



VILNIAUS UNIVERSITETAS  
MATEMATIKOS IR INFORMATIKOS FAKULTETAS  
STUDIJŲ PROGRAMA: INFORMATIKA

**Pilvo aortos aneurizmos ir trombo segmentavimas kompiuterinės  
tomografijos nuotraukose**  
**The Segmentation of the Abdominal Aortic Aneurysm and  
Thrombus in Computed Tomography Images**

Baigiamasis magistro darbas

Atliko: Aušra Šubonienė  
VU el. p.: [ausra.suboniene@mif.stud.vu.lt](mailto:ausra.suboniene@mif.stud.vu.lt)

Vadovas: Prof., Habil. dr. Gintautas Dzemyda  
Recenzentas: Dr. Tomas Plankis

Vilnius  
2022

# Turinys

Santrauka.....	4
Summary.....	5
1 Įvadas.....	6
2 Literatūros apžvalga.....	8
2.1 Šaltinių atranka.....	8
2.2 Pilvo aortos aneurizmos segmentacijai naudojami duomenys.....	9
2.2.3 Duomenų tipai.....	9
2.2.3 Duomenų šaltiniai.....	10
2.2.4 Kiti duomenų parametrai.....	11
2.2.5 Dirbtinai sukurti duomenys.....	11
2.3 Duomenų paruošimas.....	13
2.3.1 Triukšmo pašalinimas.....	13
2.3.2 Rankinis vaizdų žymėjimas.....	13
2.3.3 Automatinis ar pusiau automatinis vaizdų žymėjimas.....	14
2.4 Literatūroje naudotų metodų apžvalga.....	14
2.4.1 Taškų intensyvumu paremti metodai.....	15
2.4.2 Regiono plėtimo (aktyvaus kontūro) metodai.....	15
2.4.3 Tinklelio, morfologijos ir geometriniai metodai.....	16
2.4.4 Neuroniniai tinklai ir gilusis mokymas.....	17
2.4.5 Aktyvus mokymasis.....	18
2.4.6 Kiti metodai.....	19
3. Metodai.....	21
3.1 Neuroniniai tinklai.....	21
3.1.1 ResNet-100.....	21
3.1.2 DeepLab V3.....	22
3.1.3 U-Net.....	23
3.2. Modelių rezultatų įvertinimo metodai.....	25
3.2.1 Dice panašumo koeficientas.....	25
3.2.2 Jaccard panašumo koeficientas.....	26
3.2.3 Binarinė kryžminė entropija.....	26
4 Duomenys.....	28

4.1 Duomenų šaltinis ir pradinis duomenų apdorojimas.....	28
4.2 Duomenų paruošimas neuroniniams tinklams.....	29
4.3 Duomenų augmentacija.....	29
4.4 Duomenų žymėjimo problemos.....	30
4.5 Hounsfield vienetų transformacija.....	33
5 Skaičiavimų resursai.....	35
6 Rezultatai.....	35
6.1 Neuroninių tinklų mokymas su skirtingomis nuostolių funkcijomis.....	35
6.2 Pradinio vaizdo dydžio keitimas.....	38
6.3 Atsitiktinis tinklo svorių pašalinimas.....	38
6.4 Papildoma HU transformacija.....	41
6.5 Segmentacija naudojant du neuroninius tinklus.....	41
7 Išvados.....	45
8 Literatūra.....	47
9 Priedas. Autorės mokslinių publikacijų tekstai.....	54
10 Priedas. Pilvo aortos kontrasto ir trombo segmentavimo kodas.....	82

## **Santrauka**

Pilvo aortos aneurizmos diagnostika ir stebėseną atliekama analizuojant kompiuterinės tomografijos vaizdus, kurie leidžia vartotojams stebėti pilvo aortos aneurizmos būseną paciento kūno skerspjūvio nuotraukų sekoje. Dėl didelio automatizuotų programinės įrangos įrankių, skirtų pilvo aortos aneurizmos vaizdų analizavimui, pilvo aortos aneurizmos diagnostika ir stebėseną ilgai užtrunka. Šiame darbe sprendžiama aortos aneurizmos segmentavimo problema kompiuterinės tomografijos nuotraukose, atskirai išskiriant kontrasto ir trombo regionus. Atliekama literatūros analizė, kurioje apžvelgiami pilvo aortos aneurizmos segmentavimo tyrimai bei apžvelgiamos dažniausios šios temos problemos. Darbe atliekama pilvo aortos aneurizmos segmentacija naudojant tris neuroninius tinklus bei įvairias nuostolių funkcijas. Darbe aprašomi pilvo aortos aneurizmos segmentavimo rezultatai, gauti naudojant neuroninius tinklus su atsitiktinių tinklo svorių pašalinimu bei duomenų transformacijas. Taip pat pasiūlytas pilvo aortos aneurizmos segmentavimo metodas naudojant du atskirai apmokytus neuroninius tinklus, kurių naudojant pasiekiami rezultatai, artimi rezultatams, gautiems naudojant dvigubai didesnę pacientų kiekį.

## Summary

Computed tomography images are used by the medical experts to diagnose and monitor abdominal aortic aneurysm by analysing slices of computed tomography images. As there is a shortage of automatic software tools for the detection and diagnostics of abdominal aortic aneurysm, the process is often performed manually or semi-automatic, which results in long analysis time and increases the risk of the patient not getting treatment on time. In this work literature analysis is performed, which describes the most frequently used types of medical imaging in the abdominal aortic aneurysm research and the methods of preprocessing and marking of images. The segmentation of abdominal aortic aneurysm is performed by training three neural networks with several loss functions. Various data processing methods are used, including cropping, changing scale and ratio of original image. Dropout is used to increase the accuracy of the segmentations. In addition to this, a method for the segmentation of the abdominal aortic aneurism is suggested, which combines two neural networks that were trained to segment different regions. This way similar segmentation results can be achieved to those results, that were achieved using twice as few patients.

## 1 Įvadas

Pilvo aortos aneurizma yra lėtinė liga, kuri negydoma sukelia pilvo aortos plyšimo komplikaciją ir mirtį [RSA+20]. Pilvo aneurizmos diagnostikai ir stebėsenai naudojami kompiuterinės tomografijos vaizdai. Šiuo metu prieinamais medicinos vaizdų analizavimo įrankiais pilvo aortos aneurizmos kompiuterinės tomografijos vaizdų analizė trunka ilgai, nes trūksta automatinių aneurizmos segmentavimo analizavimo ir stebėjimo įrankių [CDE+18]. Kontrastinėje kompiuterinėje pilvo aortos tomografijoje kontrastas yra gerai matomas, todėl jį lengva išskirti neudojant neuroninius tinklus ar morfologines operacijas. Tačiau automatinis trombo segmentavimas yra daug sudėtingesnė problema dėl aplink trombą esančių panašaus intensyvumo vaizdo taškų, vaizduojančių kitus vidaus organus. Taip pat trombas nėra taisyklingos formos, kas dar labiau apsunkina jo segmentaciją.

Šio darbo tikslas yra ištirti pilvo aortos aneurizmos (atskirai kontrasto ir trombo) segmentavimo metodus naudojant neuroninius tinklus bei pasiūlyti pilvo aortos aneurizmos trombą segmentuojantį metodą. Darbe naudojamos kompiuterinės tomografijos pilvo aortos aneurizmos nuotraukos. Darbo hipotezė: neuroniniai tinklai yra tinkama alternatyva tradiciniams metodams pilvo aortos aneurizmos ir jos trombo kaip atskirų regionų segmentavimui. Darbe sprendžiami uždaviniai: pilvo aortos aneurizmos segmentacijos literatūros analizė, duomenų gavimas ir jų paruošimas atliekant reikiamas transformacijas, duomenų žymėjimų problemų sprendimas, tinkamiausio neuroninio tinklo pilvo aortai segmentuoti radimas, pilvo aortos aneurizmos segmentacijų gerinimas.

Šiame darbe atliekama automatinė pilvo aortos kontrasto ir trombo segmentacija naudojant tris neuroninius tinklus: ResNet-100, DeepLab V3 ir U-Net. Lyginami rezultatai, gaunami naudojant skirtingas nuostolių funkcijas: kryžminę entropiją, Dice koeficientą bei nuostolių funkciją, apjungiančią kryžminę entropiją ir Dice koeficientą. Taip pat taikomas programiškai išskaičiuotų trombo žymėjimų paruošimas naudojant morfologines operacijas, aortos ROI išskyrimas, atsitiktinių neuroninio tinklo jungčių pašalinimas ir segmentavimas naudojant sumažinto lango kompiuterinės tomografijos vaizdus. Tarpiniai rezultatai buvo pagerinti naudojant du atskirus neuroninius tinklus aortos kontrasto ir viso aneurizmos regiono segmentavimui. Trombo segmentacija buvo išskaičiuota iš šių dviejų neuroninių tinklų segmentacijų rezultatų.

Dalyvavimas konferencijose:

1. Vilnius University Open Series, 2021. „Pilvo aortos vietos nustatymas krūtinės ląstos tomografinėje nuotraukoje“. Autorė: Aušra Šubonienė.

2. DAMSS: 12th Conference on Data Analysis Methods for Software Systems, 2021. „On the computed tomography image data to diagnose pancreatic cancer using machine learning“. Autoriai: Šubonienė, A., Kurasova, O., Medvedev, V., Kielaitė-Gulla, A., Samuilis, A., Jagminas, D., Strupas K. & Dzemyda, G.

3. Vilnius University Open Series, 2022. „Pilvo aortos aneurizmos segmentavimas neuroniniais tinklais kompiuterinės tomografijos nuotraukose“. Autorė: Aušra Šubonienė.

Autorės publikacijos magistrantūros studijų metu medicininių vaizdų analizės ir segmentavimo tematikoje:

1. Šubonienė, A. (2021). Pilvo aortos vietos nustatymas krūtinės ląstos tomografinėje nuotraukoje. *Vilnius University Open Series*, 106-117. DOI: <https://doi.org/10.15388/LMITT.2021.12>

2. Šubonienė, A., Kurasova, O., Medvedev, V., Kielaitė-Gulla, A., Samuilis, A., Jagminas, D., Strupas K. & Dzemyda, G. (2021). On the computed tomography image data to diagnose pancreatic cancer using machine learning. In *DAMSS: 12th conference on data analysis methods for software systems*, Druskininkai, Lithuania, December 2–4, 2021 (pp. 71-72). Vilnius University Press. DOI: <https://doi.org/10.15388/DAMSS.12.2021>

3. Šubonienė, A. (2022). Pilvo aortos aneurizmos segmentavimas neuroniniais tinklais kompiuterinės tomografijos nuotraukose. *Vilnius University Open Series*, 101-114. DOI: <https://doi.org/10.15388/LMITT.2022.10>

## 2 Literatūros apžvalga

Literatūros apžvalgoje apžvelgiami šaltiniai, analizuojantys pilvo aortos aneurizmos segmentaciją. Šaltiniai buvo atrinkti naudojant „Web of Science“ duomenų bazę. Apžvelgiami dažniausiai naudojami duomenų tipai, jų paruošimas, bei analizuojami dažniausi pilvo aortos aneurizmos segmentavimo metodai, tokie kaip taškų intensyvumu paremti metodai, regiono plėtimo (aktyvaus kontūro) metodai, morfologinių operacijų ir geometriniai metodai, neuroniniai tinklai ir gilusis mokymas, bei aktyvus mokymasis.

### 2.1 Šaltinių atranka

Literatūros apžvalgos metu pilvo aortos aneurizmos segmentavimą nagrinėjantys šaltiniai buvo atrinkti naudojant „Web of Science“ duomenų bazę. Šaltinių buvo ieškoma derinant įvairias paieškos užklausas filtruojant šaltinius pagal temą, straipsnio pavadinimą bei raktinius žodžius. Naudotos paieškos:

- $TS=$ ("abdominal aortic aneurism" OR "AAA") AND  $AK=$ (segmentation)
- $AK=$ ("abdominal aortic aneurism" OR "AAA") AND  $AK=$ (segmentation)
- $(TS=$ (("abdominal aortic aneurism" OR "AAA") AND "segmentation")) OR  $TI=$ ("abdominal aortic aneurism" AND "segmentation")) AND  $AK=$ (segmentation)

Paieška buvo vykdoma visose Web of Science indeksuojamose duomenų bazėse. Šaltiniai buvo filtruojami pagal paskelbimo datą, atrenkant nuo 2010 metų paskelbtas publikacijas. Atlikus paiešką buvo gauti 48 šaltiniai.

Atlikus gautų šaltinių pirminę peržiūrą iš tolimesnės analizės buvo atmetos 8 publikacijos, nesusijusios su sprendžiama problema. Trijose publikacijose buvo nagrinėjama pilvo aortos stento segmentacijos problema ([KVO+12], [KKP+12], [KSK+17]). Šiose publikacijose stentas segmentuojamas naudojant geometrinį stento vielų modelį, kuris netinka pilvo aortos aneurizmos segmentacijai dėl skirtingų geometrinių savybių, todėl šios publikacijos nebuvo įtrauktos. Taip pat buvo atmetas vienas šaltinis, aprašantis kompresijos metodą rankiniu būdu segmentuotiems pilvo aortos aneurizmos ir kitų organų medicininiams vaizdams [AGT+20], bei šaltinis, aprašantis pilvo aortos aneurizmos EVAL operacijos metu naudojamo laido segmentaciją realiu laiku [ZXB+19]. Taip pat viena publikacija tyrė pilvo aortos aneurizmos vystymosi priklausomybę nuo nikotino pelėse [WSY+18]. Nors į paieškos



kriterijus buvo įtraukta segmentacijos raktažodžio būtinybė, dvi publikacijas teko atmesti, nes jose buvo analizuojamas aortos modeliavimas be segmentacijos [JHM+18], [HML+17].

## **2.2 Pilvo aortos aneurizmos segmentacijai naudojami duomenys**

Atliekant automatinę ar pusiau automatinę pilvo aortos aneurizmą literatūros šaltiniuose buvo dažniausiai naudojami kompiuterinės tomografijos aniogamos (CTA) ar magnetinio rezonanso tomografijos (MRI) vaizdai, nors dažniausiai naudojant MRI vaizdus jie buvo analizuojami ne vieni, bet buvo lyginti su kompiuterinės tomografijos vaizdais. Be kompiuterinės tomografijos ir magnetinio rezonanso vaizdų publikacijose pilvo aortos aneurizmos segmentavimas taip pat buvo tiriamas naudojant ultragarso būdu gautus vaizdus. Be pacientų vaizdų tyrimuose taip pat buvo naudojami ir dirbtinai sukurti duomenys. Jais buvo bandoma spręsti duomenų trūkumo problemą ir naudoti kaip papildomą duomenų rinkinį, arba testuoti teorinį modelį ir įvertinti jo efektyvumą.

### **2.2.3 Duomenų tipai**

Literatūroje pilvo aortos aneurizmos segmentacija dažniausiai buvo atliekama naudojant kompiuterinės tomografijos aniogamos (CTA) vaizdus. Kompiuterinės tomografijos (CT) tyrimas yra neinvazinis radiologinis tyrimas, skirtas vidinėms organizmo struktūroms ir jų pakitimams pamatyti, naudojant rentgeno spindulius. Tyrimo metu gaunami tiriamosios srities skerspjuvio dvimačiai vaizdai, kurie suteikia informaciją apie trimatę tiriamojo objekto struktūrą. Tyrimo metu pasiekama gera minkštųjų audinių diferenciacija, ypač gerai išskiriamos kraujagyslės naudojant intraveninį kontrastą. Greita CT tyrimo procedūra sumažina vaizdavimo klaidų kiekį dėl paciento judėjimo.

Dėl daug laiko trunkančio ir sudėtingo kompiuterinės tomografijos vaizdų rinkimo ir žymėjimo dalyje atrinktų šaltinių aneurizmos segmentacija buvo atliekama naudojant itin mažą duomenų kiekį: nuo 1 [MID+17] ar 6 [WSM+11] pacientų vaizdų sekų. Kituose tyrimuose naudojamų vaizdo sekų skaičius buvo daug didesnis, didžiausią duomenų rinkinį sudarė 321 paciento kompiuterinės tomografijos vaizdų sekos [LBH+19]. Taip pat vienoje publikacijoje buvo naudotas MicroCT tyrimas [DKO+19], kuris nuo įprastų CT vaizdų skiriasi tuo, kad MicroCT tyrimu gaunamas didesnės raiškos vaizdas bei galimas mažesnis pjūvio (angl. *slice*) storis.

Antras dažniausiai naudotas vaizdų tipas buvo magnetinio rezonanso tomografija (MRI). MRI skeneriai naudoja stiprų magnetinį lauką, jo gradientus ir radijo bangas kūno

organų vaizdams generuoti. Magnetinio rezonanso tomografijos metu, priešingai nei atliekant kompiuterinę tomografiją, nenaudojami rentgeno spinduliai ar kita jonizuojanti spinduliuotė. Vien tik MRI vaizdai buvo naudojami vienoje publikacijoje [MRG16], kurioje buvo analizuojami 8 pacientų vaizdų sekos.

Dažniausiai naudojant MRI vaizdus jie buvo analizuojami ne vieni, bet buvo lyginti su kompiuterinės tomografijos vaizdais. Nors MRI yra pacientams mažiau kenksmingas tyrimas nei kompiuterinė tomografija, jis užtrunka daug ilgiau ir negali būti taikomas pacientams su metaliniais implantais [DDP+20]

Kompiuterinė tomografija sukuria didesnės raiškos vaizdus nei MRI ir vaizduose turi mažiau artefaktų, kurie MRI vaizduose atsiranda nuo pacientų judesių ar nepilno srauto slopinimo [WTX+21], tačiau naudojant MRI duomenis galima pasiekti beveik tokius pačius gerus rezultatus kaip ir naudojant kompiuterinės tomografijos vaizdus. Atlikus pilvo aortos aneurizmos segmentaciją Dice panašumo koeficientas naudojant MRI vaizdus yra  $0,92 \pm 0,02$  ir mažai skiriasi nuo panašumo koeficiento, gauto naudojant kompiuterinės tomografijos vaizdus:  $0,94 \pm 0,03$  [WTX+21]. Gautas segmentavimas naudojant MRI vaizdus suteikia tiek pat tikslus pilvo aortos aneurizmos skersmens ir tūrio įverčius be kliniškai reikšmingų skirtumų, lyginant su automatiniais ar rankiniais matavimais su kompiuterinės tomografijos vaizdais [WTX+21].

Trys publikacijos tyrė pilvo aortos aneurizmos segmentavimą naudojant ultragarso būdu gautus vaizdus. Gauti rezultatai buvo palyginti su kompiuterinės tomografijos vaizdų rezultatais. Tyrimų metu ultragarso vaizdų rezultatai daug nesiskyrė nuo kompiuterinės tomografijos vaizdų rezultatų, tačiau iš gautų rezultatų negalima daryti išvados, kad kažkuris vienas vaizdo tipas yra geresnis. Viename tyrime gautas Dice panašumo koeficientas ultragarso vaizdams yra  $0,87 \pm 0,12$ , o kompiuterinės tomografijos vaizdams  $0,81 \pm 0,08$  [RMA+17]. Tuo tarpu kitame tyrime gauti rezultatai rodo mažą segmentacijos skirtumą: buvo gautas vidutinis  $0,855$  ultragarso ir kompiuterinės tomografijos segmentacijų panašumo koeficientas, bei apie  $10$  mm vidutinis Hausdorfo atstumas ( $1$  cm paklaida tarp segmentuotos pilvo aortos aneurizmos naudojant ultragarso ir kompiuterinės tomografijos vaizdus) [DDP+16].

### **2.2.3 Duomenų šaltiniai**

Dalyje publikacijų, ypač publikacijose, išleistose anksčiau nei 2013 metais, nebuvo nurodytas duomenų šaltinis. Publikacijoms duomenys, kurių šaltinis buvo norodytas, buvo

renkami iš trijų pagrindinių šaltinių: klinikinių tyrimų, retrospektyviai pagal kriterijus iš tyrimų duomenų bazės, ar iš kitų publikacijų autorių. Dažniausiai duomenys buvo surenkami klinikinių tyrimų metu rengiant publikaciją ir gaunant informuotą sutikimą iš pacientų. Taip pat buvo naudojami vaizdai, gauti iš ligoninių duomenų bazių. Tokiais atvejais vaizdai buvo atrenkami pagal iš anksto apibrėžtus kriterijus atrenkant vaizdus pacientų, kuriems ligoninėje buvo diagnozuota pilvo aortos aneurizma [RWW+20], [LBH+19], [RSO+12]. Dviejų publikacijų autoriai duomenis gavo iš kitų tyrėjų [AG10], [RWW+19].

#### **2.2.4 Kiti duomenų parametrai**

Visi literatūroje aprašytuose tyrimuose pilvo aortos aneurizmai segmentuoti naudojami kompiuterinės tomografijos vaizdai buvo gauti naudojant intraveninę kontrastinę medžiagą. Taip padidinamas segmentacijos tikslumas, nes aortos vidus (angl. *lumen*), prisipildęs kontrastinės medžiagos, tampa daug ryškesnis ir geriau atsiskiria nuo aplink aortą esančių organų bei trombo. Nors kompiuterinės tomografijos vaizdai buvo standartinio dydžio (512, 512), tačiau pacientų vaizdų pjūviai buvo gauti skirtingu intervalu. Mažiausio intervalo vaizdo pjūviais (0,7 mm [FEJ+10] ir 0,8 mm [MG12a]) gaunami didesnės trimatės raiškos vaizdai, tačiau taip pacientams tenka didesnė jonizuojanti spinduliuotė, nes 2 ar 3 kartus padidėja daromų nuotraukų skaičius. Dažniausiai buvo naudojamas 1 mm – 1,5 mm pjūvių storis, tačiau kartais buvo tiriami ir 2,5 mm pjūviai [SDG+10], [MID+17].

Dažniausiai segmentacijos metodai buvo kuriami ir testuojami atrenkant tik priešoperacinius neplyšusios aneurizmos vaizdus, tačiau kartais tiriami ir pooperaciniai pilvo aortos aneurizmos vaizdai (pasiektas  $0,82 \pm 0,07$  Dice panašumo koeficientas [LAK+18]). Pooperacinių vaizdų segmentavimas yra sudėtinga užduotis dėl netaisyklingos aortos formos. Trombo segmentavimas (net ir priešoperacinis) taip pat turi daug iššūkių, nes vaizduose trombas labai panašus į šalia esančius organus. Todėl nors kiti aprašyti tyrimai gavo geresnius aortos aneurizmos segmentacijos rezultatus, [LAK+18] tyrime pasiekti rezultatai taip pat yra geri atsižvelgiant į tai, kad buvo vertinta vien tik trombo segmentacija.

#### **2.2.5 Dirbtinai sukurti duomenys**

Kompiuterinės tomografijos ar magnetinio rezonanso vaizdų surinkimas gali būti brangus ir ilgas procesas, duomenis gali būti sunku gauti dėl galimų privatumo taisyklių pažeidimų. Nors ligoninės galėtų moksliniams tyrimams teikti anonimizuotus pilvo aortos aneurizmos vaizdus be rizikos pažeisti paciento privatumą, vaizdų anonimizavimas

(metaduomenų iš DICOM failų bei tekstinės informacijos iš vaizdo taškų pašalinimas) užtrunka daug laiko. Automatinė anonimizacija galėtų paspartinti šį procesą, tačiau nėra sukurto automatizuoto vaizdų anonimizavimo įrankio, kuris turėtų ypač didelį tikslumą, reikalingą siekiant išvengti teisinių pasekmių nesėkmingo anonimizavimo ir duomenų nutekėjimo atveju.

Duomenų rinkimo ir žymėjimo iššūkius kartais bandoma spręsti sukuriant dirbtinius pilvo aortos aneurizmą modeliuojančius duomenis. Dirbtiniai duomenys gali būti naudojami vieni arba kaip papildomi vaizdai realiems duomenims.

Dirbtiniai duomenys gali būti naudojami pagrindiniam realių duomenų rinkiniui papildyti, kaip tai darė [DJB+12] tyrimo autoriai. Dirbtiniai MRI vaizdai, atkartojantys žmogaus anatomines struktūras, buvo sugeneruojami naudojant paprastas geometrines formas, kurių vaizdai buvo iškraipyti pridedant triušmą, būdingą MRI vaizdams. Gauti vaizdai buvo segmentuoti ekspertų ir atskirai naudoti testuojant autorių sukurtą segmentavimo metodą. Naudojant dirbtinius duomenis buvo gauti geresni rezultatai nei su realiais duomenimis dėl sumažėjusio dirbtinių duomenų sudėtingumo ir įvairovės bei taisyklingesnių anatominių formų dirbtinių duomenų atveju. Vidutinis aortos vidinių taškų Hausdorfo atstumas buvo 1 – 2,24 mm MRI atveju, 1– 1,41 mm naudojant dirbtinius kompiuterinės tomografijos duomenis. Tuo tarpu realių vaizdų rezultatai buvo  $2,92 \pm 1,1$  mm ir  $2,68 \pm 1,25$  mm atitinkamai MRI ir kompiuterinės tomografijos vaizdams [DJB+12]. Skirtumas gali būti paaiškinamas paprastesnėmis ir taisyklingesnėmis struktūromis dirbtiniuose vaizduose. Taip pat juose nėra įvairių netaisyklingų anatominių formų bei tyrimo metu atsiradusių netikslumų dėl netiksliai atlikto testo.

Lyginant kelis segmentavimo metodus patogiu turėti galimybę ypač tiksliai apskaičiuoti segmentuojamo objekto parametrus. [WHL+16] tyrime bendradarbiaujant su gydytojais buvo sukurtas ir 3D spausdintuvu atspausdintas dirbtinis pilvo aortos modelis, kuris vėliau buvo nuskenuojamas naudojant kompiuterinę tomografiją. Autorių tirtas matematinį modelį naudojantis metodas pasiekė mažiausias vidutines aortos ašies bei skersmens paklaidas (atitinkamai  $0,50 \pm 0,27$  mm ir  $0,58 \pm 0,65$  mm). Naudojant visus tirtus metodus (matematinis modelis, regiono plėtimas, lygių aibės (ang. *level sets*) ir komercinis metodas) vidutinės segmentavimo paklaidos buvo mažesnės nei 1,2 mm, tačiau paklaidos didėjo aneurizmos pradžioje ir pabaigoje. Taip pat komercinio modelio segmentacija turėjo didžiausią

maksimalią aortos ašies padėties paklaidą distalinėje pilvo aortos dalyje (4,14 mm paklaida, kai kitų modelių maksimalios aortos ašies paklaidos buvo nuo 1,15 iki 1,31 mm).

Dirbtiniai duomenys taip pat yra naudojami siekiant sukurti trimačio aortos modelio atkūrimą iš dvimačių pjūvių informacijos indeksuojant aortos sienų taškus [JLH17]. Duomenys buvo generuoti keičiant maksimalų aortos skersmenį, asimetriją ir vingiuotumą kiekvienam aortos modeliui. Buvo daroma prielaida, kad visų modelių skerspjūviai yra apvalios formos, bei naudojamas vienodas 1,5 mm aortos sienos storis per visą aortos ilgį. Kiti modelio generavimo parametrai buvo gauti iš prieš tai atliktų tyrimų su 95 % pasikliautimo intervalu. Segmentavus sukurtų modelių skerspjūvius autoriai juos naudojo trimačio objekto vizualizacijai ir aortos sienų savybių skaičiavimui.

## **2.3 Duomenų paruošimas**

Prieš naudojant kompiuterinės tomografijos vaizdus segmentacijai atliekamas jų paruošimas pašalinant triukšmą bei sukuriant pilvo aortos aneurizmos žymėjimus. Vaizdai gali būti žymimi rankiniu, pusiau automatiniu ar automatiniu būdu. Siekiant aukščiausios žymėjimo kokybės taikomas rankinis duomenų žymėjimas, tačiau jis trunka ilgai bei žymėjimo kokybė gali priklausyti nuo eksperto šališkumo žymint vaizdus. Naudojant pusiau automatinius ar automatinius duomenų žymėjimo metodus vaizdai sužymimi greičiau, tačiau galimi įvairūs duomenų žymėjimo netikslumai. Dažnai turint mažai duomenų vaizdai žymimi rankiniu būdu, bet turint daug duomenų taikomas pradinis automatinis žymėjimas, kuris vėliau patikslinamas ekspertų atliktais vaizdų žymėjimais.

### **2.3.1 Triukšmo pašalinimas**

Vaizduose, gautuose naudojant kompiuterinę tomografiją ar MRI, esantis triukšmas pašalinamas naudojant įvairius triukšmo pašalinimo metodus, tokius kaip įprastas *low-pass* filtras [DKO+19], gradientinis ir sigmoidinis filtrai [LYK+17], ar taikant sudėtingesnę daugiapakopę analizę atliekant Gauso Laplaso dekompoziciją (angl. *Laplacian of Gaussian decomposition*) [AFA12].

### **2.3.2 Rankinis vaizdų žymėjimas**

Segmentacijos metodams kurti ir vertinti yra naudojami rankiniu ar pusiau automatiniu būdu segmentuoti vaizdai, kurie atitinka „tikros tiesos“ (angl. *ground truth*) segmentaciją palyginimui. Ši segmentacija gali būti atliekama trimis būdais: pusiau automatine segmentacija naudojant anksčiau sukurtus programinius įrankius [DDP+20], rankiniu būdu

pažymint aortos ir/ar trombo regiono kontūrus [DJB+12], [LJY+10], ar pažymint visus dominančio regiono vidinius taškus. Rankinis duomenų žymėjimas atliekamas vienam [LAK+18] ar dviem [AG10] ekspertams pažymint aortos ir trombo regionus kompiuterinės tomografijos vaizduose, tačiau kartais derinami ir kiti žymėjimo būdai įtraukiaunt ekspertus radiologijos gydytojus ir technologus [LBH+19], [KTT+10] ir vieną vaizdą žymint kelis kartus siekiant gauti geresnį tikslumą ir sumažinti šališkumo įtaką rezultatams.

Žymint vaizdus tyrimams siekiama išvengti šališkumo įvairiais būdais didinant žymėjimą atliekamų ekspertų skaičių bei laiką tarp pakartotinių vieno paciento žymėjimų.

Ekspertų žymėjimo subjektyvumas gali būti sumažinamas didinant ekspertų skaičių ar žymėjimui skiriamą laiką. Žymėjimas gali būti pradedamas nuo pradinio eksperto sužymėjimo. Siekiant sumažinti prisiminimą (ang. *recall*), tarp kelių to paties paciento vaizdų sekų žymėjimų gali būti pridedamas 7 dienų tarpas [WTX+21]. Siekiant pamatuoti to paties žymėtojo tikslumą (ang. *intra-observer variability*) dažnai atliekamas segmentavimas kelis kartus, o matuojant skirtumus tarp stebėtojų (ang. *inter-observer variability*), keli ekspertai žymi tuos pačius vaizdus, ir vėliau atsižvelgiama į jų bendras aneurizmos segmentavimo paklaidas [LBH+19], [DJB+12].

### **2.3.3 Automatinis ar pusiau automatinis vaizdų žymėjimas**

Pradinis duomenų žymėjimas gali būti atliekamas ir automatinio ar pusiau-automatinio būdu naudojant jau sukurtus programinės įrangos įrankius [KTT+12]. Automatinis vaizdų žymėjimas vyksta geičiau. Taip pat buvo pastebėta, kad tokio žymėjimo maksimalaus aortos skersmens įverčiai yra mažiau jautrūs aneurizmos padidėjimo aptikimui nei tūrio įverčiai [KTT+12]. Buvo rasta, kad daugumai pacientų nebuvo nustatytas reikšmingas maksimalaus skersmens pokytis, nors buvo aptiktas tūrio matavimų pokytis. Šie matavimų neatitikimai gali turėti įtakos aneurizmos gydymo reikalingumo nustatymui [RSO+12], kuomet svarbus ne tik aneurizmos segmentavimas, bet ir jos tūrio įvertinimas. Automatinio duomenų žymėjimo rezultatų tikslumas priklauso nuo pasirinktos programinės įrangos, kuomet pasirinkus kitą programinę įrangą gali būti gaunami atkartotini ir tikslūs rezultatai [KTD+11].

## **2.4 Literatūroje naudotų metodų apžvalga**

Pilvo aortos aneurizmos vaizdų analizėje taikomi įvairūs metodai kompiuterinių tyrimų metu gautų vaizdų segmentacijai atlikti. Praktikoje naudojami ir paprastesni metodai, paremti vaizdo taškų intensyvumo histogramos analize ir slenkstinės reikšmės parinkimu, taip pat

naudojami morfologinėmis operacijomis ar kontūro (regiono) plėtimu grįsti metodai. Sudėtingesni segmentavimo metodai naudoja matematinius modelius vaizdų analizėje. Taip pat segmentacijai sėkmingai taikomi įvairių architektūrų neuroninių tinklų metodai. Siekiant didesnio tikslumo ar generalizacijos dažnai naudojama ir kelių metodų kombinacija.

#### **2.4.1 Taškų intensyvumu paremti metodai**

Tai yra paprasčiausi pilvo aortos segmentavimo metodai, tačiau jų rezultatai yra nepastovūs ir gali suprastėti pasikeitus tyrimo aparatui, tyrimo parametrams ar aortos ar venos užsipildymu kontrastine medžiaga. Vienas iš tokių metodų yra [LKP+15] tyrimo autorių aortos segmentacijai naudotas Otsu metodas [Ots79]. Autoriai segmentacijos metu atskiria vaizduose esančius objektus atliekant klasės skirtumų minimizaciją (ang. *minimisation of intra-class variances*).

Dėl rezultatų nepastovumo ir ribotų galimybių taškų intensyvumu paremti metodai dažnai jungiami su kitais metodais. Gali būti naudojamos ir intensyvumo ir gradiento paieškos erdvės, kurios vėliau apjungiamos naudojant kintamos kaimynystės paiešką (ang. *variable neighbourhood search*) ir grafo pjūvių (ang. *graph cut*) struktūras [SKH19]. Tuomet ieškomas lokalus minimumas, kuris būtų bendras minėtoms paieškos erdvėms, analizuojant perėjimus nuo vienos erdvės prie kitos. Naudojant šį metodą autoriai pasiekia 91,88 % Dice panašumą aortos segmentacijai.

Taškų intensyvumu ir grafo pjūviu paremtas metodas buvo ištirtas jį apribojant modelį apibūdinančiais parametrais [FEJ+10]. Toks geometrinis modelis efektyviai apriboja grafo pjūvio segmentaciją nuo nuklydimų į šalia esančias venas ar organus, turinčius panašias intensyvumo reikšmes vaizduose. Gauti rezultatai visai tiksliai segmentuoja trombą tiek dvimatėse nuotraukose (vidutinis atstumas tarp ekspertų segmentacijos ir metodo rezultatų buvo 1,46 mm, std=0,4 mm), tiek ir trimačiame modelyje, kur pasiekiamas absoliutus tūrio skirtumas tik 8,0 %, std=7,0 %.

#### **2.4.2 Regiono plėtimo (aktyvaus kontūro) metodai**

Regiono plėtimo metodas ir įvairūs jo variantai (dar vadinami aktyvaus kontūro metodais) yra dažnai naudojamas pilvo aortos aneurizmos segmentavimo metodas [KPN+10], [DDP+16]. Taikant šį metodą galima pritaikyti erdvinius apribojimus segmentuojamiems objektams, ko negalima padaryti naudojant pikselių intensyvumo histograma grįstus segmentavimo metodus, neapdorojančius erdvinės informacijos.

Dažnai naudojant regiono plėtimo metodus reikalingas vartotojo įsikišimas segmentuojant nuotraukas. Gali būti prašoma nurodyti pirmą ir paskutinį sekos vaizdus, apribojančius aortos išplatėjimą. Taip pat prašoma vartotojo atlikti pradinį žymėjimą netoli aortos vidinių taškų [CLB+20]. Regiono plėtimą taikant ultragarso duomenims buvo gauti aortos segmentavimo panašumo koeficiento įvertinimai nuo 0,82 iki 0,92 [DDP+20] arba nuo 0,78 iki 0,93 [DDP+16].

Galimas regiono plėtimo metodo taikymas su papildomais kitų algoritmų išvestimi gautais apribojimais siekiant pagerinti tikslumą. [MBL+16] tyrimo autoriai pridėjo du pagalbinius algoritmus, kurie pagerina segmentavimo tikslumą trombo viršuje ir apačioje (pacientui stovint). Pirmas pagalbinis algoritmas skirtas geresniam trūkstamų šakų segmentavimui, kitas – aortinio medžio izoliavimui nuo šalia esančių struktūrų.

Regiono plėtimas taip pat kartais taikomas kartu su kitais metodais, tokiais kaip Laplaso Gauso dekompozicija, anizotropinę difuziją, logaritminių kontūrų paiešką [AFA12] ar matematinius modelius [AG10] geometrijoms apriboti. Naudojant tik matematinę modelį aortos segmentacijai buvo gautas 0,87 Dice panašumo koeficientas (autoriai matematinę modelį lygino su kitais metodais, tarp jų ir aktyvaus kontūro, kuriam gautas 0,84 Dice panašumo koeficientas) [RWW+19]. Tačiau taikant regiono plėtimą su matematinio modelio apribojimais buvo gauta mažesnė nei 2,0 mm paklaida, kuri yra priimtina klinikinių taikymų ribose.

### **2.4.3 Tinklelio, morfologijos ir geometriniai metodai**

Pilvo aortos aneurizmos segmentacija taip pat atliekama naudojant tinkleliu paremtą segmentavimo metodą [DKO+19], [LYK+17], [JLH17], kuris gali būti naudingas įvairių aneurizmos charakteristikų įvertinimui, tokių kaip įtempimas ir su juo susijusi plyšimo rizika.

Galimi ir įvairūs geometriniai ir morfologiniai aortos aneurizmos segmentavimo metodai [HD18], [ZKP12], [WSM+11], [MGM+11]. Sėkminga aortos ir trombo segmentacija buvo atlikta kartu naudojant morfologines operacijas bei lygio aibių metodą (ang. *level sets method*) [ZKP12]. Tokiu būdu naudojant ne vien tik morfologines operacijas ištaisoma segmentacijos paklydimo problema, kai šalia segmentuojamo objekto yra panašaus intensyvumo pikseliais žymimų kitų struktūrų (pvz. trombas ir šalia esantys nugaros raumenys turi labai panašų vaizdo taškų intensyvumą, ir juos atskirti yra sudėtinga).

Geometriniai metodai gali būti sėkmingai taikomi tiriant pacientui specifinius požymius nustatant pilvo aortos aneurizmos plyšimo riziką [MGM+11], kuomet radialinio metodo būdu



gauti segmentai buvo išskirstyti į trombo sujungtus komponentus (ang. *connected components*) naudojant takoskyros (ang. *watershed*) algoritimą. Po to buvo atliekama aortos segmentacija ir gautos bendrai vaizdo turiniu grįstos vaizdų charakteristikos.

#### 2.4.4 Neuroniniai tinklai ir gilusis mokymas

Pilvo aortos segmentacijai atrinktuose tyrimuose taip pat buvo naudoti įvairūs neuroninių tinklų variantai. Neuroninių tinklų ir giliojo mokymo metodais pasiekti labai geri rezultatai vaizdų analizėje lėmė ir jų platų pritaikymą medicininių tyrimų vaizduose. Literatūroje aprašyti sėkmingi segmentavimo metodai smegenų augliams [HDW+17], plaučiams [KK16], kasai [FWH+18], prostatai segmentuoti [YYC17], taip pat kelių organų segmentacijai [TPN+17], [ZTW+17]. Segmentuojant vaizdus neuroniniais tinklais tinklo išvestis turi tiek elementų kiek yra vaizdo taškų, ir atlikus segmentaciją kiekvienam vaizdo taškui priskiriama klasė. Pilvo aortos aneurizmo atveju vaizdo taškams priskiriama arba viena iš dviejų (aortos vidiniai taškai ir fonas) arba viena iš trijų (aortos vidiniai taškai, trombas ir fonas) klasių.

Pilvo aortos aneurizmos segmentavimą atliekant su neuroniniais tinklais dažinausiai naudojama U-Net ar pilnai sujungtas konvoliucinis tinklas (ang. *deep convolutional neural network*, *DCNN*), nors galimos ir kitos tinklų struktūros [MG12a], [MG12b], [SDG+10].

Įprastai U-Net neuroninio tinklo mokymo metu kaip įvestis pateikiamas vienas vaizdas, tačiau galimas ir 3D U-Net variantas. [LBH+19] tyrimo autoriai įprastą U-Net tinklą pakeitė į 3D U-Net tinklą, kuris kaip įvestį sugeba priimti kintamo ilgio vaizdų sekas. Autoriai turėjo spręsti nevienodo ilgio pacientų vaizdo sekų problemą, nes atliekant kompiuterinės tomografijos ar MRI tyrimą kiekvienam pacientui gali būti gaunamas skirtingas nuotraukų kiekis vaizdų sekoje. Dėl tyrimo parametrų ir paciento anatominių savybių negalima iš paciento vaizdų sekos atrinkti fiksuoto kiekio vaizdų, kurie būtų pateikiami kaip įvestis U-Net tinklui. Šiai problemai spręsti autoriai pakeitė tinklą taip, kad jo rezultatai nepriklausytų nuo įvesties vaizdų sekos ilgio. Autoriai naudojo grupės normalizavimą (ang. *batch normalisation*) prieš kiekvieną ReLU aktyvacijos funkciją, taip pat buvo pritaikyta išmetimo reguliarizacija su 0,2 išmetimo parametru. Gauti rezultatai buvo beveik vienodi naudojant vaizdus su kontrastu ir be jų, kas buvo mažai tikėtina dėl prastesnio vizualaus aortos atskyrimo vaizduose be kontrasto. Naudojant vaizdus su kontrastu gautas  $0,89 \pm 0,05$  Dice panašumo koeficientas, kuris vaizdų be kontrasto atveju buvo  $0,90 \pm 0,05$  [LBH+19].

Be U-Net pilvo aortos aneurizmai segmentuoti taip pat yra naudojami ir gilieji konvoliuciniai neuroniniai tinklai (DCNN), paremti pilniai sujungta konvoliucinių tinklų architektūra. Tokie neuroniniai tinklai buvo naudojami dviejuose atrinktuose tyrimuose [LAK+18], [LKL+17]. Abiem atvejais gilieji konvoliuciniai neuroniniai tinklai buvo naudojami kartu su holistiškai įdėtu kraštų aptikimo tinklu (ang. *holistically-nested edge detection network*). DetecNet aptikimo tinklas buvo pritaikytas dominančio regiono (ang. *region of interest*) aptikimui. Tuomet buvo panaudota nauja pilnai sujungtų konvoliucijų tinklų architektūra ir tinklas buvo testuotas naudojant 13 pooperacinių pacientų vaizdų sekų [LAK+18]. Autoriai pasiekė 0,82 Dice panašumo koeficientą pooperaciniams pacientų vaizdams. Kitame tyrime buvo gauti panašūs rezultatai, kur Dice panašumo koeficientas pooperaciniams pacientų vaizdams buvo  $0,837 \pm 0,062$ , priešoperaciniams:  $0,790 \pm 0,102$ .

Nors naudojant giliojo mokymo metodus buvo pasiekti geri segmentavimo rezultatai, ypač pooperacinių pacientų vaizdams, šių metodų generalizacija yra sudėtingas uždavinys radiologinių tyrimų vaizdams [ZBL+18]. Atsiradus neatitikimams dėl įrangos, kuria gaunami vaizdai, pakeitimo, pasikeitusių vaizdo gavimo algoritmų kompiuterinės tomografijos metu, ar tyrimus atliekant kitoms demografinėms pacientų grupėms tokio segmentavimo rezultatai blogėja. Toks generalizacijos trūkumas gali reikšmingai pakenkti modelių klinikiniam taikymui, nes modelio tikslumas gali sumažėti atliekant tyrimus su kita įranga, nei buvo naudojama mokymo duomenims gauti [LBH+19].

#### **2.4.5 Aktyvus mokymasis**

Keturiuose analizuotose publikacijose buvo naudojamas aktyvaus mokymosi algoritmas [MAG14], [CAM13], [MG12a], [MG12b]. Aktyvaus mokymo algoritmas bando pasiekti tiksliausią klasifikaciją naudojant mažiausią įmanomą mokymo aibę. Taip minimizuojamos žmogaus pastangos, kurių reikia mokymo duomenims sužymėti. Aktyvaus mokymo algoritmas pradedamas su mažu mokymo duomenų kiekiu. Vykstant apmokymui nauji žymėjimai vaizduose pridedami tik tada, kai jų reikia.

Taip aktyvaus mokymo algoritmas bando pasiekti tiksliausią klasifikaciją naudojant mažiausią įmanomą sužymėtų mokymo duomenų aibę. Vykstant apmokymui sužymėtų mokymo duomenų aibė padidinama tik tuomet, kai to tikrai reikia. Mokymo metu vartotojui pateikiami vaizdo taškai, kurių klasifikacija yra labiausiai neaiški modeliui. Tuomet vartotojui sužymėjus neaiškius pikselius jie yra įtraukiami į mokymo aibę ir atliekama sekanti mokymo iteracija [GCM+11]. Tokiu būdu modelio mokymas optimizuojamas išnaudojant sunkiai

klasifikuojamus pavyzdžius ir maksimizuojamos apmokyto modelio generalizacijos galimybės.

Naudojant aktyvų mokymą galima taikyti įvairius klasifikavimo algoritmus, tačiau dauguma atrinktų šaltinių, naudojančių aktyvų mokymą, geriausius rezultatus gavo naudojant atsitiktinio miško klasifikatorių. Naudojant atsitiktinį mišką ir aktyvų mokymą buvo pasiekti geri aortos ir trombo segmentavimo rezultatai kurių Dice panašumo koeficientas buvo apie 0,95 po 6 mokymo iteracijų [MG12b]. Šis metodas pasiekia vaizdo taškų klasifikavimo tikslumą iki 0,99 po 4 iteracijų [MAG14]. Viename tyrime taip pat buvo naudojamas kitas dendritinis klasifikatorius (ang. *bootstrapped dendritic classifier*) [CAM13].

#### **2.4.6 Kiti metodai**

Be jau aptartų pilvo aortos aneurizmos segmentavimo metodų atrinkti šaltiniai analizavo ir grafų analizės pagrindu kurtus metodus.

Vieno tyrimo autoriai taikė Dijkstros ir Bellman-Ford trumpiausio kelio paieškos algoritmus aortos segmentacijai [KTT+10]. Kitame tyrime naudota 3D paieška grafe, kuri gali aptikti aortos ir ją supančio trombo paviršius tuo pačiu metu naudojant grafą, sukurtą iš trikampių tinkleliu aproksimuoto aortos paviršiaus. Vidutinės aortos bei trombo paviršiaus segmentavimo paklaidos buvo atitinkamai  $0,99 \pm 0,18$  mm ir  $1,90 \pm 0,72$  mm, kas patenka į priimtina paklaidą klinikiniam taikymams [LJY+10].

1 lentelėje pavaizduota literatūros apžvalgoje apžvelgtų šaltinių santrauka. Šaltiniai išskirstyti pagal taikomą pilvo aortos aneurizmos analizės metodą. Ten, kur publikacijose buvo nurodyti Dice koeficiento įverčiai, jie yra nurodyti lentelėje. Kaip matoma 1 lentelėje, Dice koeficientas trombo segmentacijai yra daug mažesnis nei kontrasto segmentacijos ar bendros trombo ir kontrasto segmentacijos įvertis. Tai galima paaiškinti sudėtinga trombo anatomija, jo netaisyklinga forma. Taip pat trombą žyminčių vaizdo taškų intensyvumas yra labai panašus į aplink aortą esančių kitų anatominių struktūrų vaizdo taškų intensyvumą. Be to aplink aortą esantys raumenys vizualiai yra panašūs į aplink aortą galintį atsirasti tromba net tuose paciento vaizduose, kur trombo nėra. Todėl yra sudėtinga trombą atskirti nuo kitų šalia kontrasto esančių anatominių struktūrų ir identifikuoti, ar vaizde matomas trombas, tačiau net tą atlikus yra sudėtinga identifikuoti trombo ribas kompiuterinės tomografijos vaizduose.

1 lentelė. Literatūros apžvalgos šaltinių detalės

Metai		Sprendžiamas segmentacijos uždavinys	Duomenų tipas	Pacientai	Pjūvio storis, mm	Pjūvių skaičius	Dice panašumo koeficientas			Kiti segmentavimo rezultatai
							Kontrastas	Trombas	Aneurizma	
Taškų intensyvumas										
2010	[FEJ+10]	Taip	CT	8	0.7- 1.2					Vidutinis tūrio skirtumas: 8.0%
2015	[LKP+15]	Ne	CT	28						
2019	[SKH19]	Taip	3D CT	20	1- 1.25				0,919 ± 0,29	
2020	[RWW+20]	Ne	CT	150						
Regiono plėtimas										
2012	[AFA12]	Taip	CT, MRI							
2016	[MBL+16]	Ne	3D CT	14						
2016	[DDP+16]	Taip	3D US	13					0.93	
2020	[CLB+20]	Ne	CT, US	26	0.67, 2					Vidutinis tūrio skirtumas: 2.5%
2020	[DDP+20]	Taip	CT	40	3				0.92	
2021	[WTX+21]	Taip	CT, MRI	30	1.3	52-60	0.91 ± 0.03		0,92 ± 0,02	
Tinklėlio, morfologijos ir geometriniai metodai										
2011	[WSM+11]	Ne	CT	1		6				
2011	[MGM+11]	Ne	CT							
2012	[ZKP12]	Taip	CT	10						
2017	[LYK+17]	Taip	CT	145					0.86 ± 0.06	
2017	[JLH17]	Ne	Dirbtiniai duomenys							
2018	[HD18]	Taip	CT	40						
2019	[DKO+19]	Ne	MicroCT	2						
Neuroniniai tinklai										
2010	[SDG+10]	Ne	CT	20	2.5					
2017	[LKL+17]	Taip	CT	38					0,814 ± 0,087	
2018	[LAK+18]	Taip	CT	13					0,82 ± 0,07	
2019	[LBH+19]	Taip	CT	321					0,873 ± 0,129	
2020	[DBZ+20]	Taip	CT	30		450-1300			0,94	
Aktvūs mokymai										
2011	[MAG14]	Ne	CT	8	1					
2012	[MG12a]	Taip	CT		0,8					
2013	[CAM13]	Taip	CT							
Kiti metodai										
2010	[LJY+10]	Taip	CT	9	1					
2010	[KTT+10]	Ne	CT	34		2				
2011	[KTD+11]	Ne	CT	40		2				
2012	[DJB+12]	Taip	Dirbtiniai duomenys	44						Hausdorff atstumas (mm): 3,09 ± 1,81
2012	[KTT+12]	Ne	CT	56						
2012	[RSO+12]	Ne	CT	100	3					
2016	[MRG16]	Taip	MRI	8						Vidutinis kontūrų persidengimas 79%. Centrinės linijos paklaida (mm) 0,50 +- 0,27. Spindulio klaida (mm) 0,58 +- 0,65
2016	[WHL+16]	Taip		1	8					
2017	[RMA+17]	Ne	CT ir US	81						
2017	[MID+17]	Ne	CT	1	2.5					
2019	[RWW+19]		CT		0,628				0,87	

### 3. Metodai

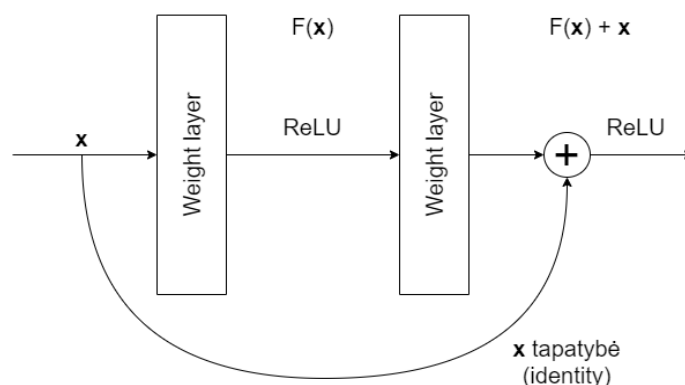
Šiame darbe pilvo aortos aneurizmos segmentacijai buvo naudoti įvairūs konvoliucijomis paremtų neuroninių tinklų variantai: ResNet-100, ir DeepWeb v3. Taip pat apžvelgiami segmentacijų vertinimo metodai.

#### 3.1 Neuroniniai tinklai

Konvoliucijomis paremti neuroniniai tinklai gali spręsti semantinio segmentavimo uždavinį. Nors paprasti konvoliuciniai tinklai gerai sprendžia klasifikavimo užduotį, atliekant vaizdų segmentaciją galimi prastesni rezultatai, nes prarandamas ryšys tarp požymio žemėlapių (ang. *feature maps*) ir pradinio vaizdo taškų. Vienas tokios problemos sprendimo būdų yra naudoti U-Net neuroninį tinklą, kuris dekoderio pabaigoje naudoja originalų vaizdą kaip papildomą sluoksnio įvestį. Šiame darbe be U-Net neuroninio tinklo taip pat buvo išbandyti ResNet-100 ir DeepLab V3 neuroniniai tinklai.

##### 3.1.1 ResNet-100

ResNet yra semantinės segmentacijos uždaviniams spręsti skirtas neuroninis tinklas, sukurtas siekiant sumažinti nykstančio gradiento problemą giliuose neuroniniuose tinkluose [HZR+16]. Iki ResNet įprastas būdas pagerinti klasifikavimo ar segmentacijos tikslumą naudojant konvoliucinius tinklus buvo didinti jų sudėtingumą pridėdant papildomų sluoksnių. Tačiau tokios neuroninių tinklų architektūros dažnai susidurdavo su nykstančio gradiento problema. Tinklo mokymo metu naudojant klaidos skidimą atgal į pradinius sluoksnius, gradientas dažnai tapdavo nepastebimai mažas dėl didelio kiekio daugybos operacijų.



1 pav. ResNet neuroninio tinkle naudojama tapatumo jungtis, formuojanti likučių (ang. *residuals*) bloką

Apmokant tokius gilius neuroninius tinklus dažnai galima pastebėti, kad gilėjant neuroniniam tinklui jo pasiektas tikslumas dažnai sustoja arba net pradeda blogėti. ResNet neuroninis tinklas siekia išvengti šios problemos naudodamas tapatumo jungtį (ang. *identity connection*), kuri apeina vieną ar daugiau sluoksnių, sujungdama sluoksnius į likučių bloką (ang. *residual block*), pavaizduotą 1 pav.

ResNet neuroninio tinklo autoriai siūlo vietoj neuroninio tinklo, aproksimuojančio  $H(x)$  funkcijas naudoti tinklą, aproksimuojantį likučių funkcijas  $F(x)=H(x)-x$  [HZR+16]. Tapatumo sąryšio įvedimas neprideda papildomų tinklo parametrų, todėl skaičiavimo sudėtingumas yra beveik toks pat, kaip ir paprastų neuroninių tinklų. Bloko įvesties ir išvesties dimensijos turi būti vienodos, bet tai yra vienintelis apribojimas bloko vidaus operacijoms. Likučių blokas dažnai sujungia kelias konvoliucines operacijas. Klaidos sklidimo atgal metu gradiento sklidimas vyksta naudojant naujai įvestą tapatumo ryšį, todėl apeinami likutinio bloko vidiniai svoriai ir sumažinama nykstančio gradiento problema. Naudojant ResNet tapatumo ryšius ir konvoliucinius sluoksnius, sujungtus į likučių blokus, buvo sėkmingai apmokyti 50 ir 100 sluoksnių gylio konvoliuciniai neuroniniai tinklai [HZR+16].

### 3.1.2 DeepLab V3

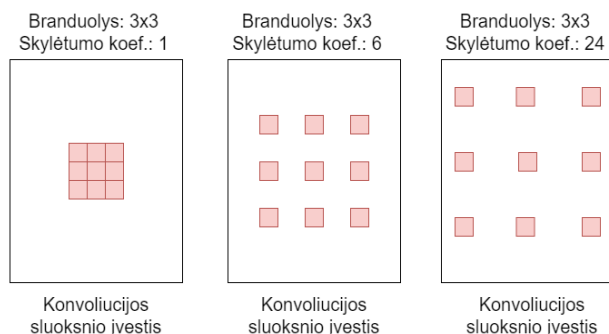
DeepLab V3 gilusis neuroninis tinklas yra neuroninis tinklas, pritaikytas segmentacijos uždaviniui spręsti, nes dėl skylėtų konvoliucijos operacijų požymių žemėlapis (ang. *feature map*) nesumažinamas tiek, kiek kituose pilnai konvoliuciniuose tinkluose, todėl prarandama mažiau informacijos apie vaizduose ensančių objektų vietą [CPS+17].

Sprendžiant segmentacijos uždavinį dažna pilnai konvoliucinių tinklų problema yra ta, kad atliekant konvoliucijos operacijas per daug sumažinamas sekančių konvoliucijos sluoksnių įvesties 2D dydis. Taip gali būti prarandama per daug erdvinės informacijos. Tai dažnai lemia prastesnę segmentacijos tikslumą, nes iš mažo dydžio paskutinių konvoliucijų įvesties reikia atkurti didelio dydžio vaizdo taškus.

DeepLab V3 neuroninis tinklas naudoja išplėstų konvoliucijų (ang. *dilated convolutions*) idėją iš DilatedNet konvoliucinio tinklo [YK15], bet DeepLab V3 atveju vienodai išplečiami visi filtro taškai. Skylėtos konvoliucijos operacijos, naudojamos DeepLab V3 konvoliuciniame neuroniniame tinkle, apibrėžiamos kaip:

$$y[i] = \sum_k x[i+r \cdot k] w[k] ,$$

kur kiekvienoje  $\uparrow$  vietoje esančiam išvesties  $y$  elementui ir filtrui  $w$ , skylėta konvoliucija yra taikoma visam požymių žemėlapiui  $x$ . Skylėtumo koeficientas  $r$  atitinka žingsnio ilgį (ang. *stride*), kurį naudojant gaunama įvesties imtis. Tai atitinka įvesties  $x$  konvoliucijos operaciją su  $\uparrow$  viršų atrinktais (ang. *upsampled*) filtrais, kurie gaunami pridėdant  $r-1$  nulį tarp dviejų iš eilės einančių filtro reikšmių kiekvienai erdvės dimensijai. Skirtingos skylėtos konvoliucijos operacijos pavaizduotos 2 pav.



2 pav. Skylėtų konvoliucijos operacijų pavyzdžiai

DeepLab V3 autoriai taip pat taiko skylėtos erdvinės piramidės grupavimą (ang. *atrous spatial pyramid pooling*) konvoliucijos blokuose [CPS+17]. Tai yra skylėta SPP versija, naudojama SPPNet tinkle [HZR+15]. Keli skylėtų konvoliucijų filtrai su skirtingais skylėtumo koeficientais yra taikomi konvoliucijos sluoksnio išvesčiai, kurių rezultatai vėliau apjungiami. Šis metodas pagerina objektų, kurių skalės vaizduose gali daug skirtis, aptikimą.

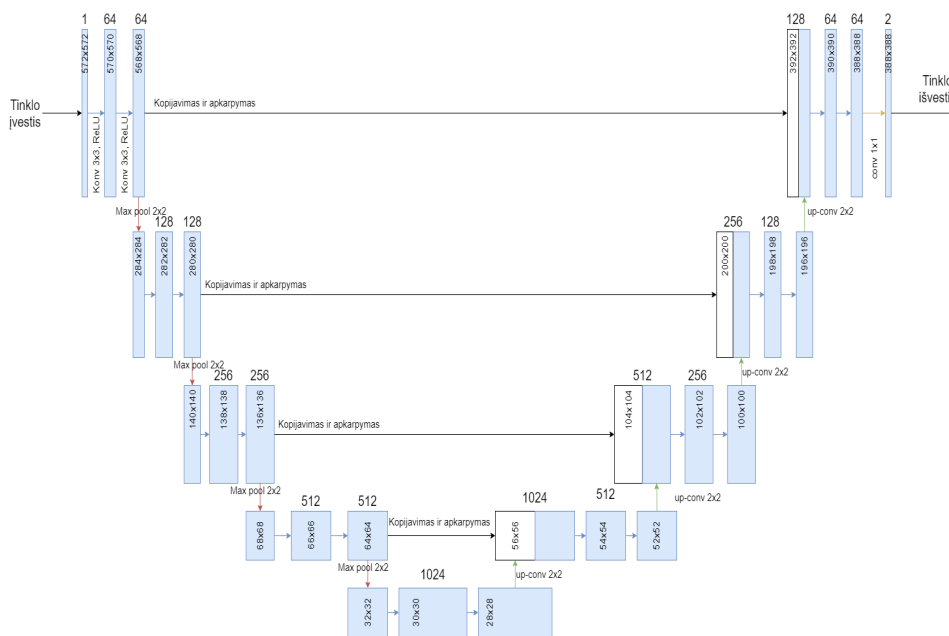
### 3.1.3 U-Net

U-Net neuroninio tinklo architektūra buvo sukurta remiantis pilno konvoliucinio tinklo architektūra [RFB15] ir buvo skirta semantinei segmentacijai pagerinti medicininiuose vaizduose. Tinklo architektūra sudaryta iš dviejų kelių. Pirmasis kelias yra duomenų sutraukimo kelias, taip pat vadinamas enkoderiu (ang. *encoder*), kuris naudojamas vaizdo duomenų kontekstui rasti. Antrasis kelias yra išplėtimo kelias, kuris dar yra vadinamas dekoderiu (ang. *decoder*), ir yra simetriškas enkoderio tinklui. Dekoderis suteikia galimybę gauti tikslią objektų lokalizaciją pradiname vaizde, ne tik apibendrintą informaciją, kuri yra gaunama kaip enkoderio išvestis. Dekoderis naudoja transponuotas konvoliucijos operacijas ir yra nuo pradžios iki galo pilnai konvoliucinis tinklas (ang. *fully convolutional network, FCN*).

U-Net tinklą sudaro tik konvoliuciniai sluoksniai be pilnai sujungto sluoksnio (ang. dense layer). Todėl U-Net tinklas kaip įvestį gali priimti bet kokio dydžio vaizdą. Autorių pasiūlyta U-Net tinklo architektūra pavaizduota 3 pav.

Kairėje U-Net struktūros dalyje matoma enkoderio dalis, kur taikomos įprastos konvoliucijos operacijos ir maksimalaus grupavimo (ang. max pooling) sluoksniai. Enkoderis sumažina U-Net įvesties vaizdo dydį, bet padidina įvesties gylį. Taip neuroninis tinklas sugeba atpažinti kokia informacija yra vaizde, bet praranda galimybę nustatyti įvesties vaizdo vietą, kurioje ta informacija yra.

Kairėje U-Net struktūros dalyje yra dekoderio dalis, kurioje taikomos transponuotos ir įprastos konvoliucijos operacijos. Šioje U-Net neuroninio tinklo dalyje vaizdų dydis yra padidinamas iki originalaus įvesties dydžio ir sumažinamas gylis, kuris buvo padidėjęs po enkoderio dalies. Dekoderis atkuria enkoderio prarastą informaciją apie tai, kur yra atpažintus objektus žymintys vaizdo taškai. Siekiant tiksliau atlikti objektų segmentacijas vaizduose, kiekvienas įvesties dydį keičiantis dekoderio žingsnis naudoja informaciją iš atitinkamo dydžio enkoderio įvesties. Taip sujungiami dekoderio transponuotų konvoliucijos sluoksnių išvesties sluoksniai su enkoderio gautais požymių žemėlapiais (ang. *feature maps*).



3 pav. U-Net tinklo architektūra



### 3.2. Modelių rezultatų įvertinimo metodai

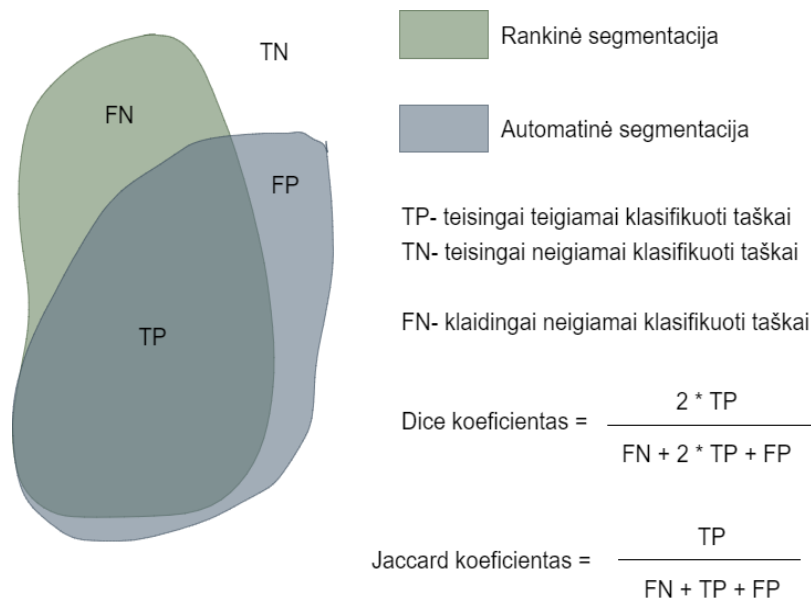
Segmentavimo rezultatai gali būti kiekiškai vertinami taikant Dice panašumo koeficientą arba sankirtos ir sąjungos santykį. Šie segmentavimo įverčiai parodo, kaip tiksliai segmentuotas regionas persidengia su tikra ekspertų atlikta segmentacija.

#### 3.2.1 Dice panašumo koeficientas

Dice panašumo koeficientas [Dic45] naudojamas kiekiškai įvertinti dviejų imčių panašumą. Vaizdų semantinės segmentacijos atveju Dice koeficientas interpretuojamas kaip panašumas tarp tikros objekto segmentacijos ir segmentacijos spėjimo, gauto naudojant segmentacijos modelį. Dice koeficientas apskaičiuojamas kaip dvigubo sankirtos dydžio ir abiejų aibių dydžių sumos santykis:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} .$$

Sprendžiant vaizdų segmentacijos uždavinį dviejų klasių atveju  $|X \cap Y|$  yra teisingai teigiamai klasifikuotų vaizdo taškų skaičius,  $|X|$  ir  $|Y|$  yra atitinkamai tikrų teigiamos klasės vaizdo taškų ir prognozuotų teigiamos klasės vaizdo taškų skaičius. Grafiškai Dice koeficiento skaičiavimas pavaizduotas 4 pav.



4 pav. Dice ir Jaccard koeficientų skaičiavimas vaizdų segmentacijoje

Kaip matoma 4 pav., vaizdų segmentavimo atveju klasių sankirta atitinka tikrų teigiamai klasifikuotų vaizdo taškų skaičių, segmentuotų klasių aibių suma skaičiuojama kaip dvigubo teisingai teigiamai klasifikuoto taškų skaičiaus, klaidingai teigiamai ir klaidingai neigiamai klasifikuotų vaizdo taškų suma.

### 3.2.2 Jaccard panašumo koeficientas

Jaccard panašumo koeficientas, dar žinomas kaip sankirta virš sąjungos, kuri dažnai trumpinama kaip IoU (ang. *Intersection over union*) yra dar vienas dažnas vaizdų segmentacijoje naudojamas modelių rezultatų įvertinimo metodas. Naudojant Jaccard panašumo koeficientą segmentacija vertinama skaičiuojant santykį tarp bendrų dviejų klasių aibių taškų ir dviejų klasių taškų aibių dydžių sumos:

$$IoU = \frac{|X \cap Y|}{|X \cup Y|},$$

kur  $|X \cap Y|$  yra teisingai teigiamai klasifikuotų vaizdo taškų skaičius,  $|X \cup Y|$  yra teigiamai klasifikuotų ir tikrų teigiamų vaizdo taškų sąjunga,  $|X|$  ir  $|Y|$  yra atitinkamai tikrų teigiamos klasės vaizdo taškų ir prognozuotų teigiamos klasės vaizdo taškų skaičius. Jaccard panašumo koeficientas taikomas vaizdų segmentacijoje skaičiuojant santykį tarp tikros ir prognozuotos segmentacijos aibių sankirtos ir sąjungos.

Grafiškai Jaccard panašumo koeficiento skaičiavimas pavaizduotas 4 pav. Kaip matoma 4 pav., vaizdų segmentavimo atveju klasių sankirta atitinka tikrų teigiamai klasifikuotų vaizdo taškų skaičių, segmentuotų klasių aibių sąjunga skaičiuojama kaip teisingai teigiamai klasifikuoto taškų skaičiaus, klaidingai teigiamai ir klaidingai neigiamai klasifikuotų vaizdo taškų suma.

### 3.2.3 Binarinė kryžminė entropija

Binarinė kryžminė entropija yra dar vienas metodas, naudojamas modelio segmentacijos klaidų skaičiavimui. Entropija yra neaiškumo matas, skaičiuojamas duotai distribucijai  $q(y)$ . Entropija skaičiuojama sumuojant visų galimų reikšmių tikimybių ir tikimybių logaritmų sandaugas visoms duomenų klasėms:

$$H(q) = - \sum_{c=1}^C q(y_c) \cdot \log(q(y_c))$$

Turint tikrą  $q(y)$  ir spėjimą  $p(y)$  nagrinėjamų dydžių distribucijas entropija tarp dviejų distribucijų skaičiuojama taip:

$$H_p(q) = - \sum_{c=1}^C q(y_c) \cdot \log(p(y_c)) \quad .$$

Panašumas tarp dviejų distribucijų skaičiuojamas naudojant Kullback-Leibler (KL) nuokrypį (ang. *Kullback-Leibler Divergence*, arba *KL divergence*):

$$D_{KL}(q||p) = H_p(q) - H(q) = \sum_{c=1}^C q(y_c) \cdot [\log(q(y_c)) - \log(p(y_c))]$$

Tai reiškia, kad kuo distribucija  $p(y)$  yra arčiau  $q(y)$  distribucijos, tuo mažesnis KL nuokrypis, taip pat ir mažesnė kryžminė entropija. Modelis, naudojantis kryžminę entropiją kaip nuostolių funkciją siekia rasti geriausią įmanomą  $p(y)$ , kad būtų minimizuojama kryžminė entropija. Treniravimo metu neuroninis tinklas naudoja visus  $N$  duomenų taškus iš mokymo imties kryžminei entropijai suskaičiuoti. Kadangi kiekvieno taško tikimybė yra  $1/N$ , kryžminė entropija skaičiuojama:

$$q(y_i) = \frac{1}{N} \Rightarrow H_p(q) = - \frac{1}{N} \sum_{i=1}^N \log(p(y_i)) \quad .$$

Kryžminė entropija skaičiuojama naudojant tikimybes, susietas su kiekvieno vaizdo taško tikra klase. Paskutinis žingsnis yra visų taškų vidurkio skaičiavimas abiem klasėms, teigiamai ir neigiamai:

$$H_p(q) = - \frac{1}{N_{pos} + N_{neg}} \left[ \sum_{i=1}^{N_{pos}} q(y_c) \cdot \log(p(y_i)) + \sum_{i=1}^{N_{neg}} q(y_c) \cdot \log(1 - p(y_i)) \right]$$

$$H_p(q) = - \frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad .$$

## 4 Duomenys

Šiame darbe naudojami kompiuterinės tomografijos vaizdai, kurie buvo sužymėti trijų medikų komandoje. Vaizdus žymėjo kraujagyslių chirurgas bei du kraujagyslių chirurgijos rezidentai. Po sužymėjimo vaizdai buvo paruošti neuroninių tinklų mokymui patikslinant trombo žymėjimus ten, kur jų nebuvo bei atlieknat Hounsfield vienetų transformaciją. Taip pat buvo sukurtos duomenų augmentacijos. Buvo keičiamos turimų vaizdų proporcijos, vaizdai buvo apkerpami ir pasukami.

### 4.1 Duomenų šaltinis ir pradinis duomenų apdorojimas

Šiame darbe buvo naudotos 17 pacientų kompiuterinės tomografijos vaizdų sekos, kurioms gauti buvo naudota kontrastinė medžiaga. Originaliuose duomenyse buvo gautos 30 pacientų vaizdų sekos [DBZ+20], tačiau dėl trūkstamų sužymėjimų buvo naudoti tik 17 pacientų duomenys. Kadangi gauti anonimizuoti vaizdai, tolesnis duomenų aprašymas apibūdina visus 30 pacientų duomenis.

Pacientų kompiuterinės tomografijos vaizdai su diagnozuota pilvo aortos aneurizma buvo surinkti nuo 2015 m. sausio mėn. iki 2019 m. gruodžio mėn. Gdansko medicinos universiteto Radiologijos departamente. Vidutinis pacientų amžius yra 70,6 metai. Iš 30 pacientų atrinkti 23 vyrų ir 7 moterų vaizdai.

Kompiuterinės tomografijos vaizdus žymėjo trijų medikų komanda: kraujagyslių chirurgas bei du kraujagyslių chirurgijos rezidentai. Visos segmentacijos buvo bendrai aptariamoms komandoje ir kraujagyslių chirurgo segmentacijos buvo pasirenkamos kaip teisingas žymėjimas tuomet, kai atsirasdavo neatitikimų tarp žymėjimų. Žymėjimai buvo atlikti naudojant ITK-SNAP programos 3.8.0 versiją OSX 10.15 sistemoje. Iš pradžių buvo atliekama automatinė kontrasto segmentacija naudojant aktyvaus kontūro metodą nuo distalinės krūtinės aortos lygio iki bendrųjų šlaunikaulio arterijų. Taip pat buvo atliktas automatinis pagrindinių pilvo aortos išsišakojimų (celiakijos kamieno, viršutinės mezenterinės ir inkstų arterijų) pradžių sužymėjimas naudojant aktyvaus kontūro metodą. Antrame žymėjimo žingsnyje buvo atliekamas rankinis pilvo aortos aneurizmos žymėjimas rankiniu būdu pažymint išorinę aortos sieną kiekviename vaizde.

Vėliau žymėjimai buvo programiškai sujungti pirmenybę teikiant rankinio žymėjimo rezultatams. Pacientų vaizdų sekas sudarė 450–1300 vaizdų, iš kurių 40–60 % reikėjo rankinio sužymėjimo. Sužymėjimo pabaigoje vaizdai buvo anonimizuoti [DBZ+20].

## 4.2 Duomenų paruošimas neuroniniams tinklams

Iš pradinių 30 pacientų buvo atrinkti 17 pacientų, turinčių pakankamai informacijos pilvo aortos aneurizmos segmentacijai atlikti. Dažniausios problemos buvo trūkstami gydytojų žymėjimų vaizdai ar nepilnai sužymėta aortos aneurizma. 13 pacientų vaizdai buvo žymėti pažymint visą aneurizmos plotą (aortos siena, trombas ir kontrastas) ir atskirai išskiriant kontrastą. Šiems pacientams trombo žymėjimas buvo programiškai išskaičiuotas iš aneurizmos ir kontrasto žymėjimo. Pacientai, kurie turėjo aneurizmos ploto žymėjimą (aortos siena, trombas ir kontrastas), bet trūko atskiro kontrasto žymėjimo, buvo neįtraukti į tolimesnę analizę (6 pacientai).


Atlikus pradinį vaizdų apdorojimą ir suvienodinus kontrasto ir trombo žymėjimus, vaizdai iš DICOM formato buvo konvertuoti į PNG atliekant HU transformaciją (`window_width=400`, `window_level=35`). Tuomet vaizdai buvo normalizuoti į  $[0, 1]$  intervalą taikant min-max normalizaciją.

## 4.3 Duomenų augmentacija

Atlikus duomenų paruošimą buvo taikoma duomenų augmentacija, siekiant padidinti turimų vaizdų skaičių. Buvo taikomas stačiakampių ar kvadratų iškirpimas vaizde, kurių ilgio ir pločio santykis yra nuo  $3/4$  iki  $4/3$ . Tuomet iškirpti stačiakampiai buvo transformuojami į pradinio vaizdo dydį. Gautas vaizdas galėjo apimti nuo 75 % iki 100 % pradinio vaizdo ploto. Taip gaunamas augmentuotas vaizdas, atitinkantis šiek tiek pakitusį paciento anatominį vaizdą. Aortos aneurizmos vaizdai kartu su kitais vidaus organais kompiuterinės tomografijos nuotraukose buvo pakeisti į šiek tiek platesnius, siauresnius, aukštesnius, žemesnius ir nukrypusius nuo centro. Šios duomenų augmentacijos buvo taikytos atsitiktiniu būdu kiekvienam vaizdai sir jo žymėjimui kiekvienos epochos pradžioje. Duomenų augmentacijos pavyzdžiai pavaizduoti 5 pav. Po pavaizduotų duomenų augmentacijų buvo padidintas turimų vaizdų kiekis išsaugant anatominių struktūrų savybes bei nebloginant vaizdų kokybės. Kokybės bloginimas būtų neišvengiamas augmentuojant duomenis naudojant papildomą triukšmą.

#### 4.4 Duomenų žymėjimo problemos

Dažnai kontrastas ir trombas buvo žymėti skirtingų gydytojų, ir net 13 iš 17 naudotų pacientų vaizduose kontrastas buvo žymimas arba atskirai, arba kartu su trombu. Neturint originalios trombo segmentacijos, ji buvo gaunama matematiškai išskaičiuojant iš turimų



5 pav. Trijų pacientų duomenų augmentacijos pavyzdžiai

aneurizmos ir kontrasto segmentacijų. Tačiau tai galimai sukūrė nevisiškai tikslius trombo žymėjimus. Tokių išskaičiuotų žymėjimų pavyzdžiai pavaizduoti 6 pav.

6 pav. pateikti aortos ir trombo žymėjimų pavyzdžiai, kuriuose yra pastebimi žymėjimo trūkumai. 6 pav. a dalyje aortos žymėjimas yra netikslus, todėl iš aneurizmos žymėjimo pašalinus taškus, priskirtus kontrastui, aortos skerspjūvio viršutinėje dalyje matomas netikslus trombo žymėjimas. Originaliame vaizde trombas apima daugiau aortos vidaus taškų nei yra

gaunama trombo žymėjime. Tuo tarpu kontrasto žymėjime kontrastui priskiriami ir kai kurie mažesnio intensyvumo vaizdo taškai aortos skerspjūvio viršuje, kurie turėtų būti pažymėti kaip trombas.

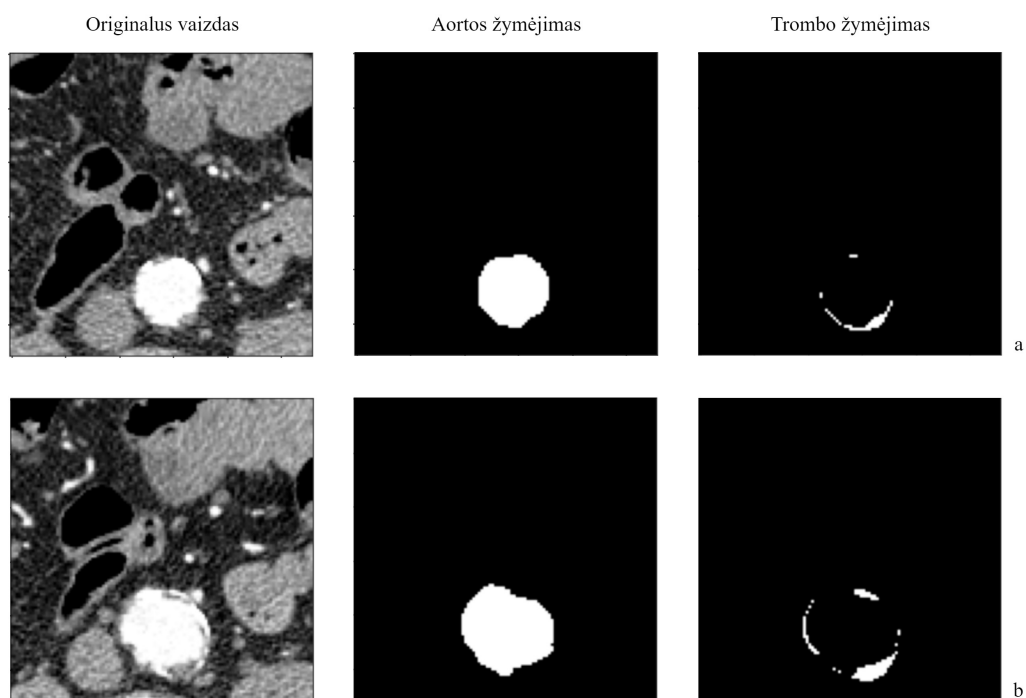
Trombo dalies žymėjimas kaip kontrastas nėra vienintelis vaizdų žymėjimo trūkumas. Į trombo žymėjimą gali būti įtraukti taškai, priklausantys kontrastui. 6 pav. b dalyje pavaizduotas aortos skerspjūvis su skerspjūvio viršuje matomu aortos sienos atsiskuoksniajimu. Aortos sienos vidiniai daliai nuslipus dėl vidinio įtempimo gali įtrūkti vidinė aortos sienos dalis. Tuomet per įtrūkimą pradeda tekėti kraujas, kuris atplėšia dar didesnę dalį vidinės aortos sienos. Šiam procesui tęsiantis palaipsniui susidaro tarsi antra arterijos dalis, kuria kontrastas yra atskirtas siaura vidine siena. Kompiuterinės tomografijos nuotraukoje tai yra matoma kaip du didelio intensyvumo vaizdo taškų plotai, apriboti aortos išorinės sienos, kurie atskirti mažesnio vaizdo taškų intensyvumo linija, kuri atitinka vidinę atplyšusią aortos sienos dalį. Tai yra matoma 6 pav. b dalyje aortos skerspjūvio viršuje. Žymint kontrastą šie šviesūs vaizdo taškai nebuvo įtraukti į kontrasto žymėjimą, todėl programiškai išskaičiuojant trombo žymėjimą iš viso aneurizmos žymėjimo jie buvo priskirti trombo taškams. Taip pat kontrasto žymėjimas netiksliai atliktas ir skerspjūvio apačioje esančiame įlinkime, esančiame prie trombo vaizdo taškų.

Taip pat 6 pav. b dalyje apatiniame kairiajame skerspjūvio krašte matomi du vaizdo taškai, kurie buvo priskirti trombui, nes toje vietoje per du vaizdo taškus nesutapo kontrasto ir aneurizmos žymėjimai. Tikėtina, kad tokie taškai neturėtų būti priskiriami trombui, tačiau neturint galimybės pasikonsultuoti su vaizdus žymėjusiais ekspertais buvo nuspręsta naudoti nepakeistus žymėjimus.

Kadangi kontrasto kontūrai kompiuterinės tomografijos vaizduose gali būti neryškūs, žymint kontrastą ir aneurizmą atskirai galimi pavienių vaizdo taškų neatitikimai kontrasto kraštuose, tačiau tai nebūtinai yra vaizdo taškai, žymintys trombo taškus. Nėra galimybės patikslinti originalių žymėjimų su juos atlikusiais ekspertais ar gauti originalius ITK-SNAP programos failus, todėl neuroninių tinklų mokymas ir testavimas buvo atliekamas su netaisytais turimais žymėjimais.

Netikslus medicininių vaizdų žymėjimas ir mažas pacientų kiekis sukelia rezultatų stabilumo ir modelio generalizacijos iššūkių. Siekiant spręsti duomenų trūkumo problemą galima naudoti medicininius vaizdus iš kelių šaltinių, tačiau negalima visiškai išspręsti duomenų žymėjimo problemų be vaizdų peržymėjimo, atliekamo ekspertų. Panašios

medicininių duomenų žymėjimo problemos yra dažnos ir kituose medicininių duomenų analizės taikymuose. Kaip buvo pastebėta [ŠKM+21], medicininių vaizdų žymėjimas skirtinguose vaizdų rinkiniuose gali nevienodai identifikuoti ne tik žymimo regiono ribas, bet į jį įtraukti ir papildomus regionus, kurie kitame duomenų rinkinyje gali būti atskirti. Viename sužymėtų duomenų rinkinyje į žymimą regioną gali būti įtraukti riebaliniai audiniai, kitame jie gali būti nežymimi. Riebalinis audinys kompiuterinės tomografijos vaizduose žymimas mažomis neigiamomis reikšmėmis (-120 - -90), o vidaus organai žymimi mažomis teigiamomis vaizdo taškų vertėmis (žr. į 2 lentelę). Tokios skirtingų duomenų žymėjimo problemos gali būti sprendžiamos atmetant tam tikro intensyvumo vaizdo taškus iš sužymėto regiono. Ši ir kitos panašios problemos yra dažnos įvairių sričių medicininiuose vaizduose, ir patirtis vienos srities vaizdų problemų srityse dažnai būna neįkainojama sprendžiant kitą medicininių vaizdų analizės uždavinį.



6 pav. Aortos ir trombo žymėjimas kompiuterinės tomografijos nuotraukose



## 4.5 Hounsfield vienetų transformacija

Kompiuterinės tomografijos metu gauti vaizdai išsaugomi DICOM (ang. *Digital Imaging and Communications in Medicine*) formatu. Šiuo formatu galima išsaugoti ne tik patį vaizdą, bet ir papildomą informaciją apie pacientą, tyrimo vietą, tyrimą atlikusį gydytoją ir kitus tyrimo parametrus. Kompiuterinės tomografijos metu gautų vaizdų taškai atitinka Hounsfield vienetų (HU, ang. *Hounsfield units*) skaičių ir svyruoja nuo apytiksliai -3000 iki 1700.

Hounsfieldo skalė skirta radiotankiui apibūdinti. Skalė apibrėžta taip, kad distiliuoto vandens radiotankis būtų 0 HU, o oro radiotankis atitiktų -1000. Kitų medžiagų HU vertės apskaičiuojamos taip:

$$HU = 1000 \times \frac{\mu - \mu_{\text{vandens}}}{\mu_{\text{vandens}} - \mu_{\text{oro}}},$$

kur  $\mu_{\text{vandens}}$  ir  $\mu_{\text{oro}}$  yra atitinkamai vandens ir oro tiesiniai silpninimo koeficientai (ang. *linear attenuation coefficients*), apibūdinantys rentgeno ar gamma spindulių srauto dalį, kuri yra sugerama arba išskaidoma per vienetinį medžiagos storį. Kai kurių medžiagų radiotankiai pavaizduoti 2 lentelėje:


2 lentelė. Medžiagų radiotankio, matuojamo HU pavyzdžiai

Medžiaga	Radiotankis, HU
Oras	-1000
Vanduo	0
Nesukrešėjęs kraujas	Nuo 13 iki 15
Sukrešėjęs kraujas	Nuo 50 iki 75
Plaučiai	Nuo -700 iki -600
Riebalai	Nuo -120 iki -90
Inkstai	Nuo 20 iki 45
Kepenys	Nuo 54 iki 66
Raumenys	Nuo 35 iki 55
Kaulai	Nuo 200 iki 3000

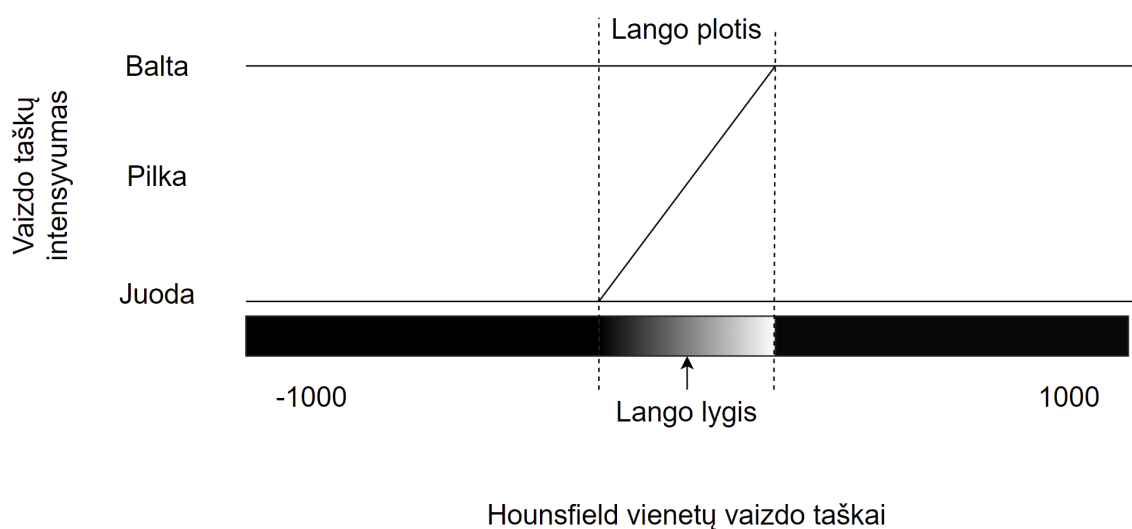
Kaip matoma 2 lentelėje, plaučiai, kurių didžioji dalis užpildyta oru, kompiuterinės tomografijos nuotraukose vaizduojami labai mažomis vertėmis. Tuo tarpu kaulai, kurių tankis, o kartu ir radiotankis, yra didelis, vaizduojami aukštomis HU vertėmis. Kompiuterinės

tomografijos nuotraukoje aukštas HU vertes turintys vaizdo taškai vaizduojami šviesiai (didelio intensyvumo pilkais vaizdo taškais), o turintys mažas HU vertes vaizduojami tamsiai.

Kraujas ir kiti vidaus organai turi panašias HU vertes. Tai sukelia problemų analizuojant kompiuterinės tomografijos nuotraukas bei naudojant jas neuroninio tinko mokymui. Todėl būtinas kompiuterinės tomografijos vaizdų apdorojimo etapas yra Hounsfield vienetų transformacija, kuri naudoja lango lygį (ang. *window level*) ir lango plotį (ang. *window width*).



7 pav. Hounsfield vienetų transformacija naudojant lango plotį ir lygį



8 pav. Hounsfield vienetų transformacija vaizdo taškams

7 pav. grafiškai pavaizduota Hounsfield vienetų lango transformacija (ang. *HU windowing*), kuomet nustatius reikiamą lango gylį ir plotį atliekama tiesinė vaizdo taškų transformacija pasirinktame Hounsfield vienetų skalės intervale. Viršutinė vaizdo taškų, išreikštų HU vienetais riba yra  $lango\ lygis + (lango\ plotis / 2)$ , apatinė vaizdo taškų, išreikštų HU vienetais riba yra  $lango\ lygis - (lango\ plotis / 2)$ .

Kaip pavaizduota 8 pav., į pasirinktą intervalą nepatekę vaizdo taškams priskiriamos nulinės vertės, o į pasirinktą intervalą patekusiems vaizdo taškams yra pritaikoma tiesinė vaizdo taškų intensyvumo transformacija. Hounsfield vienetų transformacija išryškina skirtumai tarp pasirinktų vidaus organų vaizdo taškų, bei pašalinama nesusijusi informacija vaizduose.

## 5 Skaičiavimų resursai

Neuroninių tinklų treniravimui naudotas kompiuteris su Intel Core i7 2.3 GHz procesoriumi, 64 GB RAM, NVIDIA Quadro RTX 3000 vaizdo plokšte su 6 GB RAM. Modeliams naudota Python (3.8) programavimo kalba su bibliotekomis: numpy (1.21.2), pytorch (1.10.1), torchvision (0.11.2), OpenCV (4.0.1).

## 6 Rezultatai

Pilvo aortos segmentacijai tikri buvo taikyti trys neuroniniai tinklai (ResNet-101, DeepLab V3 ir U-Net) su trimis galimomis nuostolių funkcijomis: kryžmine entropija, Dice koeficientu bei bendra kryžminės entropijos ir Dice koeficiento nuostolių funkcija. Pilvo aortos aneurizmos trombo segmentacija tirta taikant vieną neuroninį tinklą kontrasto ir trombo regionams segmentuoti. Taip pat buvo taikyti ir du atskiri neuroniniai tinklai šiems regionams segmentuoti, vėliau rezultatus apjungiant ir gaunant galutinę trombo segmentacijos įvertį.

### 6.1 Neuroninių tinklų mokymas su skirtingomis nuostolių funkcijomis

Aortos ir trombo segmentacijai atlikti buvo naudoti trys neuroninių tinklų modeliai: ResNet-101, DeepLab V3 ir U-Net. Dėl ribotų skaičiavimo resursų vaizdai buvo sumažinti iki 128x128 vaizdo taškų. 3 ir 4 lentelėse pavaizduoti neuroninių tinklų testavimo rezultatai po 10 epochų. Geriausi rezultatai pasiekti naudojant U-Net neuroninį tinklą su mišria nuostolių funkcija, apjungiančia kryžminę entropiją ir Dice panašumo koeficientą. Kaip nuostolių funkciją naudojant tik Dice koeficientą visi trys neuroniniai tinklai pasiekė panašius aortos kontrasto segmentavimo rezultatus. Dice koeficientas testavimo vaizdų segmentacijai buvo

3 lentelė. Aortos segmentavimo rezultatai naudojant skirtingus neuroninius tinklus ir nuostolių funkcijas

Nuostolių funkcija	Kryžminė entropija		Dice koeficientas		Kryžminė entropija ir Dice koeficientas	
	Dice	IoU	Dice	IoU	Dice	IoU
Segmentavimo tikslumo vertinimas						
ResNet-101	0,26774	0.17900	0,80633	0,68460	0,63592	0,50207
DeepLab V3	0,29460	0.21513	0,80479	0,68563	0,73527	0,60535
U-Net	0,81529	0.71421	0,80576	0,70532	0,87554	0,79734

apie 0,8. Taikant tik kryžminę entropiją U-Net pasiekė geriausias rezultatus testavimo aibės segmentacijai, kurie buvo iki trijų kartų geresni nei kitais neuroniniais tinklais gautų segmentacijų rezultatai. Tačiau geriausi rezultatai gauti naudojant jungtinę kryžminės entropijos ir Dice koeficiento nuostolių funkciją bei U-Net neuroninį tinklą.

DeepLab V3 tinklo aortos segmentacijų tikslumas buvo panašus į U-Net tikslumą naudojant Dice koeficientą vieną arba su kryžmine entropija kai buvo segmentuojama aorta. Tačiau segmentuojant trombą U-Net tikslumas sumažėjo taikant kryžminės entropijos nuostolių funkciją arba jungtinę nuostolių funkciją. Panašūs rezultatai buvo pasiekti naudojant ResNet-100 tinklą, tačiau maksimalus su ResNet pasiektas Dice panašumo koeficientas neviršijo maksimalaus U-Net Dice panašumo koeficiento.

4 lentelė. Trombo segmentavimo rezultatai naudojant skirtingus neuroninius tinklus ir nuostolių funkcijas

Nuostolių funkcija	Kryžminė entropija		Dice koeficientas		Kryžminė entropija ir Dice koeficientas	
	Dice	IoU	Dice	IoU	Dice	IoU
Segmentavimo tikslumo vertinimas						
ResNet-101	0,02138	0,01317	0,01127	0,00572	0,00155	0,00082
DeepLab V3	4,176e-05	2,109e-05	0,01082	0,00549	0,00039	0,00020
U-Net	0,0	0,0	0,01069	0,00543	0,01267	0,00658

5 lentelė. Aortos segmentavimo rezultatai naudojant skirtingus neuroninius tinklus ir mokymą pratęsiant iki 30 epochų.

Segmentavimo tikslumo vertinimas	10 epochų		30 epochų	
	Dice	IoU	Dice	IoU
DeepLab V3 (su Dice koeficientu)	0,80479	0,68563	0,87002	0,77551
U-Net (su kryžmine entropija)	0,81529	0,71421	0,85211	0,78376
U-Net (su jungtine nuostolių funkcija)	0,87554	0,79734	0,91557	0,86318

Pradiniai trombo segmentacijos rezultatai pavaizduoti 4 lentelėje. Nei vienas naudotas tinklas nesugebėjo gerai segmentuoti trombo, nors U-Net pasiekė geriausius rezultatus lyginant su kitais naudotais tinklais. Tačiau iš rezultatų matyti, kad geriausi rezultatai potencialiai gali būti pasiekiami naudojant jungtinę nuostolių funkciją. Dėl žymėjimuose esančių aptartų klaidų, mažo trombo ploto, kuris dažnai dar yra išskirstytas į kelis regionus, ir vaizdo taškų intensyvumo panašumo į šalia esančius vidaus organus trombui segmentuoti reikia daugiau mokymo epochų nei kontrasto segmentavimui.

6 lentelė. Trombo segmentavimo rezultatai naudojant skirtingus neuroninius tinklus ir mokymą pratęsiant iki 30 epochų.

Segmentavimo tikslumo vertinimas	10 epochų		30 epochų	
	Dice	IoU	Dice	IoU
DeepLab V3 (su Dice koeficientu)	0,01082	0,00549	0,01156	0,00587
U-Net (su kryžmine entropija)	0,0	0,0	0,16726	0,10700
U-Net (su jungtine nuostolių funkcija)	0,01267	0,00658	0,13534	0,08326

Geriausius rezultatus pasiekusių neuroninių tinklų mokymas buvo tęsiamas neuroninius tinklus mokant daugiau epochų ir naudojant geriausius rezultatus pasiekusių nuostolių funkciją. Aortos ir trombo segmentavimo rezultatai pateikti 5 ir 6 lentelėse. Geriausi rezultatai pasiekti su U-Net neuroniniu tinklu ir apjungiant kryžminę entropiją bei Dice panašumo koeficientą į vieną nuostolių funkciją. Taip buvo gautas 0,91 Dice panašumo koeficientas

aortos segmentavimui ir 0,13 Dice panašumo koeficientas trombo segmentavimui. Padidinus epochų skaičių rezultatai buvo pagerinti visiems trimis neuroniniams tinklams, tačiau U-Net su jungtine nuostolių funkcija pasiekė geriausią Dice koeficientą kontrasto segmentacijai.

## 6.2 Pradinio vaizdo dydžio keitimas

Trombo segmentaciją atlikti sudėtinga, nes aplink trombą yra panašios geometrijos struktūros, žymimos panašaus intensyvumo vaizdo taškais. Siekiant palengvinti trombo segmentaciją pradinis vaizdas buvo apkarpomamas iki 312x312 pašalinant kompiuterinės tomografijos vaizdo taškus. Taip pat anksčiau gautus rezultatus bandyta pagerinti taikant morfologines operacijas trombo žymėjimams. Dėl programiškai gautų trombo žymėjimų kartais gauti žymėjimai turi pavienių vaizdo taškų ar nesujungtų regionų, priskiriamų trombui, kurie galimai atsiranda dėl nevienodo aortos sienos žymėjimo kompiuterinės tomografijos vaizduose. Problemą bandyta spręsti taikant išplėtimo ir erozijos operacijas, siekiant sujungti atskirus trombą žyminčius regionus su smulkiais tarpais. Geriausi šios segmentacijos rezultatai pateikiami 7 lentelėje. Atlikus pradinio vaizdo apkirpimą aortos segmentacijos rezultatai liko beveik tokie patys, tačiau trombo segmentacijos rezultatai pagerėjo maždaug du kartus.

7 lentelė. Segmentavimo rezultatai taikant pradinį vaizdo apkarpyimą į aortą ir trombą dengiantį dominanti regioną (ang. *region of interest, ROI*).

Segmentuotas regionas	Be pradinio vaizdo apkarpyimo		Su pradinio vaizdo apkarpyimu	
	Dice	IoU	Dice	IoU
Aorta	0,91557	0,86318	0,91799	0,86600
Trombas	0,13534	0,08326	0,22655	0,15133

## 6.3 Atsitiktinis tinklo svorių pašalinimas

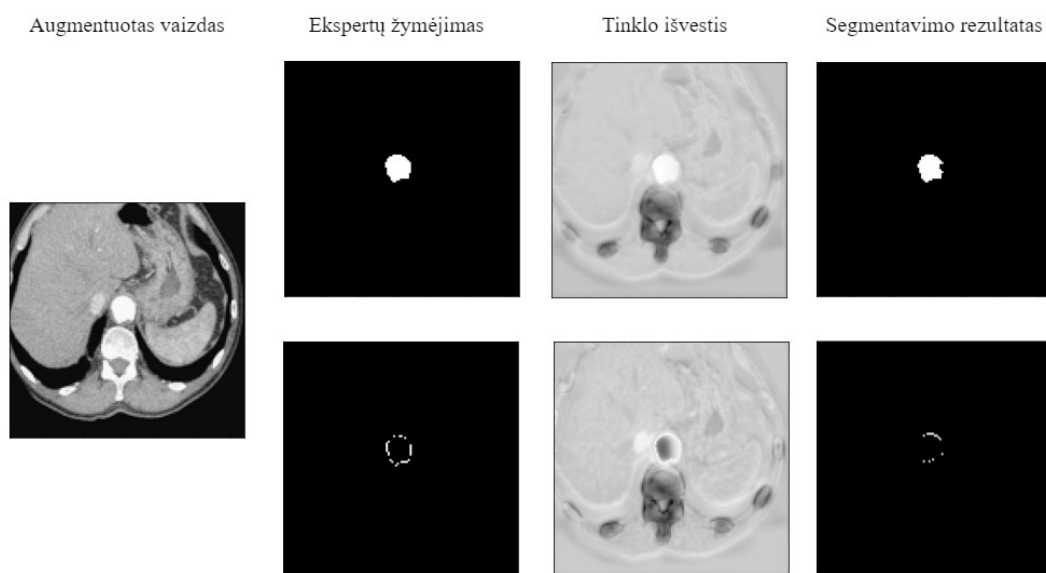
Analizuojant po vaizdo apkarpyimo gautus grafinius rezultatus buvo pastebėta, kad tinkle atsiranda permokymas (ang. *overtraining*). Permokymas įvyksta tuomet, kai tinklas per gerai išmoksta atpažinti dažnai ribotą kiekį mokymo duomenų. Tuomet testavimo tikslumas būna žemas, nes testavimo duomenys skiriasi nuo mokymo duomenų. Tai ypač aktualu turint mažą kiekį skirtingų pacientų kompiuterinės tomografijos vaizdų sekų. Tinklas gali persimokyti naudodamas kelis jam žinomus pacientus, ir prastai atlikti segmentaciją nematytų pacientų vaizdams. Siekiant to išvengti, buvo pritaikytas atsitiktinis svorių išmetimas (ang.

*dropout*) tarp trijų U-Net tinklo dekoderio sluoksnių. Nors dėl atsitiktinio svorių išmetimo šiek tiek pablogėjo aortos kontrasto segmentavimas, tačiau trombo segmentacija pagerėjo maždaug 1,6 karto. Segmentacijos rezultatai pateikiami 8 lentelėje.

8 lentelė. Segmentavimo rezultatai taikant atsitiktinį svorių pašalinimą

Segmentuotas regionas	Be atsitiktinio svorių pašalinimo		Su atsitiktiniu svorių pašalinimu	
	Dice	IoU	Dice	IoU
Aorta	0,91799	0,86600	0,86610	0,79662
Trombas	0,22655	0,15133	0,38257	0,29939

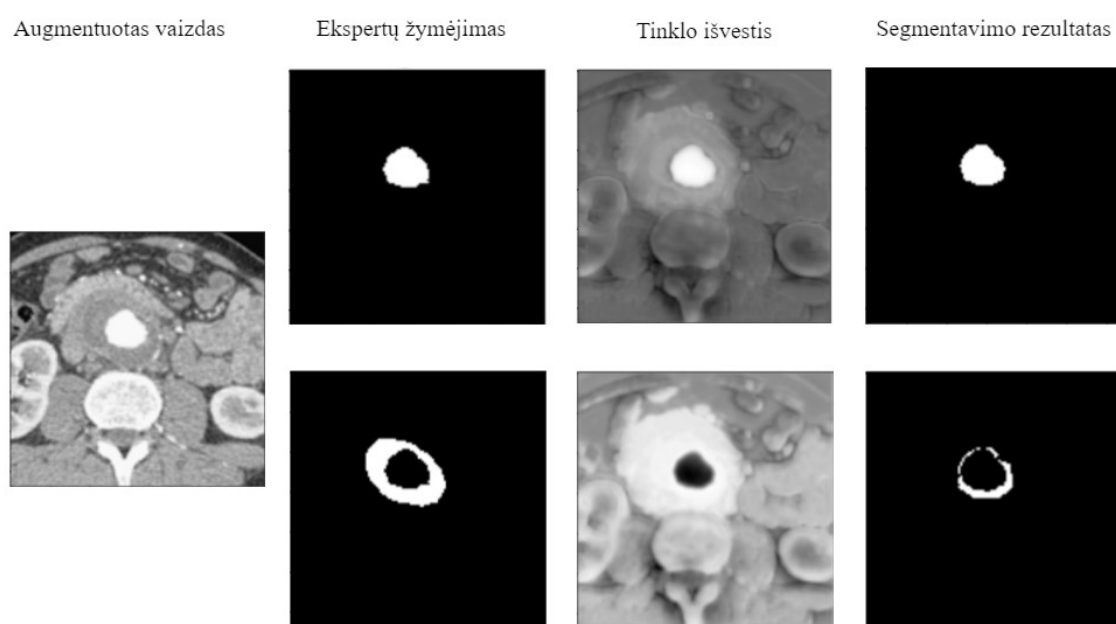
Geriausių modelių segmentavimo pavyzdžiai pateikiami 9 ir 10 pav., kuriuose vaizduojamos sudėtingo ir įprasto žymėjimo segmentacijos ir bei neuroninio tinklo išvestys. Dėl tinklo architektūros ir jungčių tarp skirtingų enkoderio ir dekoderio sluoksnių U-Net tinklas beveik nepametė lokalią informaciją apie vaizde esančias struktūras. Tai matyti ir tinklo skaičiavimo išvestyje, kur išvesties rezultatus lengva susieti su įvesties vaizdo objektų kontūrais. Segmentacijos tikslumas galėtų būti dar pagerintas taikant tinklo hiperparametrų optimizaciją: ribinės reikšmės (ang. *threshold*) keitimą, atsitiktinio svorių išmetimo derinimą.



9 pav. U-Net segmentacijos pavyzdys

Dažniausiai atliekant pilvo aortos aneurizmos analizę ekspertai naudoja Hounsfield vienetų transformaciją, kur tiek kontrastas, tiek trombas yra pakankamai gerai matomas

viename vaizde. Vienas tokių parametrų rinkinių gali būti šie: lango plotis = 400, lango gylis = 35. Siekiant pagerinti vaizdo kokybę kontrasto kraštuose, turinčiuose vidutiniškai šviesius vaizdo taškus, prarandama dalis informacijos apie nežymius vaizdo taškų intensyvumo skirtumus tarp trombo ir aplink trombą esančių organų. Todėl aortos aneurizmos segmentavimui taip pat buvo pritaikytas U-Net tinklas, kuriame vienam sužymėjimui segmentuoti kaip įvestis pateikiami du skirtingomis Hounsfield vienetų transformacijomis gauti vaizdo sluoksniai (ang. *channels*). Tikėtasi, kad tai pagerins trombo atpažinimą, nes tinklui bus suteikta papildomos informacijos apie trombą ir šalia trombo esančius panašios struktūros objektus.



10 pav. U-Net segmentacijos pavyzdys naudojant apkarpytą vaizdą

Literatūroje aprašyto segmentacijų tikslumo, gauto su turimais duomenimis, gauti ar pagerinti nepavyko: [DBZ+20] pasiekė 0,94 Dice panašumo koeficientą aneurizmos segmentacijai, kur kontrasto ir trombo regionas naudojamas kaip viena klasė ir skaičiuojamas trijų neuroninių tinklų rezultatų svorinis vidurkis segmentacijoms rasti. Šiame darbe sprendžiama problema yra sudėtingesnė, nes siekiama atskirai segmentuoti trombo regioną. Mažesnis segmentacijos tikslumas gaunamas ir dėl mažesnio duomenų kiekio, kuris naudojamas apmokyme. Šiame darbe buvo naudojami 17 iš 30 pacientų vaizdai. Siekiant atskirti skirtingų pacientų vaizdus mokymo, testavimo ir validavimo duomenyse, naudojamas daug mažesnis pacientų skaičius tinklo mokymui ir validavimui, kas lemia mažesnę vaizdų įvairovę. Taip pat bus kuriamas trimačius duomenis priimančias tinklas. Dėl nepakankamo



pacientų kompiuterinės tomografijos vaizdo sekų kiekio pilnas 3D U-Net tinklo mokymas yra negalimas, tačiau galima tinklą mokyti 3D objekto segmentais kaip tinklo įvestį naudojant tris ar penkis iš eilės einančius kompiuterinės tomografijos sekos vaizdus.

## 6.4 Papildoma HU transformacija

Atliekant Hounsfield vienetų transformaciją prarandama dalis vaizde esančios informacijos. Vienas iš klinikinėje praktikoje naudojamų parametrų rinkinių yra 400 lango plotis ir 40 lango lygis, nors analizuojant pilvo aortos aneurizmą Hounsfield vienetų transformacijos parametrai gali nežymiai kisti. Atliekant Hounsfield vienetų transformaciją su šiais parametrais gali būti prarandama dalis svarbios informacijos apie trombą, siekiant gerai pavaizduoti abu regionus: trombą ir kontrastą. Todėl buvo eksperimentiškai renkami kiti Hounsfield vienetų transformacijos parametrai, kuriuos naudojant geriausiai išsiryškintų trombo regionas, neatsižvelgiant į kontrasto vaizdavimo kokybę.

Tuomet papildomos Hounsfield vienetų transformacijos rezultatas buvo naudojamas kaip papildoma tinklo įvesties informacija. Šis antras vaizdas buvo naudojamas kaip antras pradinio vaizdo kanalas neuroninio tinklo įvestyje, panašiai kaip naudojami trys vaizdo taškų kanalai segmentuojant spalvotus vaizdus. Geriausi rezultatai pavaizduoti 8 lentelėje. Segmentavimo rezultatai naudojant U-Net tinklą kontrasto segmentacijai beveik nepasikeitė, tačiau rezultatai trombo segmentacijai suprastėjo. Tai galima iš dalies paaiškinti tuo, kad padidinus neuroninio tinklo įvesties kiekį padidėja neuroninio tinlo svorių skaičius, kuriems sėkmingai treniruoti reikia didesnio duomenų kiekio ir ilgesnio mokymo laiko.

8 lentelė. Segmentavimo rezultatai taikant du vaizdus su skirtingomis HU vienetų transformacijomis kaip neuroninio tinklo įvestis

Segmentuotas regionas	Vienas įvesties vaizdas		Du įvesties vaizdai	
	Dice	IoU	Dice	IoU
Aorta	0,91799	0,86600	0,92687	0,70204
Trombas	0,22655	0,15133	0,16338	0,12415

## 6.5 Segmentacija naudojant du neuroninius tinklus

Apmokius U-Net neuroninį tinklą siekta pagerinti rezultatus apjungiant du skirtingai apmokytus neuroninius tinklus. Duomenyse yra trombo žymėjimo problemų, taip pat trombo regionas yra sudėtingai segmentuojamas dėl panašaus intensyvumo vaizdo taškų, esančių

aplink trombą bei netaisyklingos jo formos. Todėl buvo siekta palengvinti segmentavimo užduotį apmokant du skirtingus neuroninius tinklus. Pirmasis tinklas buvo apmokytas atlikti tik kontrasto segmentaciją, kitas tinklas segmentuoja tik bendrą kontrasto ir trombo regioną. Trombo regionas gautas atėmus segmentuotą kontrasto regioną iš bendro regiono. Mokymas ir testavimas atliktas keliais būdais: naudojant visus turimus pacientų vaizdus ir naudojant tik tuos vaizdus, kuriuose trombas yra matomas.

9 lentelė. Rezultatai apmokius du neuroninius tinklus skirtingiems regionams segmentuoti

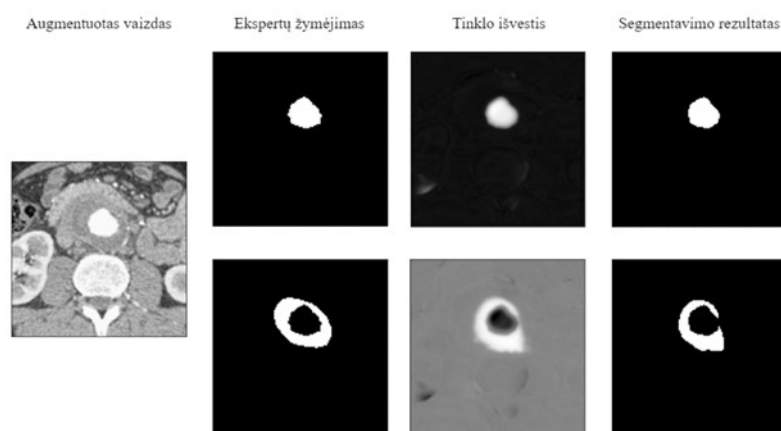
Regionas	Du segmentavimo tinklai, testuoti su visais vaizdais		Du segmentavimo tinklai, testuoti tik su matomo trombo vaizdais		Du segmentavimo tinklai, apmokyti tik matomo trombo vaizdais, testuoti su visais		Du segmentavimo tinklai, apmokyti ir testuoti tik matomo trombo vaizdais	
	Dice	IoU	Dice	IoU	Dice	IoU	Dice	IoU
Kontrastas	0,9058	0,8582	0,9066	0,8662	0,9399	0,8941	<b>0,9458</b>	<b>0,9054</b>
Trombas	0,4123	0,3325	<b>0,5820</b>	<b>0,4694</b>	0,3906	0,3202	0,5514	0,4521
Bendras	0,8444	0,7612	0,8296	0,7453	0,7931	0,7132	0,7725	0,7017

Testavimo rezultatai pavaizduoti 9 lentelėje. Kontrasto segmentavimo rezultatai yra geriausi tuomet, kai du tinklai buvo apmokyti ir testuoti tik su matomo trombo vaizdais, nors skirtumas tarp testavimo vaizdų variantų nėra toks didelis kaip tarp mokymo vaizdų variantų. Kontrasto segmentavimo Dice koeficientas beveik nepriklauso nuo to, ar testavimo metu buvo testuota su visais vaizdais, ar tik su tais vaizdais, kuriuose matomas trombas. Geresni rezultatai pasiekiami tuomet, kai neuroninis tinklas buvo mokomas tik matomo trombo vaizdais, tačiau rezultatai tarp to paties mokymo varianto ir skirtingų testavimo aibių beveik nesiskiria. Didesni skirtumai matomi trombo ir bendros pilvo aortos aneurizmos segmentacijos rezultatuose. Geriausi trombo segmentavimo rezultatai pasiekiami testuojant tik su matomo trombo vaizdais. Naudojant šį testavimą buvo pastebėtas 41 % Dice koeficiento pagerinimas lyginant su testavimu, kurio metu naudoti visi kompiuterinės tomografijos vaizdai.

Geras trombo segmentacijos pavyzdys pateiktas 11 pav. Paveiksle kairėje pusėje pavaizduotas augmentuotas vaizdas, kuris buvo naudojamas kaip neuroninio tinklo įvestis. Šis

vaizdas buvo gautas iš originalios kompiuterinės tomografijos nuotraukos šiek tiek keičiant jos proporcijas vertikalčiai suspaudžiant vaizdą. Tuomet gautas vaizdas buvo sumažintas iki 128x128 dydžio vaizdo. 11 pav. pateikti ekspertų sužymėti vaizdai, kuriuose matomi pilvo aortos kontrasto ir trombo kontūrai bei vaizdo regionai, kuriuose šie objektai yra matomi. Tinklo išvesties bei segmentavimo rezultato vaizduose matoma, kad kontrasto regionas buvo labai gerai segmentuotas. Tinklo išvestyje kontrastą žymintys vaizdo taškai turi labai aukštas teigiamas vertes, tuo tarpu trombą žyminčių taškų išvestis beveik nesiskiria nuo foną žyminčių taškų. Gautame segmentavimo rezultate matomas gerai segmentuotas kontrasto regionas, kuris vizualiai yra beveik identiškas ekspertų žymėjimui.

Trombo segmentavimo testavimo rezultatai yra daug geresni tais atvejais, kai buvo testuojama naudojant tik trombą vaizduojančius vaizdus. Tai galima paaiškinti analizuojant atliktų segmentacijų pavyzdžius. Testavimo metu segmentuojant tik tuos kompiuterinės tomografijos vaizdus, kuriuose matomas pilvo aortos aneurizmos trombas, išvengiama klaidų, kuomet kaip trombas identifikuojamos kitos panašios į trombą anatomicinės struktūros, esančios šalia aortos.




11 pav. Kontrasto ir trombo segmentacijų pavyzdžiai, testuojant ir apmokant su visais duomenimis.

Pav. 12 matoma, kad testavimui naudojant ir tuos vaizdus, kuriuose nėra trombo, trombas yra vis tiek surandamas. 12 vaizde matoma, kad kartais aplink kontrastą esančios kitos anatomicinės struktūros, tokios kaip raumenys, yra identifikuojamos kaip trombas. Tokių klaidų išvengiama, kai testavimas atliekamas tik su vaizdais, kuriuose matomas trombas. Pav. 12 pavaizduotame kompiuterinės tomografijos vaizde matomas ryškus pilvo aortos kontrasto

regionas. Didžiąją dalį kairės vaizdo pusės užima kepenys. Apatinėje vaizdo pusėje juodi lentos formos regionai vaizduoja plaučių apačią. Vaizde aplink aortą matomi raumeniniai ir kitos struktūros audiniai, kurie vizualiai gali atrodyti panašiai kaip pilvo aortos trombas, nes jie vaizduojami panašaus intensyvumo vaizdo taškais, bei turi į trombą panašią formą. Ekspertų sudarytame žymėjime trombas nėra pažymėtas.

Analizuojant paciento kompiuterinės tomografijos vaizdų seką matyti, kad aplink šį vaizdą esančiose kompiuterinės tomografijos nuotraukose į trombą panašus regionas nesiplečia, jis netampa panašus į išsiplėtusį trombą. Tačiau neuroninio tinklo išvestyje trombas yra randamas ten, kur vaizde matomos kitos anatomicinės struktūros, gaubiančios pilvo aortos kontrastą. Tai matoma ir segmentavimo rezultato 12 pav. dalyje, kuomet neuroninio tinklo išvesčiai pritaikius ribinę vertę gautame segmentavimo rezultate buvo išskirtas klaidingai segmentuotas trombo regionas.



12 pav. Kontrasto segmentacijos ir nesėkmingos trombo segmentacijos pavyzdžiai, testuojant ir apmokant su visais duomenimis.

## 7 Išvados

Apmokius tris neuroninius tinklus su skirtingomis nuostolių funkcijomis pasiekti geri kontrasto segmentavimo rezultatai, tačiau trombo segmentavimo rezultatai nėra tokie geri. Tai gali lemti per mažas tinklo mokymui turimas duomenų kiekis, žymėjimų netikslumai vaizduose ir trombo erdvinės savybės. Turint mažai pacientų įvyksta tinklo persimokymas, kurio iš dalies galima išvengti taikant atsitiktinių svorių pašalinimą.

Esamų duomenų žymėjimo neatitikimų mažinimas morfologinėmis operacijomis bei vaizdo apkarpymo taikymas pagerina rezultatus, nes sumažinamas pasimetimas tarp šalia trombo esančių anatominių struktūrų. Tinklo testavimo rezultatų vaizduose matoma, kad tinko išvestys koncentruojasi į tinkamą trombo regioną, tačiau pritaikius konvertavimą į dvejetainę išvestį dauguma vizualiai teisingų trombo segmentacijos taškų nebuvo priskirti trombo regionui. Tai galėtų būti pagerinta pateikus tinklui daugiau informacijos, pavyzdžiui naudojant trimačius duomenis. Neuroninio tinklo mokymo rezultatai nepagerėjo naudojant papildomus vaizdus su skirtinga Hounsfield vienetų transformacija nei pradinis vaizdas. Tikėtina, kad turint daugiau vaizdų galėtų būti pasiekti geresni rezultatai taikant šį metodą, bet mažai tikėtina, kad rezultatai būtų geresni nei taikant du atskirus neuroninius tinklus trombo ir aneurizmos regionų segmentacijai.

Darbe pavyko priartėti prie literatūroje aprašyto segmentavimo tilsumo naudojant turimus duomenis: [DBZ+20] pasiekė 0,94 Dice panašumo koeficientą aneurizmos segmentacijai, kur kontrasto ir trombo regionas naudojamas kaip viena klasė ir skaičiuojamas trijų neuroninių tinklų rezultatų svorinis vidurkis segmentacijoms rasti. Šiame darbe yra sprendžiama sudėtingesnė problema nei aortos segmentavimas, nes siekiama atskirai segmentuoti ir trombo regioną. Prastesni segmentacijos rezultatai gaunami ir dėl mažesnio neuroninių tinklų mokyme naudojamo duomenų kiekio. Šiame darbe buvo naudojami 17 iš 30 pacientų vaizdų, naudotų [DBZ+20] publikacijoje. Siekiant atskirti skirtingų pacientų vaizdus mokymo, testavimo ir validavimo duomenyse, naudojamas daug mažesnis pacientų skaičius tinklo mokymui ir validavimui, kas lemia mažesnę vaizdų įvairovę.

Gauti pradiniai segmentavimo rezultatai buvo pagerinti naudojant du atskirus neuroninius tinklus aortos kontrastui ir trombui segmentuoti. Taip buvo supaprastinta mokymo užduotis, ką atlikus galima pasiekti gerų rezultatų net ir naudojant beveik du kartus mažesnę duomenų kiekį nei [DBZ+20] darbe.

Naudojant 2D U-Net neuroninį tinklą prarandama erdvinė informacija, kuri yra matoma paciento kompiuterinės tomografijos vaizdų sekoje. Taip yra sunkiau identifikuoti anatomines struktūras, turinčias mažą skerspjūvio plotą, ar struktūras, kurios atrodo panašiai dėl vaizdo taškų intensyvumo ir padėties, pavyzdžiui pilvo aortos trombas ir kituose vaizduose aplink aortą esantys raumenys. Objektų segmentacijos sekimas 3D duomenyse galėtų pagerinti rezultatus nes būtų išsaugoma erdvinė informacija, todėl maži pavieniai trombo regionai galėtų būti geriau atskiriami bei pagerėtų trombo atskiriamumas nuo aplink aortą esančio raumeninio audinio. Dėl nepakankamo pacientų kompiuterinės tomografijos vaizdo sekų kiekio pilnas 3D U-Net tinklo mokymas yra negalimas, tačiau ateityje galima neuroninį tinklą mokyti 3D objekto segmentais kaip tinklo įvestį naudojant kelis iš eilės einančius kompiuterinės tomografijos sekos vaizdus.

## 8 Literatūra

- [AGT+20] Aldemir, E., Gezer, N. S., Tohumoglu, G., Barış, M., Kavur, A. E., Dicle, O., & Selver, M. A. (2020). Reversible 3D compression of segmented medical volumes: usability analysis for teleradiology and storage. *Medical physics*, 47(4), 1727-1737.
- [AFA12] Almuntashri, A., Finol, E., & Agaian, S. (2012, October). Automatic lumen segmentation in CT and PC-MR images of abdominal aortic aneurysm. In *2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 2891-2896). IEEE.
- [AG10] Auer, M., & Gasser, T. C. (2010). Reconstruction and finite element mesh generation of abdominal aortic aneurysms from computerized tomography angiography data with minimal user interactions. *IEEE transactions on medical imaging*, 29(4), 1022-1028.
- [CAM13] Chyzyhyk, D., Ayerdi, B., & Maiora, J. (2013). Active learning with bootstrapped dendritic classifier applied to medical image segmentation. *Pattern Recognition Letters*, 34(14), 1602-1608.
- [CDE+18] Chaikof, E. L., Dalman, R. L., Eskandari, M. K., Jackson, B. M., Lee, W. A., Mansour, M. A., Mastracci, T.M., Mell, M., Murad, M.H., Nguyen, L.L. and Oderich, G.S. & Starnes, B. W. (2018). The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *Journal of vascular surgery*, 67(1), 2-77.
- [CLB+20] Cercenelli, L., Lodi, S., Bortolani, B., Mascoli, C., Gargiulo, M., & Marcelli, E. (2020). EVAR-eaSE: An Easy-to-Use Software for Planning Sac Embolization in EndoVascular Aneurysm Repair Procedure. *Applied Sciences*, 10(18), 6252.
- [CPS+17] Chen, L. C., Papandreou, G., Schroff, F., & Adam, H. (2017). Rethinking atrous convolution for semantic image segmentation. arXiv preprint arXiv:1706.05587.
- [DBZ+20] Dziubich, T., Białas, P., Znaniecki, Ł., Halman, J., & Brzeziński, J. (2020, August). Abdominal aortic aneurysm segmentation from contrast-enhanced computed tomography angiography using deep convolutional networks. In *ADBIS, TPDFL and EDA 2020 Common Workshops and Doctoral Consortium* (pp. 158-168). Springer, Cham.
- [Dic45] Dice, Lee R. (1945). "Measures of the Amount of Ecologic Association Between Species". *Ecology*. 26 (3): 297–302. doi:10.2307/1932409. JSTOR 1932409.
- [DDP+20] van Disseldorp, E. M., van Dronkelaar, J. J., Pluim, J. P., van de Vosse, F. N., van Sambeek, M. R., & Lopata, R. G. (2020). Ultrasound based wall stress

analysis of abdominal aortic aneurysms using multiperspective imaging. *European Journal of Vascular and Endovascular Surgery*, 59(1), 81-91.

- [DDP+16] van Disseldorp, E. M. J., van Dronkelaar, J. J., Pluim, J. P. W., van de Vosse, F., van Sambeek, M. R. H. M., & Lopata, R. G. P. (2016, September). Automatic segmentation and registration of abdominal aortic aneurysms using 3D ultrasound. In *2016 IEEE International Ultrasonics Symposium (IUS)* (pp. 1-4). IEEE.
- [DKO+19] Dolgov, V. Y., Klyshnikov, K. Y., Ovcharenko, E. A., Glushkova, T. V., Batranin, A. V., Agienko, A. S., ... & Kutikhin, A. G. (2019). Finite element analysis-based approach for prediction of aneurysm-prone arterial segments. *Journal of Medical and Biological Engineering*, 39(1), 102-108.
- [DJB+12] Duquette, A. A., Jodoin, P. M., Bouchot, O., & Lalande, A. (2012). 3D segmentation of abdominal aorta from CT-scan and MR images. *Computerized Medical Imaging and Graphics*, 36(4), 294-303.
- [FEJ+10] Freiman, M., Esses, S. J., Joskowicz, L., & Sosna, J. (2010, April). An iterative model-constrained graph-cut algorithm for abdominal aortic aneurysm thrombus segmentation. In *2010 IEEE international symposium on biomedical imaging: from nano to macro* (pp. 672-675). IEEE.
- [GCM+11] Geremia, E., Clatz, O., Menze, B. H., Konukoglu, E., Criminisi, A., & Ayache, N. (2011). Spatial decision forests for MS lesion segmentation in multi-channel magnetic resonance images. *NeuroImage*, 57(2), 378-390.
- [HD18] Habib, S., & Dehmeshki, J. (2018, September). Automatic Segmentation of Abdominal Aortic Aneurysm. In *2018 IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT)* (Vol. 1, pp. 412-415). IEEE.
- [HML+17] He, Z., Mongrain, R., Lessard, S., & Soulez, G. (2017). Extents, Locations and Geometrical Configurations of Calcification in Abdominal Aortic Aneurysm. In *EMBECC & NBC 2017* (pp. 639-642). Springer, Singapore.
- [HZR+15] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- [HZR+16] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [JHM+18] Jalalahmadi, G., Helguera, M., Mix, D. S., & Linte, C. A. (2018, March). Toward modeling the effects of regional material properties on the wall stress distribution of abdominal aortic aneurysms. In *Medical Imaging 2018:*



*Biomedical Applications in Molecular, Structural, and Functional Imaging* (Vol. 10578, p. 105780I). International Society for Optics and Photonics.

- [JLH17] Jalalahmadi, G., Linte, C., & Helguera, M. (2017, March). A numerical framework for studying the biomechanical behavior of abdominal aortic aneurysm. In *Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging* (Vol. 10137, p. 101372A). International Society for Optics and Photonics.
- [KTT+10] Kauffmann, C., Tang, A., Therasse, E., & Soulez, G. (2010, March). An hybrid CPU-GPU framework for quantitative follow-up of abdominal aortic aneurysm volume by CT angiography. In *Medical Imaging 2010: Computer-Aided Diagnosis* (Vol. 7624, p. 76240N). International Society for Optics and Photonics.
- [KTD+11] Kauffmann, C., Tang, A., Dugas, A., Therasse, É., Oliva, V., & Soulez, G. (2011). Clinical validation of a software for quantitative follow-up of abdominal aortic aneurysm maximal diameter and growth by CT angiography. *European journal of radiology*, 77(3), 502-508.
- [KTT+12] Kauffmann, C., Tang, A., Therasse, É., Giroux, M. F., Elkouri, S., Melanson, P., ... & Soulez, G. (2012). Measurements and detection of abdominal aortic aneurysm growth: accuracy and reproducibility of a segmentation software. *European journal of radiology*, 81(8), 1688-1694.
- [KPN+10] Kim, H. C., Park, S. W., Nam, K. W., Choi, H., Choi, E. J., Jin, S., ... & Sun, K. (2010). Determination of accurate stent graft configuration in abdominal aortic aneurysm using computed tomography: a preliminary study. *Clinical imaging*, 34(4), 255-262.
- [KKP+12] Klein, A., Klaassen, M., Oostveen, L. J., van der Vliet, J. A., Hoogeveen, Y., Kool, L. J. S., ... & Slump, C. H. (2012, April). A comparison of two methods to segment stent grafts in CT data. In *Medical Imaging 2012: Biomedical Applications in Molecular, Structural, and Functional Imaging* (Vol. 8317, p. 83170H). International Society for Optics and Photonics.
- [KVO+12] Klein, A., van der Vliet, J. A., Oostveen, L. J., Hoogeveen, Y., Kool, L. J. S., Renema, W. K. J., & Slump, C. H. (2012). Automatic segmentation of the wire frame of stent grafts from CT data. *Medical image analysis*, 16(1), 127-139.
- [KSK+17] Koenrades, M. A., Struijs, E. M., Klein, A., Kuipers, H., Geelkerken, R. H., & Slump, C. H. (2017, March). Validation of an image registration and segmentation method to measure stent graft motion on ECG-gated CT using a physical dynamic stent graft model. In *Medical Imaging 2017: Computer-Aided Diagnosis* (Vol. 10134, p. 1013418). International Society for Optics and Photonics.

- [LYK+17] Lalys, F., Yan, V., Kaladji, A., Lucas, A., & Esneault, S. (2017). Generic thrombus segmentation from pre-and post-operative CTA. *International journal of computer assisted radiology and surgery*, 12(9), 1501-1510.
- [LJY+10] Lee, K., Johnson, R. K., Yin, Y., Wahle, A., Olszewski, M. E., Scholz, T. D., & Sonka, M. (2010). Three-dimensional thrombus segmentation in abdominal aortic aneurysms using graph search based on a triangular mesh. *Computers in biology and medicine*, 40(3), 271-278.
- [LKP+15] Lessard, S., Kauffmann, C., Pfister, M., Cloutier, G., Thérasse, É., de Guise, J. A., & Soulez, G. (2015). Automatic detection of selective arterial devices for advanced visualization during abdominal aortic aneurysm endovascular repair. *Medical engineering & physics*, 37(10), 979-986.
- [LKL+17] López-Linares, K., Kabongo, L., Lete, N., Maclair, G., Ceresa, M., García-Familiar, A., ... & Ballester, M. A. G. (2017). Dcnn-based automatic segmentation and quantification of aortic thrombus volume: Influence of the training approach. In *Intravascular Imaging and Computer Assisted Stenting, and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis* (pp. 29-38). Springer, Cham.
- [LAK+18] López-Linares, K., Aranjuelo, N., Kabongo, L., Maclair, G., Lete, N., Ceresa, M., ... & Ballester, M. A. G. (2018). Fully automatic detection and segmentation of abdominal aortic thrombus in post-operative CTA images using deep convolutional neural networks. *Medical image analysis*, 46, 202-214.
- [LBH+19] Lu, J. T., Brooks, R., Hahn, S., Chen, J., Buch, V., Kotecha, G., ... & Tenenholtz, N. A. (2019, October). DeepAAA: clinically applicable and generalizable detection of abdominal aortic aneurysm using deep learning. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 723-731). Springer, Cham.
- [MBL+16] Macía, I., de Blas, M., Legarreta, J. H., Kabongo, L., Hernández, Ó., Egaña, J. M., ... & Graña, M. (2016). Standard and fenestrated endograft sizing in EVAR planning: description and validation of a semi-automated 3D software. *Computerized Medical Imaging and Graphics*, 50, 9-23.
- [MG12b] Maiora, J., & Graña, M. (2012, June). Abdominal CTA image analysis through active learning and decision random forests: Application to AAA segmentation. In *The 2012 international joint conference on neural networks (IJCNN)* (pp. 1-7). IEEE.
- [MGM+11] Macía, I., Grana, M., Maiora, J., Paloc, C., & De Blas, M. (2011). Detection of type ii endoleaks in abdominal aortic aneurysms after endovascular repair. *Computers in Biology and Medicine*, 41(10), 871-880.

- [MG12a] Maiora, J., & Graña, M. (2012, March). A hybrid segmentation of abdominal CT images. In *International Conference on Hybrid Artificial Intelligence Systems* (pp. 416-423). Springer, Berlin, Heidelberg.
- [MAG14] Maiora, J., Ayerdi, B., & Graña, M. (2014). Random forest active learning for AAA thrombus segmentation in computed tomography angiography images. *Neurocomputing*, 126, 71-77.
- [MRG16] Martinez-Muñoz, S., Ruiz-Fernandez, D., & Galiana-Merino, J. J. (2016). Automatic abdominal aortic aneurysm segmentation in MR images. *Expert Systems with Applications*, 54, 78-87.
- [MID+17] Meess, K. M., Izzo, R. L., Dryjski, M. L., Curl, R. E., Harris, L. M., Springer, M., ... & Ionita, C. N. (2017, March). 3D printed abdominal aortic aneurysm phantom for image guided surgical planning with a patient specific fenestrated endovascular graft system. In *Medical Imaging 2017: Imaging Informatics for Healthcare, Research, and Applications* (Vol. 10138, p. 101380P). International Society for Optics and Photonics.
- [Ots79] Otsu, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66, 1979.
- [RFB15] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- [RWW+19] Ren, X., Wu, Y., Wang, L., Yan, X., Zhang, L., Cao, Z., & Lin, H. (2019). Three-Dimensional Reconstruction of Abdominal Aortic Aneurysm Based on Compressive Sensing With Iterative Optimization and Its Application in 3D Printing. *IEEE Access*, 7, 170012-170018.
- [RSO+12] Renapurkar, R. D., Setser, R. M., O'Donnell, T. P., Egger, J., Lieber, M. L., Desai, M. Y., ... & Flamm, S. D. (2012). Aortic volume as an indicator of disease progression in patients with untreated infrarenal abdominal aneurysm. *European journal of radiology*, 81(2), e87-e93.
- [RWW+20] Rengarajan, B., Wu, W., Wiedner, C., Ko, D., Muluk, S. C., Eskandari, M. K., ... & Finol, E. A. (2020). A comparative classification analysis of abdominal aortic aneurysms by machine learning algorithms. *Annals of biomedical engineering*, 48(4), 1419-1429.
- [RMA+17] Rouet, L., Mory, B., Attia, E., Bredahl, K., Long, A., & Ardon, R. (2017). A minimally interactive and reproducible method for abdominal aortic aneurysm quantification in 3D ultrasound and computed tomography with implicit template deformations. *Computerized Medical Imaging and Graphics*, 58, 75-85.

- [RSA+20] Ramkumar, N., Suckow, B. D., Arya, S., Sedrakyan, A., Mackenzie, T. A., Goodney, P. P., & Brown, J. R. (2020). Association of Sex With Repair Type and Long-term Mortality in Adults With Abdominal Aortic Aneurysm. *JAMA Network Open*, 3(2), e1921240-e1921240.
- [SDG+10] Shum, J., DiMartino, E. S., Goldhammer, A., Goldman, D. H., Acker, L. C., Patel, G., ... & Finol, E. A. (2010). Semiautomatic vessel wall detection and quantification of wall thickness in computed tomography images of human abdominal aortic aneurysms. *Medical physics*, 37(2), 638-648.
- [SKH19] Siriapisith, T., Kusakunniran, W., & Haddawy, P. (2019). 3D segmentation of exterior wall surface of abdominal aortic aneurysm from CT images using variable neighborhood search. *Computers in biology and medicine*, 107, 73-85.
- [ŠKM+21] Šubonienė, A., Kurasova, O., Medvedev, V., Kielaitė-Gulla, A., Samuilis, A., Jagminas, D., ... & Dzemyda, G. (2021). On the computed tomography image data to diagnose pancreatic cancer using machine learning. In DAMSS: 12th conference on data analysis methods for software systems, Druskininkai, Lithuania, December 2–4, 2021 (pp. 71-72). Vilnius University Press.
- [WTX+21] Wang, Y., Tian, B., Xiong, F., Kao, E., Zhang, Y., Liu, X., ... & Saloner, D. (2021). Computer-aided quantification of non-contrast 3D black blood MRI as an efficient alternative to reference standard manual CT angiography measurements of abdominal aortic aneurysms. *European Journal of Radiology*, 134, 109396.
- [WSY+18] Wagenhäuser, M. U., Schellinger, I. N., Yoshino, T., Toyama, K., Kayama, Y., Deng, A., ... & Tsao, P. S. (2018). Chronic nicotine exposure induces murine aortic remodeling and stiffness segmentation—implications for abdominal aortic aneurysm susceptibility. *Frontiers in physiology*, 9, 1459.
- [WSM+11] Washington, C. B., Shum, J., Muluk, S. C., & Finol, E. A. (2011). The association of wall mechanics and morphology: a case study of abdominal aortic aneurysm growth. *Journal of biomechanical engineering*, 133(10).
- [WHL+16] Wörz, S., Hoegen, P., Liao, W., Müller-Eschner, M., Kauczor, H. U., von Tengg-Kobligk, H., & Rohr, K. (2016, March). Framework for quantitative evaluation of 3D vessel segmentation approaches using vascular phantoms in conjunction with 3D landmark localization and registration. In *Medical Imaging 2016: Image Processing* (Vol. 9784, p. 978419). International Society for Optics and Photonics.
- [YK15] Yu, F., & Koltun, V. (2015). Multi-scale context aggregation by dilated convolutions. arXiv preprint arXiv:1511.07122.
- [ZBL+18] Zech, J. R., Badgeley, M. A., Liu, M., Costa, A. B., Titano, J. J., & Oermann, E. K. (2018). Variable generalization performance of a deep learning model to

detect pneumonia in chest radiographs: a cross-sectional study. *PLoS medicine*, 15(11), e1002683.

- [ZXB+19] Zhou, Y. J., Xie, X. L., Bian, G. B., Hou, Z. G., Liu, B., Lai, Z. C., ... & Zhou, X. H. (2019, December). Real-time guidewire segmentation and tracking in endovascular aneurysm repair. In *International Conference on Neural Information Processing* (pp. 491-500). Springer, Cham.
- [ZKP12] Zohios, C., Kossioris, G., & Papaharilaou, Y. (2012). Geometrical methods for level set based abdominal aortic aneurysm thrombus and outer wall 2D image segmentation. *Computer methods and programs in biomedicine*, 107(2), 202-217.

## 9 Priedas. Autorės mokslinių publikacijų tekstai

**1 publikacija.** Šubonienė, A. (2022). Pilvo aortos aneurizmos segmentavimas neuroniniais tinklais kompiuterinės tomografijos nuotraukose. Vilnius University Open Series, 101-114.

### Pilvo aortos aneurizmos segmentavimas neuroniniais tinklais kompiuterinės tomografijos nuotraukose

Aušra Šubonienė

Vilniaus universitetas, Duomenų mokslo ir skaitmeninių technologijų institutas,  
Akademijos g. 4, LT-08413, Vilnius  
[ausra.suboniene@gmail.com](mailto:ausra.suboniene@gmail.com)

---

**Santrauka.** Pilvo aortos aneurizmos diagnostikai ir stebėsenai dažnai naudojami kompiuterinės tomografijos vaizdai. Kontrastinėje tomografijos nuotraukoje kontrastas yra gerai matomas, tačiau automatinis trombo segmentavimas yra daug sudėtingesnė problema dėl aplink trombą esančių panašaus intensyvumo vaizdo taškų, vaizduojančių kitus vidaus organus. Šiame darbe atliekama pilvo aortos kontrasto ir trombo segmentacija naudojant tris neuroninius tinklus: ResNet-100, DeepLab V3 ir U-Net. Lyginami rezultatai, gauti naudojant skirtingas nuostolių funkcijas, taip pat taikomas programiškai išskaičiuotų trombo žymėjimų paruošimas naudojant morfologines operacijas. Taip pat pritaikomas atsitiktinis neuronų išmetimas ir klasifikavimas naudojant sumažinto lango kompiuterinės tomografijos vaizdus.

**Raktiniai žodžiai:** Pilvo aortos aneurizma, segmentacija, neuroniniai tinklai, kompiuterinė tomografija

---

#### 1 Įvadas

Pilvo aortos aneurizma yra lėtinė liga, kuri negydoma sukelia pilvo aortos plyšimo komplikaciją [1]. Pilvo aortos aneurizma pasireiškia pilvo aortos išplėtimu nusilpus jos sienelai, kurios diagnozei ir stebėsenai naudojama kompiuterinė tomografija. Susilpnėjusi aortos sienelė išsiplečia, ji pasidengia kraujo komponentų sluoksniu, kuris vėliau susiformuoja į trombą. Aortos sienelės išsiplėtimas gali būti 1,5 ar daugiau kartų didesnis už normalų aortos skersmenį [2]. Išsiplėtusi pilvo aorta gali plyšti ir sukelti vidinį kraujavimą. Plyšus pilvo aortos aneurizmai mirtingumas siekia 85–90 % [2]. Plyšus pilvo aortos aneurizmai ir spėjus atlikti operaciją mirtingumas vis tiek išlieka aukštas, apie 33–36 % [1]. Tačiau jei plyšimo išvengiama atliekant operaciją, mirtingumas ženkliai sumažėja iki 1–6 % [3]. Todėl ankstyva ir greita pilvo aortos aneurizmos diagnostika yra ypač svarbi.

Copyright © Arnas Nakrošis, Andrius Kriščiūnas, 2022. Published by Vilnius University Press. This is an Open Access article distributed under the terms of the Creative Commons Attribution License (CC BY), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.  
DOI: <https://doi.org/10.15388/LMITT.2022.10>

Tačiau vienas iš diagnostiką apsunkinančių veiksnių yra tai, kad šiuo metu diagnostikoje naudojami metodai ilgai užtrunka, ir trūksta automati- nių aneurizmos analizavimo ir stebėjimo įrankių [4]. Dažnai gydytojai, ana- lizuodami kompiuterinės tomografijos nuotraukas automatiniais ar pusiau automatiniais metodais, turi nurodyti pradinę aortos ir trombo vietą ar zoną, kurioje jie yra gerai matomi. Siekiant geresnės segmentavimo koky- bės šis procesas kartojamas beveik kiekvienai kompiuterinės tomografijos nuotraukai. Naudojant šiuos diagnostikos įrankius sukuriamas aortos kon- trasto trimatis modelis, tačiau jį dažnai neįtraukiamas trombas. Turint tokį trimatį modelį sunku įvertinti aortos išsiplėtimą ir trombo dydį. Remiantis kraujagyslių chirurgijos draugijos praktikos gairėmis [4] geresnis šių proce- sų standartizavimas leistų geriau nustatyti ligos progresavimo laipsnį bei greitį, tačiau šiuo metu tam trukdo naudojamas rankinis aortos skersmens matavimas, kuomet aortos skersmuo matuojamas rankiniu būdu pagal tam tikrą vartotojo pasirinktą vaizdą.

Dažnai pilvo aortos segmentacija yra neautomatinė ar pusiau automa- tinė, kuomet vartotojas turi pažymėti pradinį kontrasto ar trombo tašką ar užimamą regioną kompiuterinės tomografijos nuotraukoje. Dažnai se- gmentacija atliekama naudojant regiono plėtimo metodus ar morfologi- nes operacijas, nors tiriami ir kiti būdai, tokie kaip matematinių modelių, tinklelio algoritmų naudojimas ar aktyvusis mokymas [5], [6], [7]. Taip pat taikomi ir neuroniniai tinklai, tačiau dažniausiai atliekama visos aneurizmos segmentacija [8], nes trombo regionas dėl netaisyklingos formos ir neišsi- skiriančio vaizdo taškų intensyvumo yra sunkiai segmentuojamas. Šio dar- bo tikslas yra ištirti pilvo aortos aneurizmos (atskirai kontrasto ir trombo) segmentavimo metodus naudojant neuroninius tinklus.

## 2 Literatūros apžvalga

Literatūroje aprašyta pilvo aortos aneurizmos analizė atliekama naudojant įvairius duomenis. Dažnai naudojami kompiuterinės tomografijos angiogra- mos vaizdai (CTA) [9], [8]. Taip pat gali būti naudojami magnetinio rezonanso vaizdai (MRI) [10], ultragarso nuotraukos [7] ar net dirbtinai sukurti vaizdai [11]. Dažniausiai pilvo aortos aneurizmos segmentacijos metodai buvo ku- riami ir testuojami atrenkant tik priešoperacinius neplyšusios aneurizmos vaizdus, tačiau kartais tiriami ir pooperaciniai pilvo aortos aneurizmos vaiz- dai (pasiektas  $0,82 \pm 0,07$  Dice panašumo koeficientas [12]). Pooperacinių vaizdų segmentavimas yra sudėtinga užduotis dėl netaisyklingos aortos for-

mos. Trombo segmentavimas (net ir priešoperacinis) taip pat turi daug iššūkių, nes vaizduose trombas labai panašus į šalia esančius organus. Todėl nors kiti aprašyti tyrimai gavo geresnius aortos aneurizmos segmentacijos rezultatus, [12] tyrime pasiekti rezultatai taip pat yra geri atsižvelgiant į tai, kad buvo vertinta vien tik trombo segmentacija.

Pilvo aortos aneurizmos vaizdų analizėje taikomi įvairūs metodai kompiuterinių tyrimų metu gautų vaizdų segmentacijai atlikti. Taškų intensyvumu paremti metodai yra lengvai implementuojami aortos ir trombo segmentacijos metodai. Tokių metodų pavyzdys yra Otsu metodas [13], naudotas aortos segmentacijai [14], kurio metu vaizduose esantys objektai atskiriami atliekant klasės skirtumų minimizaciją (ang. *minimisation of intra-class variances*). Rezultatai, gauti taikant šiuos metodus, yra nepastovūs ir gali suprastėti pasikeitus tyrimo aparatui, tyrimo parametrų ar aortos ar venos užsipildymu kontrastine medžiaga, todėl šie metodai dažnai jungiami su kitais metodais: naudojamos ir intensyvumo ir gradiento paieškos erdvės [15] ar taškų intensyvumo analizė derinama su grafo pjūviais paremtais metodais [16].

Regiono plėtimo metodas ir įvairūs jo variantai (dar vadinami aktyvaus kontūro metodais) yra dažnai naudojamas pilvo aortos aneurizmos segmentavimo metodas [17], [18]. Taikant šį metodą galima pritaikyti erdvinis apribojimus segmentuojamiems objektams, ko negalima padaryti naudojant pikselių intensyvumo histograma grįstus segmentavimo metodus, neapdorojančius erdvinės informacijos. Dažnai naudojant regiono plėtimo metodus reikalingas vartotojo įsikišimas segmentuojant nuotraukas. Gali būti prašoma nurodyti pirmą ir paskutinį sekos vaizdus, apribojančius aortos išplatėjimą. Taip pat prašoma vartotojo atlikti pradinį žymėjimą netoli aortos vidinių taškų [7]. Galimas regiono plėtimo metodo taikymas su papildomais kitų algoritmų išvestimi gautais apribojimais siekiant pagerinti tikslumą [19].

Pilvo aortos aneurizmos segmentavimą atliekant su neuroniniais tinklais dažniausiai naudojamas U-Net ar pilnai sujungtas konvoliucinis tinklas (ang. *deep convolutional neural network, DCNN*), nors galimos ir kitos tinklų struktūros [20], [21], [22]. Įprastai U-Net neuroninio tinklo mokymo metu kaip įvestis pateikiamas vienas vaizdas, tačiau galimas ir 3D U-Net variantas [23]. Be U-Net pilvo aortos aneurizmai segmentuoti taip pat yra naudojami ir giliaji konvoliuciniai neuroniniai tinklai (DCNN), paremti pilniai sujungta konvoliucinių tinklų architektūra [12], [24]. DetecNet [12] aptikimo tinklas buvo pritaikytas dominančio regiono (ang. *region of interest*) aptikimui. Tuomet buvo panaudota nauja pilnai sujungtų konvoliucijų tinklų architektūra ir tinklas buvo testuotas naudojant 13 pooperacinių pacientų vaizdų sekų [12].



Autoriai pasiekė 0.82 Dice panašumo koeficientą pooperaciniams pacientų vaizdams. Kitame tyrime [24] buvo gauti panašūs rezultatai, kur Dice panašumo koeficientas pooperaciniams pacientų vaizdams buvo  $0,837 \pm 0,062$ , priešoperaciniams:  $0,790 \pm 0,102$ .

Nors naudojant giliojo mokymo metodus buvo pasiekti geri segmentavimo rezultatai, ypač pooperacinių pacientų vaizdams, šių metodų generalizacija yra sudėtingas uždavinys radiologinių tyrimų vaizdams [25]. Atsiradus neatitikimams dėl įrangos, kuria gaunami vaizdai, pakeitimo, pasikeitusių vaizdo gavimo algoritmų kompiuterinės tomografijos metu, ar tyrimus atliekant kitoms demografinėms pacientų grupėms tokio segmentavimo rezultatai blogėja. Toks generalizacijos trūkumas gali reikšmingai pakenkti modelių klinikiniam taikymui, nes modelio tikslumas gali sumažėti atliekant tyrimus su kita įranga, nei buvo naudojama mokymo duomenims gauti [23].

### 3 Aortos ir trombo aptikimo metodai

ResNet yra semantinės segmentacijos uždaviniams spręsti skirtas neuroninis tinklas, sukurtas siekiant sumažinti nykstančio gradiento problemą giliuose neuroniniuose tinkluose [26]. Iki ResNet įprastas būdas pagerinti klasifikavimo ar segmentacijos tikslumą naudojant konvoliucinius tinklus buvo didinti jų sudėtingumą pridėdant papildomų sluoksnių. Tačiau tokios neuroninių tinklų architektūros dažnai susidurdavo su nykstančio gradiento problema. Tinklo mokymo metu naudojant klaidos skidimą atgal į pradinis sluoksnius, gradientas dažnai tapdavo nepastebimai mažas dėl didelio kiekio daugybės operacijų. Apmokant tokius gilius neuroninius tinklus dažnai galima pastebėti, kad gilėjant neuroniniam tinklui jo pasiektas tikslumas dažnai sustoja arba net pradeda blogėti. ResNet neuroninis tinklas siekia išvengti šios problemos naudodamas tapatumo jungtį (ang. *identity connection*), kuri apeina vieną ar daugiau sluoksnių, sujungdama sluoksnius į likučių bloką (ang. *residual block*). Tapatumo sąryšio įvedimas neprideda papildomų tinklo parametrų, todėl skaičiavimo sudėtingumas yra beveik toks pat, kaip ir paprastų neuroninių tinklų. Likučių blokas dažnai sujungia kelias konvoliucines operacijas. Klaidos sklidimo atgal metu gradiento sklidimas vyksta naudojant naujai įvestą tapatumo ryšį, todėl apeinami likutinio bloko vidiniai svoriai ir sumažinama nykstančio gradiento problema. Naudojant ResNet tapatumo ryšius ir konvoliucinius sluoksnius, sujungtus į likučių blokus, buvo sėkmingai apmokyti 50 ir 100 sluoksnių gylio konvoliuciniai neuroniniai tinklai [26].

DeepLab V3 gilusis neuroninis tinklas yra neuroninis tinklas, pritaikytas segmentacijos uždaviniui spręsti, nes dėl skylėtų konvoliucijos operacijų požymių žemėlapis (ang. *feature map*) nesumažinamas tiek, kiek kituose pilnai konvoliuciniuose tinkluose, todėl prarandama mažiau informacijos apie vaizduose esančių objektų vietą [27]. DeepLab V3 neuroninis tinklas naudoja išplėstų konvoliucijų (ang. *dilated convolutions*) idėją iš DilatedNet konvoliucinio tinklo [28], bet DeepLab V3 atveju vienodai išplečiami visi filtro taškai. DeepLab V3 autoriai taip pat taiko skylėtos erdvinės piramidės grupavimą (ang. *atrous spatial pyramid pooling*) konvoliucijos blokuose [27]. Tai yra skylėta SPP versija, naudojama SPPNet tinkle [29]. Keli skylėtų konvoliucijų filtrai su skirtingais skylėtumo koeficientais yra taikomi konvoliucijos sluoksnio išvesčiai, kurių rezultatai vėliau apjungiami. Šis metodas pagerina objektų, kurių skalės vaizduose gali daug skirtis, aptikimą.

U-Net neuroninio tinklo architektūra buvo sukurta remiantis pilno konvoliucinio tinklo architektūra [30] ir buvo skirta semantinei segmentacijai pagerinti medicininiuose vaizduose. Tinklo architektūra sudaryta iš dviejų kelių. Pirmasis kelias yra duomenų sutraukimo kelias, taip pat vadinamas enkoderiu (ang. *encoder*), kuris naudojamas vaizdo duomenų kontekstui rasti. Antrasis kelias yra išplėtimo kelias, kuris dar yra vadinamas dekoderiu (ang. *decoder*), ir yra simetriškas enkoderio tinklui. Dekoderis suteikia galimybę gauti tikslią objektų lokalizaciją pradiname vaizde, ne tik apibendrintą informaciją, kuri yra gaunama kaip enkoderio išvestis. Dekoderis naudoja transponuotas konvoliucijos operacijas ir yra nuo pradžios iki galo pilnai konvoliucinis tinklas (ang. *fully convolutional network, FCN*). U-Net tinklą sudaro tik konvoliuciniai sluoksniai be pilnai sujungto sluoksnio (ang. *dense layer*). Todėl U-Net tinklas kaip įvestį gali priimti bet kokio dydžio vaizdą.

#### 4 Segmentavimo vertinimo metodai

Segmentavimo rezultatams vertinti buvo pasirinkti du metodai: Dice koeficientas bei sankirtos ir sąjungos santykis (IoU) (ang. *intersection over union*). Dice panašumo koeficientas [31] naudojamas kiekybiškai įvertinti dviejų imčių panašumą. Vaizdų semantinės segmentacijos atveju Dice koeficientas interpretuojamas kaip panašumas tarp tikros objekto segmentacijos ir segmentacijos spėjimo, gauto naudojant segmentacijos modelį. Dice koeficientas apskaičiuojamas kaip dvigubo sankirtos dydžio ir abiejų aibių dydžių sumos santykis:

$$Dice = \frac{2 |X \cap Y|}{|X| + |Y|}.$$

Sprendžiant vaizdų segmentacijos uždavinį dviejų klasių atveju  $|X \cap Y|$  yra teisingai teigiamai klasifikuotų vaizdo taškų skaičius,  $|X|$  ir  $|Y|$  yra atitinkamai tikrų teigiamos klasės vaizdo taškų ir prognozuotų teigiamos klasės vaizdo taškų skaičius.

Jaccard panašumo koeficientas [32], dar žinomas kaip sankirta virš sąjungos, kuri dažnai trumpinama kaip IoU (ang. *intersection over union*), yra dar vienas dažnas vaizdų segmentacijoje naudojamas modelių rezultatų įvertinimo metodas. Naudojant Jaccard panašumo koeficientą segmentacija vertinama skaičiuojant santykį tarp bendrų dviejų klasių aibių taškų ir dviejų klasių sąjungos taškų. Jaccard panašumo koeficientas taikomas vaizdų segmentacijoje skaičiuojant santykį tarp tikros ir prognozuotos klasifikacijos aibių sankirtos ir sąjungos:

$$IoU = \frac{|X \cap Y|}{|X \cup Y|}.$$


## 5 Duomenys

Šiame darbe buvo naudotos 17 pacientų kompiuterinės tomografijos vaizdų sekos, kurioms gauti buvo naudota kontrastinė medžiaga. Originaliuose duomenyse buvo gautos 30 pacientų vaizdų sekos [8], tačiau dėl trūkstatų sužymėjimų darbe buvo naudoti tik 17 pacientų duomenys. Pacientų kompiuterinės tomografijos vaizdai su diagnozuota pilvo aortos aneurizma buvo surinkti nuo 2015 m. sausio mėn. iki 2019 m. gruodžio mėn. Gdansko medicinos universiteto Radiologijos departamente. Vidutinis pacientų amžius yra 70,6 metai. Iš 30 pacientų atrinkti 23 vyrų ir 7 moterų vaizdai.

Kompiuterinės tomografijos vaizdus žymėjo trijų medikų komanda: kraujagyslių chirurgas bei du kraujagyslių chirurgijos rezidentai. Iš pradžių buvo atliekama automatinė kontrasto segmentacija naudojant aktyvaus kontūro metodą nuo distalinės krūtinės aortos lygio iki bendrųjų šlaunikaulio arterijų. Taip pat buvo atliktas automatinis pagrindinių pilvo aortos išsišakojimų (celiakijos kamieno, viršutinės mezenterinės ir inkstų arterijų) pradžių sužymėjimas naudojant aktyvaus kontūro metodą. Antrame žymėjimo žingsnyje buvo atliekamas rankinis pilvo aortos aneurizmos žymėjimas rankiniu būdu pažymint išorinę aortos sieną kiekviename vaizde. Vėliau žymėjimai buvo programiškai sujungti pirmenybę teikiant rankinio žymėjimo rezultatams. Pacientų vaizdų sekas sudarė 450–1300 vaizdų, iš kurių 40–60

% reikėjo rankinio sužymėjimo. Sužymėjimo pabaigoje vaizdai buvo anonimizuoti [8].

Atlikus pradinį vaizdų apdorojimą ir suvienodinus kontrasto ir trombo žymėjimus, vaizdai iš DICOM formato buvo konvertuoti į PNG atliekant HU transformaciją (lango plotis 400, lango lygis 35). Tuomet vaizdai buvo normalizuoti į [0, 1] intervalą taikant min-max normalizaciją. Atlikus duomenų paruošimą buvo taikoma duomenų augmentacija, siekiant padidinti turimų vaizdų skaičių. Buvo taikomas posūkis ir stačiakampių ar kvadratų iškirpimas vaizde, kurių ilgio ir pločio santykis yra nuo 3/4 iki 4/3. Tuomet iškirpti stačiakampiai buvo transformuojami į pradinio vaizdo dydį. Gautas vaizdas galėjo apimti nuo 75 % iki 100 % pradinio vaizdo ploto. Šios duomenų augmentacijos buvo taikytos atsitiktiniu būdu kiekvienam vaizdai ir jo žymėjimui kiekvienos epochos pradžioje. Duomenų augmentacijos pavyzdžiai pavaizduoti 1 pav.



1 pav. Trijų pacientų duomenų augmentacijų pavyzdžiai.

## 6 Rezultatai

Aortos ir trombo segmentacijai buvo taikyti trys neuroninių tinklų modeliai: ResNet-101, DeepLab V3 ir U-Net. Dėl ribotų skaičiavimo resursų vaizdai buvo sumažinti iki 128x128 vaizdo taškų. 1 lentelėje pavaizduoti neuroninių tinklų testavimo rezultatai aortos kontrasto segmentacijai. Geriausi rezultatai po fiksuoto epochų skaičiaus pasiekti naudojant U-Net neuroninį tinklą su mišria nuostolių funkcija, apjungiančia kryžminę entropiją ir Dice panašumo koeficientą.

Trombo segmentaciją atlikti sudėtinga, nes aplink trombą yra panašios geometrijos struktūros, žymimos panašaus intensyvumo vaizdo taškais. Siekiant palengvinti trombo segmentaciją pradinis vaizdas buvo apkarpmas iki 312x312 pašalinant kompiuterinės tomografijos vaizdo taškus. Taip pat anksčiau gautus rezultatus bandyta pagerinti taikant morfologines operacijas trombo žymėjimams. Dėl programiškai gautų trombo žymėjimų kartais gauti žymėjimai turi pavienių vaizdo taškų ar nesujungtų regionų, priskiriamų trombui, kurie galimai atsiranda dėl nevienodo aortos sienos identifikavimo kompiuterinės tomografijos vaizduose. Problemą bandyta spręsti taikant išplėtimo ir erozijos operacijas, siekiant sujungti atskirus trombą žyminčius regionus su smulkiais tarpais.

**1 lentelė.** Aortos segmentavimo rezultatai naudojant skirtingus neuroninius tinklus ir nuostolių funkcijas.

Nuostolių funkcija	Kryžminė entropija		Dice koeficientas		Kryžminė entropija ir Dice koeficientas	
	Dice	IoU	Dice	IoU	Dice	IoU
Segmentavimo tikslumo vertinimas						
ResNet-101	0,26774	0,17900	0,80633	0,68460	0,63592	0,50207
DeepLab V3	0,29460	0,21513	0,80479	0,68563	0,73527	0,60535
U-Net	0,81529	0,71421	0,80576	0,70532	<b>0,87554</b>	<b>0,79734</b>

Analizuojant po vaizdo apkarpyto gautus grafinius rezultatus buvo pastebėta, kad tinkle atsiranda permokymas (ang. *overtraining*). Siekiant to išvengti, buvo pritaikytas atsitiktinis svorių išmetimas (ang. *dropout*) tarp trijų U-Net tinklo dekoderio sluoksnių. Nors dėl atsitiktinio svorių išmetimo šiek tiek pablogėjo aortos kontrasto segmentavimas, tačiau trombo segmentacija pagerėjo maždaug 1,6 karto. Segmentacijos rezultatai atlikus pradinių vaizdų apkarpytą ir atsitiktinį svorių pašalinimą pateikiami 2 lentelėje.



**2 lentelė.** Segmentavimo rezultatai taikant vaizdų apkarpyimą ir atsitiktinį svorių pašalinimą

Segmentuotas regionas	Tik su vaizdo apkarpyimu		Su vaizdo apkarpyimu ir atsitiktiniu svorių pašalinimu	
	Dice	IoU	Dice	IoU
Kontrastas	0,91799	0,86600	0,86610	0,79662
Trombas	0,22655	0,15133	0,38257	0,29939


Apmokius U-Net neuroninį tinklą siekta pagerinti rezultatus apjungiant du skirtingai apmokytus neuroninius tinklus. Duomenyse yra trombo žymėjimo problemų, taip pat trombo regionas yra sudėtingai identifikuojamas dėl panašaus intensyvumo vaizdo taškų, esančių aplink trombą bei netaisyklingos jo formos. Todėl buvo siekta palengvinti segmentavimo užduotį apmokant du skirtingus neuroninius tinklus. Pirmasis tinklas buvo apmokytas atlikti tik kontrasto segmentaciją, kitas tinklas segmentuoja tik bendrą kontrasto ir trombo regioną. Trombo regionas gautas atėmus segmentuotą kontrasto regioną iš bendro regiono. Mokymas ir testavimas atliktas keliais būdais: naudojant visus turimus pacientų vaizdus ir naudojant tik tuos vaizdus, kuriuose trombas yra matomas.

**3 lentelė.** Rezultatai apmokius du neuroninius tinklus skirtingiems regionams segmentuoti

Regionas	Du segmentavimo tinklai, testuoti su visais vaizdais		Du segmentavimo tinklai, testuoti tik su matomo trombo vaizdais		Du segmentavimo tinklai, apmokyti tik matomo trombo vaizdais, testuoti su visais		Du segmentavimo tinklai, apmokyti ir testuoti tik matomo trombo vaizdais	
	Dice	IoU	Dice	IoU	Dice	IoU	Dice	IoU
Kontrastas	0,9058	0,8582	0,9066	0,8662	0,9399	0,8941	<b>0,9458</b>	<b>0,9054</b>
Trombas	0,4123	0,3325	<b>0,5820</b>	<b>0,4694</b>	0,3906	0,3202	0,5514	0,4521
Bendras	0,8444	0,7612	0,8296	0,7453	0,7931	0,7132	0,7725	0,7017

Testavimo rezultatai pavaizduoti 3 lentelėje. Kontrasto segmentavimo rezultatai yra geriausi tuomet, kai du tinklai buvo apmokyti ir testuoti tik su matomo trombo vaizdais, nors skirtumas tarp testavimo vaizdų variantų nėra toks didelis kaip tarp mokymo vaizdų variantų. Trombo segmentavimo testavimo rezultatai yra daug geresni tais atvejais, kai buvo testuojama naudojant tik trombą vaizduojančius vaizdus. Tai galima paaiškinti analizuojant

atliktų segmentacijų pavyzdžius. Pav. 2b matoma, kad testavimui naudojant ir tuos vaizdus, kuriuose nėra trombo, trombas yra vis tiek surandamas. 2b vaizde matoma, kad kartais aplink kontrastą esančios kitos anatomicinės struktūros, tokios kaip raumenys, yra identifikuojamos kaip trombas. Tokių klaidų išvengiama, kai testavimas atliekamas tik su vaizdais, kuriuose matomas trombas. Pav. 2a pavaizduotas trombo segmentavimo pavyzdys, kai rastos trys iš keturių trombo pusių.



**2 pav.** Kontrasto ir trombo segmentacijų pavyzdžiai, testuojant ir apmokant su visais duomenimis.

## 7 Išvados

Apmokius tris neuroninius tinklus su skirtingomis nuostolių funkcijomis pasiekti geri kontrasto segmentavimo rezultatai, tačiau trombo segmentavimo rezultatai nėra tokie geri. Tai gali lemti per mažas tinklo mokymui turimas duomenų kiekis, žymėjimų netikslumai vaizduose ir trombo erdvinės savybės. Turint mažai pacientų įvyksta tinklo persimokymas, kurio iš dalies galima išvengti taikant atsitiktinių svorių pašalinimą.

Literatūroje aprašyto segmentacijų tikslumo, gauto su turimais duomenimis, gauti ar pagerinti nepavyko, tačiau pavyko gauti panašius kontrasto segmentavimo rezultatus: [8] pasiekė 0,94 Dice panašumo koeficientą aneurizmos segmentacijai, kur kontrasto ir trombo regionas naudojamas kaip viena klasė ir skaičiuojamas trijų neuroninių tinklų rezultatų svorinis vidurkis segmentacijoms rasti. Šiame darbe sprendžiama problema yra sudėtingesnė, nes siekiama atskirai segmentuoti trombo regioną. Mažesnis segmentacijos tikslumas gaunamas ir dėl mažesnio duomenų kiekio, kuris naudojamas apmokyti. Šiame darbe buvo naudojami 17 iš 30 pacientų vaizdai. Siekiant atskirti skirtingų pacientų vaizdus mokymo, testavimo ir validavimo duomenyse, naudojamas daug mažesnis pacientų skaičius tinklo mokymui ir validavimui, kas lemia mažesnę vaizdų įvairovę.

Gautus pradinis rezultatus pavyko pagerinti naudojant du atskirus neuroninius tinklus, kurie buvo apmokyti klasifikuoti tik vieną regioną (kontrastą arba trombą). Taip supaprastinus mokymo užduotį galima pasiekti gerų rezultatų net ir naudojant beveik du kartus mažesnę duomenų kiekį nei [8] darbe.

Naudojant 2D neuroninius tinklus prarandama erdvinė informacija, todėl tampa sunkiau identifikuoti anatomines struktūras, turinčias mažą skerspjūvio plotą. Objekto segmentacijos sekimas 3D duomenyse galėtų palengvinti ilgų anatominių struktūrų, turinčių mažą skerspjūvio plotą, segmentavimą, todėl maži pavieniai trombo regionai galėtų būti geriau atskiriami. Dėl nepakankamo pacientų kompiuterinės tomografijos vaizdo sekų kiekio pilnas 3D U-Net tinklo mokymas yra negalimas, tačiau galima tinklą mokyti 3D objekto segmentais kaip tinklo įvestį naudojant tris ar penkis iš eilės einančius kompiuterinės tomografijos sekos vaizdus.



## Literatūra

- [1] Ramkumar, N., Suckow, B. D., Arya, S., Sedrakyan, A., Mackenzie, T. A., Goodney, P. P., & Brown, J. R. (2020). Association of Sex With Repair Type and Long-term Mortality in Adults With Abdominal Aortic Aneurysm. *JAMA Network Open*, 3(2), e1921240–e1921240.
- [2] Kent, K. C. (2014). Abdominal aortic aneurysms. *New England Journal of Medicine*, 371(22), 2101–2108.
- [3] Greenhalgh, R. M., Brown, L. C., Epstein, D., Kwong, G. P. S., Powell, J. T., & Sculpher, M. J. (2005). Endovascular aneurysm repair and outcome in patients unfit for open repair of abdominal aortic aneurysm (EVAR trial 2): randomised controlled trial. *Lancet*, 365(9478), 2187–2192.
- [4] Chaikof, E. L., Dalman, R. L., Eskandari, M. K., Jackson, B. M., Lee, W. A., Mansour, M. A., Mastracci, T.M., Mell, M., Murad, M.H., Nguyen, L.L. and Oderich, G.S. & Starnes, B. W. (2018). The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *Journal of vascular surgery*, 67(1), 2–77.
- [5] Maiora, J., Ayerdi, B., & Graña, M. (2014). Random forest active learning for AAA thrombus segmentation in computed tomography angiography images. *Neurocomputing*, 126, 71–77.
- [6] Dolgov, V. Y., Klyshnikov, K. Y., Ovcharenko, E. A., Glushkova, T. V., Batranin, A. V., Agienko, A. S., ... & Kutikhin, A. G. (2019). Finite element analysis-based approach for prediction of aneurysm-prone arterial segments. *Journal of Medical and Biological Engineering*, 39(1), 102–108.
- [7] Cercenelli, L., Lodi, S., Bortolani, B., Mascoli, C., Gargiulo, M., & Marcelli, E. (2020). EVAR-eaSE: An Easy-to-Use Software for Planning Sac Embolization in EndoVascular Aneurysm Repair Procedure. *Applied Sciences*, 10(18), 6252.
- [8] Dziubich, T., Białas, P., Znaniecki, Ł., Halman, J., & Brzeziński, J. (2020, August). Abdominal aortic aneurysm segmentation from contrast-enhanced computed tomography angiography using deep convolutional networks. In *ADBIS, TPDL and EDA 2020 Common Workshops and Doctoral Consortium* (pp. 158–168). Springer, Cham.
- [9] Rengarajan, B., Wu, W., Wiedner, C., Ko, D., Muluk, S. C., Eskandari, M. K., ... & Finol, E. A. (2020). A comparative classification analysis of abdominal aortic aneurysms by machine learning algorithms. *Annals of biomedical engineering*, 48(4), 1419–1429.
- [10] Wang, Y., Tian, B., Xiong, F., Kao, E., Zhang, Y., Liu, X., ... & Saloner, D. (2021). Computer-aided quantification of non-contrast 3D black blood MRI as an efficient alternative to reference standard manual CT angiography measurements of abdominal aortic aneurysms. *European Journal of Radiology*, 134, 109396.
- [11] Jalalahmadi, G., Linte, C., & Helguera, M. (2017, March). A numerical framework for studying the biomechanical behavior of abdominal aortic aneurysm. In *Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging* (Vol. 10137, p. 101372A). International Society for Optics and Photonics.
- [12] López-Linares, K., Aranjuelo, N., Kabongo, L., Maclair, G., Lete, N., Ceresa, M., ... & Ballester, M. A. G. (2018). Fully automatic detection and segmentation of abdominal aortic thrombus in post-operative CTA images using deep convolutional neural networks. *Medical image analysis*, 46, 202–214.
- [13] Otsu, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62–66, 1979.

- [14] Lessard, S., Kauffmann, C., Pfister, M., Cloutier, G., Thérasse, É., de Guise, J. A., & Soulez, G. (2015). Automatic detection of selective arterial devices for advanced visualization during abdominal aortic aneurysm endovascular repair. *Medical engineering & physics*, 37(10), 979–986.
- [15] Siriapisith, T., Kusakunniran, W., & Haddawy, P. (2019). 3D segmentation of exterior wall surface of abdominal aortic aneurysm from CT images using variable neighborhood search. *Computers in biology and medicine*, 107, 73–85.
- [16] Freiman, M., Esses, S. J., Joskowicz, L., & Sosna, J. (2010, April). An iterative model-constrained graph-cut algorithm for abdominal aortic aneurysm thrombus segmentation. In *2010 IEEE international symposium on biomedical imaging: from nano to macro* (pp. 672–675). IEEE.
- [17] Kim, H. C., Park, S. W., Nam, K. W., Choi, H., Choi, E. J., Jin, S., ... & Sun, K. (2010). Determination of accurate stent graft configuration in abdominal aortic aneurysm using computed tomography: a preliminary study. *Clinical imaging*, 34(4), 255–262.
- [18] van Disseldorp, E. M. J., van Dronkelaar, J. J., Pluim, J. P. W., van de Vosse, F., van Sambeek, M. R. H. M., & Lopata, R. G. P. (2016, September). Automatic segmentation and registration of abdominal aortic aneurysms using 3D ultrasound. In *2016 IEEE International Ultrasonics Symposium (IUS)* (pp. 1–4). IEEE.
- [19] Macía, I., de Blas, M., Legarreta, J. H., Kabongo, L., Hernández, Ó., Egaña, J. M., ... & Graña, M. (2016). Standard and fenestrated endograft sizing in EVAR planning: description and validation of a semi-automated 3D software. *Computerized Medical Imaging and Graphics*, 50, 9–23.
- [20] Maiora, J., & Graña, M. (2012, March). A hybrid segmentation of abdominal CT images. In *International Conference on Hybrid Artificial Intelligence Systems* (pp. 416–423). Springer, Berlin, Heidelberg.
- [21] Maiora, J., & Graña, M. (2012, June). Abdominal CTA image analysis through active learning and decision random forests: Application to AAA segmentation. In *The 2012 international joint conference on neural networks (IJCNN)* (pp. 1–7). IEEE.
- [22] Shum, J., DiMartino, E. S., Goldhammer, A., Goldman, D. H., Acker, L. C., Patel, G., ... & Finol, E. A. (2010). Semiautomatic vessel wall detection and quantification of wall thickness in computed tomography images of human abdominal aortic aneurysms. *Medical physics*, 37(2), 638–648.
- [23] Lu, J. T., Brooks, R., Hahn, S., Chen, J., Buch, V., Kotecha, G., ... & Tenenholtz, N. A. (2019, October). DeepAAA: clinically applicable and generalizable detection of abdominal aortic aneurysm using deep learning. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 723–731). Springer, Cham.
- [24] López-Linares, K., Kabongo, L., Lete, N., Maclair, G., Ceresa, M., García-Familiar, A., ... & Ballester, M. A. G. (2017). Dcnn-based automatic segmentation and quantification of aortic thrombus volume: Influence of the training approach. In *Intravascular Imaging and Computer Assisted Stenting, and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis* (pp. 29–38). Springer, Cham.
- [25] Zech, J. R., Badgeley, M. A., Liu, M., Costa, A. B., Titano, J. J., & Oermann, E. K. (2018). Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study. *PLoS medicine*, 15(11), e1002683.
- [26] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770–778).

- [27] Chen, L. C., Papandreou, G., Schroff, F., & Adam, H. (2017). Rethinking atrous convolution for semantic image segmentation. arXiv preprint arXiv:1706.05587.
- [28] Yu, F., & Koltun, V. (2015). Multi-scale context aggregation by dilated convolutions. arXiv preprint arXiv:1511.07122.
- [29] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904–1916.
- [30] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234–241). Springer, Cham.
- [31] Dice, Lee R. (1945). „Measures of the Amount of Ecologic Association Between Species“. *Ecology*. 26 (3): 297–302. doi:10.2307/1932409. JSTOR 1932409.
- [32] Jaccard, Paul (1912). „The Distribution of the Flora in the Alpine Zone.1“. *New Phytologist*. 11 (2): 37–50. doi:10.1111/j.1469-8137.1912.tb05611.x. ISSN 0028-646X.

**2 publikacija.** Šubonienė, A. (2021). Pilvo aortos vietos nustatymas krūtinės ąstos tomografinėje nuotraukoje. *Vilnius University Open Series*, 106-117. DOI: <https://doi.org/10.15388/LMITT.2021.12>

## Pilvo aortos vietos nustatymas krūtinės ąstos tomografinėje nuotraukoje

**Aušra Šubonienė**

Vilniaus universitetas, Duomenų mokslo ir skaitmeninių technologijų institutas, Akademijos g. 4, LT-08412 Vilnius  
[ausra.suboniene@mif.vu.lt](mailto:ausra.suboniene@mif.vu.lt)

---

**Santrauka.** Kompiuterinė tomografija, kuri naudojama pilvo aortos aneurizmos diagnostikai ir stebėjimui, leidžia vartotojams stebėti aneurizmos būseną paciento kūno skerspjūvio nuotraukų sekoje. Dažnai kompiuterine tomografija grįžtiems diagnostikos įrankiams aortos vieta turi būti nurodoma vartotojo. Darbe aprašomas pilvo aortos vidinių taškų identifikavimo būdas be pradinės aortos vietos išankstinio žymėjimo. Darbe sprendžiami uždaviniai: medicinos vaizdų analizės metodų apžvalga bei parinkimas, pirminis vaizdų apdorojimas pašalinant triukšmą bei išskiriant vaizde esančių objektų kontūrus, aortos aptikimo metodo pasiūlymas. Taip pat pasiūlomas aortos trombo aptikimo metodas, kuriam vartotojas turi pateikti sekos vaizdą, kuriame trombas yra matomas, bet jam nereikia nurodyti tikslios ar apytikslės trombo vietos.

**Raktiniai žodžiai:** Pilvo aortos aneurizma, aortos trombas, medicininių vaizdų analizė, kompiuterinė tomografija.

---

### 1 Įvadas

Pilvo aortos aneurizma yra lėtinė liga, pasireiškianti pilvo aortos išplatėjimu nusilpus jos sienelai, kurios diagnozei bei stebėsenai naudojama kompiuterinė tomografija. Esant pilvo aortos aneurizmai aortos sienelės išsiplėtimas gali būti 1.5 ar daugiau kartų didesnis už normalų aortos skersmenį [1]. Ligai progresuojant išplatėjusi aortos sienelė pasidengia kraujo komponentų sluoksniu, kuris vėliau padidėja iki trombo. Per daug išsiplėtusi aorta gali spausti aplinkinius organus arba plyšti ir sukelti stiprų kraujavimą. Nesukeliantis simptomų, nedidelės aneurizmos yra tik stebimos, periodiškai atliekant tyrimus. Jei aneurizma didelė, didėja ar sukelia simptomus, siekiant išvengti komplikacijų, ligonis būna operuojamas. Plyšus pilvo aortos aneurizmai mirštamumas siekia 85% to 90% [1]. Tokiu atveju atliekama skubi operacija. Plyšus pilvo aortos aneurizmai ir spėjus atlikti operaciją mirtingu-

mas vis tiek išlieka aukštas, apie 33-36% [2], tačiau jei plyšimo išvengiama atliekant operaciją, mirtingumas ženkliai sumažėja iki 1-6% [3].

Šiuo metu pilvo aortos aneurizmos diagnostikoje naudojami metodai užima daug laiko, nes dažnai analizuojant kompiuterinės tomografijos nuotraukas vartotojai nurodo pradinę vietą ar zoną, kurioje yra aorta kiekvienai kompiuterinės tomografijos nuotraukai vaizdų sekoje. Tuomet sukuriamas trimatis aortos modelis, skirtas aneurizmos diagnostikai. Remiantis kraujagyslių chirurgijos draugijos praktikos gairėmis [4] trūksta standartizavimo, nustatančio ligos progresavimo laipsnį ir greitį, o matuojant aortos skersmenį yra didelės paklaidos, nes skersmuo matuojamas rankiniu būdu pagal tam tikrą vartotojo pasirinktą vaizdą. Naudojant šiuo metu pasiekiamus diagnostikos įrankius gaunamas aortos kontrasto trimatis modelis, tačiau jį neįtraukiamas trombas. Taip sudėtinga įvertinti aortos išsiplėtimą, nes aortos aneurizmos atveju aortos kontrastinę dalį iš šonų dengia susidaręs trombas, kuris plečia aortos sienelę. Taip pat dabartiniai įrankiai netiksliai segmentuoja aortos vidaus taškus, kuomet nuotraukose matosi iš aortos išsišakančios arterijos ir venos. Kartais kontrasto segmentacijos metu po išsišakojimo toliau sekami ne aortos, o iš aortos išeinančios arterijos ar kontrastu užsipildžiusios venos taškai. Šio darbo tikslas yra aortos bei trombo vidinių taškų identifikacija naudojant vien tik kompiuterinės tomografijos nuotraukas, vartotojui nurodant pradinės aortos vietas. Tai sutrumpintų laiką, skirtą vieno paciento pilvo aortos aneurizmos diagnostikai, kurį gydytojas skiria vienam pacientui naudojant šiuo metu prieinamus aneurizmos diagnostikos įrankius.

Šiame darbe bus naudojami kompiuterinės tomografijos vaizdai, kuriuose pavaizduota aorta bei ją supantis trombas iki aortos išsišakojimo į dvi klubines arterijas. Siekiama aptikti aortos kontrasto bei aplink aortą esančio trombo vidinius taškus iki aortos išsišakojimo į dvi arterijas, bei atskirti ją nuo aplink arteriją esančių kitų struktūrų, tokių kaip stuburas.

## 2 Literatūros apžvalga

Medicininį vaizdų analizėje taikomi įvairūs metodai kompiuterinių tyrimų metu gautų vaizdų segmentacijai atlikti- slenkstinės reikšmės taikymas siekiant išskirti sričių kontūrus ar kontūrų aptikimas taikant diferenciaciją, regiono plėtimas, klasterizavimas, klasifikavimas, neuroniniai tinklai ar matematiniai modeliai. Sprendžiant segmentavimo problemas dažnai naudojami ir keli metodai, siekiant pagerinti segmentavimo rezultatus.

Per ilgą laiką buvo pasiūlyta daug slenkstinės reikšmės metodų, naudojamų biomedicininį vaizdų analizėje bei objektų aptikime ([5], [6]). Tarp jų, vienas efektyviausių vaizdų segmentavimo būdų yra entropija pagrįsti optimizavimo metodai, tokie kaip entropijos maksimizavimas (Kapur metodas) [7] ir kryžminės entropijos minimizavimo metodas [8]. Skaičiavimo efektyvumui pagerinti buvo pasiūlyta daugybė daugiapakopio slenksčio uždavinio metodų ([9], [10]), tačiau tinkamai pasirinkti slenkstines vertes yra sudėtinga. Tai ypač aktualu kompiuterinės tomografijos nuotraukose, kur rezultatai vaizduojami skirtingo intensyvumo pilkais pikseliais ir skirtingi organai gali turėti labai panašias pikselių vertes. Todėl medicininių vaizdų segmentavimui kartu su slenkstinės reikšmės metodu dažnai yra taikomi ir kontūrų aptikimu pagrįsti metodai.

Kontūrų aptikimu pagrįsti segmentavimo metodai yra kuriami remiantis greitu paveikslėlio pikselių intensyvumo vertės pasikeitimu, nes viena intensyvumo vertė nepateikia geros informacijos apie kontūrus. Dažnai kontūrų aptikimo būdai išskiria kontūrus, kur pirmoji išvestinė yra didesnė už tam tikrą slenkstį. Gradiento metodai yra dažnas pasirinkimas kontūrų aptikimui ([11], [12]). Kiti naudojami metodai: Roberts [13], Sobel [14], Prewitt ar Canny [15].

Vaizduose radus kontūrus, segmentacija gali būti atliekama taikant regiono plėtimo metodą. Regiono plėtimas yra paprastas regionu grįstas vaizdų segmentavimo metodas, naudojamas medicininių vaizdų analizėje ([16], [17]). Palyginus su pikselių intensyvumo histograma grįstais segmentavimo metodais, kurie nesuteikia erdvinės informacijos, tik pilkos spalvos intensyvumo lygių pasiskirstymą, taikant regiono plėtimo metodą galima tuo pačiu metu pritaikyti ir erdvinius apribojimus. Pagrindinis regiono plėtimo metodu paremtos segmentacijos trūkumas yra tai, kad regiono plėtimui reikalingas teisingai parinktas pradinis taškas, kas dažnai reikalauja vartotojo veiksmų. Šiai problemai spręsti yra sukurti ir automatiniai pradinio taško parinkimo sprendimai, nors dažnai tai sumažina segmentacijos tikslumą, jei metodas nesuteikia vartotojui klaidų taisymo galimybių ([18], [19]).

Kadangi medicinos vaizdų analizėje analizuojamų objektų formos gali būti iš anksto žinomos (vidaus organų formos, šonkaulių išsidėstymas bei jų kontūras, kraujagyslių skerspjūvis, kaulo forma ir pan.), medicinos vaizdų analizėje geri rezultatai pasiekiami ir naudojant modeliais paremtus metodus. Tokių metodų prielaida yra ta, kad analizuojamose struktūrose vyrauja



iš anksto žinomos formos, todėl galima ieškoti tikimybinio modelio, apibūdinančio tą formą ir jos kitimą.

Kompiuterinės tomografijos vaizdų registracijos problema yra sėkmingai sprendžiama taikant matematinius modelius šonkauliais apriboto ploto identifikacijai bei vaizdų registracijai ([20], [21]). Sukurtas modelis leidžia atlikti sėkmingą kompiuterinės tomografijos vaizdų registraciją net esant posūkio kampo, skalės bei postūmio skirtumams tarp analizuojamų vaizdų. Tai yra ypač aktualu, kuomet kompiuterinės tomografijos nuotraukos daromos naudojant skirtingus kompiuterinės tomografijos įrenginius ar pacientui šiek tiek keičiant poziciją tyrimo metu. Toks modelis taip pat gerai veikia nepriklausomai nuo kontrastinės medžiagos naudojimo ar nenaudojimo tyrimuose. Kiti sėkmingi medicininių vaizdų analizės modeliais paremti metodai apima aktyvių kontūrų modelius (angl. active contour model) ir aktyvios formos modelius (ang. active appearance models) [22], [23], [24].

Atliekant aortos ir trombo segmentaciją aukščiau minėti metodai apjungiami kartu, taip sukuriant aukšto patikimumo vartotojui patogų metodą. Tokio metodo pavyzdys yra [25] sukurtas aortos ir trombo segmentavimo metodas, kuris naudoja ribų sklidimo ir aktyvaus kontūro metodus. Sukurtas metodas buvo įvertintas naudojant 40 kompiuterinės tomografijos vaizdų sekų. Buvo pasiekta stipri koreliacija tarp segmentavimo metu gautų rezultatų ir vertinimui naudotų eksperto segmentuotų vaizdų.

### 3 Duomenys

Analizei buvo naudojami 3 pacientų vaizdai, gauti kompiuterinės tomografijos metu. Kiekvienos kompiuterinės tomografijos nuotraukos dydis 512x512, nuotraukos darytos 2.5 mm intervalu. Nuotraukose ryškiai pavaizduoti šonkauliai, gulimasis paviršius, taip pat aorta bei kitos kraujagyslės, nes tyrimų metu buvo naudota kontrastinė medžiaga.

Kompiuterinės tomografijos metu radiacijos absorbuojamas matuojamas Hounsfield vienetais (HU), kuriuos vėliau reikia perskaičiuoti į pikselių intensyvumą. Taip skirtingo tankio organai, kuriems yra būdingas skirtinga radiacijos sugertis, ekrane atvaizduojami skirtingo intensyvumo pikseliais. Tyrimų metu gauti vaizdai buvo normalizuoti į [0, 255] intervalą, išreiškiant gautus HU į pikselių pilkos spalvos intensyvumą, kuris buvo skaičiuojamas naudojant reikšmes  $L=40$  ir  $W=350$ .

## 4 Aortos ir trombo aptikimo metodai

### 4.1 Aortos aptikimas

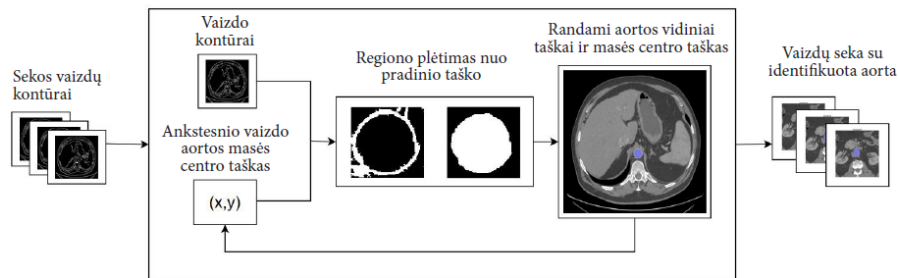
Aortos ir trombo aptikimui pritaikomi standartiniai vaizdų apdorojimo metodai, tokie kaip triukšmo vaizde pašalinimas naudojant Gauso, medianos, dvišalį bei nelokaliųjų vidurkių filtrus, kontūrų išskyrimas Sobel metodu, morfologinės operacijos, tokios kaip išplėtimas, erozija bei skeletonizacija. Darbe taip pat naudojami klasterizavimo, Hough transformacijos bei regiono plėtimo metodai.

Aortos identifikavimo problemai spręsti buvo pasirinktas regiono plėtimo metodas. Regiono plėtimui reikalingas gerai parinktas pradinis taškas, priklausantis norimam regionui, nuo kurio regionas ir būtų plečiamas. Siekiant išvengti vartotojo įsikišimo ir aortos vidinius taškus rasti automatiškai, pradinis aortos taškas buvo rastas pasinaudojant nuosekliais kompiuterinės tomografijos duomenimis bei aortos anatomija. Atliekant pradinio taško paiešką analizuojant pirmus 10 sekos vaizdų, kiekviename vaizde naudojant Hough transformaciją apskritimams buvo rasti visi apskritimai, kurių spindulys yra tarp 30 ir 70 taškų. Taip buvo rasti ne tik aortą žymintys apskritimai, bet ir kiti apskritimai, žymintys stuburo slankstelius bei organų apvalias dalis. Šie rasti apskritimai buvo klasterizuojami naudojant aglomeratyvų hierarchinį klasterizavimą. Dėl aortos anatominių savybių aortą žymintys apskritimai sudaro klasterį, turinį didžiausią elementų kiekį.

Ne sekos pradžioje esančiuose vaizduose aortos kontūrai gali būti deformuoti apskritimą šiek tiek suplojant. Taip pat vaizduose tampa matomos iš aortos išeinančios kraujagyslės, kurios iškreipia aortos kontūrą. Dėl šių priežasčių tolimesniuose sekos vaizduose naudojant tik Hough transformaciją kontrastui aptikti būtų gaunami netikslūs rezultatai, nes būtų ieškoma tik apskritimų. Todėl segmentacijai buvo pasirinktas regiono plėtimo metodas nuo pradinio taško. Aukščiau minėtos Hough transformacijos bei klasterizacijos metu gautas taškas buvo naudojamas kaip pradinis regiono plėtimo taškas primam sekos vaizdui.

Radus aortos vidinius taškus regiono kontūras buvo patikslintas morfologinėmis operacijomis pašalinant pavienius pikselius, įsiterpusius į regiono vidų. Tuomet buvo randamas segmentuoto regiono masės centro taškas, kuris buvo naudojamas kaip sekančio sekos vaizdo regiono plėtimo pradžios taškas. Aortos kontrasto segmentavimo schema pavaizduota 1 pav.

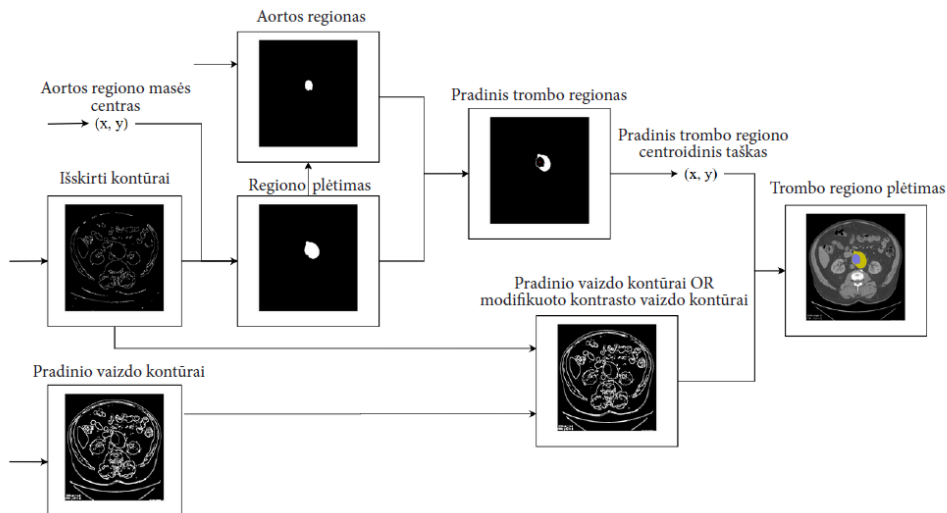




1 pav. Aortos kontrasto aptikimo schema.

## 4.2 Trombo aptikimas

Trombo identifikavimui buvo nurodytas pradinis vaizdas, kuriame trombo forma aiškiai matoma. Iš pradžių buvo išskirti aortos vidinius taškus bei aortos trombą atitinkančio regiono bendri kontūrai. Tam pradiniam vaizde buvo pašalintas triukšmas naudojant tuos pačius metodus, kaip ir aortos vidinių taškų išskyrimo atveju. Tuomet buvo pakeistas vaizdo taškų intensyvumo reikšmių pasiskirstymas. Turint anksčiau rastą aortos vidinių taškų matricą jos masės centras buvo naudotas bendram trombo ir aortos regionui rasti regiono plėtimo būdu. Iš šio bendro aortos bei trombo regiono



2 pav. Aortos trombo aptikimo schema.

atėmus trombo regiono taškus gautas pradinis trombą žymintis regionas. Radus šio regiono centroidinį tašką, jis buvo panaudotas kaip pradinis taškas trombui rasti.

Kontūrų taškų matrica trombo radimui buvo gauta sudedant pradinio vaizdo kontūrus, naudotus aortos radimui, bei išryškinto trombo regiono kontūrus. Tai buvo reikalinga trombo regiono uždarymui, nes pradiniuose regionuose dėl aplink aortą ir trombą esančių detalių trombo sienelės ne visada buvo teisingai identifikuojamos ir kontūrai buvo neuždari. Esant neuždariems kontūrams regiono plėtimo būdu trombas nebūtų teisingai identifikuojamas, įtraukiant į analizuojamą regioną didžiąją dalį visų vaizdo taškų.


## 5 Rezultatai

Pritaikius aortos aptikimo metodą pacientų kompiuterinės tomografijos vaizdų sekoms buvo segmentuotas aortos kontrasto regionas. Sėkmingai identifikavus aortos vidinius taškus pirmame sekos vaizde, sekančiuose vaizduose aortos vidiniai taškai randami naudojant rasto regiono taškus žyminčią binarinę matricą. Kiekvienam  $n$ -tajam sekos vaizdui naudojama prieš tai buvusio  $n-1$ -ojo vaizdo regiono matrica, kurios svorio centro koordinatės naudojamos kaip  $n$ -tojo vaizdo pradinis taškas regiono plėtimo metodui.

Aortos segmentavimo rezultatai pavaizduoti 3 pav. Matoma, kad algoritmas sugebėjo sėkmingai segmentuoti aortos kontrasto regioną vaizdų sekoje iki aortos išsišakojimo. Sėkmingai atpažįstamas ne tik apskritimo formos aortos vaizdas, bet ir deformuotas į ovalą ar vaizdas su matomu aortos išsišakojimu į kitas kraujagysles. Tirtuose vaizduose atliekant aortos segmentavimą atpažintas regionas nenuklysta į šalia esančias besijungiančias kraujagysles.

3 pav. pirmame vaizde aortos taškai aiškiai matomi ir gerai išskirti. Aorta yra beveik taisyklingo apskritimo formos, jai rasti buvo naudojamas Hough transformacijos būdu gautų apskritimų hierarchinės klasterizacijos rezultatai. Dešimtame vaizde aorta yra šiek tiek deformuotos formos, iš šonų suspausta viršutinėje jos dalyje, tačiau taškų radimas taip pat buvo sėkmingas, nes nebuvo reikalaujama, kad aortos regionas būtų panašus į taisyklingą apskritimą. Regionui rasti buvo naudotas prieš tai sekoje buvusio 9 vaizdo aortos regioną identifikuojančios matricos masės centras. 20 vaizde matoma aorta bei iš jos išsišakojanti kraujagyslė. Ieškant aortos vidinių taš-


kų kraujagyslės pradžia taip pat buvo identifikuota kaip priklausanti aortai. 30 vaizde matomas aortos linkio skerspjūvis, dėl kurio aortos forma vaizde tampa labai suspausto apskritimo formos, tačiau jos vidinių taškų identifikacija buvo taip pat sėkminga. 40 vaizde pavaizduota aortos vidinis regionas bei jį supančio trombo pradžia, kuris gerai matomas 50 ir 60 vaizduose. Paskutiniame 75 vaizde atvaizduotas sėkmingai atpažintas paskutinis aortos skerspjūvis iki jos išsišakojimo.



**3 pav.** Aortos kontrasto regiono segmentavimo rezultatai.

Turint anksčiau rastą aortos vidinių taškų matricą jos masės centras buvo naudotas bendram trombo ir aortos regionui rasti regiono plėtimo būdu. Iš šio bendro aortos bei trombo regiono atėmus trombo regiono taškus gautas pradinis trombą žymintis regionas. Radus šio regiono centroidinį tašką, jis buvo panaudotas kaip pradinis taškas trombui rasti.

Kontūrų taškų matrica trombo radimui buvo gauta sudedant pradinio vaizdo kontūrus, naudotus aortos radimui, bei išryškinto trombo regiono kontūrus. Tai buvo reikalinga trombo regiono uždarymui, nes pradiniuose regionuose dėl aplink aortą ir trombą esančių detalių trombo sienelės ne visada buvo teisingai identifikuojamos ir kontūrai buvo neuždari. Esant neuždariems kontūrams regiono plėtimo būdu trombas nebūtų teisingai identifikuojamas, įtraukiant į analizuojamą regioną didžiąją dalį visų vaizdo taškų. Naudojant išryškinto aproksimuoto trombo regiono centroidinį tašką kaip regiono plėtimo pradžios tašką pradinio vaizdo kontūruose buvo gautas rezultatas, pavaizduotas 4 pav. violetine spalva pažymėti rasti aortos vidaus taškai, o geltona – aplink aortos vidų esantis trombas. 4 pav. matomas teisingai segmentuotas aortos kontrasto regionas bei beveik teisingai segmentuotas trombo regionas.



**4 pav.** Aortos kontrasto ir trombo regiono segmentavimo rezultatas.

Trombo segmentavimo rezultatai nėra tokie tikslūs kaip kontrasto segmentavimo atveju. Segmentuojant trombą jo vaizdo taškų intensyvumas yra labai panašus į kitų šalia esančių anatominių struktūrų, tokių kaip rau-

menys ar kiti organai. Todėl trombo kai kur trombo kraštai nėra pilnai segmentuojami. 4 pav. trombo regiono apačioje aortos sienelė nėra vientisai sujungta su trombu, atsiranda nenatūralus banguotas kraštas. Taip pat trombo regionui jo viršuje priskiriami ne jam priklausantys taškai, kurių intensyvumas yra labai panašus į trombo taškų intensyvumą.

## 6 Išvados

Šiame darbe buvo sukurtas aortos vidaus taškų identifikavimo būdas, nereikalaujant vartotojo įsikišimo. Aortos centras randamas automatiškai pasinaudojant Hough transformacija apskritimams, hierarchiniu klasterizavimu bei regiono plėtimo metodu. Tokiam aortos aptikimui reikalinga informacija iš kelių vienas po kito sekoje esančių kompiuterinės tomografijos vaizdų, siekiant rasti aortos centrą bei atskirti jį nuo stuburo. Šis aortos radimas yra patogesnis vartotojui, nes nereikalauja jo laiko, žinių ir pastangų sėkmingam aortos identifikavimui, tačiau aortos radimui reikia daugiau duomenų-neužtenka tik pirmo vaizdo kompiuterinės tomografijos vaizdų sekoje.

Taip pat buvo sėkmingai išskirtas aortos trombas, nurodant pradinį vaizdą sekoje, nuo kurio jo reikia ieškoti. Trombui išskirti buvo panaudota informacija apie anksčiau rastą aortos vidaus taškų centrą, todėl trombas taip pat buvo identifikuojamas be vartotojo nurodymo, kuri vaizdo dalis žymi trombą, ar kokiu pikselių intensyvumu trombas yra atvaizduojamas. Tolimesniuose tyrimuose siekiant trombo išskyrimą atlikti be vartotojo įsikišimo (kaip tai buvo daroma aortos vidaus taškų atveju) būtų būtina rasti sprendimą, kaip atpažinti vaizdą, kuriame yra aiškiai matomas trombas. Galbūt tai būtų galima padaryti naudojant pikselių intensyvumo histogramą regionui, esančiam aplink aortos vidinius taškus, ir ieškant vaizdo, kuriame pikseliai būtų aiškiai suskirstyti į vieną ar dvi klases. Aplink aortą esančios kitos struktūros bei vaizdo fonas lemia didelius pikselių intensyvumo skirtumus. Tačiau vaizdo su trombu atveju aplink aortos vidaus taškus tam tikru spinduliu esantys pikseliai turėtų beveik vienodas intensyvumo reikšmes didžiajai daliai tokių pikselių. Šiam metodui pilnai ištirti reikia atlikti detalesnę analizę, tačiau potencialiai jis leistų identifikuoti trombą kompiuterinės tomografijos vaizdų sekoje be vartotojo įsikišimo.

Tolimesniuose tyrimuose šioje temoje bus siekiama tobulinti aortos vidaus taškų bei aortos trombo aptikimo metodus. Šiame darbe naudoti vaizdai, kuriuose aorta vaizduojama iki išsišakojimo į dvi klubines arterijas. Atei-



tyje planuojama tęsti tyrimus bei identifikuoti aortos vidaus taškus po jos išsišakojimo, bei sukurti trimatę aortos bei joje esančio trombo vizualizaciją.

## Literatūra

- [1] Kent, K. C. (2014). Abdominal aortic aneurysms. *New England Journal of Medicine*, 371(22), 2101-2108.
- [2] Ramkumar, N., Suckow, B. D., Arya, S., Sedrakyan, A., Mackenzie, T. A., Goodney, P. P., & Brown, J. R. (2020). Association of Sex With Repair Type and Long-term Mortality in Adults With Abdominal Aortic Aneurysm. *JAMA Network Open*, 3(2), e1921240-e1921240.
- [3] Greenhalgh, R. M., Brown, L. C., Epstein, D., Kwong, G. P. S., Powell, J. T., & Sculpher, M. J. (2005). Endovascular aneurysm repair and outcome in patients unfit for open repair of abdominal aortic aneurysm (EVAR trial 2): randomised controlled trial. *Lancet*, 365(9478), 2187-2192.
- [4] Chaikof, E. L., Dalman, R. L., Eskandari, M. K., Jackson, B. M., Lee, W. A., Mansour, M. A., Mastracci, T.M., Mell, M., Murad, M.H., Nguyen, L.L. and Oderich, G.S. & Starnes, B. W. (2018). The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *Journal of vascular surgery*, 67(1), 2-77.
- [5] Barbieri, A. L., De Arruda, G. F., Rodrigues, F. A., Bruno, O. M., & da Fontoura Costa, L. An entropy-based approach to automatic image segmentation of satellite images. *Physica A: Statistical Mechanics and its Applications*, 390(3), 512-518, 2011.
- [6] Maitra, M., & Chatterjee, A. A novel technique for multilevel optimal magnetic resonance brain image thresholding using bacterial foraging. *Measurement*, 41(10), 1124-1134, 2008.
- [7] Kapur, J. N., Sahoo, P. K., & Wong, A. K. A new method for gray-level picture thresholding using the entropy of the histogram. *Computer vision, graphics, and image processing*, 29(3), 273-285, 1985.
- [8] Kullback, S. *Information theory and statistics*. Courier Corporation, 1997.
- [9] Sathya, P. D., & Kayalvizhi, R. Optimal multilevel thresholding using bacterial foraging algorithm. *Expert Systems with Applications*, 38(12), 15549-15564, 2011.
- [10] Chander, A., Chatterjee, A., & Siarry, P. A new social and momentum component adaptive PSO algorithm for image segmentation. *Expert Systems with Applications*, 38(5), 4998-5004, 2011.
- [11] Jain, A. K. *Fundamentals of digital image processing*. Englewood Cliffs, NJ: Prentice Hall, 2004.
- [12] Kekre, H. B., Sarode, T. K., & Raul, B. (2008). Color image segmentation using Kekre's algorithm for vector quantization. *International Journal of Computer Science (IJCS)*, 3(4), 287-292.
- [13] Roberts, L. G. *Machine perception of three-dimensional solids (Doctoral dissertation, Massachusetts Institute of Technology)*, 1963.
- [14] Gupta, S., & Mazumdar, S. G. Sobel edge detection algorithm. *International journal of computer science and management Research*, 2(2), 1578-1583, 2013.
- [15] Kumar, M., & Saxena, R. Algorithm and technique on various edge detection: A survey. *Signal & Image Processing*, 4(3), 65, 2013.
- [16] Pan, Z., & Lu, J. A Bayes-based region-growing algorithm for medical image segmentation. *Computing in science & Engineering*, 9(4), 32-38, 2007.

- [17] Mubarak, D. M. N., Sathik, M. M., Beevi, S. Z., & Revathy, K. A hybrid region growing algorithm for medical image segmentation. *International Journal of Computer Science & Information Technology*, 4(3), 61, 2012.
- [18] Shan, J., Cheng, H. D., & Wang, Y. A novel automatic seed point selection algorithm for breast ultrasound images. In *2008 19th International Conference on Pattern Recognition* (pp. 1-4). IEEE, 2008.
- [19] Mohammed, M. A., Ghani, M. K. A., Hamed, R. I., Abdullah, M. K., & Ibrahim, D. A. Automatic segmentation and automatic seed point selection of nasopharyngeal carcinoma from microscopy images using region growing based approach. *Journal of Computational Science*, 20, 61-69, 2017.
- [20] Bilinskas, M. J., Dzemyda, G., & Trakymas, M. Feature-Based Registration of Thorax CT Scan Slices. *Informatika*, 28(3), 439-452, 2017.
- [21] Bilinskas, M. J., Dzemyda, G., & Trakymas, M. Approximation of the ribs-bounded contour in a tomography scan slice. *International Journal of Information Technology & Decision Making*, 17(01), 83-102, 2018.
- [22] Geurts, A., Sakas, G., Kuijper, A., Becker, M., & von Landesberger, T. Visual comparison of 3d medical image segmentation algorithms based on statistical shape models. In *International Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management*, pp. 336-344, Springer, Cham, 2015.
- [23] Schmid, J., Kim, J., & Magnenat-Thalmann, N. Robust statistical shape models for MRI bone segmentation in presence of small field of view. *Medical image analysis*, 15(1), 155-168, 2011.
- [24] Albrecht, T., Lüthi, M., Gerig, T., & Vetter, T. Posterior shape models. *Medical image analysis*, 17(8), 959-973, 2013.
- [25] Lareyre, F., Adam, C., Carrier, M., Dommerc, C., Mialhe, C., & Raffort, J. (2019). A fully automated pipeline for mining abdominal aortic aneurysm using image segmentation. *Scientific reports*, 9(1), 1-14.

**3 publikacija.** Šubonienė, A., Kurasova, O., Medvedev, V., Kielaitė-Gulla, A., Samuilis, A., Jagminas, D., ... & Dzemyda, G. (2021). On the computed tomography image data to diagnose pancreatic cancer using machine learning. In DAMSS: 12th conference on data analysis methods for software systems, Druskininkai, Lithuania, December 2–4, 2021 (pp. 71-72). Vilnius University Press. DOI: <https://doi.org/10.15388/DAMSS.12.2021>

## On the Computed Tomography Image Data to Diagnose Pancreatic Cancer Using Machine Learning

Aušra Šubonienė<sup>1</sup>, Olga Kurasova<sup>1</sup>, Viktor Medvedev<sup>1</sup>,  
Aistė Kielaitė-Gulla<sup>2</sup>, Artūras Samuilis<sup>3</sup>, Džiugas Jagminas<sup>4</sup>,  
Kęstutis Strupas<sup>2</sup>, Gintautas Dzemyda<sup>1</sup>

<sup>1</sup> Institute of Data Science and Digital Technologies  
Vilnius University

<sup>2</sup> Institute of Clinical Medicine, Faculty of Medicine  
Vilnius University

<sup>3</sup> Institute of Biomedical Sciences, Department of Radiology,  
Nuclear Medicine and Medical Physics, Faculty of Medicine  
Vilnius University

<sup>4</sup> Faculty of Medicine  
Vilnius University

*ausra.suboniene@mif.vu.lt*

Medical imaging data, which is suitable for solving segmentation problems, are difficult to obtain due to data sensitivity issues and the effort that is required to make ground truth segmentations. In order to increase the robustness of results by including more medical images, multiple datasets are often combined. However, challenges arise when trying to combine such datasets from different sources. Populations of patients that differ by age and other conditions could affect the results. Also, there might be different approaches to segmentation and its accuracy. Experts can segment medical images as true to anatomical structures as possible, or they might include some surrounding tissues in order to speed up manual segmentation. Also, rough region boundaries can be used instead of segmentations. Lastly, there can be different diagnostic devices used, which might result in different pre-processing of images.

Data sources. Due to data sensitivity and effort that is needed to anonymise images, there is a lack of publicly available pancreatic cancer data. Most publicly available medical data is without segmentation by experts, and images that do have some anatomical structures segmented are scarce. Currently, the largest public collections of computer tomography (CT) images of pancreatic cancer are available are the Can-



cer Imaging Archive (TCIA) dataset and Medical Segmentation Decathlon dataset. The Medical Segmentation Decathlon dataset consists of 421 portal-venous phase 3D CT scans. Segmentations of both the pancreatic parenchyma and pancreatic mass (cyst or tumour) are provided, although done as ROI only, which makes the segmentation process quicker but less accurate. TCIA dataset consists of 82 abdominal contrast enhanced 3D CT scans with slice thickness between 1.5–2.5 mm. Manual segmentations were done only to segment the pancreas. Here we also analyse the dataset which was acquired in the Vilnius University Hospital Santaros Klinikos. Segmentations that were provided by the experts consist of healthy pancreas, pancreatic cancer and pancreatic duct, which can be confused with pancreatic cancer by machine learning algorithms due to similar intensity of pixels. When combining publically available datasets segmentation differences need to be taken into account and some additional manual segmentation might be needed.

Differences in populations of patients. Due to the limited availability of medical images and pancreatic cancer being more common later in life, it is difficult to achieve equal coverage of all age categories of pancreatic cancer patients. This can be partially solved by increasing the dataset size of categories by retrospective analysis of computer tomography images provided by the medical institution, that have been filtered by the desired conditions.

Issues in the quality of the segmentation. Manual segmentations of computer tomography images can be prepared using different approaches to segmentation and its accuracy. Experts can segment medical images as true to anatomical structures as possible, or they might include some surrounding tissues in order to speed up manual segmentation. Also, rough region boundaries can be used instead of segmentations. Data pre-processing might be done by removing fat tissue based on the values of Hounsfield units. This results in holes and irregular edges of segmented regions. This creates additional problems when trying to unify segmentations across multiple datasets and might reduce the accuracy of segmentations when using machine learning.

Different diagnostic devices. Lastly, there can be different diagnostic devices used, which might result in different pre-processing of images. Even after pre-processing, these different diagnostic devices can have unique artefacts in computer tomography images that can reduce segmentation accuracy when combining multiple datasets.

## 10 Priedas. Pilvo aortos kontrasto ir trombo segmentavimo kodas

```
segmentavimas_unet_2_kanalai.ipynb
#%%

import numpy as np
from src.paths import ROOT_DIR
from src.tools.data_handling import DataLoader as PathLoader
import matplotlib.pyplot as plt
import nibabel as nib
import torch
import os
import random

import torchvision.transforms.functional as TF

import cv2 as cv
from sklearn.model_selection import train_test_split
from src.evaluations.evaluate import evaluate, dice_loss
import torch.nn.functional as F
from time import strftime, localtime

#%%

%load_ext autoreload
%autoreload 2

#%%

print(torch.version.cuda)
torch.cuda.is_available()

#%%
```

```

seed = 100

if torch.cuda.is_available():
    DEVICE = 'cuda:0'
    print('Running on the GPU')
else:
    DEVICE = "cpu"
    print('Running on the CPU')

###

files_loader = PathLoader()
images_path = ROOT_DIR / 'data_single_slice'
all_images = files_loader.get_filenames_in_directory(images_path)

aorta_files = list(filter(lambda x: 'aorta' in x, all_images))
image_files = list(filter(lambda x: 'image' in x, all_images))
thrombus_files = list(filter(lambda x: 'thrombus' in x, all_images))

###

all_patients = [name.split("_")[1] for name in aorta_files]
all_patients = np.unique(all_patients)

id_train_val, id_test = train_test_split(all_patients, test_size=0.15, random_state=seed)
id_train, id_valid = train_test_split(id_train_val, train_size=0.90, random_state=seed)
print(len(id_train), len(id_valid), len(id_test))

###

def get_data_split(files, prefix, id_train, id_valid, id_test):
    x_train = [s for s in files if any(i in f"{prefix}_{s}" for i in id_train)]

```

```

x_valid = [s for s in files if any(i in f"{prefix}_{s}" for i in id_valid)]
x_test = [s for s in files if any(i in f"{prefix}_{s}" for i in id_test)]

return x_train, x_valid, x_test

aorta_train, aorta_valid, aorta_test = get_data_split(aorta_files, 'aorta', id_train, id_valid, id_test)
images_train, images_valid, images_test = get_data_split(image_files, 'image', id_train, id_valid, id_test)
thrombus_train, thrombus_valid, thrombus_test = get_data_split(thrombus_files, 'thrombus', id_train, id_valid, id_test)

print(len(images_train), len(images_valid), len(images_test))
print(len(aorta_train), len(aorta_valid), len(aorta_test))
print(len(thrombus_train), len(thrombus_valid), len(thrombus_test))

###

def seed_everything(seed):
    random.seed(seed)
    os.environ['PYTHONHASHSEED'] = str(seed)
    np.random.seed(seed)
    torch.manual_seed(seed)
    torch.cuda.manual_seed(seed)
    torch.cuda.manual_seed_all(seed)
    torch.backends.cudnn.deterministic = True

seed_everything(seed)
device = 'cuda'

###

```

```

from torch.optim.lr_scheduler import StepLR
from torch.utils.data import DataLoader, Dataset
from torchvision import datasets, transforms

NEW_SIZE = 128

train_transforms2 = transforms.Compose([
    transforms.ToPILImage(),
    transforms.Resize((NEW_SIZE, NEW_SIZE)),
    transforms.RandomRotation(8.0),
    transforms.RandomResizedCrop(NEW_SIZE, scale=(0.75, 1.0)),
    transforms.ToTensor()
])

#%%

def one_hot_encode(arr, total_classes):
    encodings = []

    for class_num in range(1, total_classes + 1):
        arr_encoded = (np.array(arr) == class_num).astype(int).tolist()
        encodings.append(arr_encoded)

    result = np.array(encodings)[:, 0]
    result2 = result.copy()
    result2[0] = result[1]
    result2[1] = result[0]

    return result2

def hounsfield_to_pixel(image, window_width=400, window_level=40):

```

```

image_edited = np.array(image) - window_level
image_edited = np.clip(image_edited, - (window_width / 2), (window_width / 2))
return image_edited

```

```

class AortaDataset(Dataset):

```

```

    masks_list = []

```

```

    def __init__(self, file_list, masks_list, thrombus_list, transform=None):

```

```

        self.file_list = [images_path / file for file in file_list]

```

```

        self.masks_list = [images_path / file for file in masks_list]

```

```

        self.thrombus_list = [images_path / file for file in thrombus_list]

```

```

    def __len__(self):

```

```

        self.filelength = len(self.file_list)

```

```

        return self.filelength

```

```

    def transform(self, image1, image2, mask):

```

```

        min_1 = image1.min()

```

```

        min_2 = image2.min()

```

```

        to_PIL = transforms.ToPILImage()

```

```

        image1 = to_PIL(image1)

```

```

        image2 = to_PIL(image2)

```

```

        mask = to_PIL(mask)

```

```

        rotation_angle = random.uniform(-10, 10)

```

```

        image1 = TF.rotate(image1, rotation_angle, fill=int(min_1))

```

```

        image2 = TF.rotate(image2, rotation_angle, fill=int(min_2))

```

```

        mask = TF.rotate(mask, rotation_angle, fill=0)

```

```

        i, j, h, w = transforms.RandomResizedCrop.get_params(image1, scale=(0.75, 1.0), ratio=(3. / 4., 4. / 3.))

```

```

        image1 = TF.resized_crop(image1, i, j, h, w, size=[NEW_SIZE, NEW_SIZE],
interpolation=TF.InterpolationMode.BICUBIC)

        image2 = TF.resized_crop(image2, i, j, h, w, size=[NEW_SIZE, NEW_SIZE],
interpolation=TF.InterpolationMode.BICUBIC)

        mask = TF.resized_crop(mask, i, j, h, w, size=[NEW_SIZE, NEW_SIZE],
interpolation=TF.InterpolationMode.NEAREST)

stacked = np.stack([np.array(image1), np.array(image2)])
image = TF.to_tensor(stacked)
image = image.swapaxes(0, 1)
image = image.swapaxes(1, 2)

mask = TF.to_tensor(mask)

return image, mask

def preprocess_mask(self, img):
    kernel = np.ones((3, 3), np.uint8)
    img = np.uint8(img)

    img = cv.dilate(img, kernel, iterations=1)
    img = cv.erode(img, kernel, iterations=1)
    img = cv.dilate(img, kernel, iterations=1)
    img = cv.erode(img, kernel, iterations=1)

    img = img.astype(int)

    return img

def load_nii_image(self, image_path, is_mask=False, crop_border=100, window_size=400,
window_level=40):
    img=nib.load(image_path)
    img = img.get_fdata()

```

```

if not is_mask:
    img = hounsfield_to_pixel(img, window_size, window_level)

img = np.squeeze(img)
img = img.astype(int)
img = img[crop_border:-crop_border, crop_border:-crop_border]

if is_mask:
    img = self.preprocess_mask(img)

return img

def __getitem__(self, idx):
    img_path = self.file_list[idx]
    aorta_path = self.masks_list[idx]
    thrombus_path = self.thrombus_list[idx]

    crop_border = 110

    img1 = self.load_nii_image(img_path, is_mask=False, crop_border=crop_border, window_size=300,
window_level=15)

    img2 = self.load_nii_image(img_path, is_mask=False, crop_border=crop_border, window_size=80,
window_level=45)

    lbl = self.load_nii_image(aorta_path, is_mask=True, crop_border=crop_border)
    lbl2 = self.load_nii_image(thrombus_path, is_mask=True, crop_border=crop_border)
    lbl_both = lbl2 + lbl * 2

    img, lbl = self.transform(img1, img2, lbl_both)
    img = (img - img.min())/(img.max() - img.min())

    lbl = np.array(lbl)

```



```

    lbl = one_hot_encode(lbl, 2)
    lbl = torch.from_numpy(lbl)

    return img, lbl

#%%

train_data = AortaDataset(images_train, aorta_train, thrombus_train, transform=train_transforms2)
valid_data = AortaDataset(images_valid, aorta_valid, thrombus_valid, transform=train_transforms2)
test_data = AortaDataset(images_test, aorta_test, thrombus_test, transform=train_transforms2)

#%%

batch_size = 32

train_loader = DataLoader(dataset=train_data, batch_size=batch_size, shuffle=False)
valid_loader = DataLoader(dataset=valid_data, batch_size=batch_size, shuffle=False)
test_loader = DataLoader(dataset=test_data, batch_size=batch_size, shuffle=False)

print(len(train_data), len(train_loader))
print(len(valid_data), len(valid_loader))
print(len(test_data), len(test_loader))

#%%

def plot_grey_image(data, print_data = False):

    if print_data:
        print("plot_grey_image")
        print(np.unique(data))
        plt.figure()

```

```

plt.imshow(data, cmap="Greys_r")
plt.show()

idx = 350
test_image, test_mask = train_data[idx]

print(test_image.shape)
plot_grey_image(test_image[0])
plot_grey_image(test_image[1])
plot_grey_image(test_mask[0], True)
plot_grey_image(test_mask[1], True)

###

idx = 400
test_image, test_mask = train_data[idx]

print(test_image.shape)
plot_grey_image(test_image[0])
plot_grey_image(test_image[1])
plot_grey_image(test_mask[0], True)
plot_grey_image(test_mask[1], True)

###

file_list_v2 = [images_path / file for file in images_train]
masks_list_v2 = [images_path / file for file in aorta_train]
thrombus_list_v2 = [images_path / file for file in thrombus_train]

print(file_list_v2[idx])
print(masks_list_v2[idx])
print(thrombus_list_v2[idx])

```

```
###
```

```
def hounsfield_to_pixel_temp(image, window_width=400, window_level=40):
```

```
    print("hounsfield_to_pixel_temp-")
```

```
    image_edited = np.array(image) - window_level
```

```
    image_edited = np.clip(image_edited, - (window_width / 2), (window_width / 2))
```

```
    return image_edited
```

```
def load_nii_image_temp(image_path, is_mask=False, window_width=400, window_len=40):
```

```
    print("load_nii_image_temp-")
```

```
    img=nib.load(image_path)
```

```
    img = img.get_fdata()
```

```
    if is_mask==False:
```

```
        img = hounsfield_to_pixel_temp(img, window_width, window_len)
```

```
    img = np.squeeze(img)
```

```
    img = img.astype(int)
```

```
    return img
```

```
img = load_nii_image_temp(file_list_v2[idx], window_width=300, window_len=15) # first
```

```
plot_grey_image(img)
```

```
###
```

```
flat_image = test_image[0].flatten()
```

```
flat_image = np.array(flat_image)
```

```

%%

plt.figure()
plt.hist(flat_image, bins=50)
plt.show()

%%

test_image[0].shape

%% md

# U-Net mokymas

%%

from tqdm import tqdm
import torch
import torch.optim as optim
import torch.nn as nn
from src.models.unet_model import UNet

lr = 0.0003
model = UNet(n_channels=2, n_classes=2)

amp = False

optimizer = optim.Adam(model.cuda().parameters(), lr=0.0001)
criterion = nn.BCEWithLogitsLoss()
scheduler = optim.lr_scheduler.ReduceLROnPlateau(optimizer, mode='min', factor=0.1, patience=4,
verbose=True)

global_step = 0

```

```

###

now = strftime("%Y%m%d_%H%M%S", localtime())
model_name = now
MODEL_PATH = ROOT_DIR / "models" / f"{model_name}.pth"
print(model_name)

###

train_losses = []
validation_losses = []

###

epoch = 50
epochs = 75

###

for epoch in range(epoch, epochs):
    model.train()
    epoch_loss = 0
    validation_loss = 0
    LOSS_VALS = []
    number_of_batches = 0

    print(f'Epoch {epoch + 1}/{epochs}')
    for data, label in tqdm(train_loader):
        number_of_batches += 1
        images = data
        true_masks = label

```

```

assert images.shape[1] == model.n_channels, \
    f'Network has been defined with {model.n_channels} input channels, '\
    f'but loaded images have {images.shape[1]} channels. Please check that '\
    'the images are loaded correctly.'

images = images.to(device=device, dtype=torch.float32)
true_masks = true_masks.to(device=device, dtype=torch.float32)

with torch.cuda.amp.autocast(enabled=amp):
    masks_pred = model(images)
    labels_true = true_masks

    loss = (criterion(masks_pred, true_masks)) + dice_loss(F.softmax(masks_pred, dim=1).float(),
true_masks, multiclass=True)

    optimizer.zero_grad()
    loss.backward()
    optimizer.step()

    global_step += 1
    epoch_loss += loss.item()

with torch.no_grad():
    epoch_val_accuracy = 0
    epoch_val_loss = 0
    print(len(masks_pred))
    loss = criterion(masks_pred, labels_true)

    val_loss = evaluate(model, valid_loader, device)
    scheduler.step(val_loss)

    validation_loss += val_loss

```

```

print('Validation Dice score: {}'.format(validation_loss))
validation_losses.append(validation_loss)

print('Epoch loss: {}'.format(epoch_loss / number_of_batches))
train_losses.append(epoch_loss / number_of_batches)

torch.save({'model_state_dict': model.state_dict(),
           'optim_state_dict': optimizer.state_dict(),
           'epoch': epoch,
           'loss_values': LOSS_VALS
           }, MODEL_PATH)

###

validation_losses[50:] = [X.cpu().detach().numpy() for X in validation_losses[50:]]
validation_losses

###

plt.figure()
plt.plot(train_losses, label="train")
plt.plot(validation_losses, label="validation")
plt.legend()
plt.show()

###

plt.figure()
plt.plot(validation_losses, label="validation")
plt.legend()
plt.show()

```

```

%%

model.eval()

y_true = []
y_pred = []
images = []

for batch in test_loader:
    image, mask_true = batch[0], batch[1]
    y_true.extend(mask_true.cpu().detach().numpy())
    image = image.to(device=device, dtype=torch.float32)
    images.extend(image.cpu().detach().numpy())

    with torch.no_grad():
        mask_pred = model(image)
        y_pred.extend(mask_pred.cpu().detach().numpy())

%% md

# Segmentacijos testavimo duomenims

%%

predictions = np.array(y_pred)
images = np.array(images)
y_true = np.array(y_true)

%%

idx = 200

```



```

def plot_semg_result(img, title=""):
    plt.figure()
    plt.imshow(img, cmap='Greys_r')
    plt.title(title)
    plt.show()

plot_semg_result(images[idx][0])
plot_semg_result(predictions[idx][0])
plot_semg_result(y_true[idx][0], "y_true")
plot_semg_result((predictions[idx][0] > 0.5).astype(int))

res = np.array((torch.sigmoid(torch.Tensor(predictions[idx][0])) > 0.5)).astype(int)
plot_semg_result(res)

###

plot_semg_result(images[idx][1])
plot_semg_result(predictions[idx][1])
plot_semg_result(y_true[idx][1], "y_true")
plot_semg_result((predictions[idx][1] > 0.5).astype(int))

res = np.array((torch.sigmoid(torch.Tensor(predictions[idx][1])) > 0.5)).astype(int)
plot_semg_result(res)

###

idx = 4

plot_semg_result(images[idx][0])
plot_semg_result(predictions[idx][0])

```

```

plot_scmg_result(y_true[idx][0], "y_true")
plot_scmg_result((predictions[idx][0] > 0.5).astype(int))

res = np.array((torch.sigmoid(torch.Tensor(predictions[idx][0])) > 0.5)).astype(int)
plot_scmg_result(res)

###

plot_scmg_result(images[idx][1])
plot_scmg_result(predictions[idx][1])
plot_scmg_result(y_true[idx][1], "y_true")
plot_scmg_result((predictions[idx][1] > 0.5).astype(int))

res = np.array((torch.sigmoid(torch.Tensor(predictions[idx][1])) > 0.5)).astype(int)
plot_scmg_result(res)

###

plt.hist(predictions[idx][1])

### md

# Dice koeficientas

###

def get_dice_one_image(y_true, y_pred, smooth=1):
    y_true_f = np.array(y_true).flatten()
    y_pred_f = np.array(y_pred).flatten()
    intersection = np.sum(y_true_f * y_pred_f)

    denom = np.sum(y_true_f) + np.sum(y_pred_f) + smooth

```

```

if denom == 0 and smooth == 0:
    return 0

return (2 * intersection + smooth) / (np.sum(y_true_f) + np.sum(y_pred_f) + smooth)

def IoU(y_true, y_pred):
    y_true_f = np.array(y_true).flatten()
    y_pred_f = np.array(y_pred).flatten()

    intersection = np.sum(y_true_f * y_pred_f)
    union = np.sum(y_true_f) + np.sum(y_pred_f) - intersection
    if union == 0:
        return 0

    return intersection / union

def get_class_scores(y_true_aorta, y_pred_aorta, threshold=0.5):
    aorta_dice_coeffs = []
    aorta_iou_coeffs = []

    for idxx in range(len(y_true_aorta)):
        y_pred_aorta_singe = np.array(y_pred_aorta[idxx] >= threshold).astype(int)
        y_true_aorta_singe = y_true_aorta[idxx]

        aorta_dice = get_dice_one_image(y_true_aorta_singe, y_pred_aorta_singe, smooth=0.01)
        aorta_IoU = IoU(y_true_aorta_singe, y_pred_aorta_singe)

        aorta_dice_coeffs.append(aorta_dice)
        aorta_iou_coeffs.append(aorta_IoU)

    return np.array(aorta_dice_coeffs).mean(), np.array(aorta_iou_coeffs).mean()

```

```

def sigmoid(x):
    return 1 / (1 + np.exp(x))

def get_class_scores_sigmoid(y_true_aorta, y_pred_aorta, threshold=0.5):
    aorta_dice_coeffs = []
    aorta_iou_coeffs = []

    for idx in range(len(y_true_aorta)):
        y_pred_aorta_singe = (sigmoid(np.array(y_pred_aorta[idx])) >= threshold).astype(int)
        y_true_aorta_singe = y_true_aorta[idx]

        aorta_dice = get_dice_one_image(y_true_aorta_singe, y_pred_aorta_singe, smooth=0)
        aorta_IoU = IoU(y_true_aorta_singe, y_pred_aorta_singe)

        aorta_dice_coeffs.append(aorta_dice)
        aorta_iou_coeffs.append(aorta_IoU)

    return np.array(aorta_dice_coeffs).mean(), np.array(aorta_iou_coeffs).mean()

def evaluate_model_two_classes(mask_true, predictions):

    y_pred_aorta = predictions[:, 0]
    y_pred_thrombus = predictions[:, 1]
    y_true_aorta = mask_true[:, 0, :, :]
    y_true_thrombus = mask_true[:, 1, :, :]

    aorta_dice, aorta_iou = get_class_scores(y_true_aorta, y_pred_aorta)
    thrombus_dice, thrombus_iou = get_class_scores_sigmoid(y_true_thrombus, y_pred_thrombus,
threshold=0.5)

```

```

print(f"Aorta. Dice: {aorta_dice}, IoU: {aorta_iou}")
print(f"Thrombus. Dice: {thrombus_dice}, IoU: {thrombus_iou}")

return aorta_dice, thrombus_dice

#%%

aorta_dice, thrombus_dice = evaluate_model_two_classes(y_true, predictions)

#%%

aorta_true = y_true[:, 0]
thrombus_true = y_true[:, 1]

thrombus_slices = (thrombus_true.sum(axis=(1, 2)) > 0).astype(int).sum()
aorta_slices = (aorta_true.sum(axis=(1, 2)) > 0).astype(int).sum()

print("thrombus_slices: ", thrombus_slices)
print("aorta_slices: ", aorta_slices)

#%%

weighted_dice = (aorta_dice * aorta_slices + thrombus_dice * thrombus_slices) / (aorta_slices +
thrombus_slices)
average_dice = (aorta_dice + thrombus_dice) / 2
print("weighted_dice: ", weighted_dice)
print("average_dice: ", average_dice)

#%%

```