

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

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 išplatėjimu nusilpus jos sienelei, kurios diagnozei ir stebėsenai naudojama kompiuterinė tomografija. Susilpnėjusi aortos sienelė išsiplėčia, 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.

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 į jį dažnai neįtraukiamas trombas. Turint tokį trimatį modelį sunku įvertinti aortos išsiplėtimą ir trombo dydį. Remiantis kraujagyslių chirurgijos draugijos praktikos gairėmis [4] geresnis šių procesų 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 matematinų modelių, tinklėlio 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 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 [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 giliai 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 pradinius 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 parametru, 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. *trous 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 gali-mybę gauti tikslią objektų lokalizaciją pradiniam vaizde, ne tik apibendrin-tą informaciją, kuri yra gaunama kaip enkoderio išvestis. Dekoderis naudo-ja transponuotas konvoliucijos operacijas ir yra nuo pradžios iki galo pilnai konvoliucinis tinklas (ang. *fully convolutional network, FCN*). U-Net tinklą su-daro 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 koefi-cientas 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 koeficien-tas interpretuojamas kaip panašumas tarp tikros objekto segmentacijos ir segmentacijos spėjimo, gauto naudojant segmentacijos modelį. Dice koefi-cientas 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 trūkstamų 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 apkarpomomas 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 | 0,87554 | 0,79734 |

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 apkarpyimą ir atsitiktinį svorių pašalinimą pateikiami 2 lentelėje.

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

| Segmentuotas regionas | Tik su vaizdo apkarpymu | | Su vaizdo apkarpymu 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 | 0,9458 | 0,9054 |
| Trombas | 0,4123 | 0,3325 | 0,5820 | 0,4694 | 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 skerspūvio plotą. Objekto segmentacijos sekimas 3D duomenyse galėtų palengvinti ilgų anatomių struktūrų, turinčių mažą skerspūvio 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., Joscowicz, 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., ... & Tenenholz, 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). Dcnv-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.