,  $\theta = 0$ . Agreguoti rezultatai pateikti 3 lentelėje, kur  $f(\cdot)_\mu$  yra vidutinė (iš 500) funkcijos reikšmė su optimizavimo metu gautais parametrais,  $f(\cdot)_{min}$  – minimali funkcijos reikšmė (tikėtinas globalus minimumas),  $f(\cdot)_{max}$  – maksimali iš gautų minimalių funkcijos reikšmė. Stulpelyje „laikas“ pateiktas vidutinis vieno bandymo vieno procesoriaus branduolio skaičiavimo

laikas sekundėmis. Skaičiavimai atlikti naudojant kompiuterį, kurio procesorius yra Intel® Core™ i7-2600 @ 3,4GHz, ir Matlab R2013a programinę įrangą.

3 lentelė. Vieno ir dviejų žingsnių optimizavimo rezultatai.

	Vieno žingsnio optimizavimas				Dviejų žingsnių optimizavimas			
	$f(\cdot)_\mu$	$f(\cdot)_{min}$	$f(\cdot)_{max}$	laikas	$f(\cdot)_\mu$	$f(\cdot)_{min}$	$f(\cdot)_{max}$	laikas
1	261,80	24,492	10184	224,34	24,495	24,492	24,522	296,20
2	232,16	25,925	13065	216,34	25,932	25,925	25,950	317,67
3	251,62	26,989	12365	250,95	26,991	26,989	27,003	320,83
4	293,16	27,739	13215	196,19	27,746	27,739	27,790	271,56
5	264,51	29,167	13575	195,26	29,183	29,167	29,238	281,84
6	292,42	32,343	14556	215,48	32,360	32,343	32,412	301,75
7	265,88	27,510	12581	207,97	27,512	27,510	27,545	281,82

Rezultatai 3 lentelėje rodo, kad taikant dviejų žingsnių optimizavimą užtenka lokalaus optimizavimo metodo, nes, nepaisant padidėjusio skaičiavimo laiko, su didele tikimybe užtikrina minimumą, artimą globaliam. Buvo naudoti tik 2, 7 (su  $\omega = 35$ ), 9 ir 11 ribojimai, nes kiti ribojimai nebuvo pažeisti optimizavimo metu. Keli kreivės įtaikymų pavyzdžiai pateikti 34 pav. Funkcijos reikšmės, pateiktos 3 lentelėje, atitinka  $\sim 5 - 7$  mm vidutinį atstumą nuo kaulinį audinį vaizduojančio pikselio iki kreivės taško, kai šonkaulių skersmuo yra iki 1 cm, o stuburo slankstelio – iki 4 cm.



34 pav. Optimizavimo rezultatų pavyzdžiai.

### 3.2.2.3 Optimizavimo pagreitinimas naudojant analizines išvestines

Skaičiuojant funkcijos  $f(\cdot)$  reikšmę (24), kiekvienam kaulinio audinio taškui (pikseliui) skaičiuojamas artimiausias taškas modelyje, todėl bendras sudėtingumas yra  $\mathcal{O}(m \cdot (n + n_t))$ , kur  $m$  yra kaulinio audinio pikselių kiekis, o  $n + n_t$  yra modelio taškų kiekis. Taigi funkcijos reikšmės įvertinimas yra gana brangus. Jį pagreitinti galima, jei pagreitinama artimiausio modelio taško paieška, pavyzdžiui, naudojant artimiausio kaimyno paiešką. Šiame darbe tokie pagreitinimai neišbandyti, nes dėmesys skirtas tikslumui užtikrinti.

Tačiau pabandyta pagreitinti patį optimizavimo procesą naudojant optimizuojamos funkcijos analizines dalines išvestines. Pirminėms išvestinėms sudaryti naudota Maple<sup>14</sup> programinė įranga. Dalinės išvestinės pateiktos (28), (29) ir (31)–(37) formulėse.

$$\begin{aligned} \frac{\partial f}{\partial s} = \sum_i^m & -2 \left(1 + \sin\left(\frac{2\pi}{n}k_i\right)\right)^s \ln\left(1 + \sin\left(\frac{2\pi}{n}k_i\right)\right) \left( (b_{1i} - x_{k_i}) \right. \\ & \cdot \left( a \cos\left(\frac{2\pi}{n}k_i\right) \cos\theta + b \sin\left(\frac{2\pi}{n}k_i\right) \sin\theta \right) \\ & \left. + (b_{2i} - y_{k_i}) \left( a \cos\left(\frac{2\pi}{n}k_i\right) \sin\theta + b \sin\left(\frac{2\pi}{n}k_i\right) \cos\theta \right) \right) \end{aligned} \quad (28)$$

$$\frac{\partial f}{\partial \beta} = \sum_i^m \begin{cases} \beta'(k_i), & \text{kai } \beta > |\varphi_{k_i} - \pi/2| \\ 0, & \text{kitu atveju} \end{cases} \quad (29)$$

$$\begin{aligned} \beta'(k_i) = & 2c \sin^{l-1} \left( \frac{\pi}{2\beta} \left( \frac{2\pi}{n}k_i - \frac{\pi}{2} + \beta \right) \right) l \cos \left( \frac{\pi}{2\beta} \left( \frac{2\pi}{n}k_i - \frac{\pi}{2} + \beta \right) \right) \\ & \cdot \frac{\pi}{2\beta^2} \left( \frac{\pi}{2} - \frac{2\pi}{n}k_i \right) \\ & \cdot \left( (b_{1i} - x_{k_i}) \left( a \cos\left(\frac{2\pi}{n}k_i\right) \cos\theta - b \sin\left(\frac{2\pi}{n}k_i\right) \sin\theta \right) \right. \\ & \left. + (b_{2i} - y_{k_i}) \left( a \cos\left(\frac{2\pi}{n}k_i\right) \sin\theta - b \sin\left(\frac{2\pi}{n}k_i\right) \cos\theta \right) \right) \end{aligned} \quad (30)$$

<sup>14</sup> <http://www.maplesoft.com>

$$\begin{aligned} \frac{\partial f}{\partial c} = \sum_i^m 2 \sin^l \left( \pi \left( \frac{2\pi}{n} k_i - \frac{\pi}{2} + \beta \right) / 2\beta \right) & \left( (b_{1i} - x_{k_i}) \right. \\ & \cdot \left( a \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta + b \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta \right) \\ & \left. + (b_{2i} - y_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \sin \theta + b \sin \left( \frac{2\pi}{n} k_i \right) \cos \theta \right) \right) \end{aligned} \quad (31)$$

$$\begin{aligned} \frac{\partial f}{\partial l} = \sum_i^m 2c \sin^l \left( \frac{\pi \left( \frac{2\pi}{n} k_i - \frac{\pi}{2} + \beta \right)}{2\beta} \right) \ln \left( \sin \left( \frac{\pi \left( \frac{2\pi}{n} k_i - \frac{\pi}{2} + \beta \right)}{2\beta} \right) \right) & \\ & \cdot \left( (b_{1i} - x_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta + b \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta \right) \right. \\ & \left. + (b_{2i} - y_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \sin \theta + b \sin \left( \frac{2\pi}{n} k_i \right) \cos \theta \right) \right) \end{aligned} \quad (32)$$

$$\begin{aligned} \frac{\partial f}{\partial a} = \sum_i^m -2\rho \left( \frac{2\pi}{n} k_i \right) \cos \left( \frac{2\pi}{n} k_i \right) & \\ \cdot \left( (b_{1i} - x_{k_i}) \cos \theta + (b_{2i} - y_{k_i}) \sin \theta \right) & \end{aligned} \quad (33)$$

$$\frac{\partial f}{\partial b} = \sum_i^m 2\rho \left( \frac{2\pi}{n} k_i \right) \sin \left( \frac{2\pi}{n} k_i \right) \cdot \left( (b_{1i} - x_{k_i}) \sin \theta - (b_{2i} - y_{k_i}) \cos \theta \right) \quad (34)$$

$$\frac{\partial f}{\partial x_0} = \sum_i^m -2(b_{1i} - x_{k_i}) \quad (35)$$

$$\frac{\partial f}{\partial y_0} = \sum_i^m -2(b_{2i} - y_{k_i}) \quad (36)$$

$$\begin{aligned} \frac{\partial f}{\partial \theta} = \sum_i^m 2(b_{1i} - x_{k_i}) \left( a\rho \left( \frac{2\pi}{n} k_i \right) \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta \right. & \\ + b\rho \left( \frac{2\pi}{n} k_i \right) \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta & \\ + 2(b_{2i} - y_{k_i}) \left( -a\rho \left( \frac{2\pi}{n} k_i \right) \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta \right. & \\ + b\rho \left( \frac{2\pi}{n} k_i \right) \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta & \left. \right) \end{aligned} \quad (37)$$

$k_i$  apskaičiuojamas pagal (24) formulę, t. y.  $k_i = \arg \min_{j=0, n+n_t-1} \|\mathbf{b}_i - \mathbf{c}_j\|$ .

$\varphi_{k_i}$  yra kampas polinėse koordinatėse, pagal kurį gautas  $k_i$ -asis taškas. Jeigu

optimizuojamas supaprastintas modelis, kaip aprašyta 3.2.2.1 punkte,  $\frac{\partial f}{\partial \beta} = 0$ , o  $c$  ir  $l$  dalinės išvestinės pateiktos (38) ir (39) formulėse.

$$\begin{aligned} \frac{\partial f}{\partial c} = & \sum_i^m 2 \sin^l \left( \frac{\pi}{n} k_i + \frac{\pi}{4} \right) \\ & \cdot \left( (b_{1i} - x_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta \right. \right. \\ & + b \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta \left. \right) \\ & + (b_{2i} - y_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \sin \theta \right. \\ & \left. \left. + b \sin \left( \frac{2\pi}{n} k_i \right) \cos \theta \right) \right) \end{aligned} \quad (38)$$

$$\begin{aligned} \frac{\partial f}{\partial l} = & \sum_i^m 2c \sin^l \left( \frac{\pi}{n} k_i + \frac{\pi}{4} \right) \ln \left( \sin \left( \frac{\pi}{n} k_i + \frac{\pi}{4} \right) \right) \\ & \cdot \left( (b_{1i} - x_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \cos \theta \right. \right. \\ & + b \sin \left( \frac{2\pi}{n} k_i \right) \sin \theta \left. \right) \\ & + (b_{2i} - y_{k_i}) \left( a \cos \left( \frac{2\pi}{n} k_i \right) \sin \theta \right. \\ & \left. \left. + b \sin \left( \frac{2\pi}{n} k_i \right) \cos \theta \right) \right) \end{aligned} \quad (39)$$

Buvo 200 kartų išbandytas lokalus optimizavimas aštuoniems sluoksniams pradedant nuo atsitiktinai sugeneruotų pradinių taškų, kiekvieną kartą optimizuojant tiek su skaitiniu būdu įvertintomis išvestinėmis, tiek su analizinėmis išvestinėmis. Pradiniai taškai generuojami tokiuose pačiuose intervaluose, kaip ir 3.2.2.2 punkte. Agreguoti rezultatai pateikti 4 lentelėje, kur  $f(\cdot)_\mu$  yra vidutinė (iš 200) funkcijos reikšmė su optimizavimo metu gautais parametrais,  $f(\cdot)_{min}$  – minimali funkcijos reikšmė,  $f(\cdot)_{max}$  – maksimali iš gautų minimalių funkcijos reikšmė. Stulpelyje „laikas“ pateiktas vidutinis vieno bandymo vieno procesoriaus branduolio skaičiavimo laikas sekundėmis.

Skaičiavimai atlikti naudojant kompiuterį, kurio procesorius yra Intel® Core™ i7-2600 @ 3,4GHz, ir Matlab R2013a programinę įrangą.

4 lentelė. Optimizavimo rezultatai, išvestines įvertinant skaitiniu ir analiziniu būdais.

	Išvestinės įvertintos skaitiniu būdu				Išvestinės apskaičiuotos analiziniu būdu			
	$f(\cdot)_\mu$	$f(\cdot)_{min}$	$f(\cdot)_{max}$	laikas	$f(\cdot)_\mu$	$f(\cdot)_{min}$	$f(\cdot)_{max}$	laikas
1	24,50	24,49	24,52	283,0	24,50	24,49	24,52	167,5
2	25,93	25,92	25,95	370,6	25,94	25,92	25,95	193,5
3	26,99	26,99	27,00	332,1	26,99	26,99	27,01	181,6
4	27,75	27,74	27,79	270,7	27,75	27,74	27,79	163,9
5	29,18	29,17	29,24	282,1	29,18	29,17	29,24	164,2
6	32,36	32,34	32,41	327,3	32,36	32,34	32,42	191,9
7	27,51	27,51	27,54	253,9	27,59	27,51	27,54	144,3

Rezultatai 4 lentelėje rodo, kad vidutinis vienos kreivės įtaikymo laikas sluoksnyje išvestines įvertinant skaitiniu būdu yra ~298 sekundės, o išvestines įvertinant analiziniu būdu – ~170 sekundžių, todėl optimizavimas naudojant analizes išvestines yra ~1,75 karto greitesnis nei naudojant skaitines išvestines.

### 3.3 Trečio skyriaus išvados

1. Pasiūlytas matematinis modelis ne tik aproksimuoja šonkaulių skerspjuvį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame žmogaus skersinei plokštumai, bet ir leidžia įvertinti paciento posūkį pagal vertikalią ašį tomografijos atlikimo metu.
2. Iš viso suformuluoti 11 ribojimų lokalaus optimizavimo uždavinyje, tačiau tyrimai parodė, kad tinkamai parinkus pradinį tašką, 7 ribojimai lieka nepažeisti per visą optimizavimo procesą. Taip gali būti suprastinamas uždavinys.
3. Kaulinį audinį vaizduojančių pikselių tankis yra ypač didelis stuburo aplinkoje. Tad ši vieta gali paveikti modelio struktūrą. Atkarpos,

lygiagrečios žmogaus sagitalinei ašiai, pridėjimas užtikrina gerą šonkaulių sistemos aproksimaciją ir stuburo aplinkoje.

4. Pasiūlyta dviejų žingsnių optimizavimo strategija. Pirmame žingsnyje sprendžiamas supaprastintas (mažesnio kintamųjų skaičiaus) uždavinys, o po to optimizavimui naudojami visi 8 kintamieji. Šiuo atveju gaunami rezultatai, geresni nei vieno žingsnio strategijos, nes optimizavimas antru atveju pradamas nuo geresnio pradinio taško, gaunamo po pirmojo etapo. Todėl globaliojo optimizavimo problemai spręsti pakanka lokaliajo optimizavimo metodų.
5. Optimizavimo procesą galima pagreitinti naudojant optimizuojamos funkcijos analizes dalines išvestines. Eksperimentiškai nustatyta, kad optimizavimas naudojant analizes išvestines yra ~1,75 karto greitesnis negu įvertinant išvestines skaitiniu būdu.



# 4

## Sluoksnių registravimas

Radiologams dažnai tenka rasti kompiuterinės tomografijos vaizdo sluoksnio vietą kitame tomografiniame vaizde, t. y. turint tomografinio vaizdo  $A'$  sluoksnį  $A'$ , reikia jį palyginti su visais tomografinio vaizdo  $A''$  sluoksniais ir iš jų išrinkti panašiausią sluoksnį  $A''_k$ :

$$k = \arg \min_{A''_j \in A''} \text{dist}(A', A''_j), \quad (40)$$

kur funkcija  $\text{dist}(A_i, A_j)$  yra sluoksnių panašumo kriterijus. Toliau šiame skyriuje apsvarstytos kelios skirtingos galimos  $\text{dist}(A_i, A_j)$  funkcijos.

Šiame darbe  $A'$  ir  $A''$  vadinami pirminiu sluoksniu ir tomografiniu vaizdu (tomografinis vaizdas yra dvimačių sluoksnių rinkinys, arba trimatis vaizdas), atitinkamai;  $A'$  ir  $A''$  – tiksliniu sluoksniu ir tomografiniu vaizdu, atitinkamai. Analogiškai  $B'$  ir  $C'$  žymimi pirminio vaizdo kaulinį audinį vaizduojančių pikselių koordinatinių aibė ir modelio kreivės taškų seka, atitinkamai, o  $B''$  ir  $C''$  – tikslinio vaizdo kaulinį audinį vaizduojančių pikselių koordinatinių aibė ir modelio kreivės taškų seka, atitinkamai. Pavyzdžiui,  $C'' = (\mathbf{c}''_i = [x_i \ y_i]^T, i = \overline{0, n-1})$  yra tikslinio sluoksnio modelio kreivės taškų seka.

Sluoksnių registravimas grindžiamas:

1. Matematinio modelio parametrų reikšmėmis  $M = \langle s, c, l, a, b, x_0, y_0, \theta \rangle$ ,
2. Modelio kreivės taškų seka  $C$ ,

### 3. Modelio kreivės taškų svoriais $\mathbf{W}$ .

Registruojant nenaudojama modelio atkarpa, aprašyta (22) formulėje, ši atkarpa skirta tik tinkamam modelio aproksimavimui užtikrinti. Dėl to toliau  $\mathbf{C}$  bus žymima seka  $\mathbf{C} = (\mathbf{c}_i = [x_i \ y_i]^\top, i = \overline{0, n-1})$ ,  $x_i = x\left(\frac{2\pi}{n}i - \frac{\pi}{2}\right)$  ir  $y_i = y\left(\frac{2\pi}{n}i - \frac{\pi}{2}\right)$ , kur  $x(\varphi)$  ir  $y(\varphi)$  yra apibrėžti (21).

Registruojant sluoksnius, galima atsižvelgti ne vien tik į šonkauliais apriboto kontūro formą, bet ir į kaulinį audinį vaizduojančių pikselių tankį atskirų modelio kreivės taškų aplinkoje – taip įvertinami modelio kreivės taškų svoriai. Modelio kreivės taškų svoriai gaunami dalijant kaulinį audinį vaizduojančius pikselius kreivės taškams  $\mathbf{C}$ , suformuojama  $n$  grupių. Modelio kreivės taškai  $[x_i \ y_i]^\top$ ,  $i = \overline{0, n-1}$  turi svorius  $\mathbf{W} = (w_0, w_1, \dots, w_{n-1})$ , kur  $w_i$  yra kaulinį audinį vaizduojančių pikselių kiekis  $i$ -oje grupėje;  $i$ -oji grupė turi kreivės taškui  $[x_i \ y_i]^\top$  nei taškui  $[x_j \ y_j]^\top$ ,  $\forall j \neq i$  artimesnius pikselius. Dėl paprastumo toliau šiame darbe  $\mathbf{W} = (w_0, w_1, \dots, w_{n-1})$  žymimi normalizuoti svoriai, kur  $\sum_{i=0}^{n-1} w_i = 1$ .

Registravimo metodas turi būti invariantiškas poslinkiui (angl. *translation*), posūkiui apie žmogaus vertikalią ašį ir mastelio pokyčiui (angl. *scale*). Invariantiškumą posūkiui apie žmogaus sagitalinę ir skersinę ašis užtikrina pats tomografas – pacientas tiesiog neturi galimybės pasisukti kitomis kryptimis dėl vietos stokos.

## 4.1 Registravimo invariantiškumo užtikrinimas

### 4.1.1 Invariantiškumas posūkiui

Matematinis modelis turi parametą  $\theta$ , nusakantį paciento posūkį pagal žmogaus vertikalią ašį. Taip pat šis parametras nurodo modelio kreivės posūkį apie tašką  $[x_0 \ y_0]^\top$ . Registravimo posūkio invariantiškumas realizuotas atsukant modelio kreivę kampu  $-\theta$  apie tašką  $[x_0 \ y_0]^\top$ . Atsukti reikia tiek

---

pirminio, tiek tikslinio sluoksnių modelių kreives, modelių parametrai tampa  $M' = \langle s', c', l', a', b', x'_0, y'_0, 0 \rangle$  ir  $M'' = \langle s'', c'', l'', a'', b'', x''_0, y''_0, 0 \rangle$ . Dėl paprastumo toliau šiame skyriuje  $C' = ([x'_i \ y'_i]^\top, i = \overline{0, n-1})$  ir  $C'' = ([x''_i \ y''_i]^\top, i = \overline{0, n-1})$  žymima pirminio ir tikslinio sluoksnių modelių kreivės taškų sekos po atsukimo.

#### 4.1.2 Invariantiškumas mastelio pokyčiui

Dažniausiai lyginami sluoksniai turi skirtingus mastelius, šie priklauso nuo tomografo nustatymų. Nustatymai gali skirtis tomografijos atlikimo metu. Vienas iš tokių parametrų yra pikselių dydis, t. y. kokį dydį milimetrais atitinka vienas pikselis. Toliau nagrinėjami tik tie atvejai, kai pikselis yra kvadratas, t. y. jo horizontalus ir vertikalus dydžiai sutampa.

Matematinis modelis turi mastelį nusakančius parametrus  $a$  ir  $b$ . Šie parametrai gali būti keičiami lyginant du sluoksnius. Toliau pateikti trys skirtingi mastelio invariantiškumo užtikrinimo variantai O1, O2 ir O3. O2 ir O3 variantai naudojami, kai DICOM metaduomenys yra netikslūs ar visiškai prarasti.

Pirmas variantas O1 yra DICOM metaduomenų panaudojimas. Tarkime, kad pirminio sluoksnio pikselio mastelis yra  $z'$ , o antrinio –  $z''$ . Patikslinti pirminio sluoksnio modelio parametrai yra  $M' = \langle s', c', l', a' \cdot z'/z'', b' \cdot z'/z'', x'_0, y'_0, 0 \rangle$ . Antrinio sluoksnio modelio parametrai lieka nepakitę, t. y.  $M'' = \langle s'', c'', l'', a'', b'', 0, x''_0, y''_0 \rangle$ .

O2 ir O3 variantai pagrįsti faktu, kad lyginami to paties paciento sluoksniai, mastelis sulyginamas naudojant kreivės ypatybes:

O2 – didžiausią srities, apribotos kreive, plotį,

O3 – srities, apribotos kreive, plotą.

Jeigu naudojamas plotis (O2 variantas), tikslinio sluoksnio modelio parametrai lieka tokie patys, o pirminio sluoksnio modelio parametrai tampa šie:

$$\begin{aligned}
M' &= \langle s', c', l', a' \cdot z, b' \cdot z, 0, x'_0, y'_0 \rangle, \\
z &= \text{width}(\mathbf{C}'') / \text{width}(\mathbf{C}'), \\
\text{width}(\mathbf{C}') &= \max_i x'_i - \min_i x'_i, \text{width}(\mathbf{C}'') = \max_i x''_i - \min_i x''_i.
\end{aligned} \tag{41}$$

Jeigu naudojamas plotas (O3 variantas), tikslinio sluoksnio modelio parametrai lieka tokie patys, o pirminio sluoksnio modelio parametrai tampa šie:

$$\begin{aligned}
M' &= \langle s', c', l', a' \cdot z, b' \cdot z, 0, x'_0, y'_0 \rangle, \\
z &= \sqrt{\text{area}(\mathbf{C}'') / \text{area}(\mathbf{C}')}, \\
\text{area}(\mathbf{C}') &= \frac{1}{2} (x'_0 y'_1 - x'_1 y'_0 + x'_1 y'_2 - x'_2 y'_1 + \dots + x'_{n-2} y'_{n-1} \\
&\quad - x'_{n-1} y'_{n-2} + x'_{n-1} y'_0 - x'_0 y'_{n-1}), \\
\text{area}(\mathbf{C}'') &= \frac{1}{2} (x''_0 y''_1 - x''_1 y''_0 + x''_1 y''_2 - x''_2 y''_1 + \dots + x''_{n-2} y''_{n-1} \\
&\quad - x''_{n-1} y''_{n-2} + x''_{n-1} y''_0 - x''_0 y''_{n-1}).
\end{aligned} \tag{42}$$

4.2 poskyryje eksperimentiškai palyginti visi trys variantai O1, O2 ir O3.

Dėl paprastumo toliau šiame skyriuje  $\mathbf{C}' = ([x'_i \ y'_i]^\top, i = \overline{0, n-1})$  žymima pirminio sluoksnio modelio kreivės taškų seka po mastelio suvienodinimo ( $\mathbf{C}''$  seka nekinta).

### 4.1.3 Invariantiškumas poslinkiui

Yra įvairių atvejų, kai reikia suderinti lyginamų sluoksnių kreivių pradžios taškus, pavyzdžiui, pacientas gali kitaip gulėti ant lovos, pozicija gali skirtis ir kai masteliai suvienodinami.

Poslinkio invariantiškumas įgyvendintas dviem žingsniais: pirmiausia pirminio sluoksnio modelio kreivė paslenkama horizontaliai, tada vertikalčiai.

Kaulinio audinio skerspjūvį aproksimuojantis matematinis modelis pasižymi vertikalia simetrija, t. y. vertikali simetrijos ašis kerta  $x'_0$  ir  $x''_0$  pirminiam ir tiksliniam sluoksniui, atitinkamai. Todėl horizontalaus poslinkio invariantiškumas užtikrinamas paslenkant pirminio sluoksnio modelį per  $\Delta x$ :

$$\Delta x = x''_0 - x'_0. \tag{43}$$

Reikia atkreipti dėmesį, kad  $x_0'' - x_0' = \frac{1}{n} \sum_{i=0}^{n-1} (x_i'' - x_i')$ , t. y.  $\Delta x$  yra atitinkamų pirminio ir tikslinio sluoksnių modelių kreivių taškų abscisių vidurkis. Pirminio sluoksnių modelio parametrai tampa  $M' = \langle s', c', l', a' \cdot z, b' \cdot z, x_0' + \Delta x, y_0', 0 \rangle$ , tai yra ekvivalentu  $M' = \langle s', c', l', a' \cdot z, b' \cdot z, x_0'', y_0', 0 \rangle$ .

Surasti optimalų vertikalų pirminio sluoksnių modelio poslinkį  $\Delta y$  yra gerokai sunkiau: modelio kreivė nėra simetriška jokiai horizontaliai tiesei, o kreivės „spyglio“ ilgis ( $y_0 - \min_i y_i$ , kai  $\theta = 0$ ) gali skirtis nuo netgi labai panašių sluoksnių, nes  $y_0$  skirtumą gali iš dalies kompensuoti  $s$  parametras.

Toliau pateiktos sukurtos ir išnagrinėtos kelios skirtingos  $\Delta y$  paieškos strategijos.

#### 4.1.3.1 Atitinkamų taškų palyginimas (ATP)

Paprasčiausias  $\Delta y$  paieškos būdas yra atstumo tarp  $i$ -ojo pirminio sluoksnių modelio kreivės taško ir  $i$ -ojo tikslinio sluoksnių modelio kreivės taško minimizavimas. Toks uždavinys galėtų būti formuluojamas kaip mažiausių kvadratų:

$$\min_{\Delta y} \phi(\Delta y) = \min_{\Delta y} \sum_{i=0}^{n-1} (y_i'' - (y_i' + \Delta y))^2. \quad (44)$$

$\phi$  išvestinė yra

$$\frac{d\phi}{d\Delta y} = \sum_{i=0}^{n-1} 2(y_i'' - (y_i' + \Delta y)) \quad (45)$$

ir išsprendus  $\frac{d\phi}{d\Delta y} = 0$ , gaunamas  $\Delta y$ :

$$\Delta y = \frac{1}{n} \sum_{i=0}^{n-1} (y_i'' - y_i'), \quad (46)$$

t. y.  $\Delta y$  yra atitinkamų pirminio ir tikslinio sluoksnių modelių kreivių taškų ordinačių vidurkis.

Atitinkamų taškų lyginimas turi labai rimtų trūkumų. 35(a) pav. raudona linija pavaizduota pirminio sluoksnio modelio kreivė, mėlyna linija pavaizduota atitinkamo teisingo tikslinio sluoksnio modelio kreivė ir pilka atkarpa sujungti šešiasdešimt pirminio ir tikslinio sluoksnių modelių kreivių taškai. Šių modelių pozicija nustatyta naudojant (46) – aiškiai matyti, kad ji netinkama. Pastūmus raudoną kreivę žemyn galima gauti geresnį sugretinimą (35(b) pav.), tačiau atstumai tarp atitinkamų taškų gali ir padidėti – 35(b) pav. pilka atkarpa yra ilgesnė nei 35(a) pav. Šis pavyzdys rodo, kad (46) netinkamas  $\Delta y$  paieškai.

#### 4.1.3.2 Pilnas mažiausių kvadratų metodas (PMK)


35 pav. aiškiai parodo, kad  $i$ -asis pirminio sluoksnio modelio kreivės taškas turi būti lyginamas ne su  $i$ -uoju tikslinio sluoksnio modelio kreivės tašku, o su artimiausiu tašku ant pastarosios kreivės. Taigi optimalaus  $\Delta y$  paieškos problema galėtų būti formuluojama kaip pilnas mažiausių kvadratų metodas (angl. *total least-squares*):

$$\min_{\Delta y} \phi(\Delta y) = \min_{\Delta y} \sum_{i=0}^{n-1} (y_i'' - (\bar{y}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta y))^2, \quad (47)$$


kur  $\bar{y}'(x_i'', y_i'', \Delta x, \Delta y)$  yra funkcija, gražinanti artimiausio pirminio modelio kreivės (pastumtos per  $[\Delta x \ \Delta y]^T$ ) taško ordinatę nuo  $[x_i'' \ y_i'']^T$ . Kaip ir anksčiau, horizontalaus poslinkio invariantiškumas užtikrinamas su  $\Delta x = x_0'' - x_0'$ . Šio darbo eksperimentuose pirminio modelio kreivė tiesiškai interpoliuojama tarp  $n$  taškų siekiant tiksliai įvertinti  $\bar{y}'$  reikšmę, o (47) lygtis sprendžiama naudojant vienos dimensijos paiešką.

Kai kurie lyginimo pavyzdžiai rodo, kad rezultatai galėtų būti dar geresni. Pavyzdžiui, pirminio (36(a) pav.) ir tikslinio (36(b) pav.) sluoksnių modelių kreivės pavaizduotos 36(c) pav. raudona ir mėlyna kreivėmis, atitinkamai. Šiuose sluoksniuose krūtinkaulis nėra matomas. Modelių kreivės labai panašios tose srityse, kur yra kaulinį audinį vaizduojančių pikselių; dideli skirtumai išryškėja ten, kur kreivė eina per minkštuosius audinius vaizduojančius pikselius, pavyzdžiui, viršuje viduryje. Taigi pilno mažiausių kvadratų metodo

trūkumas yra tas, kad jis vienodai reikšmingai įtraukia į skaičiavimus vietas, kuriose vaizduojami tiek minkštieji, tiek kauliniai audiniai.



35 pav. Kreivių sugretinimas, naudojant atitinkamų taškų palyginimą.



36 pav. Sluoksnių lyginimas, naudojant pilną mažiausių kvadratų metodą: (a) pirminis ir (b) antrinis tos pačios vietos (žmogaus atžvilgiu) sluoksniai, (c) šių sluoksnių modeliai.

#### 4.1.3.3 Svorinis pilnas mažiausių kvadratų metodas (SPMK)

Siekiant išspręsti vietų, kuriose vaizduojami minkštieji audiniai, neapibrėžtumą, jose esantys modelio kreivės taškai neturi būti įtraukti į sluoksnių lyginimą. Tai įgyvendinta įvedant modelio kreivės taškų svorius, kaip aprašyta 4-to skyriaus pradžioje.  $\Delta y$  paieška formuluojama kaip svorinis pilnas mažiausių kvadratų uždavinys (angl. *weighted total least-squares*):

$$\min_{\Delta y} \phi(\Delta y) = \min_{\Delta y} \sum_{i=0}^{n-1} \left( (y_i'' - (\bar{y}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta y))^2 \cdot (w_i'' - \bar{w}'(x_i'', y_i'', \Delta x, \Delta y))^2 \right), \quad (48)$$

kur  $\bar{w}'(x_i'', y_i'', \Delta x, \Delta y)$  yra funkcija, grąžinanti artimiausio pirminio modelio kreivės (pastumtos per  $[\Delta x \ \Delta y]^T$ ) taško svorį nuo  $[x_i'' \ y_i'']^T$ . Kaip ir

anksčiau,  $\Delta x = x_0'' - x_0'$ . Šiame darbe vykdytuose eksperimentuose siekiant tiksliai įvertinti  $\bar{w}'(x_i'', y_i'', \Delta x, \Delta y)$  reikšmę pirminio sluoksnio modelio kreivės taškų svoriai tiesiškai interpoliuoti, o (48) lygtis sprendžiama naudojant vienos dimensijos paiešką.

Šios strategijos trūkumas yra vienmatė paieška, nes jai reikia daug skaičiavimo resursų.

#### 4.1.3.4 Svorinis mažiausių kvadratų metodas (SMK)


Naudojant šią strategiją sprendžiama įprasta mažiausių kvadratų problema:

$$\min_{\Delta y} \phi(\Delta y) = \min_{\Delta y} \sum_{i=0}^{n-1} (y_i'' - (\bar{y}'(x_i'', \Delta x) + \Delta y))^2 w_i'' \cdot \bar{w}'(x_i'', \Delta x), \quad (49)$$

kur  $\bar{y}'(x_i'', \Delta x)$  yra funkcija, gražinanti pirminio modelio kreivės (pastumtos per  $\Delta x$ ) taško ordinatę ties  $x_i''$ , priklausomai nuo to, ar  $i$ -asis tikslinio sluoksnio modelio kreivės taškas  $[x_i'' \ y_i'']^T$  yra viršutinėje, ar apatinėje kreivės dalyje;  $\bar{w}'(x_i'', \Delta x)$  yra pirminio sluoksnio modelio kreivės (pastumtos per  $\Delta x$ ) svoris ties  $x_i''$ , taip pat priklausomai nuo to, ar  $i$ -asis taškas yra viršutinėje, ar apatinėje dalyje. Kaip ir anksčiau,  $\Delta x = x_0'' - x_0'$ .  $w_i''$  yra tikslinio sluoksnio modelio kreivės  $i$ -ojo taško  $[x_i'' \ y_i'']^T$  svoris. Šio darbo eksperimentuose  $\bar{y}'(x_i'', \Delta x)$  ir  $\bar{w}'(x_i'', \Delta x)$  funkcijos gaunamos interpoliuojant pirminio sluoksnio modelį.

Viršutinė ir apatinė kreivės dalys gaunamos tikrinant gretimų kreivės taškų abscises. Kai  $i$  kinta nuo 0 iki  $n - 1$ , kreivės taškai išsidėstę prieš laikrodžio rodyklę nuo „spyglio“ (smailiausio taško). Viršutinei kreivės daliai priklauso taškų seka, prasidedanti ties tokiu  $i$  (pažymėkime jį  $i^*$ ), kuriam galioja nelygybė  $x_{i+1} < x_i$ , ir pasibaigia ties tokiu  $i$  (pažymėkime jį  $i^{**}$ ), kuriam galioja nelygybė  $x_{i+1} > x_i$ . Apatinę kreivės dalį sudaro du likę kreivės posekiai (visi likę kreivės taškai), pirmas prasideda  $i^{**}$ -uoju tašku, pasibaigia – 0-iu; antras prasideda 0-iu tašku, pasibaigia –  $i^*$ -uoju.  $i^*$ -as ir  $i^{**}$ -as taškai yra bendri taškai tiek viršutinei, tiek apatinei dalims. Kreivės dalijimas į viršutinę ir apatinę dalis yra pavaizduotas 37 pav.





37 pav. Kreivės dalijimas į viršutinę ir apatinę dalis.

(49) lygtis gali būti išspręsta analiziškai:

$$\Delta y = \frac{\sum_{i=0}^{n-1} (y_i'' - \bar{y}'(x_i'', \Delta x)) w_i'' \cdot \bar{w}'(x_i'', \Delta x)}{\sum_{i=0}^{n-1} w_i'' \cdot \bar{w}'(x_i'', \Delta x)}. \quad (50)$$

#### 4.1.4 Invariantiškumo užtikrinimas nenaudojant matematinio modelio

Piramidinis Lucas-Kanade algoritmas leidžia rasti geometrinę transformaciją, įvertinančią tiek poslinkį, tiek mastelį, tiek posūkį. Piramidinis Lucas-Kanade algoritmas, aprašytas 2.3.4.4 punkte, randa lyginamų sluoksnių kontrolinius taškus ir jų atitikmenis, ir naudodamas RANSAC metodą, aprašytą 2.3.4.3 punkte, įvertina geometrinę transformaciją. Šie du metodai realizuoti `estimateRigidTransform` funkcijoje OpenCV bibliotekoje. Ši funkcija taikoma dviem sluoksniams (pilkos skalės vaizdams).

Gauta transformacija taikytina tiek pirminio sluoksnio kaulinį audinį vaizduojančių pikselių aibei (pažymėkime rezultata  $\mathbf{B}^*$ ), tiek pirminio sluoksnio matematinio modelio kreivei  $\mathbf{C}$  (pirma įvertinami svoriai).

Šiame darbe piramidinis Lucas-Kanade algoritmas naudojamas įvertinti 3-iaame skyriuje sukurto matematinio modelio efektyvumui.

## 4.2 Sluoksnių palyginimo kriterijai

Turint dviejų sluoksnių matematinių modelių parametrus  $M = \langle s, c, l, a, b, x_0, y_0, \theta \rangle$ , tiesiogiai sluoksnių lyginti negalima, nes:

1. Parametrai  $x_0$ ,  $y_0$  ir  $\theta$  tik nusako kūno padėtį,
2.  $a$  ir  $b$  nusako mastelį, kuris priklauso nuo tomografo nustatymų,
3. Parametro  $s$  nedidelį pokytį gali iš dalies kompensuoti  $y_0$ ,
4.  $c$  ir  $l$  parametrai skirti krūtinkauliui aprašyti, o sluoksniš krūtinkaulio gali ir nekirsti,
5.  $c$  ir  $l$  parametrai gali daryti įtaką parametrai  $b$ .

Dėl šių priešasčių sluoksniams lyginti reikia visos kreivės. Šiame poskyryje pasiūlyti įvairūs lyginimo kriterijai, naudojantys modelio kreivę ir / ar svorius. Pirmieji trys kriterijai kyla tiesiogiai iš poslinkio invariantiškumo užtikrinimo strategijų. Taip pat pateiktas lyginimo kriterijus, visiškai nenaudojantis 3-iame skyriuje sukurto matematinio modelio. 4.3 poskyryje yra pateikti šių lyginimo kriterijų bandymų rezultatai su skirtingomis invariantiškumo masteliui ir poslinkiui užtikrinimo strategijomis.

Paprasčiausias lyginimo kriterijus, be to, atitinkantis 4.1.3.1 papunktyje pateiktą poslinkio invariantiškumo užtikrinimo strategiją, yra atitinkamų taškų lyginimas:

$$\begin{aligned} dist(A'; A'') = \sum_{i=0}^{n-1} & \left( (x_i'' - (x_i' + \Delta x))^2 \right. \\ & \left. + (y_i'' - (y_i' + \Delta y))^2 \right), \end{aligned} \quad (51)$$

kur naudojama atstumų tarp atitinkamų pirminio ir tikslinio sluoksnių modelių kreivių taškų kvadratų suma. Šio kriterijaus trūkumas koreliuoja su 4.1.3.1 papunktyje pavaizduotu trūkumu – atitinkami taškai gali būti toli vienas nuo kito.

Tokiu kriterijaus trūkumu nepasižymintis, be to, atitinkantis 4.1.3.2 papunktyje pateiktą poslinkio invariantiškumo užtikrinimo strategiją, yra pilnas mažiausių kvadratų kriterijus:

$$\begin{aligned} dist(A'; A'') = \sum_{i=0}^{n-1} & \left( (x_i'' - (\bar{x}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta x))^2 \right. \\ & \left. + (y_i'' - (\bar{y}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta y))^2 \right), \end{aligned} \quad (52)$$

kur  $\bar{x}'(x_i'', y_i'', \Delta x, \Delta y)$  yra funkcija, grąžinanti artimiausio pirminio modelio kreivės (pastumtos per  $[\Delta x \ \Delta y]^T$ ) taško abscisę nuo  $[x_i'' \ y_i'']^T$ ; funkcija  $\bar{y}'(x_i'', y_i'', \Delta x, \Delta y)$  yra aprašyta 4.1.3.2 punkte. Šio kriterijaus trūkumas koreliuoja su 4.1.3.2 papunktyje pavaizduotu trūkumu – vienodai reikšmingai įtraukia į skaičiavimus vietas, kuriose vaizduojami tiek minkštieji, tiek kaulinis audiniai.

Tokiu trūkumu nepasižymintis, be to, atitinkantis 4.1.3.3 papunktyje pateiktą poslinkio invariantiškumo užtikrinimo strategiją, lyginimo kriterijus yra svorinis pilnas mažiausių kvadratų:

$$\begin{aligned} dist(A'; A'') = \sum_{i=0}^{n-1} & \left( (x_i'' - (\bar{x}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta x))^2 \right. \\ & \left. + (y_i'' - (\bar{y}'(x_i'', y_i'', \Delta x, \Delta y) + \Delta y))^2 \right) \\ & \cdot (w_i'' - \bar{w}'(x_i'', y_i'', \Delta x, \Delta y))^2. \end{aligned} \quad (53)$$

Sluoksnių lyginimo kriterijus galėtų būti grindžiamas ir vien tik svorių lyginimu:

$$dist(A'; A'') = \sum_{i=0}^{n-1} (w_i'' - \bar{w}'(x_i'', y_i'', \Delta x, \Delta y))^2. \quad (54)$$

Siekiant įvertinti 3-iame skyriuje sukurto matematinio modelio efektyvumą, pasiūlytas ir sluoksnių lyginimo kriterijus, nenaudojantis matematinio modelio, o lyginantis dvi kaulinį audinį vaizduojančių pikselių aibes:

$$dist(\mathbf{B}^*, \mathbf{B}'') = (|\mathbf{B}^*| - |\mathbf{I}| + |\mathbf{B}''| - |\mathbf{I}|) / (|\mathbf{B}^*| + |\mathbf{B}''|), \quad (55)$$

kur  $\mathbf{B}^*$  yra transformuota  $\mathbf{B}'$  aibė,  $\mathbf{I}$  yra  $\mathbf{B}^*$  ir  $\mathbf{B}''$  aibių sankirta,  $|\cdot|$  yra aibės kardinalumas. Čia aibių sankirta suprantama kaip binarinių vaizdų  $\mathbf{B}^*$  ir  $\mathbf{B}''$

loginis IR operatorius, kai lyginami atitinkami pikseliai (angl. *pixel-wise*). (55) formulėje skaitiklį galima suprasti kaip loginį griežtą ARBA (angl. *XOR*) operatorių, pritaikytą  $\mathbf{B}^*$  ir  $\mathbf{B}''$  aibėms.  $dist(\mathbf{B}^*, \mathbf{B}'')$  įgyja reikšmes iš intervalo  $[0; 1]$ .

Jeigu naudojamas 4.1.4 punkte aprašytas sutapdinimo metodas,  $\mathbf{B}'$  transformuoti į  $\mathbf{B}^*$  naudojama matrica  $T$ . Kad būtų įmanoma įvertinti aibių sankirtą  $I$ , transformavimas turi būti atliktas taip, kad  $\mathbf{B}^*$  aibės elementai būtų sveikųjų skaičių vektoriai.

### 4.3 Eksperimentai

Eksperimentais siekiama nustatyti, kokie invariantiškumo užtikrinimo būdai ir sluoksnių lyginimo kriterijai yra geriausi, kokią įtaką registravimo rezultatams daro sluoksnių storis ir matematinio modelio įtaikymui pasirinkta optimizavimo paklaida bei sustojimo sąlyga. Optimizavimui naudojamas Matlab kvazi-Niutono metodas [99]. Invariantiškumo užtikrinimo ir sluoksnių storio įtakos tyrimuose modelio kreivės taškų kiekis pasirinktas  $n = 180$  ir  $n_t = 10$ , optimizavimas stabdomas, kai skirtumas  $\Delta f(\cdot)$  tarp gretimų iteracijų tikslo funkcijos reikšmių yra mažesnis kaip  $10^{-10}$  [100].

#### 4.3.1 Sluoksnių palyginimo kriterijų įvertinimas

Kadangi CT sluoksnių storių dažnai skiriasi, o tai gali paveikti galutinius registravimo rezultatus, sluoksnių lyginimo kriterijai išbandyti su viena tomografinių vaizdų pora, kur sluoksnių storis yra 1,25 mm, pirminis tomografinis vaizdas turi 96 sluoksnius, o tikslinis – 106 sluoksnius. Kiekvienas lyginimo kriterijus išbandytas su visais trimis mastelio pokyčio invariantiškumo užtikrinimo variantais (O1, O2 ir O3) ir keturiomis poslinkio invariantiškumo užtikrinimo strategijomis (ATP, PMK, SPMK, SMK), kiekvieną kartą ieškoma 96 sluoksnių tiksliniame tomografiniame vaizde. Kadangi teisingas sluoksnių indeksas žinomas iš anksto, registravimo paklaida buvo absoliutinis atstumas tarp dviejų tikslinių sluoksnių pozicijų (žmogaus vertikaloje ašyje): nustatyto

pagal (40) formulę ir teisingo. Registravimas vykdomas tikslinio sluoksnio storio tikslumu. Gali būti, kad pirminis sluoksnis yra tarp dviejų tikslinių sluoksnių, tokiu atveju teisingas yra artimesnis. Didesniu tikslumu nustatyti sluoksnio poziciją sudėtinga net radiologui.

Agreguoti (iš 96) registravimo rezultatai – vidutinė paklaida  $\varepsilon_{mean}$  (milimetrais), standartinis nuokrypis  $\sigma$  ir maksimali paklaida  $\varepsilon_{max}$  (milimetrais) – pateikiami 5–8 lentelėse. Siektina paklaida  $\varepsilon_{mean}$  turėtų būti ne didesnė kaip pusė tikslinio sluoksnio storio, šiuo atveju  $\varepsilon_{mean} \leq 0,625$ .

5 lentelė. Registravimo rezultatai, gauti naudojant (51).

	ATP			PMK			SPMK			SMK		
	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
O1	6,58	8,41	36,3	7,10	9,42	46,3	6,47	8,49	36,3	4,53	4,84	26,3
O2	8,88	11,5	47,5	9,30	11,8	47,5	9,22	12,1	46,3	5,42	5,92	26,3
O3	9,96	12,8	56,3	9,23	11,7	47,5	9,52	12,7	56,3	5,14	5,64	26,3

6 lentelė. Registravimo rezultatai, gauti naudojant (52).

	ATP			PMK			SPMK			SMK		
	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
O1	7,24	9,22	38,8	9,97	9,23	38,8	9,92	9,47	38,8	6,9	5,39	25,0
O2	8,63	11,9	46,3	10,1	14,6	60,0	11,3	15,5	60,0	4,15	4,73	26,3
O3	7,72	10,9	46,3	8,74	13,5	60,0	9,17	13,7	60,0	4,99	5,32	31,3

5 ir 6 lentelėse matyti, kad registravimo rezultatai, naudojant tiek atitinkamų taškų lyginimą, tiek pilną mažiausių kvadratų kriterijų, nėra geri, nepriklausomai nuo to, kaip užtikrinamas mastelio pokyčio ar poslinkio invariantiškumas.

7 lentelė. Registravimo rezultatai, gauti naudojant (53).

	ATP			PMK			SPMK			SMK		
	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
O1	0,68	0,76	2,50	1,17	1,41	12,5	0,98	0,60	2,50	0,85	0,69	2,50
O2	0,76	0,87	3,75	0,86	1,24	6,25	0,47	0,66	2,50	0,49	0,69	3,75
O3	0,74	0,86	3,75	0,94	1,22	6,25	0,70	0,74	3,75	0,64	0,67	2,50

8 lentelė. Registravimo rezultatai, gauti naudojant (54).

	ATP			PMK			SPMK			SMK		
	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
O1	0,44	0,67	2,5	0,57	0,76	3,75	0,47	0,61	1,25	0,51	0,61	1,25
O2	0,29	0,53	1,25	0,43	0,69	3,75	0,31	0,54	1,25	0,33	0,55	1,25
O3	0,23	0,52	2,5	0,33	0,55	1,25	0,26	0,51	1,25	0,34	0,56	1,25

Rezultatai 7 ir 8 lentelėse rodo, kad svorių naudojimas leidžia gauti eile geresnį registravimo tikslumą, lyginant su rezultatais 5 ir 6 lentelėse, kur svoriai nebuvo vertinami. Nors (54) kriterijaus vidutinės paklaidos rezultatai su ATP strategija yra geresni nei su SMK strategija, tačiau negarantuoja patikimumo, nes atitinkami lyginamų modelių kreivių taškai gali būti nutolę (žr. 35 pav.). Tai paaiškina, kodėl naudojant ATP strategiją  $\varepsilon_{max}$  yra didesnis nei naudojant SMK strategiją.

#### 4.3.2 Sluoksnių storio įtaka registravimo paklaidai

9 lentelėje pateikti tomografinių vaizdų sluoksnių su įvairiais storiais registravimo rezultatai, naudojant O2 mastelio pokyčio ir SMK poslinkio invariantiškumo užtikrinimo strategijas bei (54) sluoksnių lyginimo kriterijų. (a) stulpelyje nurodytas pirminio sluoksnių storis, (b) – antrinio sluoksnių storis, (c) – pirminių sluoksnių kiekis (tiek registravimo rezultatų yra agreguojami ir pateikiami atitinkamoje eilutėje), (d) – tikslinių sluoksnių kiekis (tarp jų yra ieškoma pirminių sluoksnių). Kiekvienoje eilutėje pateikti vienos lygintų tomografinių vaizdų poros registravimo rezultatai, kur iš pradžių pirminiame tomografiniame vaizde rankiniu būdu atmetami sluoksniai, kurių nėra tiksliniame tomografiniame vaizde, nes registravimo algoritmas negali pats nustatyti, ar pirminis sluoksnių storis yra tiksliniame tomografiniame vaizde. Visi sluoksniai, kurių storis yra 1,25 mm, gauti suleidus kontrastinę medžiagą, o sluoksnių, kurių storis yra 2,5 mm, – be jos. Pirmoje eilutėje reikšmės sutampa su 8 lentelėje O2 eilutėje SMK reikšmėmis.

9 lentelė. Skirtingo storio sluoksnių registravimo rezultatai.

(a)	(b)	(c)	(d)	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
1,25	1,25	96	106	0,326	0,549	1,25
2,5	1,25	48	106	0,156	0,413	1,25
2,5	1,25	49	106	0	0	0
2,5	2,5	49	53	0,102	0,495	2,5
1,25	2,5	103	53	0,121	0,537	2,5
1,25	2,5	106	53	0,142	0,578	2,5

9 lentelėje pateikti rezultatai neparodo aiškaus ryšio tarp sluoksnio storio ir gautos registravimo paklaidos. Kai sluoksnis storesnis, jis ne toks panašus į greta esančius sluoksnius, ir todėl klaidos retėja, tačiau net ir viena klaida tampa reikšmingesnė. Registravimo paklaida nepriklauso nuo kontrastinės medžiagos naudojimo tomografijos metu.

#### 4.3.3 Sluoksnių registravimas piramidiniu Lucas-Kanade algoritmu

10 lentelėje pateikti tomografinių vaizdų sluoksnių su įvairiais storiais registravimo rezultatai, naudojant Piramidinį Lucas-Kanade algoritmą invariantiškumui užtikrinti ir kaulinio audinio taškų (55) bei svorinį (54) sluoksnių palyginimus. (a)-(d) stulpeliai yra analogiški 9 lentelei, eilutėse pateikti tų pačių tomografinių vaizdų porų registravimo rezultatai kaip ir 9 lentelėje.

10 lentelė. Registravimas, kai invariantiškumui transformacijoms nenaudojamas matematinis modelis.

(a)	(b)	(c)	(d)	(55) palyginimo krit.			(54) palyginimo krit.		
				$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
1,25	1,25	96	106	1,00	0,91	3,75	1,95	4,03	38,8
2,5	1,25	48	106	0,60	0,67	2,50	4,66	10,2	40,0
2,5	1,25	49	106	0,43	0,74	2,50	2,12	5,52	38,8
2,5	2,5	49	53	0,61	1,08	2,50	3,01	5,71	40,0
1,25	2,5	103	53	0,34	0,86	2,50	1,84	1,84	7,50
1,25	2,5	106	53	0,33	0,85	2,50	4,58	10,6	45,0

Rezultatai 10 lentelėje rodo, koks svarbus yra pradinis sluoksnių sutapdinimas: galima įvairiais kriterijais lyginti du sluoksnius, tačiau jeigu nebus tinkamai nustatyta padėtis vienas kito atžvilgiu, rezultatai nebus geri. Piramidiniu Lucas-Kanade algoritmu gauta transformacijos matrica netinkama pirminiam vaizdui transformuoti, nes nors šis metodas ir daro nedidelių paklaidų vertindamas transformacijos matricą, tačiau jos lemia dideles galutinio registravimo rezultato paklaidas. Taip pat piramidinis Lucas-Kanade algoritmas netinka tomografiniams vaizdams registruoti, kai vienas vaizdas gautas suleidus kontrastinę medžiagą, kitas – nesuleidus (tokie pavyzdžiai 10 lentelėje pateikti eilutėse, kuriose nurodytas skirtingas sluoksnių storis).

#### 4.3.4 Optimizavimo tikslumo įtaka registravimo paklaidai

Siekiant išsiaiškinti optimizavimo sustojimo kriterijaus ir modelio kreivės taškų kiekio įtaką registravimo tikslumui, atlikti eksperimentai registruojant vieną tomografinių vaizdų porą (tą pačią kaip ir 4.3.1 punkte, kad būtų galima palyginti), esant skirtingam kreivės taškų kiekiui  $n$  ir optimizavimą stabdant pasirenkant skirtingus  $\Delta f(\cdot)$ . Čia  $\Delta f(\cdot)$  yra skirtumas tarp gretimų iteracijų tikslo funkcijos reikšmių. Naudojami O2 mastelio pokyčio ir SMK poslinkio invariantiškumo užtikrinimo būdai ir (54) sluoksnių lyginimo kriterijai. 11 lentelėje pateikti registravimo rezultatai, stulpeliai sugrupuoti pagal optimizavimo sustojimo kriterijų, o eilutėse nurodytas modelio kreivės taškų kiekis.

11 lentelė. Registravimo paklaida priklausomai nuo optimizavimo tikslumo.

$n$	$\Delta f(\cdot) < 10^{-4}$			$\Delta f(\cdot) < 10^{-6}$			$\Delta f(\cdot) < 10^{-8}$			$\Delta f(\cdot) < 10^{-10}$		
	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$	$\varepsilon_{mean}$	$\sigma$	$\varepsilon_{max}$
30	1,38	3,19	30	0,96	1,13	5,0	0,96	0,98	3,75	0,96	0,98	3,75
45	1,47	7,85	77,5	1,46	7,85	77,5	1,43	7,85	77,5	1,43	7,85	77,5
60	0,52	0,67	2,5	0,57	0,7	2,5	0,55	0,72	3,75	0,55	0,72	3,75
90	0,65	0,74	2,5	0,56	0,74	2,5	0,57	0,74	2,5	0,57	0,74	2,50
180	0,34	0,58	2,5	0,38	0,63	2,5	0,34	0,56	1,25	0,34	0,56	1,25



Kiekvienu atveju įvertintas skaičiavimo laikas įtaikant kreivę dviem tomografiniams vaizdams po 106 sluoksnius ir registruojant kompiuteriu, kurio procesorius yra Intel® Core™ i7-2600 @ 3,4GHz, ir Matlab R2013a programine įranga. Taikytas dviejų etapų optimizavimas, tačiau dalinės išvestinės nenaudotos. 12 ir 13 lentelėse pateiktas procesoriaus vieno branduolio darbo laikas sekundėmis optimizuojant ir registruojant, atitinkamai, priklausomai nuo optimizavimo sustojimo kriterijaus ir modelio kreivės taškų kiekio.

12 lentelė. Optimizavimo trukmė.

$n$	$\Delta f(\cdot) < 10^{-4}$	$\Delta f(\cdot) < 10^{-6}$	$\Delta f(\cdot) < 10^{-8}$	$\Delta f(\cdot) < 10^{-10}$
30	497978	520933	529558	524893
45	534591	562763	584072	585623
60	686761	743194	755061	757077
90	1008763	1097189	1132819	1134220
180	1980107	2184475	2264490	2261621

13 lentelė. Registravimo trukmė.

$n$	$\Delta f(\cdot) < 10^{-4}$	$\Delta f(\cdot) < 10^{-6}$	$\Delta f(\cdot) < 10^{-8}$	$\Delta f(\cdot) < 10^{-10}$
30	390	703	359	281
45	453	671	984	62
60	734	656	750	593
90	437	859	453	859
180	531	828	656	187

Galima pastebėti, kad registravimo rezultatai priklauso nuo modelio kreivės taškų kiekio  $n$ . Esant didesniai  $n$  užtenka mažesnio optimizavimo tikslumo  $\Delta f(\cdot)$ . Visais atvejais geriausi rezultatai gaunami, kai  $n = 180$ . Registravimo laikas yra žymiai mažesnis nei modelio įtaikymo laikas, todėl tikslinga pirmiau suskaičiuoti visų CT vaizdo sluoksnių modelių parametrus, o tik po to vykdyti vaizdų lyginimą.

## 4.4 Ketvirto skyriaus išvados

1. Pasiūlytas registravimo metodas yra invariantiškas poslinkiui, posūkiui ir mastelio pokyčiui, todėl sluoksnius galima registruoti nepriklausomai nuo paciento pozicijos lovos atžvilgiu ir tomografo parametrų, lemiančių pikselių dydį. Pasiektas  $\sim 0,1$  mm registravimo tikslumas.
2. Rezultatai neparodo aiškaus ryšio tarp sluoksnio storio ir gautos registravimo paklaidos, tačiau akivaizdžiai matosi, kad kai sluoksnis storesnis, jis ne toks panašus į greta esančius sluoksnius, ir todėl klaidos retėja.
3. Eksperimentai rodo, kad piramidiniu Lucas-Kanade algoritmu gauta transformacijos matrica netinkama pirminiam vaizdui transformuoti, nes dėl nedidelių pokyčių transformacijoje atsiranda didelių pokyčių registravimo rezultatuose: vidutinė paklaida yra 1 mm, o maksimali  $-3,75$  mm. Geriausia su tais pačiais duomenimis pasiekta vidutinė paklaida  $-0,33$  mm, o maksimali  $-1,25$  mm.
4. Esant didesniam modelio kreivės taškų kiekio  $n$  užtenka mažesnio optimizavimo tikslumo  $\Delta f(\cdot)$ . Tačiau ypač geri rezultatai gaunami, kai  $n = 180$ .
5. Išbandytos keturios poslinkio invariantiškumo užtikrinimo strategijos ir trys mastelio pokyčio invariantiškumo strategijos. Geriausi rezultatai pasiekti, kai registruojama atsižvelgiant ne vien į šonkauliais apriboto kontūro formą, bet ir į kaulinį audinį vaizduojančių pikselių tankį atskirų modelio kreivės taškų aplinkoje – taip įvertinami modelio kreivės taškų svoriai. Svorijų naudojimas leido gauti eile geresnį registravimo tikslumą lyginant su geriausiu nesvoriniu metodu.

# 5

## Išvados

### 5.1 Analitinės apžvalgos rezultatai

Projekcinė radiografija ir kompiuterinė tomografija – ypač populiarios diagnostikos priemonės, nes leidžia be chirurginės intervencijos stebėti žmogaus organizmo pokyčius ir pasirinkti tinkamiausią gydymo strategiją. Kompiuteriniu tomografu gaunamos tiriamosios srities trimatės rekonstrukcijos, t. y. skersinio pjūvio dvimačiai vaizdai. Taigi lengvai diferencijuojami pacientų audiniai ir organai. Analizuojant projekcinės radiografijos 2D vaizdus ar kompiuterinės tomografijos 3D vaizdus kyla vaizdų segmentavimo problema. Segmentavimas leidžia išskirti objektus, esančius vaizde. Tinkamo segmentavimo metodo pasirinkimą lemia sprendžiamas vaizdo analizės uždavinys ir kiek yra laiko sprendimui priimti. Segmentavimas dažnai taikomas prieš registravimą, nes segmento kontūrai gali būti naudojami registruojant. Sudėtingesniais atvejais segmentavimą atlieka radiologas rankiniu būdu, t. y. pažymi (apveda) norimą organą vaizde.

Medicininį vaizdų kontūrų paieška yra paprastesnė nei įprastinių nuotraukų, nes medicininiai vaizdai dažniausiai gaunami stacionaria ar pusiau stacionaria įranga: pašaliniai faktoriai daro mažesnę įtaką atskiro pikselio ar vokselio reikšmei. Norint palyginti ar sujungti vaizdus, gautus skirtingu metu, skirtingais įrenginiais ar skirtingais įrenginių nustatymais, taikomi vaizdų registravimo metodai. Tai procesas, kai skirtingi vaizdai transformuojami į vieną koordinatinių sistemą. Medicininį vaizdų tekstūra yra vienodesnė nei įprastinių

nuotraukų, todėl daug dažniau taikomi intensyvumu grindžiami registravimo metodai. Siekiant tikslių analizės rezultatų, segmentuoti ir atskiriems organams aprašyti naudojami ir matematiniai modeliai. Šie leidžia gan paprastomis kreivėmis aproksimuoti kontūrus, nusakančius tiriamus vidaus organus. Matematinų modelių taikymas – tai tematika, kuriai plėtoti dabar atsiranda daugiau skaičiuojamųjų galimybių, turint omeny, kad sprendžiami aproksimavimo uždaviniai kartais būna gana sudėtingi. Didėjant kompiuterinės tomografijos prieinamumui, atsiranda kompiuterinės tomografijos vaizdų saugojimo ir paieškos problemos. DICOM standartu aprašytų vaizdų metaduomenys kartais būna netikslūs ir jais negalima remtis vaizdams lyginti. Tikslesni sprendimai gaunami lyginant sluoksnius, lygiagrečius žmogaus skersinei plokštumai, skirtinguose kompiuterinės tomografijos vaizduose ir ieškoma tų sluoksnių vieta žmogaus vertikaloje ašyje.

## 5.2 Disertacinio darbo išvados

1. Pasiūlytas matematinis modelis, aproksimuojantis šonkaulių skerspjūvį kompiuterinės tomografijos vaizdo sluoksnyje, lygiagrečiame žmogaus skersinei plokštumai, leidžia ir įvertinti paciento posūkį pagal vertikalią ašį tomografijos atlikimo metu.
2. Kaulinį audinį vaizduojančių pikselių tankis ypač didelis stuburo aplinkoje, tad ši vieta gali paveikti bendrą modelio struktūrą. Atkarpos, lygiagrečios žmogaus sagitalinei ašiai, pridėjimas užtikrina gerą šonkaulių sistemos aproksimaciją ir stuburo aplinkoje.
3. Pasiūlyta dviejų žingsnių optimizavimo strategija modelio parametrus rasti: pirmame žingsnyje sprendžiamas supaprastintas (mažesnio kintamųjų skaičiaus) uždavinys, po to optimizavime naudojami visi kintamieji. Parodyta, kad globaliojo optimizavimo problemai spręsti pakanka lokaliajo optimizavimo metodų.
4. Pasiūlytas registravimo metodas yra invariantiškas poslinkiui, posūkiui ir mastelio pokyčiui, todėl sluoksnius galima registruoti

---

nepriklausomai nuo paciento pozicijos lovos atžvilgiu ir tomografo parametrų, lemiančių pikselių dydį. Pasiiektas  $\sim 0,1$  mm registravimo tikslumas.

5. Eksperimentai rodo, kad piramidiniu Lucas-Kanade algoritmu gauta transformacijos matrica netinkama pirminiam vaizdui transformuoti, nes dėl nedidelių pokyčių transformacijoje atsiranda didelių pokyčių registravimo rezultatuose: vidutinė paklaida yra 1 mm, o maksimali – 3,75 mm. Geriausia su tais pačiais duomenimis pasiekta vidutinė paklaida – 0,33 mm, o maksimali – 1,25 mm.
6. Išbandytos keturios poslinkio invariantiškumo užtikrinimo strategijos ir trys mastelio pokyčio invariantiškumo strategijos. Geriausi rezultatai pasiekti, kai registruojama atsižvelgiant ne vien į šonkauliais apriboto kontūro formą, bet ir į kaulinį audinį vaizduojančių pikselių tankį atskirų modelio kreivės taškų aplinkoje – taip įvertinami modelio kreivės taškų svoriai. Svorijų naudojimas leido gauti eile geresnį registravimo tikslumą lyginant su geriausiu nesvoriniu metodu.



# 6

## Bibliografija

- [1] I. H. Witten, E. Frank ir M. A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques*, Third Edition, Boston: Morgan Kaufmann, 2011.
- [2] W. R. Hendee ir E. R. Ritenour, *Medical Imaging Physics*, Fourth Edition, New Jersey, USA: Wiley-Liss, 2002.
- [3] M. O. Güld, M. Kohlen, D. Keysers, H. Schubert, B. Wein, J. Bredno ir T. M. Lehmann, „Quality of DICOM header Information for Image Categorization,“ įtraukta *International Symposium on Medical Imaging*, San Diego, CA, USA, 2002.
- [4] T. Emrich, F. Graf, H.-P. Kriegel, M. Schubert, M. Thoma ir A. Cavallaro, „CT slice localization via instance-based regression,“ įtraukta *Medical Imaging: Image Processing*, 2010.
- [5] F. Graf, H.-P. Kriegel, M. Schubert, S. Pölsterl ir A. Cavallaro, „2D image registration in CT images using radial image descriptors,“ *Medical Image Computing and Computer-Assisted Intervention--MICCAI 2011*, p. 607–614, 2011.
- [6] Á. Fernández, N. Rabin, R. R. Coifman ir J. Eckstein, „Diffusion methods for aligning medical datasets: location prediction in CT scan images,“ *Medical image analysis*, t. 18, nr. 2, p. 425–432, 2014.

- [7] J. Shi, B. Sahiner, H.-P. Chan, L. Hadjiiski, C. Zhou, P. N. Cascade, N. Bogot, E. A. Kazerooni, Y.-T. Wu ir J. Wei, „Pulmonary nodule registration in serial CT scans based on rib anatomy and nodule template matching,“ *Medical physics*, t. 34, nr. 4, p. 1336–1347, 2007.
- [8] S. A. Holcombe, S. C. Wang ir J. B. Grotberg, „Modeling female and male rib geometry with logarithmic spirals,“ *Journal of biomechanics*, t. 49, nr. 13, p. 2995–3003, 2016.
- [9] A. Kumar, J. Kim, W. Cai, M. Fulham ir D. Feng, „Content-based medical image retrieval: a survey of applications to multidimensional and multimodality data,“ *Journal of digital imaging*, t. 26, nr. 6, p. 1025–1039, 2013.
- [10] J. J. Bozzola ir D. Lonnie R., *Electron Microscopy, Second Edition*, New Jersey, USA: Wiley-Liss, 2001.
- [11] M. J. Dykstra ir L. E. Reuss, *Biological electron microscopy: Theory, Techniques, and Troubleshooting*, Norwell: Kluwer Academic Publishers, 2003.
- [12] S. Cheriyaedath, „Types of Electron Microscopes,“ 2013. [Tinkle]. <https://www.news-medical.net/life-sciences/Types-of-Electron-Microscopes.aspx>. [Kreiptasi 2017 09 11].
- [13] R. Dalvi ir R. Abugharbieh, „Fast feature based multi slice to volume registration using phase congruency,“ įtraukta *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2008.
- [14] The Advanced Fertility Center of Chicago, „Early Pregnancy Ultrasound Findings and Pictures at 5 to 6 weeks,“ 2009. [Tinkle]. <http://www.advancedfertility.com/ultraso1.htm>. [Kreiptasi 2017 09 11].
- [15] R. W. Brown, Y. C. N. Cheng, E. M. Haacke, M. R. Thompson ir R. Venkatesan, *Magnetic Resonance Imaging: Physical Principles and Sequence Design, Second Edition*, Wiley Blackwell, 2014.
- [16] F. W. Kremkau, *Sonography Principles and Instruments, Ninth Edition*, Saunders, 2015.



- 
- [17] E. Z. Zhang, J. G. Laufer, R. B. Pedley ir P. C. Beard, „In vivo high-resolution 3D photoacoustic imaging of superficial vascular anatomy,“ *Physics in Medicine & Biology*, t. 54, nr. 4, p. 1035, 2009.
- [18] S. Vaithilingam, T. J. Ma, Y. Furukawa, I. O. Wygant, X. Zhuang, A. D. L. Zerda, O. Oralkan, A. Kamaya, S. s. Gambhir, R. B. Jeffrey ir B. T. Khuriyakub, „Three-dimensional photoacoustic imaging using a two-dimensional CMUT array,“ *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, t. 56, nr. 11, p. 2411–2419, 2009.
- [19] P. Treigys, „Development and Application of Methods in the Graphical Ophthalmological and Thermovisual Data Analysis,“ Technika, Vilnius, 2010.
- [20] F. P. M. Oliveira ir J. M. R. S. Tavares, „Registration of plantar pressure images,“ *International Journal for Numerical Methods in Biomedical Engineering*, t. 28, nr. 6-7, p. 589–603, 2012.
- [21] UCL Department of Medical Physics and Bioengineering, Photoacoustic Imaging Group, „Photoacoustic Imaging,“ 2008. [Tinkle]. <http://www.medphys.ucl.ac.uk/research/mle/images.htm>. [Kreiptasi 2017 09 11].
- [22] P. Allisy-Roberts ir J. Williams, Farrs Physics for Medical Imaging, Second Edition, W.B. Saunders, 2008.
- [23] R. Quinn, R. A. Quinn ir C. C Sigl, Radiography in Modern Industry, Fourth Edition, Eastman Kodak Company, X-Ray Division, 1980.
- [24] R. A. Novelline, Squires Fundamentals of Radiology, Harvard University Press, 1997.
- [25] D. Habermehl, K. Henkner, S. Ecker, O. Jäkel, J. Debus ir S. E. Combs, „Evaluation of different fiducial markers for image-guided radiotherapy and particle therapy,“ *Journal of radiation research*, t. 54, nr. Suppl1, p. i61–i68, 2013.
- [26] W. R. Webb, W. E. Brant ir N. M. Major, Fundamentals of Body CT E-Book, Elsevier Health Sciences, 2014.

- [27] R. R. Carlton ir A. M. K. Adler, *Principles of Radiographic Imaging: An Art and A Science*, Cengage Learning, 2012.
- [28] D. Richfield, „Medical gallery of David Richfield,“ *WikiJournal of Medicine*, t. 1, nr. 2, p. 9, 2014.
- [29] J. Hatton, B. McCurdy ir P. B. Greer, „Cone beam computerized tomography: the effect of calibration of the Hounsfield unit number to electron density on dose calculation accuracy for adaptive radiation therapy,“ *Physics in Medicine & Biology*, t. 54, nr. 15, p. N329, 2009.
- [30] R. Szeliski, „Image Alignment and Stitching: A Tutorial,“ *Foundations and Trends in Computer Graphics and Vision*, t. 2, nr. 1, p. 1–104, 2006.
- [31] M. J. Black ir A. Rangarajan, „On the unification of line processes, outlier rejection, and robust statistics with applications in early vision,“ *International Journal of Computer Vision*, t. 19, nr. 1, p. 57–91, 1996.
- [32] D. Scharstein, R. Szeliski ir R. Zabih, „A taxonomy and evaluation of dense two-frame stereo correspondence algorithms,“ įtraukta *Proceedings IEEE Workshop on Stereo and Multi-Baseline Vision (SMBV 2001)*, 2001.
- [33] B. Glocker, A. Sotiras, N. Komodakis ir N. Paragios, „Deformable Medical Image Registration: Setting the State of the Art with Discrete Methods,“ *Annual Review of Biomedical Engineering*, t. 13, nr. 1, p. 219–244, 2011.
- [34] B. D. Lucas ir T. Kanade, „An Iterative Image Registration Technique with an Application to Stereo Vision,“ įtraukta *Proceedings of the 7th International Joint Conference on Artificial Intelligence - Volume 2*, San Francisco, CA, USA, 1981.
- [35] J.-y. Bouguet, „Pyramidal implementation of the Lucas Kanade feature tracker,“ 2000.
- [36] A. V. Oppenheim ir R. W. Schaffer, *Discrete-Time Signal Processing*, Pearson Education, 2011.

- 
- [37] F. Badra, A. Qumsieh ir G. Dudek, „Rotation and zooming in image mosaicing,“ įtraukta *Applications of Computer Vision, 1998. WACV '98. Proceedings., Fourth IEEE Workshop on*, 1998.
- [38] M. Brown, R. Szeliski ir S. Winder, „Multi-image matching using multi-scale oriented patches,“ įtraukta *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2005.
- [39] I. Zoghlami, O. Faugeras ir R. Deriche, „Using geometric corners to build a 2D mosaic from a set of images,“ įtraukta *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1997.
- [40] A. Bartoli, M. Coquerelle ir P. F. Sturm, „A Framework for Pencil-of-Points Structure-from-Motion,“ įtraukta *8th European Conference on Computer Vision (ECCV '04), Prague, Czech Republic, May 11-14, 2004*, Berlin, 2004.
- [41] J. Matas, O. Chum, M. Urban ir T. Pajdla, „Robust wide-baseline stereo from maximally stable extremal regions,“ *Image and Vision Computing*, t. 22, nr. 10, p. 761–767, 2004.
- [42] K. Rohr, „Localization properties of direct corner detectors,“ *Journal of Mathematical Imaging and Vision*, t. 4, nr. 2, p. 139–150, 1994.
- [43] C. Harris ir M. Stephens, „A combined corner and edge detector,“ įtraukta *Proceedings of Fourth Alvey Vision Conference*, 1988.
- [44] D. G. Lowe, „Distinctive Image Features from Scale-Invariant Keypoints,“ *International Journal of Computer Vision*, t. 60, nr. 2, p. 91–110, 2004.
- [45] C. T. Zahn, „An algorithm for noisy template matching,“ 1974.
- [46] A. Goshtasby ir G. C. Stockman, „Point pattern matching using convex hull edges,“ *IEEE Transactions on Systems, Man, and Cybernetics*, t. 15, nr. 5, p. 631–637, 1985.
- [47] P. J. Besl ir N. D. McKay, „A method for registration of 3-D shapes,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, t. 14, nr. 2, p. 239–256, 1992.

- [48] B. Zitová ir J. Flusser, „Image registration methods: a survey,“ *Image and Vision Computing*, t. 21, nr. 11, p. 977–1000, 2003.
- [49] S. AbdelSayed, D. Ionescu ir D. Goodenough, „Matching and registration method for remote sensing images,“ įtraukta *Geoscience and Remote Sensing Symposium, 1995. IGARSS '95. 'Quantitative Remote Sensing for Science and Applications', International*, 1995.
- [50] T. M. Lehmann, „A two-stage algorithm for model-based registration of medical images,“ įtraukta *Proceedings. Fourteenth International Conference on Pattern Recognition (Cat. No.98EX170)*, 1998.
- [51] R. Kories ir G. Zimmermann, „A versatile method for the estimation of displacement vector fields from image sequences,“ įtraukta *Proceedings of Workshop on Motion: Representation and Analysis*, 1986.
- [52] N. Vujovic ir D. Brzakovic, „Establishing the correspondence between control points in pairs of mammographic images,“ *IEEE Transactions on Image Processing*, t. 6, nr. 10, p. 1388–1399, 1997.
- [53] H. Li, B. S. Manjunath ir S. K. Mitra, „A contour-based approach to multisensor image registration,“ *IEEE Transactions on Image Processing*, t. 4, nr. 3, p. 320–334, 1995.
- [54] M. Muja ir D. G. Lowe, „Fast approximate nearest neighbors with automatic algorithm configuration,“ įtraukta *VISAPP International Conference on Computer Vision Theory and Applications*, 2009.
- [55] M. Muja ir D. G. Lowe, „FLANN - Fast Library for Approximate Nearest Neighbors, User Manual,“ 2013. [Tinkle]. [https://www.cs.ubc.ca/research/flann/uploads/FLANN/flann\\_manual-1.8.4.pdf](https://www.cs.ubc.ca/research/flann/uploads/FLANN/flann_manual-1.8.4.pdf). [Kreiptasi 2017 09 13].
- [56] M. A. Fischler ir R. C. Bolles, „Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography,“ *Communications of the ACM*, t. 24, nr. 6, p. 381–395, 1981.
- [57] P. Torr ir A. Zisserman, „Robust computation and parametrization of multiple view relations,“ įtraukta *Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271)*, 1998.

- 
- [58] P. H. S. Torr ir A. Zisserman, „MLESAC: A New Robust Estimator with Application to Estimating Image Geometry,“ *Computer Vision and Image Understanding*, t. 78, nr. 1, p. 138–156, 2000.
- [59] J. S. Beis ir D. G. Lowe, „Shape Indexing Using Approximate Nearest-Neighbour Search in High-Dimensional Spaces,“ įtraukta *Proceedings of the 1997 Conference on Computer Vision and Pattern Recognition (CVPR '97)*, Washington, 1997.
- [60] E. Rublee, V. Rabaud, K. Konolige ir G. Bradski, „ORB: An Efficient Alternative to SIFT or SURF,“ įtraukta *Proceedings of the 2011 International Conference on Computer Vision*, Washington, 2011.
- [61] E. Rosten ir T. Drummond, „Machine Learning for High-speed Corner Detection,“ įtraukta *Proceedings of the 9th European Conference on Computer Vision - Volume Part I*, Berlin, 2006.
- [62] E. Rosten, R. Porter ir T. Drummond, „Faster and Better: A Machine Learning Approach to Corner Detection,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, t. 32, nr. 1, p. 105–119, 2010.
- [63] M. Calonder, V. Lepetit, C. Strecha ir P. Fua, „BRIEF: Binary Robust Independent Elementary Features,“ įtraukta *Computer Vision -- ECCV 2010: 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5-11, 2010, Proceedings, Part IV*, Berlin, 2010.
- [64] A. Gionis, P. Indyk ir R. Motwani, „Similarity Search in High Dimensions via Hashing,“ įtraukta *Proceedings of the 25th International Conference on Very Large Data Bases*, San Francisco, CA, USA, 1999.
- [65] J. R. Quinlan, „Induction of Decision Trees,“ *Machine Learning*, t. 1, nr. 1, p. 81–106, 1986.
- [66] P. L. Rosin, „Measuring Corner Properties,“ *Computer Vision and Image Understanding*, t. 73, nr. 2, p. 291–307, 1999.

- [67] M. Everingham, „The PASCAL Visual Object Classes Challenge 2006 (VOC2006) Results,“ 2006. [Tinkle]. <http://web.archive.org/web/20150418165611/http://pascallin.ecs.soton.ac.uk/challenges/VOC/databases.html>. [Kreiptasi 2017 09 13].
- [68] Q. Lv, W. Josephson, Z. Wang, M. Charikar ir K. Li, „Multi-probe LSH: Efficient Indexing for High-dimensional Similarity Search,“ įtraukta *Proceedings of the 33rd International Conference on Very Large Data Bases*, Vienna, 2007.
- [69] B. Brendel, S. Winter, A. Rick, M. Stockheim ir H. Ermert, „Bone registration with 3D CT and ultrasound data sets,“ *International Congress Series*, t. 1256, p. 426–432, 2003.
- [70] B. Brendel, S. Winter, A. Rick, M. Stockheim ir H. Ermert, „Registration of 3D CT and ultrasound datasets of the spine using bone structures,“ *Computer Aided Surgery*, t. 7, nr. 3, p. 146–155, 2002.
- [71] E. Ferrante ir N. Paragios, „Slice-to-volume medical image registration: A survey,“ *Medical Image Analysis*, t. 39, p. 101–123, 2017.
- [72] D. L. G. Hill, P. G. Batchelor, M. Holden ir D. J. Hawkes, „Medical image registration,“ *Physics in medicine and biology*, t. 46, nr. 3, p. R1, 2001.
- [73] P. Kovesi, „Phase congruency detects corners and edges,“ įtraukta *The Australian pattern recognition society conference: DICTA 2003*, 2003.
- [74] H. Mahmoud, F. Masulli ir S. Rovetta, „Feature-Based Medical Image Registration Using a Fuzzy Clustering Segmentation Approach,“ įtraukta *Computational Intelligence Methods for Bioinformatics and Biostatistics: 9th International Meeting, CIBB 2012, Houston, TX, USA, July 12-14, 2012 Revised Selected Papers*, Berlin, 2013.
- [75] J. Mitra, S. Ghose, D. Sidibé, A. Oliver, R. Martí, X. Lladó, J. C. Vilanova, J. Comet ir F. Meriaudeau, „Weighted likelihood function of multiple statistical parameters to retrieve 2D TRUS-MR slice correspondence for prostate biopsy,“ įtraukta *2012 19th IEEE International Conference on Image Processing*, 2012.

- 
- [76] A. Yavariabdi, A. Bartoli, C. Samir, M. Artigues ir M. Canis, „Mapping and characterizing endometrial implants by registering 2D transvaginal ultrasound to 3D pelvic magnetic resonance images,“ *Computerized Medical Imaging and Graphics*, t. 45, p. 11–25, 2015.
- [77] A. Gourdon ir N. Ayache, „Registration of a Curve on a Surface Using Differential Properties,“ įtraukta *Proceedings of the Third European Conference-Volume II on Computer Vision - Volume II*, London, 1994.
- [78] J. C. Russ, *The Image Processing Handbook*, Fourth Edition, CRC Press, 2002.
- [79] D. Bradley ir G. Roth, „Adaptive thresholding using the integral image,“ *Journal of Graphics Tools*, t. 12, nr. 2, p. 13–21, 2007.
- [80] M. Kass, A. Witkin ir D. Terzopoulos, „Snakes: Active contour models,“ *International journal of computer vision*, t. 1, nr. 4, p. 321–331, 1988.
- [81] L. D. Cohen, „On active contour models and balloons,“ *CVGIP: Image Understanding*, t. 53, nr. 2, p. 211–218, 1991.
- [82] Y. Boykov, O. Veksler ir R. Zabih, „Fast approximate energy minimization via graph cuts,“ *IEEE Transactions on pattern analysis and machine intelligence*, t. 23, nr. 11, p. 1222–1239, 2001.
- [83] Y. Boykov ir V. Kolmogorov, „An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, t. 26, nr. 9, p. 1124–1137, 2004.
- [84] M. Betke, H. Hong, D. Thomas, C. Prince ir J. P. Ko, „Landmark detection in the chest and registration of lung surfaces with an application to nodule registration,“ *Medical Image Analysis*, t. 7, nr. 3, p. 265–281, 2003.
- [85] Y. Kang, K. Engelke ir W. A. Kalender, „A new accurate and precise 3-D segmentation method for skeletal structures in volumetric CT data,“ *IEEE transactions on medical imaging*, t. 22, nr. 5, p. 586–598, 2003.

- [86] J. Staal, B. van Ginneken ir M. Viergever, „Automatic rib segmentation in CT data,“ *Computer vision and mathematical methods in medical and biomedical image analysis*, p. 193–204, 2004.
- [87] M. W. Kindig ir R. W. Kent, „Characterization of the centroidal geometry of human ribs,“ *Journal of biomechanical engineering*, t. 135, nr. 11, p. 111007, 2013.
- [88] R. M. Haralick, K. Shanmugam ir others, „Textural features for image classification,“ *IEEE Transactions on systems, man, and cybernetics*, nr. 6, p. 610–621, 1973.
- [89] J. Canny, „A computational approach to edge detection,“ *IEEE Transactions on pattern analysis and machine intelligence*, nr. 6, p. 679–698, 1986.
- [90] S. Wold, K. Esbensen ir P. Geladi, „Principal component analysis,“ *Chemometrics and intelligent laboratory systems*, t. 2, nr. 1-3, p. 37–52, 1987.
- [91] J. Feulner, S. K. Zhou, S. Seifert, A. Cavallaro, J. Hornegger ir D. Comaniciu, „Estimating the body portion of CT volumes by matching histograms of visual words,“ įtraukta *Proceedings of the SPIE Medical Imaging 2009 Conference (SPIE)*, Lake Buena Vista, FL, USA, 2009.
- [92] A. Frank ir A. Asuncion, „UCI Machine Learning Repository,“ 2010. [Tinkle]. <https://archive.ics.uci.edu/ml/datasets/Relative+location+of+CT+slices+on+axial+axis>. [Kreiptasi 2017 09 14].
- [93] R. R. Coifman ir S. Lafon, „Diffusion maps,“ *Applied and computational harmonic analysis*, t. 21, nr. 1, p. 5–30, 2006.
- [94] R. Fisher, S. Perkins, A. Walker ir E. Wolfart, „Mathematical Morphology,“ 2003. [Tinkle]. <http://homepages.inf.ed.ac.uk/rbf/HIPR2/matmorph.htm>. [Kreiptasi 2017 11 01].
- [95] C. Tomasi ir R. Manduchi, „Bilateral filtering for gray and color images,“ įtraukta *Computer Vision, 1998. Sixth International Conference on*, 1998.



- 
- [96] R. Fisher, S. Perkins, A. Walker ir E. Wolfart, „Logical AND/NAND,“ 2003. [Tinkle]. <http://homepages.inf.ed.ac.uk/rbf/HIPR2/and.htm>. [Kreiptasi 2017 11 01].
- [97] H. I. Choi, S. W. Choi ir H. P. Moon, „Mathematical theory of medial axis transform,“ *pacific journal of mathematics*, t. 181, nr. 1, p. 57–88, 1997.
- [98] A. M. Andrew, „Another efficient algorithm for convex hulls in two dimensions,“ *Information Processing Letters*, t. 9, nr. 5, p. 216–219, 1979.
- [99] The MathWorks, Inc., „Find minimum of unconstrained multivariable function,“ 2017. [Tinkle]. <https://se.mathworks.com/help/optim/ug/fminunc.html>. [Kreiptasi 2017 11 01].
- [100] The MathWorks, Inc., „Tolerances and Stopping Criteria,“ 2017. [Tinkle]. <https://se.mathworks.com/help/optim/ug/tolerances-and-stopping-criteria.html>. [Kreiptasi 2017 11 01].

## 6.1 Autoriaus publikacijų sąrašas disertacijos tema

### 6.1.1 Straipsniai recenzuojamuose periodiniuose moksliniuose leidiniuose

- [1] **M. J. Bilinskas**, G. Dzemyda, M. Trakymas, „Approximation of the Ribs-Bounded Contour in a Tomography Scan Slice,“ *International Journal of Information Technology & Decision Making*, priimta (doi: [10.1142/S0219622017500298](https://doi.org/10.1142/S0219622017500298)), 2017.
- [2] **M. J. Bilinskas**, G. Dzemyda, M. Sabaliauskas, „Speeding-up the Fitting of the Model Defining the Ribs-bounded Contour,“ *Applied Computer Systems*, t. 21, nr. 1, p. 66–70, 2017.
- [3] **M. J. Bilinskas**, G. Dzemyda, M. Trakymas, „Feature-Based Registration of Thorax CT Scan Slices,“ *Informatica*, t. 28, nr. 3, p. 439–452, 2017.

### 6.1.2 Straipsniai kitose konferencijų medžiagose

- [1] **M. J. Bilinskas**, G. Dzemyda, M. Trakymas, „Computed Tomography Image Analysis: The Model of Ribs-Bounded Contour,“ įtraukta *Proceedings of the 23rd International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision, Plzen, Czech Republic*, 2015.
- [2] **M. J. Bilinskas**, G. Dzemyda, „Optimization in modeling the ribs-bounded contour from computer tomography scan,“ įtraukta *Numerical computations: theory and algorithms (NUMTA-2016): proceedings of the 2nd international conference, Pizzo Calabro, Italy*, 2016.
- [3] G. Dzemyda, **M. J. Bilinskas**, „Modelling the ribs-bounded contour in computer tomography images,“ įtraukta *Proceedings of the Международный конгресс по информатике: Информационные системы и технологии, Minsk, Belarus*, 2016.

# A Priedas

## Šonkaulių, krūtinkaulio ir stuburo segmentavimo C# programinis kodas

```
// 1. Bilateralinis filtravimas
slice = new BilateralFilter2D(5, 5, 70).Apply(slice);

// 2. Lovos paieška
// 2.1. Slenkstis
Bitmap2D<bool> binary = slice.Threshold(0);

// 2.2. Žemiausias taškas
Vector2Di bottomPoint = binary.GetIndicesReversed().First(v => binary[v]);
binary = binary.Dilate(Binary2DOperations.GenerateRoundKernel(2));

// 2.3. Pašalinamas komponentas (jeigu jis ne didžiausias), rišlus bottomPoint
List<Tuple<Vector2Di, int>>
    massCenters = binary.ListOfMassCenterOfConnectedComponents();
int areaOfLargestBlob = massCenters.Max(center => center.Item2);
if (binary.MassCenterOfConnectedComponent(bottomPoint).Item2
    < areaOfLargestBlob)
    slice = slice.And(binary.FilterConnectedComponents(bottomPoint).Negate());

// 3. Kaulų segmentavimas naudojant dvigubą slenkstį
binary = slice.Threshold(170);
binary = slice.Threshold(130).And(binary.FillInside());

// 4. Bandyamas paslėpti širdį
int
    left = binary.GetIndicesWhereTrue().Min(v => v.X),
    right = binary.GetIndicesWhereTrue().Max(v => v.X),
    top = binary.GetIndicesWhereTrue().Min(v => v.Y),
    bottom = binary.GetIndicesWhereTrue().Max(v => v.Y),
    topSpace = 40;
Bitmap2D<bool>
    eroded = binary.Erode(Binary2DOperations.GenerateRoundKernel(7)),
    heart = eroded.FilterConnectedComponents(
        Enumerable.Range(top + topSpace, (bottom - top) / 2 - topSpace)
            .SelectMany(y => Enumerable.Range(left, right - left)
                .Select(x => new Vector2Di(x, y))));
eroded = eroded.And(heart.Negate());
heart = binary.FilterConnectedComponents(heart);
binary = binary.And(heart.Negate());
```

```

// 5. Bandytas paslėpti aortą
Bitmap2D<int> dtI = eroded.DistanceTransform();
IEnumerable<Vector2Di> possibleAortas = dtI.FindLocalMaximalList()
    .Where(v => dtI[v] > 3 && dtI[v] < 9)
    .Select(v => Tuple.Create(v, eroded.MassCenterOfConnectedComponent(v)))
    .Where(tt => tt.Item2.Item2 < 200)
    .OrderBy(tt => (tt.Item2.Item1 - tt.Item1).SquareLength())
    .Select(tt => tt.Item1).ToList();

// 5.1. Aorta, jeigu ji yra, atskiriama nuo stuburo
if (possibleAortas.Count() > 0)
{
    // 5.1.2. Ieškomi didesni komponentai šalia - tai turi būti stuburas
    dtI = binary.DistanceTransform();
    Vector2Di
        biggestBlob = new Vector2Di(0, 0), current,
        aortaC = possibleAortas.First();
    int Radius = 40, aortaRadius = dtI[aortaC], dist;

    for (int y = aortaC.Y - Radius; y < aortaC.Y + Radius; ++y)
        for (int x = aortaC.X - Radius; x < aortaC.X + Radius; ++x)
        {
            current = new Vector2Di(x, y);
            dist = (current - aortaC).SquareLength();
            if (dist < Radius * Radius && dist >= aortaRadius * aortaRadius)
                if (current.IsBounded(dtI.Size)
                    && dtI[current] > dtI[biggestBlob])
                    biggestBlob = current;
        }

    if (biggestBlob.X != 0)
    {
        // 5.1.3. Surandamas kelias tarp jų
        Bitmap2D<byte>
            skeleton = dtI.LinearlyNormalize(0, 255)
                .And(binary.Skeleton()),
            distances = new Bitmap2D<byte>(binary.Size, byte.MaxValue);
        Queue<Vector2Di>
            queue = new Queue<Vector2Di>(new List<Vector2Di> { biggestBlob });
        distances[biggestBlob] = 0;
        Vector2Di next, minDT = new Vector2Di(0, 0);
        while (queue.Count > 0)
        {
            current = queue.Dequeue();
            foreach (Vector2Di n in Vector2Di.N8)
                if ((next = current + n).IsBounded(binary.Size)
                    && distances[next] == byte.MaxValue && skeleton[next] > 0)
                {
                    distances[next] = (byte)(distances[current] + 1);
                    queue.Enqueue(next);
                    if (next == aortaC)
                    {
                        queue.Clear();
                        break;
                    }
                }
        }
    }
}

```

---

```

// 5.2. Jeigu kelias egzistuoja, jis nutraukiamas
if (Vector2Di.N8.Any(v => distances[v + aortaC] < byte.MaxValue))
{
    // 5.2.1. Einama link stuburo ir surandama ploniausia vieta
    Vector2Di thinnestPoint = new Vector2Di(0, 0);
    byte thinness = byte.MaxValue, stepIndex = 0;
    current = aortaC;
    while (distances[next = Vector2Di.N8.Select(v => v + current)
        .Where(v => v.IsBounded(skeleton.Size))
        .MinBy(v => distances[v])] < distances[current])
    {
        ++stepIndex;
        if (skeleton[next] < thinness && skeleton[next] > 0)
        {
            thinness = skeleton[next];
            thinnestPoint = next;
        }
        current = next;
    }

    // 5.2.2. Bandoma nutraukti kelią ties ploniausia vieta
    if (distances[current] == 0)
    {
        Bitmap2D<bool> copy = new Bitmap2D<bool>(binary);
        copy.DrawCircle(thinnestPoint, thinness + 1, false);

        // 5.2.3. Patikrinama, ar nutraukimas sėkmingas
        Bitmap2D<bool> aorta = copy.FilterConnectedComponents(aortaC);
        int maxDist = 0;
        foreach (Vector2Di v in aorta.GetIndicesWhereTrue())
            maxDist = Math.Max(maxDist, (v - aortaC).SquareLength());

        if (dtI[aortaC] * dtI[aortaC] * 2 > maxDist)
            binary = copy;
    }
}

}

}

binary = binary.MorphologyOpen(Binary2DOperations.GenerateRoundKernel(1));

// 6. Paliekami tik tie komponentai, kurie yra rišlūs su:
// 6.1. Iškilioju apvalkalu
List<Vector2Di> seeds = binary.ConvexHull().GetIndicesWhereTrue().ToList();
// 6.2. Trikampiu apačioje
int triangleH = 80, triangeCenter = (left + right) / 2, width = right - left;
width /= 2;
for (int th = 0; th < triangleH; ++th)
    for (int x = 0; x < th * width / (2 * triangleH); ++x)
    {
        seeds.Add(new Vector2Di(triangeCenter + x, bottom - triangleH + th));
        seeds.Add(new Vector2Di(triangeCenter - x, bottom - triangleH + th));
    }
// 6.3. Juosta viršuje
for (int y = top; y < top + 15; ++y)
    for (int x = left; x < right; ++x)
        seeds.Add(new Vector2Di(x, y));
binary = binary.FilterConnectedComponents(seeds);

Bitmap2D<bool> opened = new Bitmap2D<bool>(binary.Size);

```

```
seeds.ForEach(v => opened[v] = true);  
return binary;
```

`slice` yra pilkos skalės sluoksnis. `BilateralFilter2D` yra bilateralinis filtras, kurio parametrai yra branduolio spindulys, atstumo koeficientas ir spalvos koeficientas. `Threshold(t)` metodas pilkos skalės vaizdą paverčia binariniu, kuriame baltas pikselis reiškia, kad pradiniam pilkos skalės vaizde atitinkamoje vietoje buvęs pikselis buvo ne mažesnis kaip  $t$ . `Dilate(kernel)` metodas išplečia binarinį vaizdą naudodamas `kernel` branduolį. `GenerateRoundKernel(r)` metodas sukuria  $r$  spindulio apvalų branduolį.

`ListOfMassCenterOfConnectedComponents()` metodas sudaro sąrašą kortežų, kuriame nurodyti kiekvieno binarinio vaizdo rišlaus komponento masės centras ir plotas. `MassCenterOfConnectedComponent(seed)` metodas sukuria kortežą, kuriame nurodyti komponento, jungaus pikseliui / -iams `seed`, masės centras ir plotas. `FilterConnectedComponents(seed)` binariniame vaizde palieka tik rišlius su pikseliu / -iais `seed` komponentus. `Negate()` metodas sukuria binarinio vaizdo atvirkščią vaizdą, t. y. gaunamas baltas pikselis reiškia, kad atitinkamoje vietoje pradiniam vaizde buvo juodas pikselis, ir atvirkščiai. `And()` metodas gali jungti tiek du binarinius vaizdus, tiek pilkos skalės ir binarinį vaizdus. Pirmuoju atveju vaizde gaunamas baltas pikselis, jei abiejuose pradinuose vaizduose atitinkamoje vietoje buvo balti pikseliai. Antruoju atveju gaunamame vaizde pikselio spalva yra tokia, kokia ji pradiniam pilkos skalės vaizde tuo atveju, jeigu pradiniam binariniame vaizde toje vietoje yra baltas pikselis, kitu atveju – juodas. `FillInside()` baltai nuspalvina tuos juodus vaizdo komponentus, kurie yra ant didesnių baltų komponentų.

`DistanceTransform()` apskaičiuoja binarinio vaizdo atstumo transformaciją, gaunamas pilkos skalės vaizdas. `FindLocalMaximaList()` vaizde suranda lokalius maksimumus (gražina sąrašą taškų). `Skeleton()` sudaro binarinio vaizdo skeletą (gaunamas binarinis vaizdas). `LinearlyNormalize(min, max)` tiesiškai normalizuoja vaizdo pikselių reikšmes intervale nuo `min` iki `max`.

---

`MorphologyOpen(kernel)` metodas vykdo binarinio vaizdo morfologinį atidarymą naudodamas `kernel` branduolį. `ConvexHull()` apskaičiuoja binarinio vaizdo baltų pikselių išorinį apvalkalą ir grąžina taip pat binarinį vaizdą.

Klasė `Vector2Di` aprašo tašką sveikaisiais skaičiais. Jos metodas `IsBounded(size)` patikrina, ar vektorius yra vaizdo, kurio dydis `size`, ribose, o metodas `SquareLength()` grąžina vektoriaus ilgio kvadratą.

Mykolas Jurgis Bilinskas

MATEMATINIO MODELIO SUKŪRIMAS IR TAIKYMAS KRŪTINĖS LAŠTOS  
KOMPIUTERINĖS TOMOGRAFIJOS VAIZDAMS PARAMETRIZUOTI IR REGISTRUOTI

Daktaro disertacija

Fiziniai mokslai, informatika (09 P)

Redaktorė Jorūnė Rimeisytė