



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Giliojo mokymosi metodai intracerebrinių aneurizmų diagnostikai

Baigiamasis magistro studijų projektas

Rasa Zabulionytė
Projekto autorė

Doc. dr. Tomas Iešmantas
Vadovas

Kaunas, 2021



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Giliojo mokymosi metodai intracerebrinių aneurizmų diagnostikai

Baigiamasis magistro studijų projektas

Taikomoji matematika (6211AX006)

Rasa Zabulionytė

Projekto autorė

Doc. dr. Tomas Iešmantas

Vadovas

Prof. dr. Robertas Alzbutas

Recenzentas

Kaunas, 2021



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Rasa Zabulionytė

Giliojo mokymosi metodai intracerebrinių aneurizmų diagnostikai

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Rasa Zabulionytė

Patvirtinta elektroniniu būdu

Zabulionytė Rasa. Giliojo mokymosi metodai intracerebrinių aneurizmų diagnostikai. Magistro studijų baigiamasis projektas / vadovas doc. dr. Tomas Iešmantas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (Matematikos mokslai).

Reikšminiai žodžiai: klasifikavimas, segmentavimas, sąsūkų neuroniniai tinklai, ResNet, U-Net.

Kaunas, 2021. 70 p.

Santrauka

Intracerebrinės aneurizmos yra viena dažniausių subarachnoidinės hemoragijos – insulto, kuomet kraujas išsilieja į subarachnoidinę tarpą, priežasčių. Kadangi ši liga neretai baigiasi mirtimi, o dauguma išgyvenusių pacientų lieka neįgalūs, svarbu tyrimus pacientams atlikti reguliariai ir laiku pastebėti galvos smegenyse susidarančias aneurizmas bei stebėti jų kitimą. Siekiant palengvinti intracerebrinių aneurizmų diagnostiką bei ją automatizuoti, darbe buvo pasitelkti giliojo mokymosi metodai – sąsūkų neuroniniai tinklai.

Šio baigiamojo magistro darbo tikslas yra sukurti ir išanalizuoti giliaisiais dirbtinių neuronų tinklais grįstus modelius, skirtus magnetinio rezonanso angiografijos tyrimo metu gautų galvos tūrio vaizdų klasifikavimui ir segmentavimui. Vaizdų klasifikavimui pagal tai, ar vaizde matoma aneurizma ar ne, naudotas klasikinis sąsūkų neuroninis tinklas bei ResNet-34 tinklo architektūra. Intracerebrinių aneurizmų segmentavimui naudotos trys skirtingos U-Net architektūros: U-Net-15, U-Net-27, U-Net-36.

Išnagrinėjus gautus rezultatus pastebėta, jog klasikinis sąsūkų neuroninis tinklas geriau nei ResNet-34 klasifikuoja magnetinio rezultato angiografijos vaizdus. Intracerebrinių aneurizmų segmentavimui geriausiai tinka didžiausia tyrime naudota U-Net architektūra (U-Net-36). Vis dėlto, darbe naudoti tinklai dažniausiai aneurizmas aptikdavo, bet neretai segmentuodavo jas didesnes, nei šios iš tiesų yra.

Projektą sudaro trys dalys: literatūros apžvalga, duomenys ir tyrimų metodai bei tyrimų rezultatų ir jų aptarimo dalis. Literatūros apžvalgoje yra apžvelgiama intracerebrinių aneurizmų aptikimo, klasifikavimo ir segmentavimo problema; duomenų ir tyrimų metodų dalyje yra aptariami turimi ir darbe naudoti magnetinio rezonanso angiografijos vaizdai, jų apdorojimas bei tinklų architektūros, naudotos tyrime; o tyrimų rezultatų ir jų aptarimų dalyje yra aprašomi rezultatai, gauti naudojant sąsūkų neuroninius tinklus aneurizmų klasifikavimo ir segmentavimo problemai spręsti.

Zabulionytė Rasa. Deep learning methods for the diagnostics of intracerebral aneurysm. Master's Final Degree Project / supervisor assoc. prof. dr. Tomas Iešmantas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematical Sciences).

Keywords: classification, segmentation, convolutional neural network, ResNet, U-Net.

Kaunas, 2021. 70 pages.

Summary

Intracerebral aneurysm is one of the most common causes of subarachnoid hemorrhage, also known as a stroke, when the blood spills into subarachnoid space. Whereas this disease often ends up in death while the majority of surviving patients stay disabled, it is important to regularly perform analysis of patients in order to notice developing brain aneurysms on time and to monitor their change. In order to lighten and automate diagnostics of intracerebral aneurysms, deep learning methods of convolutional neural networks were used in this scientific work.

The aim of this master's thesis is to create and analyze models based on deep neural networks. These models are intended for classification and segmentation of head volume images which are taken during magnetic resonance angiography procedure. For image classification whether an aneurysm is visible or not, classic convolutional neural networks and ResNet-34 network architecture were used. Three different U-Net architectures (U-Net-15, U-Net-27, U-Net-36) were used for segmentation of intracerebral aneurysms.

After examining the results, it was noticed that classic convolutional neural networks classify images, which are taken during magnetic resonance angiography procedure, better than ResNet-34. The largest U-Net architecture (U-Net-36) that was used in this research is best suited for segmentation of intracerebral aneurysms. However, even though networks that were used in this research were able to detect aneurysms most of the time, they were segmented larger than they actually are.

The project consists of three parts: literature review, data and research methods, the results and summary of the research. In the part of literature review, detection, classification and segmentation problem of intracerebral aneurysms is reviewed. In the part of data and research methods, images of magnetic resonance angiography procedure and their processing are being reviewed, as well as network architectures that were used in the research. In the part of results and summary, results which were obtained by using convoluted neural networks aneurysms in order to solve the problem of classification and segmentation are being described.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	12
Įvadas.....	13
1. Literatūros apžvalga	14
1.1. Intracerebrinės aneurizmos.....	14
1.2. Vaizdų su intracerebrinėmis aneurizmomis klasifikavimas	16
1.3. Intracerebrinių aneurizmų aptikimas ir segmentavimas.....	18
2. Duomenys ir tyrimo metodai.....	28
2.1. Tyrime naudoti duomenys.....	28
2.2. Tyrime naudoti metodai	31
2.2.1. Intracerebrinių aneurizmų klasifikavimas	31
2.2.2. Intracerebrinių aneurizmų segmentavimas.....	35
2.3. Tikslumo metrikos.....	41
3. Tyrimų rezultatai ir jų aptarimas.....	44
3.1. Intracerebrinių aneurizmų klasifikavimas	44
3.2. Intracerebrinių aneurizmų segmentavimas	47
Išvados	66
Literatūros sąrašas	67

Lentelių sąrašas

1 lentelė. Binarinio ir daugiaklasio kompiuterinės tomografijos vaizdų klasifikavimo modelio architektūra	18
2 lentelė. Literatūros analizė	26
3 lentelė. Sumaišymo matrica	41
4 lentelė. Tyrimo tikslumo klasifikacija pagal AUC reikšmes	42
5 lentelė. Klasikinio CNN tinklo rezultatai	45
6 lentelė. ResNet-34 tinklo rezultatai	47
7 lentelė. Klasifikavimo metodų rezultatų palyginimas	47
8 lentelė. U-Net-15 rezultatai	52
9 lentelė. U-Net-27 rezultatai	58
10 lentelė. U-Net-36 rezultatai	64
11 lentelė. Segmentavimo metodų rezultatų palyginimas	65

Paveikslų sąrašas

1 pav. Kompiuterinės tomografijos angiografijos tyrimu gauti vaizdai	15
2 pav. Tekėjimo laiko sekos magnetinio rezonanso angiografijos tyrimu gautas vaizdas.....	15
3 pav. Dviejų dimensijų (2D) skaitmeninės angiografijos vaizdas iš kairiosios vidinės miego arterijos šoninio vaizdo (a), vaizduojantis didelę aneurizmą (pažymėta juoda rodykle). Mažesnės aneurizmos (pažymėta balta rodykle), pavaizduotos trijų dimensijų (3D) skaitmeninės angiografijos šonine (b) ir įstrižai šonine (c) kryptimi, vaizdai.	16
4 pav. 1D CNN intracerebrinės aneurizmos aptikimo schema	17
5 pav. Binarinio ir daugiaklasio kompiuterinės tomografijos vaizdų klasifikavimo modelio architektūra	18
6 pav. 3D CNN modelio schema aneurizmomis segmentuoti	19
7 pav. Vaizdo išankstinio apdorojimo eiga pacientui, turinčiam dešinės centrinės arterijos aneurizmą (pažymėta rodykle). Pilnai automatizuotas smegenų kaukės skaičiavimas iš gautų galvos ir kaklo kompiuterinės tomografijos angiografijos vaizdų (padengtas žalia spalva (a)). Išgautas smegenų vaizdas (b). 3D kraujagyslių vaizdai su 0,5–5 dydžio tūrinio vaizdo elementais (c) bei 5–15 dydžio tūrinio vaizdo elementais (d)	20
8 pav. Angiografijų projekcijos. Neutrali pozicija (angl. <i>neutral position</i>) (N), plėtinys (angl. <i>extention</i>) (E), dešinysis galinis įstrižas (angl. <i>right posterior oblique</i>) (RPO), dešinys šoninis išlinkimas (angl. <i>right lateral flexion</i>) (RLF), dešinys priekinis įstrižas (angl. <i>right anterior oblique</i>) (RAO), kairys galinis įstrižas (angl. <i>left posterior oblique</i>) (LPO), kairys šoninis išlinkimas (angl. <i>left lateral flexion</i>) (LLF), kairys priekinis įstrižas (angl. <i>left anterior oblique</i>) (LAO).....	21
9 pav. Keturių sluoksnių tankio blokų architektūra aneurizmų aptikimui	22
10 pav. Blokinė tyrimo schema.....	23
11 pav. „DeepMedic“ sąsūkų neuroninio tinklo architektūra	24
12 pav. Dviejų pakopų sąsūkų neuroninis tinklas aneurizmų aptikimui.....	25
13 pav. Regiono lokalizacijos etapo architektūra	25
14 pav. Aneurizmos aptikimo etapo architektūra	26
15 pav. TOF-MRA vaizdai skirtingomis projekcijomis	28
16 pav. TOF-MRA vaizdai skirtingomis projekcijomis. Raudona spalva žymimos aneurizmos.....	29
17 pav. Dvimatis suvienodinto dydžio, normalizuotas smegenų sluoksnio vaizdas.....	30
18 pav. TOF-MRA vaizdas be aneurizmų skirtingomis projekcijomis	30
19 pav. Dvimatis smegenų be aneurizmų sluoksnio vaizdas	31
20 pav. Klasikinio CNN tinklo architektūra	32
21 pav. ResNet-34 tinklo architektūra	34
22 pav. U-Net-15 tinklo architektūra	36
23 pav. U-Net-27 tinklo architektūra	38
24 pav. U-Net-36 tinklo architektūra	40
25 pav. ROC kreivė.....	42
26 pav. IoU metrikos apskaičiavimo formulė	43
27 pav. Klasikinio CNN 1 dalies kryžminės validacijos ROC kreivė	44
28 pav. Klasikinio CNN 2 dalies kryžminės validacijos ROC kreivė	44
29 pav. Klasikinio CNN 3 dalies kryžminės validacijos ROC kreivė	44
30 pav. Klasikinio CNN 4 dalies kryžminės validacijos ROC kreivė	44
31 pav. Klasikinio CNN 5 dalies kryžminės validacijos ROC kreivė	45
32 pav. ResNet-34 1 dalies kryžminės validacijos ROC kreivė	46

33 pav. ResNet-34 2 dalies kryžminės validacijos ROC kreivė	46
34 pav. ResNet-34 3 dalies kryžminės validacijos ROC kreivė	46
35 pav. ResNet-34 4 dalies kryžminės validacijos ROC kreivė	46
36 pav. ResNet-34 5 dalies kryžminės validacijos ROC kreivė	46
37 pav. U-Net-15 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	48
38 pav. U-Net-15 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	48
39 pav. U-Net-15 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	48
40 pav. U-Net-15 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	48
41 pav. U-Net-15 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	48
42 pav. U-Net-15 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	49
43 pav. U-Net-15 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	49
44 pav. U-Net-15 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	49
45 pav. U-Net-15 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	49
46 pav. U-Net-15 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	49
47 pav. U-Net-15 1 dalies kryžminės validacijos ROC kreivė	50
48 pav. U-Net-15 2 dalies kryžminės validacijos ROC kreivė	50
49 pav. U-Net-15 3 dalies kryžminės validacijos ROC kreivė	50
50 pav. U-Net-15 4 dalies kryžminės validacijos ROC kreivė	50
51 pav. U-Net-15 5 dalies kryžminės validacijos ROC kreivė	50
52 pav. U-Net-15 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	51
53 pav. U-Net-15 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės	51
54 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas.....	52
55 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas.....	53
56 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas.....	53
57 pav. U-Net-27 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	54
58 pav. U-Net-27 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	54

59 pav. U-Net-27 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	54
60 pav. U-Net-27 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	54
61 pav. U-Net-27 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	54
62 pav. U-Net-27 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	55
63 pav. U-Net-27 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	55
64 pav. U-Net-27 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	55
65 pav. U-Net-27 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	55
66 pav. U-Net-27 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	55
67 pav. U-Net-27 1 dalies kryžminės validacijos ROC kreivė	56
68 pav. U-Net-27 2 dalies kryžminės validacijos ROC kreivė	56
69 pav. U-Net-27 3 dalies kryžminės validacijos ROC kreivė	56
70 pav. U-Net-27 4 dalies kryžminės validacijos ROC kreivė	56
71 pav. U-Net-27 5 dalies kryžminės validacijos ROC kreivė	56
72 pav. U-Net-27 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	57
73 pav. U-Net-27 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės	57
74 pav. U-Net-27 tinklu gauti rezultatai Nr. 1: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas.....	58
75 pav. U-Net-27 tinklu gauti rezultatai Nr. 2: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas.....	59
76 pav. U-Net-27 tinklu gauti rezultatai Nr. 3: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas.....	59
77 pav. U-Net-36 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	60
78 pav. U-Net-36 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	60
79 pav. U-Net-36 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	60
80 pav. U-Net-36 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	60
81 pav. U-Net-36 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos	60
82 pav. U-Net-36 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	61

83 pav. U-Net-36 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	61
84 pav. U-Net-36 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	61
85 pav. U-Net-36 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	61
86 pav. U-Net-36 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	61
87 pav. U-Net-36 1 dalies kryžminės validacijos ROC kreivė	62
88 pav. U-Net-36 2 dalies kryžminės validacijos ROC kreivė	62
89 pav. U-Net-36 3 dalies kryžminės validacijos ROC kreivė	62
90 pav. U-Net-36 4 dalies kryžminės validacijos ROC kreivė	62
91 pav. U-Net-36 5 dalies kryžminės validacijos ROC kreivė	62
92 pav. U-Net-36 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos.....	63
93 pav. U-Net-36 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės	63
94 pav. U-Net-36 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-36 tinklu segmentuotas vaizdas.....	64

Santrumpų ir terminų sąrašas

Santrumpos:

ADS – aneurizmos aptikimo etapas;

ASDH – ūminis subdūrinis kraujavimas;

BPH – smegenų politraumos kraujavimas;

CNN – sąsūkų neuroniniai tinklai;

DIP – klasikinis skaitmeninis vaizdo apdorojimas;

Doc. – docentas;

Dr. – daktaras;

FPN – ypatybių piramidiniai tinklai;

IPH – intraparenchiminis kraujavimas;

KTA – kompiuterinės tomografijos angiografija;

LAO – kairys priekinis įstrižas angiografijos projekcijos vaizdas;

MIP – maksimalaus intensyvumo projekcija;

MRA – magnetinio rezonanso angiografija;

Prof. – profesorius;

RAO – dešinysis priekinis įstrižas angiografijos projekcijos vaizdas;

RLS – regiono lokalizacijos etapas;

SAH – subarahnoidinė hemoragija;

TOF-MRA – tekėjimo laiko magnetinio rezonanso angiografija.

Terminai:

Intracerebrinė aneurizma – smegenų kraujagyslės sienelės išsiplėtimas.

Kompiuterinės tomografijos angiografija – tai kompiuterinės tomografijos tyrimas panaudojant intraveninį kontrastavimą. Tyrimas su intraveniniu kontrastavimu padidina kompiuterinės tomografijos jautrumą diagnozuojant pažeidimus, kurie padidina hematoencefalinio barjero laidumą [1, 2].

Subarahnoidinė hemoragija – insultas, kuomet kraujas išsilieja į subarahnoidinį tarpą.

Tekėjimo laiko magnetinio rezonanso angiografija – nekontrastinis tyrimas, skirtas atvaizduoti žmogaus kraujagyslių sistemą [3].

Įvadas

Temos aktualumas:

Subarachnoidinė hemoragija – insultas, kuomet kraujas išsilieja į subarachnoidinį tarpą, yra dažna, ypatingai vyresnių žmonių, mirties priežastis. Intracerebrinės aneurizmos sukelia apie 85 % subarachnoidinių hemoragijų, kurių net pusė baigiasi mirtimi, o dauguma išgyvenusių pacientų lieka neįgalūs. Kadangi šios ligos pasekmės yra itin pavojingos, svarbu tyrimus pacientams atlikti reguliariai ir laiku pastebėti galvos smegenyse susidarančias aneurizmas bei stebėti jų kitimą. Siekiant palengvinti intracerebrinių aneurizmų diagnostiką bei ją automatizuoti, darbe buvo pasitelkti giliojo mokymosi metodai – sąsūkų neuroniniai tinklai.

Dauguma literatūros šaltinių, nagrinėjančių intracerebrinių aneurizmų diagnostiką, klasifikavimą ar segmentavimą yra ne senesni nei keturių metų, o taip pat analogiškų tyrimų skaičius nuolat didėja. Dėl šios priežasties galima teigti, jog magistriniame darbe nagrinėta tema yra aktuali ir naudinga radiologijos bei neurologijos sričių medicams ir jų pacientams.

Problematika:

Baigiamajame magistriniame darbe bus nagrinėjamos intracerebrinės aneurizmos, esančios tekėjimo laiko magnetinio rezonanso angiografijos tyrimu gautuose vaizduose. Atsižvelgiant į tai, kad norint aneurizmas identifikuoti yra reikalingas ekspertinis vertinimas, kuris neretai yra labai ilgas ir atliekamas su klaidomis, darbu buvo siekiama sukurti modelius, skirtus vaizdų su aneurizmomis klasifikavimo bei segmentavimo automatizavimui.

Projekto tikslas:

Ištirti giliaisiais dirbtinių neuronų tinklais grįstų modelių taikymo galimybes intracerebrinių aneurizmų diagnostikoje.

Projekto uždaviniai:

- Apžvelgti mokslinę literatūrą, skirtą giliųjų neuroninių tinklų taikymui aneurizmų aptikime ir segmentavime.
- Parinkti ir išanalizuoti giliaisiais neuroniniais tinklais grįstą klasifikavimo algoritimą, skirtą magnetinio rezonanso angiografijos tyrimo metu gautiems galvos tūrio vaizdams klasifikuoti pagal tai, ar vaizde matoma aneurizma, ar ne.
- Parinkti ir išanalizuoti giliaisiais neuroniniais tinklais grįstą segmentavimo algoritimą, skirtą magnetinio rezonanso angiografijos tyrimo metu gautiems galvos tūrio vaizdams segmentuoti, kai segmentuojama aneurizma.
- Įvertinti analizuotų algoritmų tikslumą, paklaidų pobūdį bei esamus trūkumus.

1. Literatūros apžvalga

Subarachnoidinė hemoragija (SAH) – insultas, kuomet kraujas išsilieja į subarachnoidinį tarpą, sudaro 1–7 % visų insultų. Intracerebrinės aneurizmos sukelia apie 85 % SAH, kurių net pusė baigiasi mirtimi, o dauguma išgyvenusių pacientų lieka neįgalūs. Plyšusioms aneurizmomms diagnozuoti yra naudojami radiologiniai tyrimai: kompiuterinės tomografijos angiografija (KTA) bei tekėjimo laiko magnetinio rezonanso angiografijos tyrimas (TOF-MRA) [4]. Šie tyrimai taip pat yra naudojami ir neplyšusių aneurizmų diagnostikai. Kadangi šios ligos pasekmės yra itin pavojingos, svarbu tyrimus pacientams atlikti reguliariai ir laiku pastebėti galvos smegenyse susidarančias aneurizmas bei stebėti jų kitimą. Siekiant palengvinti intracerebrinių aneurizmų diagnostiką bei ją automatizuoti galima pasitelkti kompiuterių mokslą – giliojo mokymosi metodus.

1.1. Intracerebrinės aneurizmos


Intracerebrinė aneurizma – tai išsiplėtusi smegenų arterijos vieta, prisipildžiusi kraujo, o kraujagyslės sienelė aneurizmos vietoje yra išplonėjusi arba silpna. Išsiplėtusi aneurizma gali spausti nervus ar kitus smegenų audinius [5]. Trūkusi intracerebrinei aneurizmai įvyksta kraujo išsiliejimas į smegenis – subarachnoidinė hemoragija, o tai gali sukelti rimtų sveikatos problemų, tokių kaip insultas, smegenų pažeidimas, koma ar mirtis [4, 5].

Spontanišė SAH yra mirtinai pavojinga neurologijos patologija [6, 7]. Pagrindinė šios patologijos priežastis yra plyšusi intracerebrinė aneurizma [4, 6]. „Pagrindinis pradinis SAH simptomas – staigus nepakeliamas galvos skausmas (85–95 % pacientų), apibūdinamas kaip „stipriausias galvos skausmas gyvenime“, lydymas pykinimo, vėmimo, šviesos baimės, psichomotorinio sujaudinimo“ [6, 8]. Subarachnoidinė hemoragija, sukelta plyšusios galvos smegenų arterinės aneurizmos, yra susijusi su aukštu mirtingumu. Vienos dažniausių mirčių priežasčių yra šios SAH komplikacijos: smegenų išemija, vazospazmas, smegenų vandenė, pakartotinis kraujavimas [1, 2, 3, 6].


Tiek SAH, tiek intracerebrinėms aneurizmomms nustatyti dažniausiai yra naudojami du tyrimai: kompiuterinės tomografijos angiografija bei tekėjimo laiko magnetinio rezonanso angiografijos tyrimas. Kompiuterinės tomografijos angiografija yra kompiuterinės tomografijos tyrimas panaudojant intraveninį kontrastavimą. Toks tyrimas padidina kompiuterinės tomografijos jautrumą diagnozuojant kraujagyslių pažeidimus. Kompiuterinė tomografija yra metodas, pagrįstas skirtinga rentgeno spindulių sugertimi organuose, kuomet yra paveikiama tik tam tikra organizmo vieta, kompiuterinio tomografo aparatui skleidžiant siaurą rentgeno spinduliuotės sluoksnį [6, 8]. 1 paveiksle yra pavaizduotas kompiuterinės tomografijos angiografijos būdu gautas smegenų vaizdas [9]. Galime matyti, jog dėl intraveninio kontrastavimo kraujagysles plika akimi galime atskirti nuo kitų galvos smegenų audinių.

Magnetinio rezonanso angiografija yra neinvazinis tyrimas, neturintis jonizuojančiosios spinduliuotės. Šis tyrimas yra taikomas diagnozuojant galvos smegenų kraujagyslių anatomiją bei įvairias patologijas, tokias kaip aneurizmos, arterioveninės malformacijos, veninių sinusų trombozė, stenozė, angiopatija, disekacija. Magnetinio rezonanso angiografija (MRA) gali būti naudojama nustatant neplyšusias ir plyšusias intracerebrines aneurizmas, vertinant jų geometriją ir padėti prieš operacinį gydymą [10, 11, 12, 13]. TOF-MRA literatūroje dažnai vadinamas 3D-TOF-MRA. Šis tyrimas yra neinvazinis metodas, skirtas vaizduoti kraujagysles, nenaudojant kontrastinės medžiagos. TOF-MRA tyrimas yra pagrįstas su srautu susijusių sukinių, patenkančių į vaizdą, padidimu. Kadangi šie sukinių yra nestacionarūs, todėl duodama daugiau signalo nei iš stacionarių

sukinių, esančių aplink [14]. 2 paveiksle yra pateiktas tekėjimo laiko sekos magnetinio rezonanso angiografijos tyrimu gautas vaizdas [15, 16].




1 pav. Kompiuterinės tomografijos angiografijos tyrimu gauti vaizdai



2 pav. Tekėjimo laiko sekos magnetinio rezonanso angiografijos tyrimu gautas vaizdas

Dar vienas būdas atvaizduoti intracerebrines aneurizmas yra trijų dimensijų skaitmeninė angiografija, kitaip dar vadinama 3D sukamaisiais DSA (angl. *3D rotational DSA (3D-RA)*). 3D skaitmeninė angiografija leidžia gydytojams kruopščiai apžiūrėti intracerebrines aneurizmas ir kitus kraujagyslių

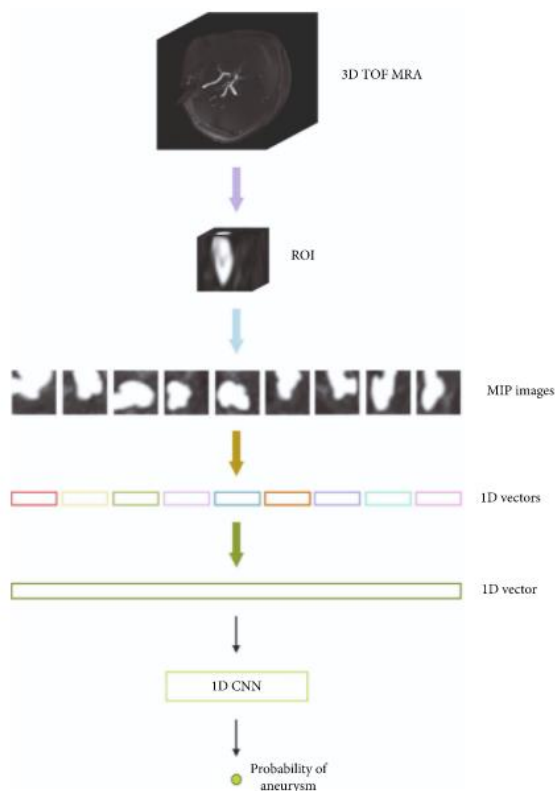
pažeidimus angiografijos tyrime ar intervencinės procedūros metu. Eksperimentinių tyrimų metu [17] buvo įrodyta, jog 3D rotacinė DSA veikia geriau nei MRA arba KTA, nes TOF-MRA nepakankamai įvertina aneurizmos tūrį, o KTA pervertina. Nepaisant to, 3D DSA vis dar veikia vaizdo artefaktai, kurie gali turėti įtakos diagnostikos tikslumui ir gali daryti įtaką klinikiniam sprendimams [18, 19]. 3 paveiksle vaizduojama 3D rotacinių DSA vaizdų ir 2D skaitmeninės angiogramos vaizdų palyginimas. Paveiksle parodoma, jog 3D DSA vaizdai yra tikslesni, nes šalia didžiosios aneurizmos, vaizduojamos 2D ir 3D vaizduose, yra mažoji, matoma tik 3D vaizduose, o dviejų dimensijų skaitmeninės angiogramos vaizde mažesnėsios aneurizmos nematyti [20].



3 pav. Dviejų dimensijų (2D) skaitmeninės angiografijos vaizdas iš kairiosios vidinės miego arterijos šoninio vaizdo (a), vaizduojantis didelę aneurizmą (pažymėta juoda rodykle). Mažesnės aneurizmos (pažymėta balta rodykle), pavaizduotos trijų dimensijų (3D) skaitmeninės angiografijos šonine (b) ir įstrižai šonine (c) kryptimi, vaizdai.

1.2. Vaizdų su intracerebrinėmis aneurizmomis klasifikavimas

Sąsūkų neuroniniai tinklai (angl. *Convolutional Neural Network (CNN)*) yra neretai naudojami klasifikavimo problemoms spręsti naudojant medicininius vaizdus. Tai leidžia automatizuoti ligų diagnostiką. Wenguang ir kt. (2020) nagrinėjo automatinį intracerebrinių aneurizmų aptikimą trijų dimensijų tekėjimo laiko magnetinio rezonanso angiografijos tyrimo vaizduose naudodamas vienmačius sąsūkų neuroninius tinklus [21, 22]. Darbo schema pateikta 4 paveiksle.



4 pav. 1D CNN intracerebrinės aneurizmos aptikimo schema


Pradinį trijų dimensijų TOF-MRA vaizdą autorius skaidė į tūrinio vaizdo elementus (angl. *voxel*) išilgai smegenų, apimant visą originalų trijų dimensijų vaizdą. Kiekvienam tūrinio vaizdo elementui buvo atliktas segmentavimas 3D fragmentui, esančiam 3D TOF-MRA tūrinio vaizdo centre. Toks fragmentas yra vadinamas dominančiu regionu (angl. *Region of Interest (ROI)*). Kiekvienam ROI kai kurie maksimalaus intensyvumo projekcijos (angl. *Maximum Intensity Projection (MIP)*) vaizdai, kuriuose yra pagrindinės originalaus vaizdo savybės, yra generuojami naudojant ROI vaizdus keliomis kryptimis. Atitinkamai keli vienos dimensijos vektoriai, kurių ilgis yra m , yra gaunami kaupiant MIP vaizdo taškus skirtingomis kryptimis. Tyrime buvo kaupiami vaizdai n kryptimis. Kiekvienam ROI yra gaunami n vienmačių, m ilgio vektorių, kurie yra sujungiami į naują vienmatį vektorių, kurio ilgis yra $m \times n$. Autorius generavo devynis MIP vaizdus kiekvienam ROI. Taigi, naudojo devynis koncentruotus vienmačius $m \times n$ dydžio vektorius kiekvienam ROI. Kitame etape šie devyni vektoriai buvo sujungti į vieną $9 \times m \times n$ ilgio 1D vektorių. Buvo sudarytas vienmatis sąsūkų neuroninis tinklas aneurizmai aptikti, kurio įvestis yra $9 \times m \times n$ ilgio 1D vektorius, o išvestis yra 1 arba 0, kuris atitinkamai nusako ar yra aneurizma, ar jos nėra. Apmokius vienmatį CNN, jį galima naudoti aneurizmai nustatyti iš TOF-MRA vaizdų projektuojant juos į vienmačius vektorius [21].

Ker ir kt. (2019) darbe buvo nagrinėti smegenų vaizdai gauti kompiuterinės tomografijos tyrimo metu. Tyrimo tikslas buvo sudaryti trijų dimensijų sąsūkų neuroninį tinklą, skirtą klasifikuoti kompiuterinės tomografijos nuotraukas su šiais pažeidimais: smegenys be pažeidimo, subarachnoidinė hemoragija (SAH), intraparenchiminis kraujavimas (IPH), ūminis subdurinis kraujavimas (ASDH) ir smegenų politraumos kraujavimas (BPH). Buvo tirtas tinklo tikslumas, atliekant klasifikavimą tarp dviejų klasių: smegenų vaizdai be pakitimo ir su pakitimais, bei tarp keturių klasių: smegenų vaizdai be pakitimų, SAH, IPH, ASDH. Tyrime buvo naudotas vaizdų ribinimas (angl. *thresholding*) duomenų apdorojimo etape, o tai pagerino 3D CNN klasifikavimo

tikslumą. 1 lentelėje bei 5 paveiksle yra pateikta naudota architektūra trijų dimensijų sąsūku neuroniniam tinklui [23].

1 lentelė. Binarinio ir daugiaklasio kompiuterinės tomografijos vaizdų klasifikavimo modelio architektūra

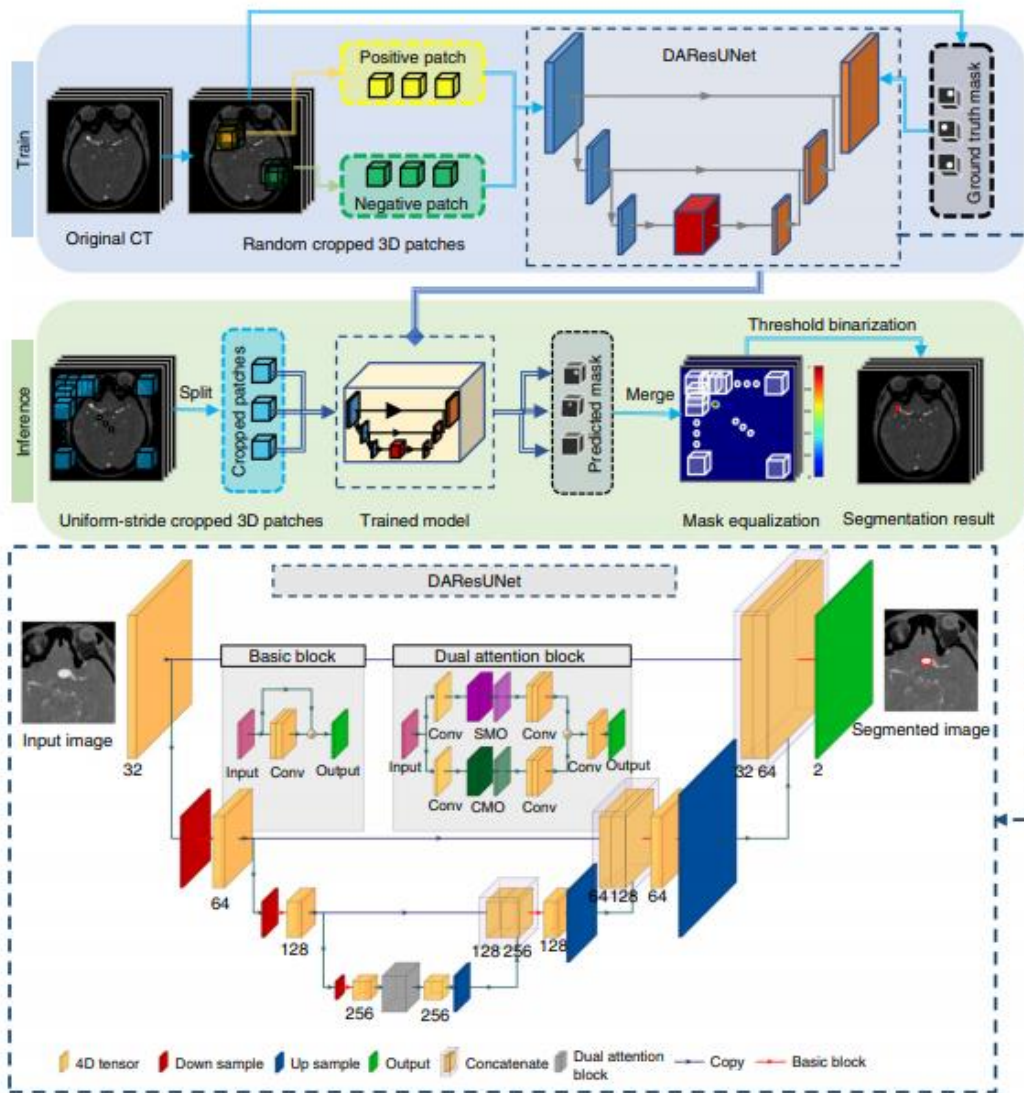
Layer	Kernel Size	Stride	Output Size (Width × Length × Depth × Filters)
Input	-	-	50 × 50 × 28
Convolution 1	3 × 3 × 3	1	50 × 50 × 28 × 32
Pooling 1	2 × 2 × 2	2	25 × 25 × 14 × 32
Convolution 2	3 × 3 × 3	1	25 × 25 × 14 × 64
Pooling 2	2 × 2 × 2	2	13 × 13 × 7 × 64
Convolution 3	3 × 3 × 3	1	13 × 13 × 7 × 128
Pooling 3	2 × 2 × 2	2	7 × 7 × 4 × 128
Fully Connected 1	-	-	25,088 × 1024
Fully Connected 2	-	-	1024 × 2



5 pav. Binarinio ir daugiaklasio kompiuterinės tomografijos vaizdų klasifikavimo modelio architektūra


1.3. Intracerebrinių aneurizmų aptikimas ir segmentavimas

Sąsūku neuroniniai tinklai (angl. *Convolutional Neural Network*) taip pat neretai naudojami objektų aptikimo ir segmentavimo problemoms spręsti naudojant medicininius vaizdus. Aneurizmų aptikimą, naudojant KTA vaizdus, nagrinėjo ir aprašė Zhao ir kt. (2020). Darbe naudotas modelis yra trijų dimensijų sąsūku neuroninis tinklas skirtas vaizdams segmentuoti bei pavadintas DAREsUNet. Visų pirma buvo naudota kodavimo ir dekodavimo architektūra laipsniškam perėjimui nuo originaliųjų kompiuterinės tomografijos vaizdų iki segmentuoto vaizdo (žr. 6 pav.). Vėliau, užlaikymo blokai (angl. *residual blocks*) buvo įtraukiami į tinklą stabiliam mokymuisi ir tinklo gylio didinimui. Taip pat, siekiant gauti patikimesnes funkcijų charakteristikas į tinklą buvo įtraukti dvigubo dėmesio blokai (angl. *dual attention blocks*). Tyrimo rezultatai parodė, jog modelis turi gerą toleranciją vaizdų kokybei ir skirtingų medikų pateiktos nuotraukos duoda šiek tiek skirtingą modelio tikslumą [24].



6 pav. 3D CNN modelio schema aneurizmomis segmentuoti

Rahil ir kt. (2020) nagrinėjo tiek vaizdų aptikimą, tiek segmentavimą. Tyrime buvo nagrinėtos kompiuterinės tomografijos angiografijos nuotraukos. Darbe buvo atlikti keli vaizdų paruošimo etapai. Visų pirma, buvo sukurtas smegenų kaukės apskaičiavimo algoritmas, naudojantis statistinio parametrinio atvaizdavimo (angl. *statistical parametric mapping*) programinės įrangos paketo 8 versiją. Taip pat smegenų vaizdams buvo pritaikytas daugiasluoksnis kraujagyslių stiprinimo filtras (angl. *a multi-scale vessel enhancement filter*), skirtas sustiprinti kontrastui tarp arterijų bei kompiuterinės tomografijos angiogramos vaizdų fono. Tokiu būdu buvo apskaičiuoti du vaizdai su sustiprintomis kraujagyslėmis: vienas su 0,5–5 tūrinio vaizdo elementais (angl. *voxel*), o kitas su 5–15 tūrinio vaizdo elementais. Šie du skirtingi vaizdai, juos vertinant kartu, padeda atskirti kraujagysles nuo aneurizmų. Antra, buvo atliktas vaizdo standartizavimas skaidant vaizdus į $0,5 \times 0,5 \times 0,5 \text{ mm}$ dimensijų paveikslėlius bei normalizuotas jų intensyvumas. Pradinis KTA vaizdas buvo normalizuotas tarp 5–95 % jo intensyvumo reikšmių, o vaizdai, kuriems pritaikytas daugiasluoksnis kraujagyslių stiprinimo filtras, buvo normalizuoti Z-balu (angl. *Z-score*). 7 paveiksle yra pateiktas vaizdų paruošimo etapas [25].



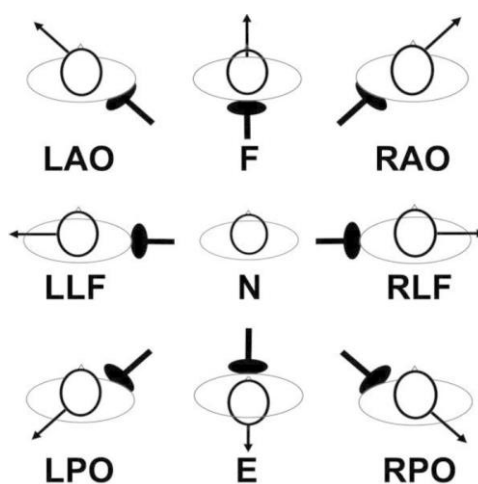
7 pav. Vaizdo išankstinio apdorojimo eiga pacientui, turinčiam dešinės centrinės arterijos aneurizmą (pažymėta rodykle). Pilnai automatizuotas smegenų kaukės skaičiavimas iš gautų galvos ir kaklo kompiuterinės tomografijos angiografijos vaizdų (padengtas žalia spalva (a)). Išgautas smegenų vaizdas (b). 3D kraujagyslių vaizdai su 0,5–5 dydžio tūrinio vaizdo elementais (c) bei 5–15 dydžio tūrinio vaizdo elementais (d)

Šiame moksliniame tyrime buvo naudotas trijų dimensijų sąsūkų neuroninis tinklas. Šis CNN buvo paremtas „DeepMedic“, kuriam reikalinga gili trijų dimensijų sąsūkų neuroninio tinklo architektūra su dviem identiškais keliais, kurie naudoja skirtingas vaizdo skiriamąsias gebas, kad užfiksuotų kontekstinę informaciją [26]. 3D vaizdų segmentai, kurie yra centruoti toje pačioje vietoje, suteikia įvestį dviem keliais. Vienu iš šių būdų vaizdas yra imamas tik iš vienos trečiosios pradinio vaizdo. Modelis yra sudarytas iš 11 sluoksnių su 33 dydžio branduoliais. Modelio 4, 6, 8 ir 10 sluoksnis yra su liekamosiomis jungtimis (angl. *residual connections*), o 9 ir 10 sluoksniai yra pilnai sujungti (angl. *fully connected*) [25].

Šiame tyrime buvo naudoti trys skirtingi modelio apmokymo procesai, pavadinti DLM-Orig, DLM-Vess ir DLM-LDim. Pirmuoju atveju (DLM-Orig) sąsūkų neuroninio tinklo įvestis yra originalus kompiuterinės tomografijos vaizdas, kurio mokymui naudojamų vaizdų segmentų dydis yra 25^3 tūrinio vaizdo elementai. DLM-Vess įvestis yra daugiakanalė, susidedanti iš kompiuterinės tomografijos angiografijos vaizdų ir dviejų sustiprintų kraujagyslių vaizdų. Mokymuisi naudojamų vaizdų segmentų dydis yra 25^3 tūrinio vaizdo elementai. DLM-LDim atveju KTA vaizdai atspindi tinklo įvestį, bet išgautų segmentų dydis šiuo atveju buvo padidintas nuo 25^3 iki 45^3 tūrinio vaizdo elementų [25].

Norint padidinti apmokymo duomenų kiekį, buvo naudotas duomenų augmentavimas, t. y. jie buvo išplėsti perkeliant vaizdus pagal jų ašis. Apmokymo partijos dydis (angl. *batch size*) buvo parinktas 15, naudotas partijos normalizavimui (angl. *batch normalization*). Kaip aktyvavimo funkcija buvo naudotas parametrinis ištiesintas linijinis vienetas (angl. *parametric rectified linear unit*), o „Dice“ panašumo koeficientas buvo naudotas kaip nuostolių funkcija. Taip pat apmokymo epochų skaičius buvo 30. Visi trys tinklai buvo apmokyti naudojant 5-kių kartų kryžminės validacijos metodą (angl. *five-fold-cross-validation*), duomenis skiriant į 80–20 % apmokymo-validavimo imtis be duomenų persidengimų. Darbe taipogi buvo įvesta DLM-Ens strategija, kuri nurodo galutinį aneurizmų segmentavimo rezultatą [25].

Dar vieną tyrimą smegenų aneurizmų aptikimo ir segmentavimo srityje atliko Xinke ir kt. (2021). Darbe sudarytas trijų dimensijų sąsūkų neuroninis tinklas, skirtas atpažinti ir segmentuoti intracerebrines aneurizmas 3D sukamuosiuose DSA (angl. *3D rotational DSA (3D-RA)*) vaizduose. Pradiniai paveikslėliai buvo 1024×1024 dydžio, vėliau vaizdai buvo suskaidyti į $0,308 \times 0,308$, $0,340 \times 0,340$ ir $0,370 \times 0,370$ tūrinio vaizdo elementus. Trijų dimensijų sukamieji DSA vaizdai yra sudaromi iš dviejų dimensijų vaizdo projekcijų, užfiksuotų iš 133 kampų tarp dešinio priekinio įstrižo (angl. *the right anterior oblique (RAO)*) ir kairio priekinio įstrižo (angl. *the left anterior oblique (LAO)*) [27]. 8 paveiksle vaizduojamos angiografijų projekcijos [28].

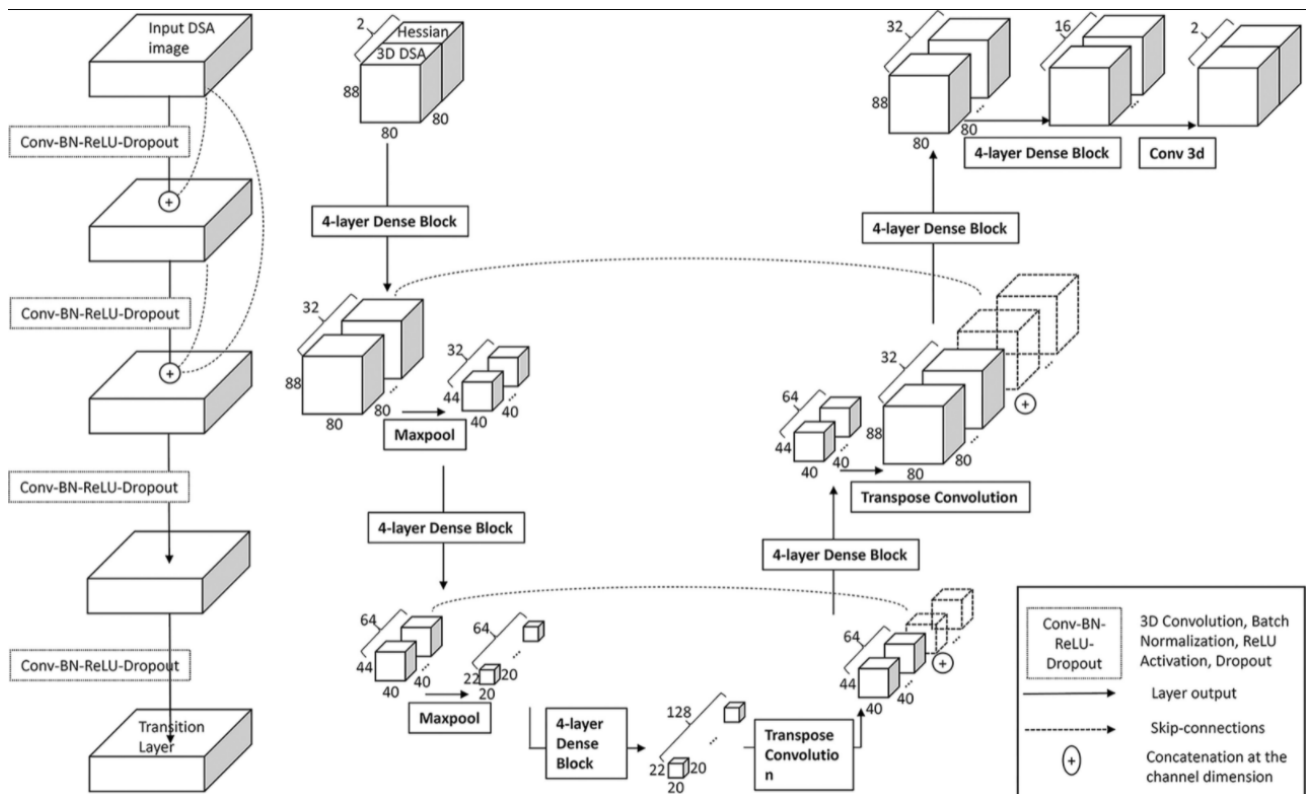


8 pav. Angiografijų projekcijos. Neutrali pozicija (angl. *neutral position*) (N), plėtinys (angl. *extention*) (E), dešinysis galinis įstrižas (angl. *right posterior oblique*) (RPO), dešinys šoninis išlinkimas (angl. *right lateral flexion*) (RLF), dešinys priekinis įstrižas (angl. *right anterior oblique*) (RAO), kairys galinis įstrižas (angl. *left posterior oblique*) (LPO), kairys šoninis išlinkimas (angl. *left lateral flexion*) (LLF), kairys priekinis įstrižas (angl. *left anterior oblique*) (LAO)

Tiek DSA projekcijos vaizdas, tiek ekspertiniu būdu pažymėtos aneurizmų segmentavimo anotacijos gali būti laikomos sinogramomis, todėl darbe naudojant atvirkštinę Radono transformaciją (angl. *inverse Radon transform*) sinogramos buvo rekonstruotos į trijų dimensijų tūrinius vaizdus bei trijų dimensijų segmentavimo anotaciją atitinkamai kiekvienam paveikslui. Siekiant sustiprinti intracerebrinių kraujagyslių kontrastą su fonu, visų pirma DSA vaizdams buvo pritaikytas intensyvumo langų vaizdo filtras (angl. *intensity windowing image filter*) iš ITK programos. Vėliau segmentavimo tūrinei rekonstrukcijai buvo taikyta morfologinė erozija ir uždarymas (angl. *morphological erosion and closing*), kad išlygintų gautą tūrinę aneurizmos segmentavimo kaukę. Tikėtina, jog šio žingsnio poveikis yra minimalus, nes bet koks šio proceso metu atliktas segmentavimo kaukės išlyginimas nesukels didelio poveikio nei žmogiškos klaidos, nei rankiniu

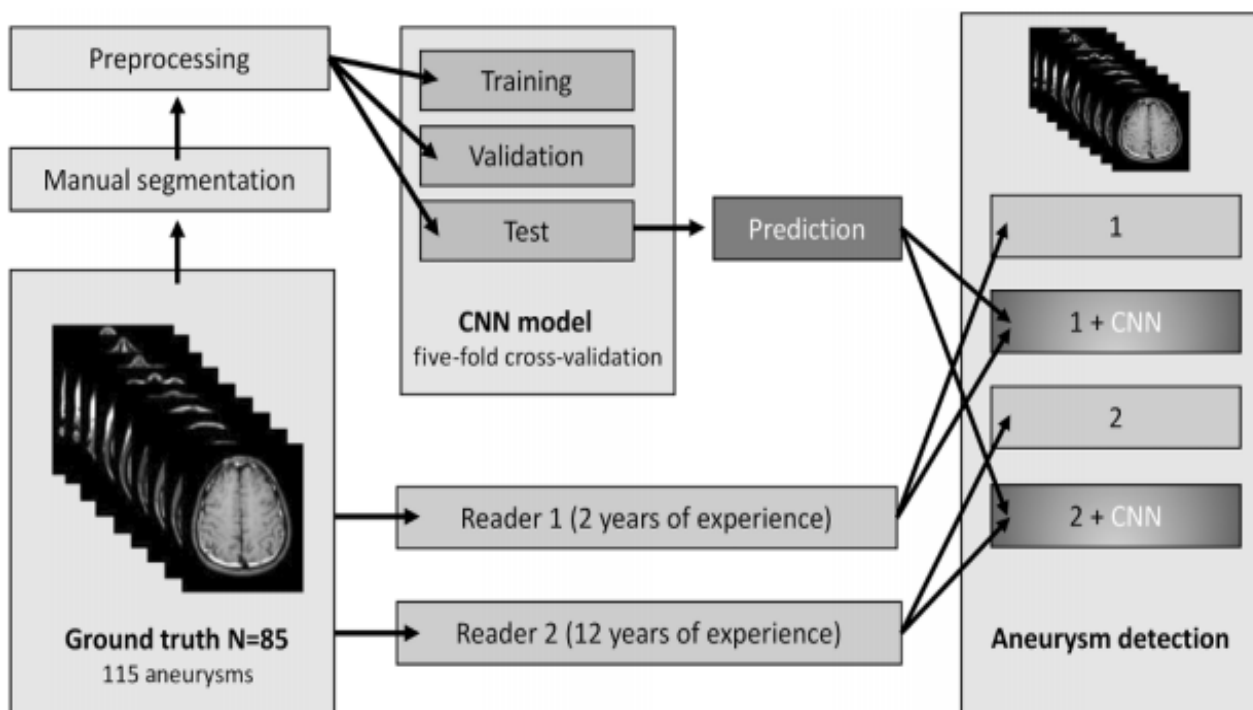
būdu žymimoms aneurizmos vaizduose. Galiausiai visi rekonstruoti trijų dimensijų tūriniai vaizdai buvo sumažinti 8 kartus bei apkarpyti iki $80 \times 80 \times 80$ pikselių su izotropiniu tarpu, o tokie paveikslėliai buvo naudoti kaip 3D CNN modelio įvestis [27].

Darbe buvo naudota modifikuota U-Net tinklo architektūra su tankio blokais (angl. *dense blocks*) (žr. 9 pav.). Tankio blokuose kiekvienas sluoksnis yra tiesiogiai sujungtas su kiekvienu kitu sluoksniu, o tai sudaro tapačią transformaciją (angl. *identity transform*) tarp sluoksnių, kuri yra duomenų transformacija, leidžianti be pakeitimų nukopijuoti šaltinio duomenis į paskirties duomenis be pakitimų [27, 29, 30]. Be to, panašios „praleidimo“ jungtys (angl. „*skip*“ *connections*) yra įtrauktos į U-Net tinklo priešingus sluoksnius (sumažintas kodavimas lyginant su dekodavimo pavyzdžiu), o tai padeda lokalizuoti daugybę kodavimo funkcijų [27, 31]. Modelio įvestis yra pilnai rekonstruotas 3D DSA tūrinis vaizdas ir jo 3D tūris su Hesiano filtru (angl. *Hessian filter*). 3D Hesiano filtras sukuria antros eilės vaizdo išvestinę [27, 32]. Šis filtras yra naudojamas tam, kad kraujagyslių kraštai būtų ryškesni, nes pikselių intensyvumo gradientas prie kraujagyslių kraštų yra daug didesnis nei jų centre. Šis filtruotas Hesiano tūris yra sudedamas kartu su pradiniu DSA vaizdu bei paduodamas kaip dviejų kanalų vaizdas į modelį [27, 33]. Taip pat buvo naudotas Adamo optimizatorius. Nuostolių funkcijai buvo naudotos svorinė „Dice“ nuostolių bei svorinė kryžminės entropijos nuostolių (angl. *cross-entropy loss*) funkcijos, o tai padeda išspręsti ne aneurizmos fono taškų klasės disbalansą segmentuojant mažas aneurizmas [27, 34]. Tinklo rezultatas yra dvi tokio paties dydžio išvestys, kurioms dar yra pritaikyta „softmax“ funkcija. „Softmax“ funkcijos išvestys, suteikiančios fonui ir aneurizmoms tikimybę pagal tūrinio vaizdo elementus, saugomos trijų dimensijų matricioje. Šiai tikimybės matriciai pritaikius slenkstį, gaunama segmentavimo kaukė, identiška ekspertų anotacijų segmentavimo kaukėms [27].



9 pav. Keturių sluoksnių tankio blokų architektūra aneurizmų aptikimui

Faron ir kt. (2019) moksliniame darbe aprašė giliojo mokymosi neuroninio tinklo veikimą, skirtą intracerebrinių aneurizmų aptikimui iš 3D tekėjimo laiko magnetinio rezonanso angiografijos vaizdų, bei palygino tinklo rezultatus su patyrusio ir mažiau patyrusio mediko vertinimu. Šiame darbe buvo sukurtas aneurizmų aptikimo modelis pasinaudojant „DeepMedic“ sistema. Naudotas duomenų rinkinys buvo sudarytas iš 85 pacientų. Kiekvieno iš pacientų 3D TOF-MRA vaizdus vertino du medikai: pirmasis – turintis 2 metų patirtį, bei antrasis – turintis 12 metų patirtį nustatant aneurizmas. Atitinkami tyrimai buvo anonimizuoti bei eksportuoti iš vietinės archyvavimo ir ryšių sistemos (angl. *local archiving and communication system*) duomenų bazės į specialią duomenų talpyklą. Ekspertinį aneurizmų nustatymą atliko patyręs neuroradiologijos specialistas, naudodamas ITKSNAP programinę įrangą bei remdamasis kritine vizualine apžiūra, radiologijos ataskaitomis ir prieinamais papildomais tyrimais (KTA, skaitmenine angiografija (DSA)). Tokiu būdu buvo nustatyta 115 negydytų aneurizmų. Vidutinis didžiausias skersmuo ir vidutinis tūris buvo atitinkamai $7,1 \pm 4,4 \text{ mm}$ (diapazonas $2,1 - 437,0 \text{ mm}$) ir $214,6 \pm 480,9 \text{ mm}^3$ (diapazonas $6,4 - 4518,0 \text{ mm}^3$). Didžioji dalis aneurizmų buvo išsidėstę vidurinėse miego arterijose (angl. *the internam carotid arteries*) ($N = 48$), paskui vidurinėse smegenų arterijose (angl. *the middle cerebral arteries*) ($N = 26$), galinėse kraujagyslėse (angl. *the posterior circulation*), įskaitant galines susisiekiančias arterijas ($N = 22$), bei priekinėse smegenų arterijose (angl. *the anterior cerebral arteries*) ($N = 19$). 10 paveiksle pateikiama tyrimo schema [35].




10 pav. Blokinė tyrimo schema

Modelio įvestis yra 85 pacientų trijų dimensijų TOF-MRA nuotraukos, kuriose yra 115 aneurizmų. Šis duomenų rinkinys buvo naudojamas kaip sąsūkų neuroninio tinklo įvestis bei buvo pateiktas dviem aukščiau paminėtiems medikams, turintiems skirtingą diagnostinio neurografavimo patirtį. Tokiu būdu buvo siekiama palyginti modelio rezultatus su medikų išvadomis [35].

Darbe buvo naudotas „DeepMedic“ CNN architektūros karkasas, skirtas trijų dimensijų vaizdų segmentavimui. „DeepMedic“ sąsūkų neuroninio tinklo architektūra yra pateikta 11 paveiksle [36].

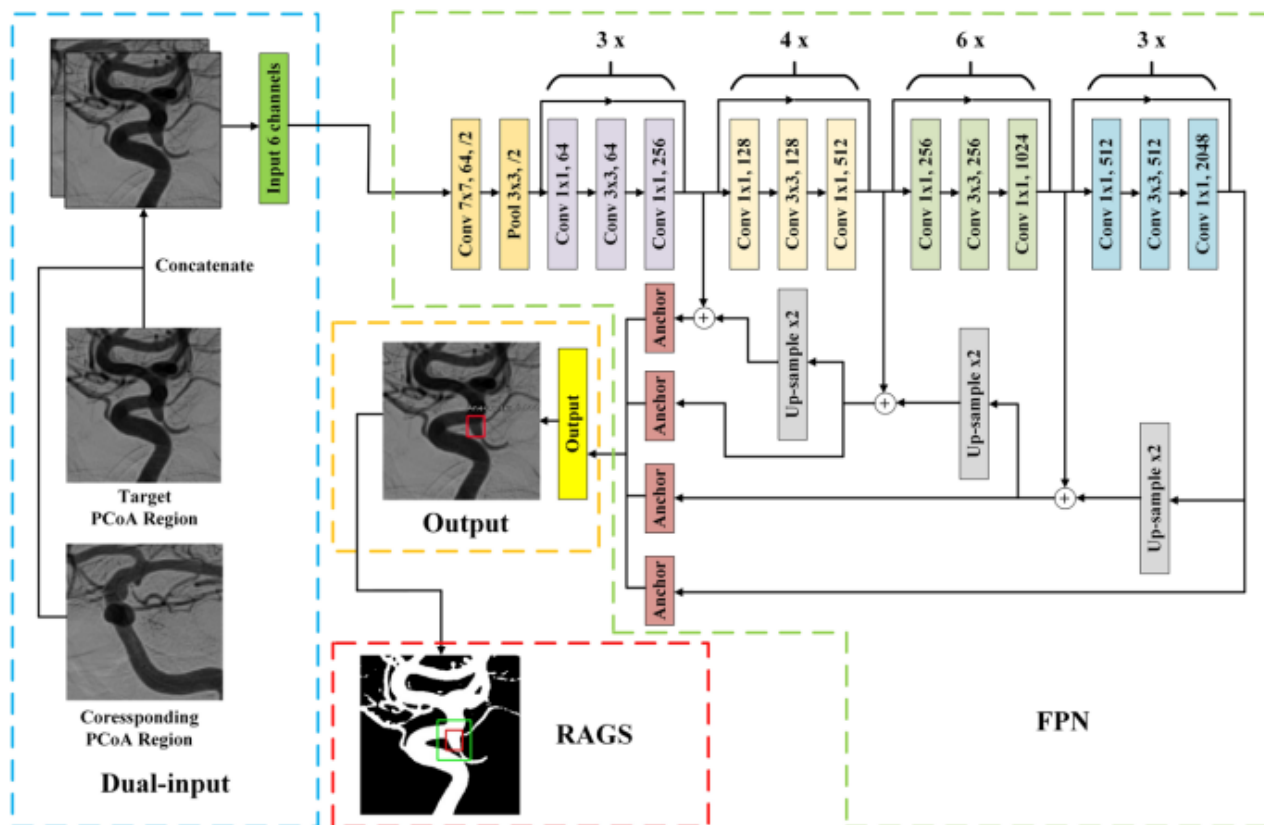
Segmentavimas, t. y. kiekvieno tūrinio vaizdo elemento klasifikacija į fono arba aneurizmos klasę, palengvina sąsūkų neuroninio tinklo modelio vidinių parametrų koregavimą priklausomai nuo pradinės įvesties bei modelio išvesties prognozės. Darbe duomenys buvo skirstomi į apmokymo, validavimo bei testavimo duomenų imtis bei buvo naudotas penkių kartų kryžminio validavimo metodas (angl. *five-fold cross-validation*). Taip pat duomenys buvo pakartotinai atrinkti į 0,5 mm kraštinės ilgio izotropinius tūrinius elementus. Kiekviena gauta reikšmė buvo normalizuota pagal vidurkį lygų 0 ir standartinį nuokrypį lygų 1. Bendras šio modelio jautrumas (angl. *sensitivity*) buvo 90 %, o klaidingai teigiama reikšmė (angl. *false positive rate*) vienam atvejui buvo 6,1 [35].



11 pav. „DeepMedic“ sąsūkų neuroninio tinklo architektūra

Intracerebrinių aneurizmų aptikimą iš skaitmeninių vaizdų nagrinėjo ir Haihan ir kt. (2019). Šiame tyrime buvo pasiūlyta dviejų pakopų sąsūkų neuroninio tinklo (angl. *two-stage convolutional neural network*) architektūra, skirta automatiškai aptikti intracerebrines aneurizmas iš dviejų dimensijų DSA vaizdų. Pirmoje pakopoje – regiono lokalizacijos etape (angl. *region localization stage*) (RLS), aptikimo sistema randa aneurizmos regioną ir tokiu būdu sumažina kitų regionų (fono) trukdžius. Aneurizmos aptikimo etape (angl. *aneurysm detection stage*) (ADS) detektorius apjungia priekinio ir šoninio angiografinio vaizdo informaciją, kad būtų galima nustatyti intracerebrines aneurizmas naudojant klaidingai teigiamo slopinimo algoritmą (angl. *false-positive suppression algorithm*). Tinklo schema pateikta 12 paveiksle [37].

Tyrime buvo naudoti vaizdai su vidinės miego arterijos (angl. *internal carotid artery*), galinės komunikacijos arterijos (angl. *posterior communicating artery*) sritimi. Duomenų imtis buvo skaidoma į apmokymo ir testavimo imtis, atitinkamai į jų pateko 241 ir 40 vaizdų. Tyrime naudotas metodas yra šimtą kartų greitesnis nei klasikinis skaitmeninis vaizdo apdorojimas (angl. *classical digital image processing*) (DIP) bei naudojant šią architektūrą buvo pasiektas 93,5 % tikslumas, o AUC reikšmė yra 0,942, kai DIP tikslumas yra 62,5 %, o AUC – 0.69 [37].



14 pav. Aneurizmos aptikimo etapo architektūra

Toliau 2 lentelėje pateikti suklasifikuoti nagrinėti literatūros šaltiniai.

2 lentelė. Literatūros analizė

Literatūra	Duomenų gavimo būdas	Problema			Metodas
		Aptikimas	Klasifikavimas	Segmentavimas	
Faron ir kt. (2019) [35]	3D TOF-MRA	+			2D CNN
Haihan ir kt. (2019) [37]	2DDSA	+			Dviejų pakopų CNN
Ker ir kt. (2019) [23]	KTA		+		3D CNN
Rahil ir kt. (2020) [25]	KTA	+		+	3D CNN
Wenguang at al. (2020) [21]	3D TOF-MRA		+		1D CNN
Xinke ir kt. (2021) [27]	3D DSA	+		+	3D CNN
Zhao ir kt. (2020) [24]	KTA			+	3D CNN

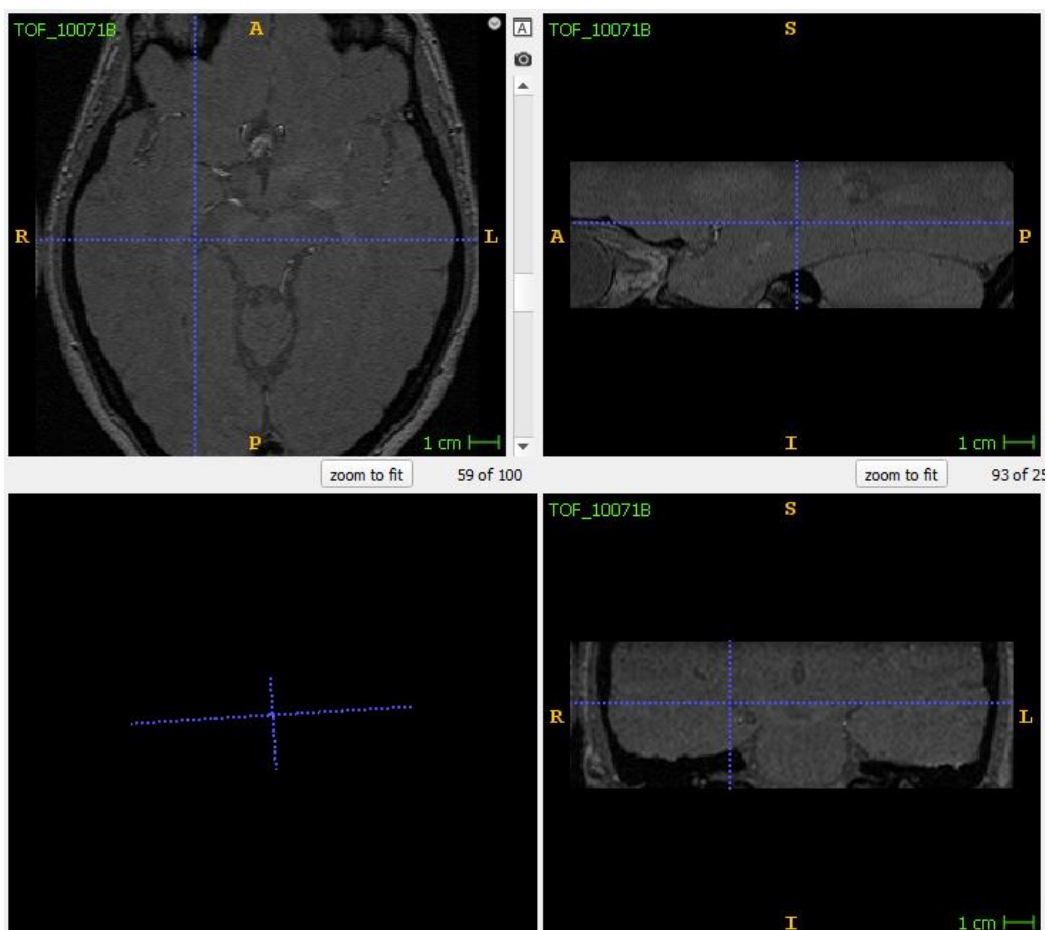
Atlikus literatūros šaltinių analizę galima pastebėti, jog baigiamojo magistro darbo temos aktualumas yra neabejotinas. Atsižvelgiant į tai, kad subarachnoidinės hemoragijos pasekmės yra labai skaudžios, kuo ankstyvesnis su mažiau klaidų intracerebrinių aneurizmų aptikimas ir diagnozavimas, leidžiantys laiku pritaikyti gydymą bei apsaugoti pacientą nuo galimo kraujo išsiliejimo į smegenis, yra itin svarbus. Magnetinio rezonanso angiografijos arba kompiuterinės tomografijos angiografijos tyrimų aneurizmų aptikimo automatizavimas padėtų išspręsti problemas, kylančias dėl netinkamai padarytų išvadų aptinkant aneurizmas ekspertiniu būdu bei sumažintų krūvį radiologams ir neurologams. Šiame darbe naudojantis magnetinio rezonanso angiografijos tyrimo metu gautų galvos tūrio vaizdais parenkami ir išanalizuojami giliaisiais neuroniniais tinklais grįsti klasifikavimo ir segmentavimo algoritmai.

2. Duomenys ir tyrimo metodai

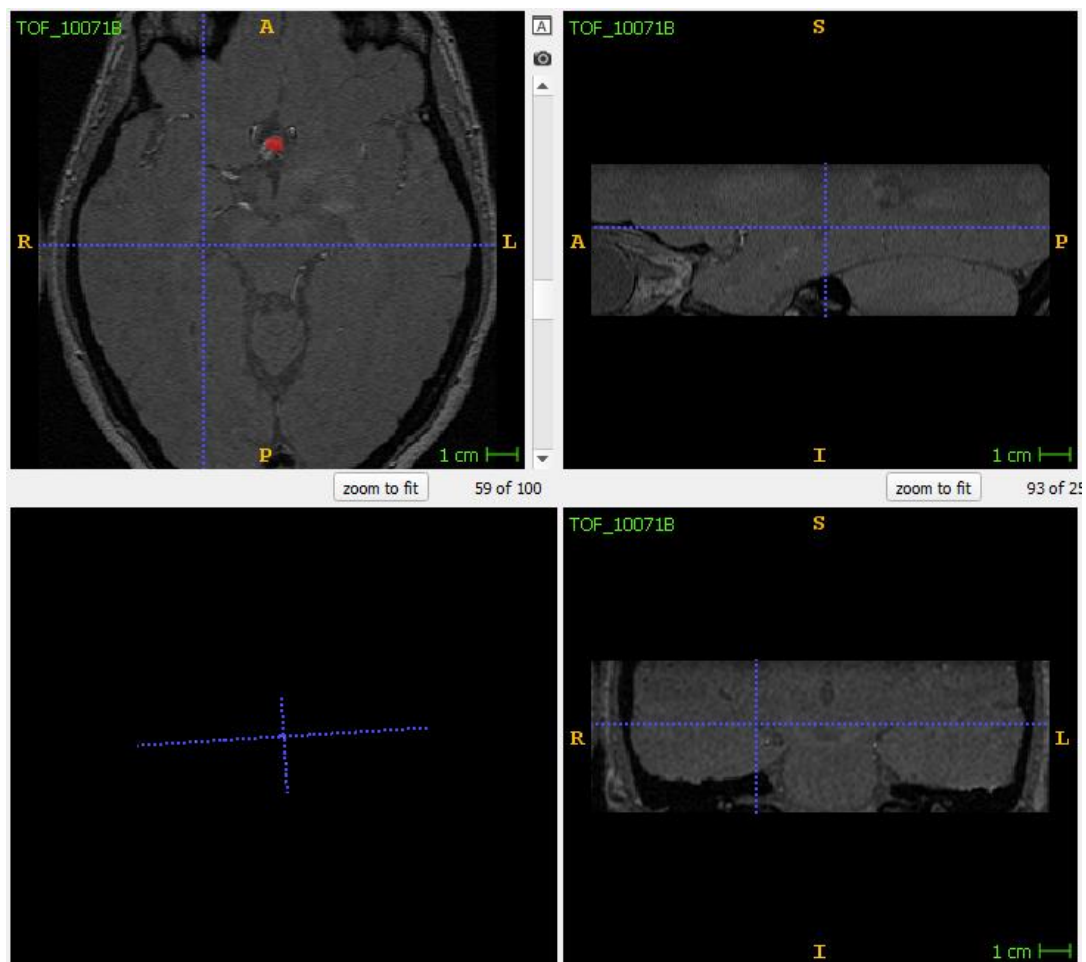
2.1. Tyrime naudoti duomenys

Tyrime buvo naudoti tekėjimo laiko magnetinio rezonanso angiografijos vaizdai gauti iš aneurizmų aptikimo ir segmentavimo konkurso (angl. *aneurysm detection and segmentation challenge*) [39]. Duomenų rinkinį sudarė 113 smegenų TOF-MRA vaizdų, iš kurių 43 yra be aneurizmų, 35 yra su aneurizmomis prieš gydymą bei 35 tų pačių pacientų smegenų vaizdai atitinkamai, tik jau tyrimas darytas po gydymo. Kiekvienam duomenų objektui yra pateiktas TOF-MRA vaizdas – duomenų failas, išsaugotas NIfTI formatu, bei trimatė segmentavimo kaukė, taip pat saugoma NIfTI formatu.

Susipažinimui su duomenų rinkiniu buvo naudojama ITK-SNAP programa, su kuria galima apžiūrėti trimačius tekėjimo laiko magnetinio rezonanso angiografijos vaizdus bei segmentuotas aneurizmas. 15 paveiksle vaizduojamas TOF-MRA skirtingomis projekcijomis, o 16 paveiksle vaizduojamas tas pats smegenų vaizdas, tik raudona spalva yra pažymėta intracerebrinė aneurizma. Šiame vaizde aneurizma yra didelė, o nemaža dalis aneurizmų yra mažesnės – sunkiai pastebimos žmogaus akimi.




15 pav. TOF-MRA vaizdai skirtingomis projekcijomis



16 pav. TOF-MRA vaizdai skirtingomis projekcijomis. Raudona spalva žymimos aneurizmos

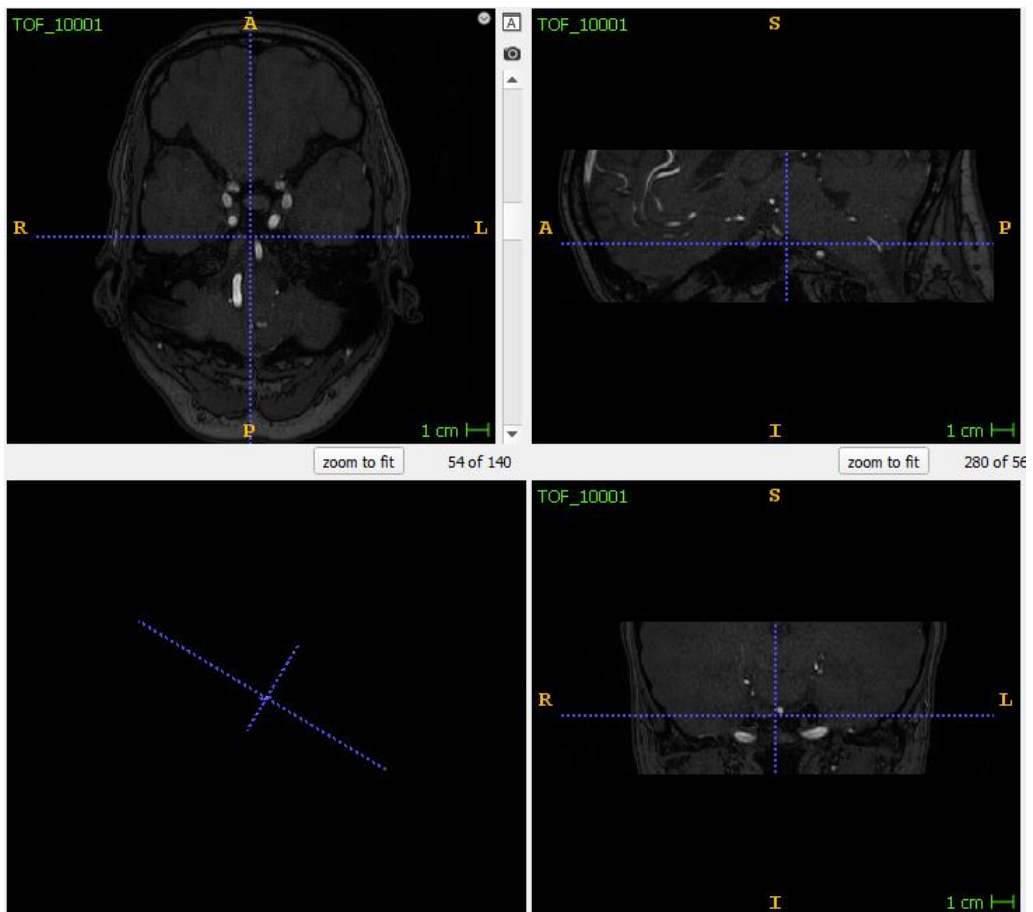
Kadangi trys vaizdai buvo nepilni, t. y. dalis smegenų vaizdo yra prarasta, tad šiuos tris pacientų smegenų vaizdus (10037, 10056B, 10059B) pašaliname iš duomenų imties, naudojamos tolimesniame tyrime.

Tyrime buvo naudoti dvimačiai smegenų vaizdai, todėl buvo pjaustoma pradinė trimatė duomenų imtis. Buvo gauti dvimačiai smegenų sluoksnių vaizdai (žr. 17 pav.). Kiekvienas pradinis vaizdas yra sudaryto dydžio trimatė matrica, todėl, atlikus duomenų pjaustymą į sluoksnius, suvienodiname vaizdų dydį – apdoroti vaizdai yra 300×300 dydžio. Vėliau, atlikome duomenų normalizavimą, o gautus suvienodinto dydžio, normalizuotus smegenų sluoksnių dvimačius vaizdus naudojome tolimesniame tyrime.




17 pav. Dvimatis suvienodinto dydžio, normalizuotas smegenų sluoksnio vaizdas

17 paveiksle yra vaizduojamas tas pats smegenų sluoksnis, matomas 15 ir 16 paveiksle (10071B paciento 59 sluoksnis). Galime pastebėti, kad normalizavus paveikslą, vaizdas šiek tiek pašviesėjo, bet didelių pakitimų neįvyko. Taip pat verta paminėti, kad šviesios paveikslo vietos ne visada yra intracerebrinės aneurizmos. 18 ir 19 paveiksle pateikiamas smegenų be aneurizmų (10001 paciento 54 sluoksnis) trimatis bei dvimatis vaizdas. Galime pastebėti, jog šiuose paveiksluose yra ne viena vieta su didele pikselių intensyvumo reikšme, bet nei viena iš šių vietų nėra aneurizma.



18 pav. TOF-MRA vaizdas be aneurizmų skirtingomis projekcijomis



19 pav. Dvimatis smegenų be aneurizmų sluoksnių vaizdas

Atlikus pradinių duomenų paruošimą, gavome 14 605 dvimačius smegenų sluoksnių vaizdus, iš kurių 1 316 yra vaizdai su aneurizmomis, o 13 289 – be intracerebrinių aneurizmų.

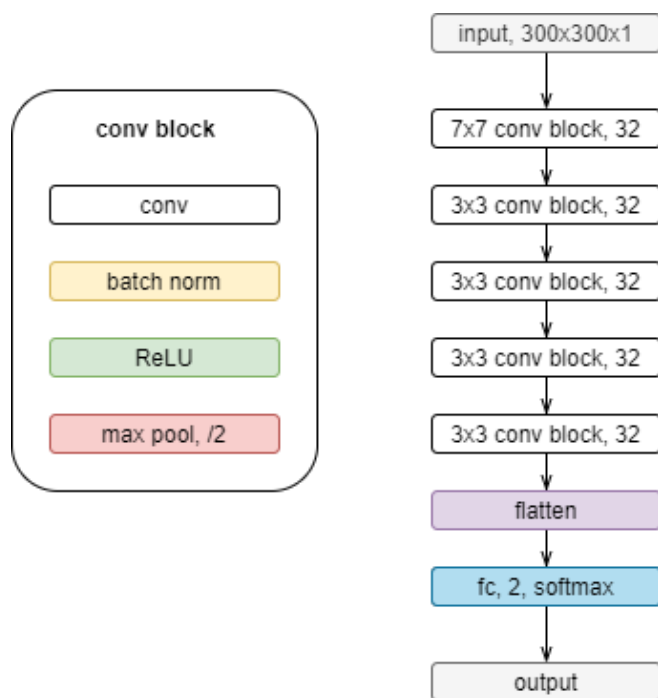
2.2. Tyrime naudoti metodai

Tiek klasifikavimo, tiek segmentavimo uždaviniams spręsti darbe buvo naudoti sąsūkų neuroniniai tinklai. Klasifikavimui buvo naudotas klasikinis CNN tinklas ir ResNet-34 tinklo architektūra, o segmentavimui – trys skirtingos U-Net architektūros: U-Net-15, U-Net-27, U-Net-36. Visiems šiems tinklams buvo naudotas penkių dalių kryžminės validacijos metodas, o duomenų imtis buvo skaidoma į apmokymo, validavimo ir testavimo duomenų imtis klasifikavimo užduotyje bei apmokymo ir validavimo duomenų imtis sprendžiant segmentavimo problemą.

2.2.1. Intracerebrinių aneurizmų klasifikavimas

Sprendžiant klasifikavimo į dvi klases: 0 klasė – nėra aneurizmos, 1 klasė – yra aneurizma, problema buvo naudotos dvi sąsūkų neuroninio tinklo architektūros – klasikinis CNN bei ResNet-34 tinklas. Abiejų šių tinklų įvestis yra dvimačiai smegenų sluoksnių vaizdai, o išvestis – klasės etiketė, nusakanti, ar paveiksle yra, ar nėra, aneurizma.

Pirmasis tinklas yra klasikinis sąsūkų neuroninis tinklas, turintis 42 370 parametrų. Tinklo įvestis yra $300 \times 300 \times 1$ dydžio smegenų sluoksnių vaizdai, o išvestis – binariniai dydžiai, nusakantys kuriai klasei (su aneurizma ar be jos) priklauso atitinkamas vaizdas. Šis sąsūkų neuroninis tinklas yra sudarytas iš penkių sąsūkų blokų, iš kurių pirmojo filtro dydis yra 7×7 , o visų likusių sąsūkų blokų filtrų dydis yra 3×3 . Sąsūkų blokai yra sudaryti iš sąsūkų sluoksnių su atitinkamu filtrų dydžiu bei su 32 filtrais. Sąsūkų sluoksniams naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija bei dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 . Po penkių sąsūkų blokų buvo atliktas filtro išskleidimas (angl. *flatten*) bei įtrauktas pilnai sujungtas (angl. *fully connected*) sluoksnis su 2 filtrais bei „softmax“ aktyvacijos funkcija. Šio tinklo architektūra yra pateikta 20 paveiksle.



20 pav. Klasikinio CNN tinklo architektūra

Šiam tinklui yra taikyta penkių kartų kryžminė validacija. Tinklo apmokymui buvo naudotas partijos dydis (angl. *batch size*) lygus 16, tinklas turėjo po 150 epochų kiekvienoje kryžminės validacijos dalyje.

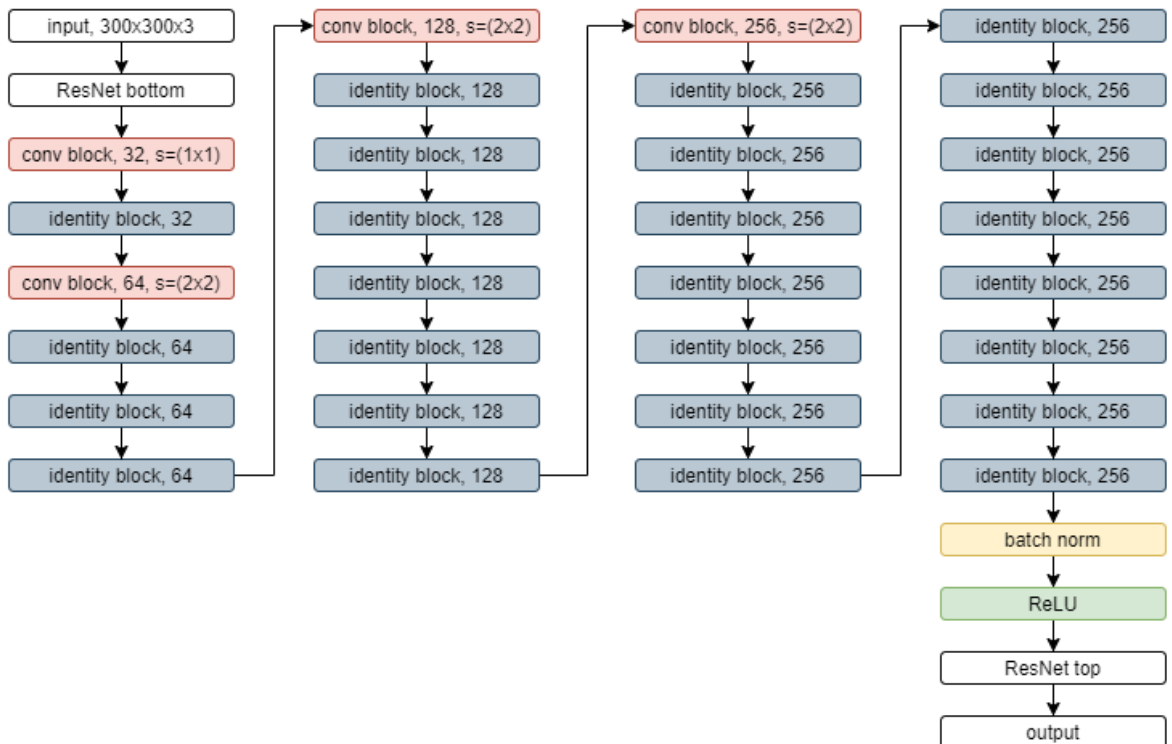
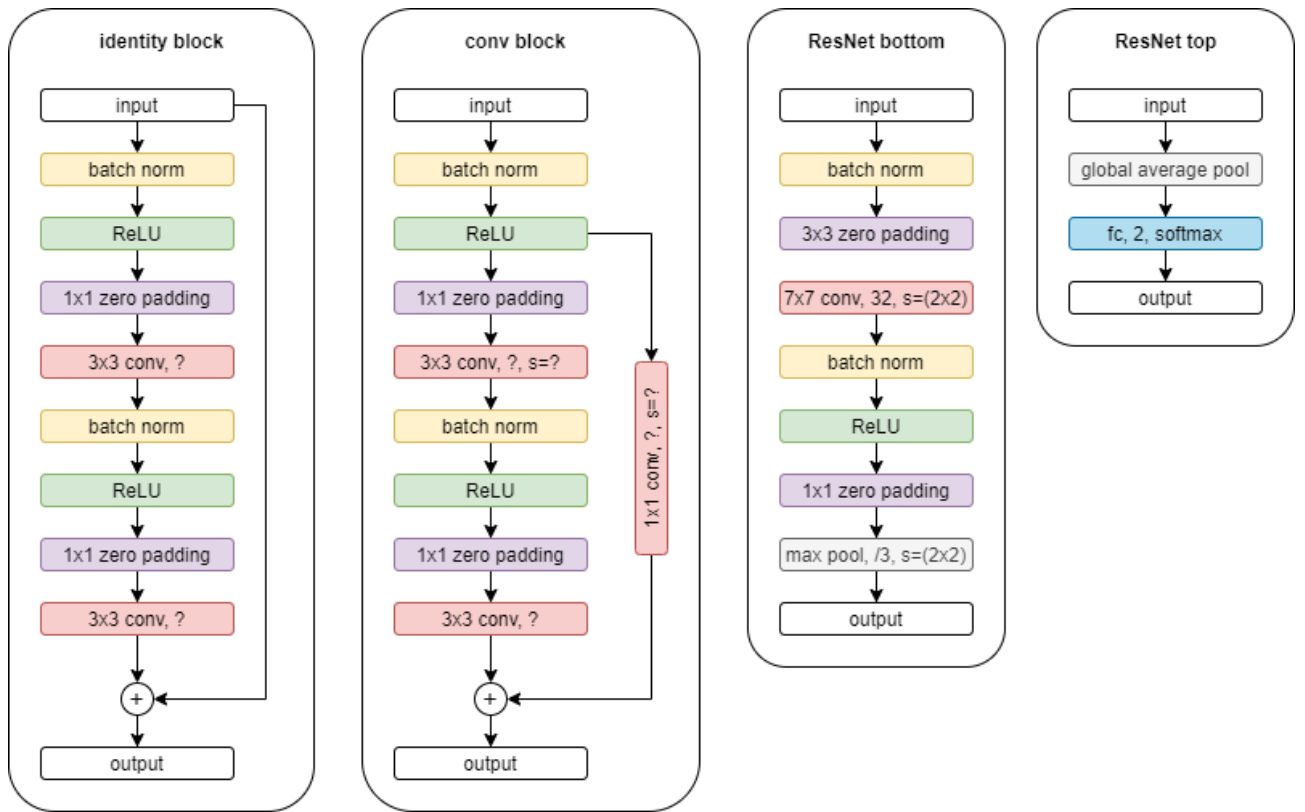
Darbe aneurizmų klasifikavimui buvo naudota ir sudėtingesnė architektūra – ResNet-34 tinklas (žr. 21 pav.). Tinklo įvestis yra $300 \times 300 \times 3$ dydžio, ją sudaro $300 \times 300 \times 1$ dydžio dvimačiai smegenų sluoksnių vaizdai, o kitas matricos reikšmes užpildo nulinės reikšmės. Šiame sąsūkų neuroniniame tinkle yra naudojamas tapatusis blokas, kuriame naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija bei dviejų dimensijų nulinis užpildas (angl. *2D zero padding*), kurio filtro dydis yra 1×1 . Taip pat šiame bloke yra sąsūkų sluoksnis, kurio filtro dydis yra 3×3 . Sąsūkų sluoksniui naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija bei dviejų dimensijų nulinis užpildas (angl. *2D zero padding*) su filtru, kurio dydis yra 1×1 . Galiausiai buvo pridėdamas dar vienas sąsūkų sluoksnis su 3×3 filtro dydžiu. Prie tapačiojo bloko buvo pridėdama pradinė tapačiojo bloko įvestis.

Šiame tinkle taip pat yra apibrėžtas sąsūkų blokas, kuriame naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija, dviejų dimensijų nulinis užpildas (angl. *2D zero padding*), kurio filtro dydis yra 1×1 . Toliau seka sąsūkų sluoksnis, kurio filtro dydis yra 3×3 . Šiam sluoksniui naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija, dviejų dimensijų nulinis užpildas (angl. *2D zero padding*) su filtru, kurio dydis yra 1×1 . Vėliau buvo pridėdamas dar vienas sąsūkų sluoksnis su 3×3 filtro dydžiu. Prie gauto rezultato buvo pridėtas konvoliucinis sluoksnis su 3×3 filtro dydžiu bei poslinkiu 2×2 , tik atliktas po pirmojo „ReLU“ aktyvacijos funkcijos pridėjimo.

Naudotai ResNet-34 architektūrai galime atskirai apibrėžti tinklo pradžią ir pabaigą. Tinklo pradžios bloke naudotas partijos normalizavimas (angl. *batch normalization*) bei dviejų dimensijų nulinis užpildas (angl. *2D zero padding*), kurio filtro dydis yra 3×3 . Taip pat šiame bloke yra sąsūkų

sluoksnis, kurio filtro dydis yra 7×7 , filtrų skaičius yra 32, o šio sąsūkų sluoksnio poslinkis yra 2×2 . Sąsūkų sluoksniui naudotas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija, dviejų dimensijų nulinis užpildas (angl. *2D zero padding*) su filtru, kurio dydis yra 1×1 . Taip pat į tinklą įtrauktas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 3×3 . Tinklo pabaigos bloke buvo naudotas visuotinis vidurkinimo sutraukimas (angl. *global average pooling*) bei įtrauktas pilnai sujungtas (angl. *fully connected*) sluoksnis su dviem filtrais bei „softmax“ aktyvacijos funkcija.

Tinklo struktūra susideda tokiu būdu: pradinė įvestis yra apdorojama tinklo pradžios bloku, toliau seka sąsūkų blokas su 32 filtrais, o šio sąsūkų sluoksnio poslinkis yra 1×1 , bei tapatusis blokas su 32 filtrais. Toliau tinklą sudaro sąsūkų blokas su 64 filtrais bei 2×2 poslinkiu, trys tapatūs blokai su 64 filtrais, sąsūkų blokas su 128 filtrais bei 2×2 poslinkiu, 7 tapatūs blokai su 128 filtrais, sąsūkų blokas su 256 filtrais bei 2×2 poslinkiu ir 15 tapačių blokų su 256 filtrais. Galiausiai į tinklą buvo įtraukiamas partijos normalizavimas (angl. *batch normalization*), „ReLU“ aktyvacijos funkcija bei pridėtas tinklo pabaigos blokas.



21 pav. ResNet-34 tinklo architektūra

Šiam tinklui buvo taikyta penkių kartų kryžminė validacija. Tinklo apmokymui buvo naudotas partijos dydis (angl. *batch size*) lygus 32, tinklas turėjo po 150 epochų kiekvienoje kryžminės validacijos dalyje.

2.2.2. Intracerebrinių aneurizmų segmentavimas

Sprendžiant intracerebrinių aneurizmų segmentavimo užduotį buvo naudotos trys U-Net tinklo architektūros: U-Net-15, U-Net-27, U-Net-36, kur skaičius nusako sąsūkų sluoksnių kiekį tinkle. Šių tinklų įvestis yra dvimačiai smegenų sluoksnių vaizdai, o išvestis – dvimačiai segmentuoti smegenų sluoksnių vaizdai. Visų trijų naudotų architektūrų įvestis yra $304 \times 304 \times 1$ dydžio.

U-Net-15 sąsūkų neuroninio tinklo architektūroje galime išskirti du blokus: „conv2“ ir „up“ blokus. Blokas „conv2“ yra sudarytas iš dviejų sąsūkų sluoksnių, kurių filtro dydis yra 3×3 bei kuriems buvo naudota „ReLU“ aktyvacijos funkcija. „up“ bloke yra padidinimo (angl. *upsampling*) du kartus etapas bei vienas sąsūkų sluoksnis su 2×2 filtro dydžiu ir „ReLU“ aktyvacijos funkcija.

Pradinei duomenų įvesčiai buvo pritaikomas „conv2“ blokas su 64 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtraukiamas partijos normalizavimas (angl. *batch normalization*). Tuomet buvo pritaikytas „conv2“ blokas su 64 filtrais, atliktas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtrauktas partijos normalizavimas (angl. *batch normalization*). Paskui buvo įtraukiamas „conv2“ blokas su 128 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , įtraukiamas partijos normalizavimas (angl. *batch normalization*). Galiausiai pritaikytas dar vienas „conv2“ blokas su 256 filtrais, atliktas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , įtrauktas partijos normalizavimas (angl. *batch normalization*). Visa ši dalis yra vadinama užkodavimu (angl. *encoding*).

Po užkodavimo tinklo dalies buvo naudojama atkodavimo (angl. *decoding*) dalis. Joje naudotas „up“ blokas su 128 filtrais, įvestas sujungimo sluoksnis, „conv2“ blokas su 128 filtrais, partijos normalizavimas (angl. *batch normalization*). Paskui sekė „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv2“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*) bei vėl įvestas „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv2“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*).

Galiausiai tinkle buvo naudojamas sąsūkų sluoksnis, kurio filtro dydis yra 3×3 , filtrų skaičius yra 64, o aktyvacijos funkcija yra „ReLU“, bei dar vienas sąsūkų sluoksnis su vienu filtru, kurio dydis yra 1×1 . Šiam sluoksniui buvo naudojama „sigmoid“ aktyvacijos funkcija.

U-Net-15 tinklo architektūros schema yra pavaizduota 22 paveiksle.

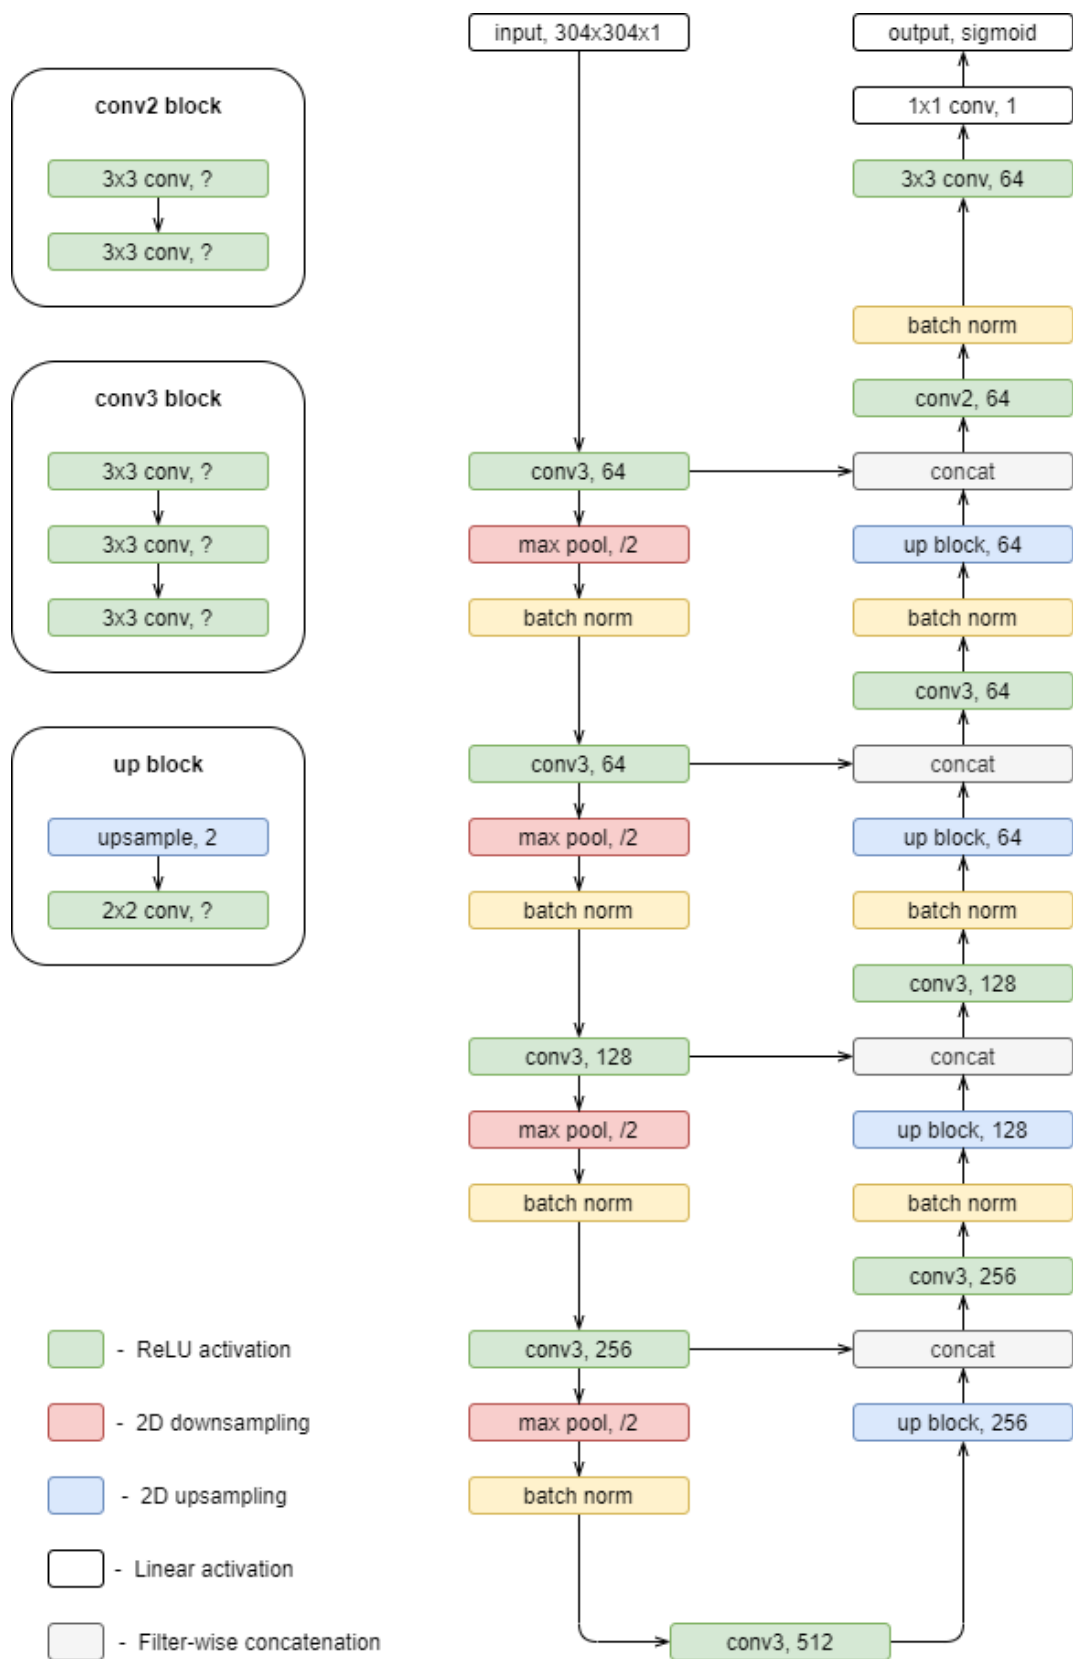
U-Net-27 sąsūkų neuroninio tinklo architektūroje galime išskirti tris blokus: „conv2“, „conv3“ ir „up“ blokus. Blokas „conv2“ yra sudarytas iš dviejų sąsūkų sluoksnių, kurių filtro dydis yra 3×3 bei jiems abiem yra naudota „ReLU“ aktyvacijos funkcija. Blokas „conv3“ yra sudarytas iš trijų sąsūkų sluoksnių su 3×3 filtro dydžiu ir „ReLU“ aktyvacijos funkcijos. Trečiajame „up“ bloke yra padidinimo (angl. *upsampling*) du kartus etapas bei vienas sąsūkų sluoksnis su 2×2 filtro dydžiu ir „ReLU“ aktyvacijos funkcija.

Pradinei duomenų įvesčiai buvo pritaikomas „conv3“ blokas su 64 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtraukiamas partijos normalizavimas (angl. *batch normalization*). Tuomet pritaikomas „conv3“ blokas su 64 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtraukiamas partijos normalizavimas (angl. *batch normalization*). Paskui įtrauktas „conv3“ blokas su 128 filtrais, atliktas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , įtrauktas partijos normalizavimas (angl. *batch normalization*) bei pritaikytas dar vienas „conv3“ blokas su 256 filtrais, atliktas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , ir įtrauktas partijos normalizavimas (angl. *batch normalization*). Galiausiai, buvo įtraukiamas „conv3“ blokas su 512 filtrais. Visa ši dalis yra vadinama užkodavimu (angl. *encoding*).

Po tinklo dalies užkodavimo yra naudojama atkodavimo (angl. *decoding*) dalis. Joje buvo naudojamas „up“ blokas su 256 filtrais, įvedamas sujungimo sluoksnis, „conv3“ blokas su 256 filtrais, partijos normalizavimas (angl. *batch normalization*). Vėliau į tinklą įtrauktas „up“ blokas su 128 filtrais, įvestas sujungimo sluoksnis, „conv3“ blokas su 128 filtrais, partijos normalizavimas (angl. *batch normalization*). Paskui sekė „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv3“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*) bei vėl įvestas „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv2“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*).

Galiausiai tinkle naudotas sąsūkų sluoksnis, kurio filtro dydis yra 3×3 , filtrų skaičius – 64, o aktyvacijos funkcija yra „ReLU“, bei dar vienas sąsūkų sluoksnis su vienu filtru, kurio dydis yra 1×1 . Šiam sluoksniui buvo naudojama „sigmoid“ aktyvacijos funkcija.

Šio tinklo architektūra yra pavaizduota 23 paveiksle.



23 pav. U-Net-27 tinklo architektūra

Tinklui U-Net-27 buvo taikyta penkių kartų kryžminė validacija. Tinklo apmokymui buvo naudotas partijos dydis (angl. *batch size*) lygus 16, tinklas turėjo po 200 epochų kiekviename kryžminės validacijos dalyje.

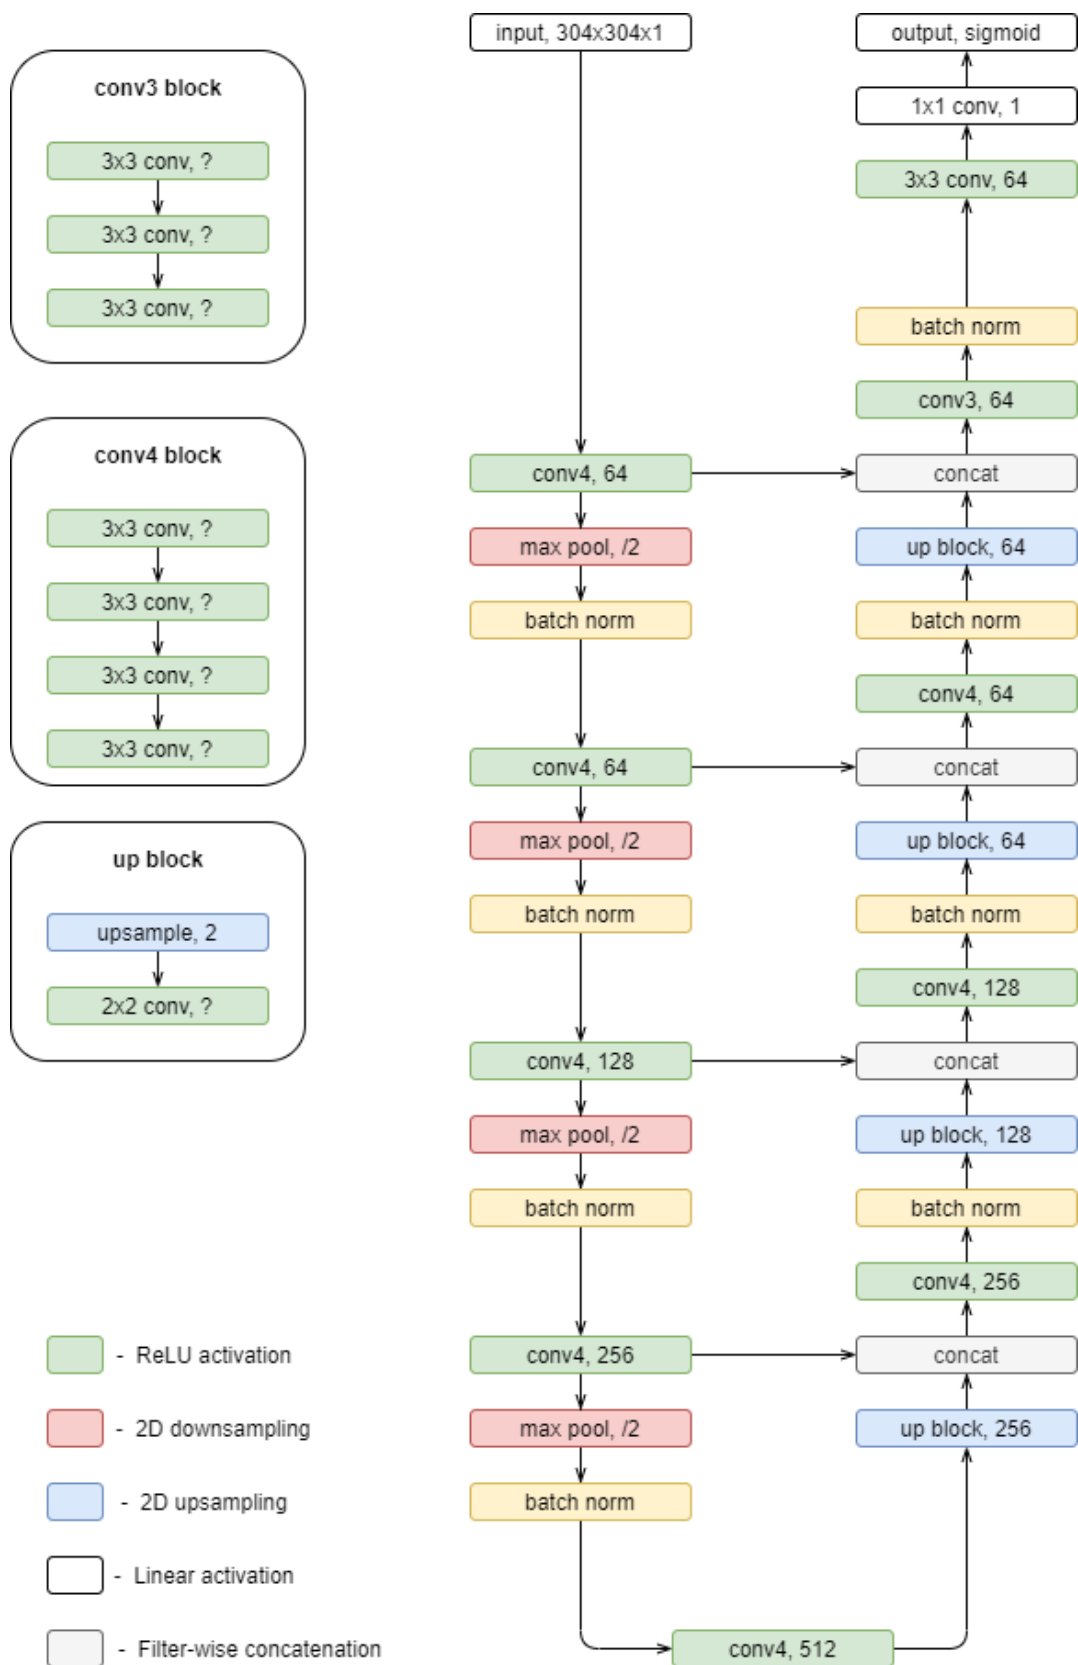
U-Net-36 sąsūkų neuroninio tinklo architektūroje galime išskirti tris blokus: „conv3“, „conv4“ ir „up“ blokus. Blokas „conv3“ yra sudarytas iš trijų sąsūkų sluoksnių, kurių filtro dydis yra 3×3 bei visiems jiems yra naudota „ReLU“ aktyvacijos funkcija. Blokas „conv4“ yra sudarytas iš keturių sąsūkų sluoksnių su 3×3 filtro dydžiu ir „ReLU“ aktyvacijos funkcijos. Trečiajame „up“ bloke yra padidinimo (angl. *upsampling*) du kartus etapas bei vienas sąsūkų sluoksnis su 2×2 filtro dydžiu ir „ReLU“ aktyvacijos funkcija.

Pradinei duomenų įvesčiai yra pritaikomas „conv4“ blokas su 64 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtraukiamas partijos normalizavimas (angl. *batch normalization*). Tuomet pritaikomas „conv4“ blokas su 64 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , bei įtraukiamas partijos normalizavimas (angl. *batch normalization*). Paskui įtraukiamas „conv4“ blokas su 128 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , įtraukiamas partijos normalizavimas (angl. *batch normalization*) bei pritaikomas dar vienas „conv4“ blokas su 256 filtrais, atliekamas dviejų dimensijų didžiausios reikšmės sutraukimas (angl. *2D max pooling*), kur filtro dydis yra 2×2 , ir įtraukiamas partijos normalizavimas (angl. *batch normalization*). Galiausiai įtraukiamas „conv4“ blokas su 512 filtrais. Visa ši dalis yra vadinama užkodavimu (angl. *encoding*).

Po užkodavimo tinklo dalies buvo naudojama atkodavimo (angl. *decoding*) dalis. Joje yra naudojamas „up“ blokas su 256 filtrais, įvedamas sujungimo sluoksnis, „conv4“ blokas su 256 filtrais, partijos normalizavimas (angl. *batch normalization*). Vėliau į tinklą įtraukiamas „up“ blokas su 128 filtrais, įvedamas sujungimo sluoksnis, „conv4“ blokas su 128 filtrais, partijos normalizavimas (angl. *batch normalization*). Paskui seka „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv4“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*) bei vėl įvedamas „up“ blokas su 64 filtrais, sujungimo sluoksnis, „conv3“ blokas su 64 filtrais, partijos normalizavimas (angl. *batch normalization*).

Galiausiai tinkle buvo naudojamas sąsūkų sluoksnis, kurio filtro dydis yra 3×3 , filtrų skaičius – 64, o aktyvacijos funkcija yra „ReLU“, bei dar vienas sąsūkų sluoksnis su vienu filtru, kurio dydis yra 1×1 . Šiam sluoksniui buvo naudojama „sigmoid“ aktyvacijos funkcija.

U-Net-36 tinklo architektūros schema yra pavaizduota 24 paveiksle.



24 pav. U-Net-36 tinklo architektūra

U-Net-36 tinklui, taip pat kaip ir kitoms dviems U-Net architektūroms, buvo taikyta penkių kartų kryžminė validacija. Tinklo apmokymui buvo naudotas partijos dydis (angl. *batch size*) lygus 16, o tinklas turėjo po 200 epochų kiekvienoje kryžminės validacijos dalyje.

2.3. Tikslumo metrikos

Klasifikavimo užduoties tikslumui įvertinti buvo naudojama tikslumo (angl. *accuracy*) metrika bei ploto po „ROC“ kreivės reikšmė – AUC metrika.

Tikslumo reikšmė (*acc*) buvo skaičiuojama iš sumaišymo matricos (angl. *confusion matrix*) (žr. 3 lentelėje).

3 lentelė. Sumaišymo matrica

		Prognozuojamos klasės	
		+	-
Tikrosios klasės	+	TP	FN
	-	FP	TN

TP – pozityvių atvejų, kurie suklasifikuojami kaip pozityvūs, skaičius;

FP – negatyvių atvejų, kurie suklasifikuojami kaip pozityvūs, skaičius;

FN – pozityvių atvejų, kurie suklasifikuojami kaip negatyvūs, skaičius;

TN – negatyvių atvejų, kurie suklasifikuojami kaip negatyvūs, skaičius [40].

Tikslumo metrika nusako teisingai prognozuotų atvejų procentinę dalį ir yra skaičiuojama pagal formulę:

$$acc = \frac{TN+TP}{TN+TP+FN+FP} \quad (1)$$


Jautrumo metrika (angl. *sensitivity*) parodo, kokia yra teisingai prognozuota ieškomos klasės dalis. Jautrumo metrika yra apskaičiuojama tokiu būdu:

$$sensitivity = \frac{TP}{TP+FN} \quad (2)$$

Specifiškumo metrika (angl. *specificity*) parodo, kiek yra teisingai prognozuotų neigiamos klasės objektų, o apskaičiuojama pagal formulę:

$$specificity = \frac{TN}{TN+FP} \quad (3)$$

ROC kreivė yra grafinis santykio tarp jautrumo ir specifiškumo pateikimas, padedantis rasti optimalų modelį. Ši kreivė parodo, ar klasifikacija yra gera, ar ne. Tobulos klasifikacijos atveju, diagnostinio testo jautrumas ir specifiškumas yra lygus 100 %, tuomet ROC kreivė eina per tašką (0, 1). ROC kreivė pateikta 25 paveiksle [41].



25 pav. ROC kreivė

AUC metrika nusako plotą po ROC kreive, t. y. AUC matuoja visą dvimatį plotą po ROC kreive. Metrikos reikšmė apskaičiuojama pagal formulę:

$$AUC = \int_0^1 ROC(t)dt \quad (4)$$

Visos gautos AUC reikšmės būna intervale tarp 0 ir 1. Tyrimo tikslumo klasifikacija pagal AUC reikšmes yra pateikta 4 lentelėje [41].

4 lentelė. Tyrimo tikslumo klasifikacija pagal AUC reikšmes


AUC reikšmė	Klasifikavimo tikslumas
$0,9 \leq AUC < 1,0$	Puikus
$0,8 \leq AUC < 0,9$	Geras
$0,7 \leq AUC < 0,8$	Vidutiniškas
$AUC < 0,7$	Blogas

Segmentavimo tikslumui nustatyti darbe buvo naudotos AUC reikšmės bei IoU metrika.

IoU metrika – tai metrika nusakanti aibių sankirtos ir sąjungos santykį. Ši metrika yra naudojama būtent segmentavimo tikslumui apskaičiuoti ir yra gaunama iš originalaus segmentuoto vaizdo ir segmentavimo prognozės sankirtos ir sąjungos santykio. IoU metrikos reikšmė apskaičiuojama pagal formulę:

$$IoU = \frac{\text{aibių sankirta}}{\text{aibių sąjunga}} \quad (5)$$

Vizualiai šią metriką galima pavaizduoti tokiu būdu [42]:

$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


26 pav. IoU metrikos apskaičiavimo formulė


3. Tyrimų rezultatai ir jų aptarimas

3.1. Intracerebrinių aneurizmų klasifikavimas


Intracerebrinių aneurizmų klasifikavimui buvo sudarytos bei naudotos dvi sąsūkų neuroninių tinklų architektūros: klasikinis CNN bei daug didesnė architektūra – ResNet-34. Su abiem šiais tinklais buvo naudota 5 dalių kryžminė validacija, skaičiuotos kiekvienos dalies tikslumo metrikos: validavimo tikslumas, testavimo tikslumas ir AUC reikšmės bei apskaičiuotos vidutinės šių tikslumo metrikų reikšmės visoms dalims bendrai. Taip pat kiekvienai kryžminės validacijos daliai buvo pavaizduota ROC kreivė.

Klasikinis sąsūkų neuroninis tinklas buvo apmokytas naudojantis apmokymo duomenų imtimi. Po to buvo atliktas jo validavimas su validavimo duomenų imtimi bei testavimas, naudojant testavimo duomenų imtį. Testavimo duomenų imtis sudarė 20 % visų duomenų (3 778 vaizdai), apmokymo – 68 % (12 845 vaizdai), o validavimo – 12 % (2 266 vaizdai).


27-31 paveiksluose yra pavaizduotos ROC kreivės kiekvienai kryžminės validacijos daliai. Matome, jog gauti rezultatai kiekvienai daliai yra pakankamai panašūs. Visgi, iš ROC kreivės 4 ir 5 kryžminės validacijos dalims galime matyti, jog prognozė yra tiksliausia, o 2 ir 3 dalims – prasčiausia.




27 pav. Klasikinio CNN 1 dalies kryžminės validacijos ROC kreivė




29 pav. Klasikinio CNN 3 dalies kryžminės validacijos ROC kreivė



28 pav. Klasikinio CNN 2 dalies kryžminės validacijos ROC kreivė



30 pav. Klasikinio CNN 4 dalies kryžminės validacijos ROC kreivė



31 pav. Klasikinio CNN 5 dalies kryžminės validacijos ROC kreivė


Visi gautieji klasikinio CNN tinklo rezultatai yra pateikti 5 lentelėje.

5 lentelė. Klasikinio CNN tinklo rezultatai


	Kryžminės validacijos dalis					Vidurkis	Standartinis nuokrypis
	1	2	3	4	5		
Validavimo tikslumas	0,9824	0,9710	0,9761	0,9595	0,9655	0,9824	0,0079
Testavimo tikslumas	0,7229	0,7084	0,6908	0,8003	0,8472	0,7539	0,0598
AUC reikšmė	0,8059	0,8176	0,7836	0,8999	0,9364	0,8487	0,0589

Kaip galime matyti, validavimo tikslumas yra labai panašus visoms kryžminės validacijos dalims – standartinis nuokrypis yra 0,0079. Vidutinė validavimo tikslumo reikšmė yra 0,9824. Testavimo tikslumas yra ženkliai mažesnis nei validavimo tikslumas – testavimo tikslumo vidurkis yra 0,7539. Taip pat šios metrikos standartinis nuokrypis yra 0,0598, todėl galime pastebėti, jog skirtingoms kryžminio validavimo dalims gaunami skirtingi prognozavimo rezultatai. Didžiausia AUC reikšmė yra 5 kryžminės validacijos dalies – 0,9364, o mažiausia – 3 dalies, t. y. 0,7836. Vidutinė AUC reikšmė yra 0,8487, todėl galime teigti, jog klasikinis sąsūkų neuroninis tinklas gerai klasifikuoja mūsų turimą intracerebrinių aneurizmų vaizdų imtį.


Klasifikavimo problemai spręsti naudojome ir didesnę tinklą – ResNet-34. Šio tinklo rezultatai pateikti 32-36 paveiksluose bei 6 lentelėje. Iš paveikslų matome, kad ROC kreivės reikšmės yra blogiausios su trečia kryžminio validavimo dalimi, o geriausios – su penkta kryžminio validavimo dalimi.




32 pav. ResNet-34 1 dalies kryžminės validacijos ROC kreivė




35 pav. ResNet-34 4 dalies kryžminės validacijos ROC kreivė



33 pav. ResNet-34 2 dalies kryžminės validacijos ROC kreivė



36 pav. ResNet-34 5 dalies kryžminės validacijos ROC kreivė



34 pav. ResNet-34 3 dalies kryžminės validacijos ROC kreivė

ResNet-34 tinklo rezultatai yra pateikti 6 lentelėje. Kaip galime matyti, validavimo tikslumas, taip pat kaip ir su klasikiniu CNN, yra labai panašus visoms kryžminės validacijos dalims – standartinis nuokrypis yra 0,0039. Vidutinė validavimo tikslumo reikšmė yra 0,9824. Testavimo tikslumo vidurkis yra 0,7249, o standartinis nuokrypis – 0,0751. Didžiausia AUC reikšmė yra 5 kryžminės validacijos dalies – 0,9106, o mažiausia – 3 dalies, t. y. 0,7074. Vidutinė AUC reikšmė yra 0,8076, todėl galime teigti, jog ResNet-34 tinklas taip pat pakankamai gerai klasifikuoja mūsų turimą duomenų imtį.

6 lentelė. ResNet-34 tinklo rezultatai

	Kryžminės validacijos dalis					Vidurkis	Standartinis nuokrypis
	1	2	3	4	5		
Validavimo tikslumas	0,9881	0,9759	0,9810	0,9836	0,9832	0,9824	0,0039
Testavimo tikslumas	0,7001	0,6734	0,6343	0,7713	0,8454	0,7249	0,0751
AUC reikšmė	0,7965	0,7802	0,7074	0,8433	0,9106	0,8076	0,0675

Klasifikavimo metodų rezultatų palyginimas yra pateiktas 7 lentelėje. Galime matyti, jog klasikinis CNN tinklas tiksliau prognozuoja, ar vaizde yra intracerebrinė aneurizma: tiek vidutinė AUC reikšmė, tiek vidutinis testavimo tikslumas yra didesni nei naudojant ResNet-34 tinklą (klasikinio CNN: $acc_{test} = 0,7539$, $AUC = 0,8487$, ResNet-34: $acc_{test} = 0,7249$, $AUC = 0,8076$). Abiejų sąsūkų neuroninių tinklų vidutinis validavimo tikslumas yra vienodas – 0,9824.

7 lentelė. Klasifikavimo metodų rezultatų palyginimas


Tinklo architektūra	Tikslumo metrika		
	Vidutinis validavimo tikslumas	Vidutinis testavimo tikslumas	Vidutinė AUC reikšmė
Klasikinis CNN	0,9824	0,7539	0,8487
ResNet-34	0,9824	0,7249	0,8076

Taigi, atsižvelgiant į aukščiau aprašytus rezultatus, galime daryti išvadą, jog klasikinis sąsūkų neuroninis tinklas geriau klasifikuoja vaizdus su aneurizmomis.

3.2. Intracerebrinių aneurizmų segmentavimas


Kita darbe nagrinėta užduotis yra intracerebrinių aneurizmų segmentavimas. Šiai problemai spręsti buvo naudotos trys skirtingos U-Net architektūros: U-Net-15, U-Net-27, U-Net-36. Visoms šioms architektūroms apmokyti buvo naudota apmokymo duomenų imtis, o validavimui – validavimo imtis. Testavimo imtis šiuo atveju naudota nebuvo. Apmokymo duomenų imtį sudarė 80 % visų duomenų (1 040 vaizdų), o validavimo – 20 % (260 vaizdų). Segmentavimo užduotyje buvo naudoti tik tie smegenų sluoksnių vaizdai, kuriuose yra matomos aneurizmos, todėl duomenų imtis yra 14 kartų mažesnė.

37-56 paveiksluose bei 8 lentelėje yra pateikti U-Net-15 tinklo rezultatai. Pirmuose penkiuose paveiksluose (37-41 pav.) pavaizduotos apmokymo (mėlyna linija) bei validavimo imties (raudona linija) nuostolių funkcijos. Galime matyti, jog, apmokymo nuostolių funkcijos reikšmės po truputį mažėja visas 200 epochų bei yra labai panašios su visomis penkiomis kryžminės validacijos dalimis, o validavimo nuostolių funkcijos gan greitai nusistovi ir beveik nebekinta.




37 pav. U-Net-15 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos


linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




40 pav. U-Net-15 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos



38 pav. U-Net-15 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




41 pav. U-Net-15 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




39 pav. U-Net-15 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos


42-46 paveiksluose yra pateiktas vidutinės IoU reikšmės kitimas per epochas. Mėlyna linija žymi apmokymo IoU reikšmes, o raudona – validacijos. Grafikuose galime matyti, jog pirmų keturių kryžminės validacijos dalių IoU reikšmės, kintant epochų skaičiui, stipriai varijuoja, o penktosios kryžminės validacijos dalies IoU reikšmės, kintant epochų skaičiui, nelabai keičiasi ir yra labai mažos – tik apie 0,5.




42 pav. U-Net-15 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




45 pav. U-Net-15 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos



43 pav. U-Net-15 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




46 pav. U-Net-15 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




44 pav. U-Net-15 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos

47-51 paveiksluose yra pateiktos U-Net-15 tinklo ROC kreivės. Galime matyti labai panašius rezultatus kaip ir su kitais dviem tinklais: su pirmomis keturiomis kryžminės validacijos dalimis aneurizmos yra segmentuojamos pakankamai gerai, o penktoje dalyje modelio prognozė yra


priešinga, todėl dėl šios priežasties skaičiuojant AUC reikšmę ją pakoreguosime turimą AUC reikšmę atimant iš 1.




47 pav. U-Net-15 1 dalies kryžminės validacijos ROC kreivė




50 pav. U-Net-15 4 dalies kryžminės validacijos ROC kreivė



48 pav. U-Net-15 2 dalies kryžminės validacijos ROC kreivė




51 pav. U-Net-15 5 dalies kryžminės validacijos ROC kreivė




49 pav. U-Net-15 3 dalies kryžminės validacijos ROC kreivė

Žemiau pateiktame paveiksle yra pavaizduotos IoU reikšmės kiekvienai kryžminės validacijos daliai. Mėlyna linija pažymėtos apmokymo IoU reikšmės, o raudona – validacijos. Galime matyti, jog validavimo IoU reikšmės yra gerokai mažesnės nei apmokymo IoU reikšmės.



52 pav. U-Net-15 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos

53 paveiksle mėlyna linija žymi pakoreguotas AUC reikšmes su skirtingomis kryžminės validacijos dalimis, o raudoni taškai – pradinės reikšmės. Matome, jog modifikavus paskutinės kryžminės validacijos dalies AUC reikšmę, visų dalių AUC reikšmės tapo ganėtinai panašios.




53 pav. U-Net-15 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės

Žemiau esančioje lentelėje yra pateikti visi U-Net-15 tinklo rezultatai. Kaip galime matyti, apmokymo IoU standartinis nuokrypis yra 0,0068, o vidurkis – 0,9606. Validavimo IoU vidurkis yra 0,7169, o standartinis nuokrypis yra 0,1032. Didžiausia AUC reikšmė yra 3 kryžminės validacijos dalies – 0,8297, o mažiausia – pirmos dalies, t. y. 0,6806. Vidutinė AUC reikšmė yra 0,7515, todėl pagal gautas metrikas galime teigti, jog U-Net-15 tinklas vidutiniškai gerai segmentuoja mūsų turimą duomenų imtį.


8 lentelė. U-Net-15 rezultatai

	Kryžminės validacijos dalis					Vidurkis	Standartinis nuokrypis
	1	2	3	4	5		
Apmokymo IoU	0,9643	0,9574	0,9606	0,9501	0,9706	0,9606	0,0068
Validavimo IoU	0,7769	0,7564	0,8056	0,7292	0,5167	0,7169	0,1032
AUC reikmė	0,6806	0,7029	0,8297	0,7293	0,8151	0,7515	0,0601


Žemiau esančiuose 54-56 paveiksluose yra pateikti U-Net-15 tinklo segmentuoti aneurizmų vaizdai. Viršutiniame kairiajame paveiksle matomas pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas. 54 paveiksle matome, jog tinklas aptiko aneurizmą, bet segmentavo ją didesnę nei išties yra. Kitame paveiksle (žr. 55 pav.) matome, jog aneurizma taip pat rasta, bet tinklo segmentuotame vaizde ji yra žymiai mažesnė nei originale. Paskutiniame paveiksle (žr. 56 pav.) pavaizduota, jog tinklui aneurizmos nepavyko aptikti.



54 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas




55 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas



56 pav. U-Net-15 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-15 tinklu segmentuotas vaizdas


57-76 paveiksluose bei 9 lentelėje yra pateikti U-Net-27 tinklo rezultatai. Pirmuose penkiuose paveiksluose (57-61 pav.) yra pavaizduotos apmokymo (mėlyna linija) bei validavimo imties (raudona linija) nuostolių funkcijos. Galime matyti, jog apmokymo nuostolių funkcijos reikšmės po truputį mažėja visas 200 epochų bei yra labai panašios su visomis 5 kryžminės validacijos dalimis, o validavimo nuostolių funkcijos reikšmės mažėja ne su visomis kryžminės validacijos duomenų

dalimis. Iš 1 ir 5 dalių paveikslų galime matyti, jog nuostolių funkcijos reikšmės nelabai mažėja per epochas, o su 3 dalies duomenimis yra matomas sparčiausias nuostolių funkcijos reikšmių mažėjimas.




57 pav. U-Net-27 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos


linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




60 pav. U-Net-27 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos



58 pav. U-Net-27 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




61 pav. U-Net-27 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




59 pav. U-Net-27 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos


62-66 paveiksluose yra pateiktas vidutinės IoU reikšmės kitimas per epochas. Mėlyna linija žymi apmokymo IoU reikšmes, o raudona – validacijos. Grafikuose galime matyti, jog pirmų keturių kryžminės validacijos dalių IoU reikšmės yra virš 0,7, o penktosios kryžminės validacijos dalies IoU reikšmės yra labai mažos – tik apie 0,5.




62 pav. U-Net-27 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




65 pav. U-Net-27 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos



63 pav. U-Net-27 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




66 pav. U-Net-27 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




64 pav. U-Net-27 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos


67-71 paveiksluose yra pateiktos U-Net-27 tinklo ROC kreivės. Galime matyti, jog su pirmomis keturiomis kryžminės validacijos dalimis aneurizmos yra segmentuojamos pakankamai gerai, o penktoje dalyje modelio prognozė yra priešinga – dėl šios priežasties, skaičiuojant AUC reikšmę, ją pakoreguosime, turimą AUC reikšmę atimdami iš 1.




67 pav. U-Net-27 1 dalies kryžminės validacijos ROC kreivė




70 pav. U-Net-27 4 dalies kryžminės validacijos ROC kreivė



68 pav. U-Net-27 2 dalies kryžminės validacijos ROC kreivė




71 pav. U-Net-27 5 dalies kryžminės validacijos ROC kreivė



69 pav. U-Net-27 3 dalies kryžminės validacijos ROC kreivė


Žemiau pateiktame paveiksle yra pavaizduotos IoU reikšmės kiekvienai kryžminės validacijos daliai. Mėlyna linija pažymėtos apmokymo IoU reikšmės, o raudona – validacijos. Galime matyti, jog

5 kryžminės validacijos dalies apmokymo IoU reikšmė yra didžiausia, o validavimo – mažiausia. Validavimo imties IoU didžiausias yra su pirma kryžminės validacijos dalimi.



72 pav. U-Net-27 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos

73 paveiksle mėlyna linija žymi pakoreguotas AUC reikšmes su skirtingomis kryžminės validacijos dalimis, o raudoni taškai – pradinės reikšmės. Kaip matome, po paskutinės kryžminės validacijos dalies AUC reikšmės modifikavimo, visų dalių AUC reikšmės tapo ganėtinai panašios.




73 pav. U-Net-27 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės

Žemiau esančioje lentelėje yra pateikti visi U-Net-27 tinklo rezultatai. Kaip galime matyti, apmokymas IoU yra labai panašus visoms kryžminės validacijos dalims – standartinis nuokrypis yra 0,0077. Vidutinė apmokymo IoU reikšmė yra 0,9420. Validavimo IoU vidurkis yra 0,7262, o standartinis nuokrypis yra 0,1159. Didžiausia AUC reikšmė yra 3 kryžminės validacijos dalies – 0,8338, o mažiausia – antros dalies, t. y. 0,6627. Vidutinė AUC reikšmė yra 0,7734, todėl pagal gautas metrikas galime teigti, jog U-Net-27 tinklas taip pat vidutiniškai tiksliai segmentuoja mūsų turimą duomenų imtį.


9 lentelė. U-Net-27 rezultatai

	Kryžminės validacijos dalis					Vidurkis	Standartinis nuokrypis
	1	2	3	4	5		
Apmokymo IoU	0,9479	0,9390	0,9323	0,9371	0,9537	0,9420	0,0077
Validavimo IoU	0,8435	0,7538	0,7837	0,7451	0,5050	0,7262	0,1159
AUC reikmė	0,8045	0,6627	0,8338	0,762	0,8041	0,7734	0,0599


Žemiau esančiuose 74-76 paveikluose pateikėme U-Net-27 tinklo segmentuotus aneurizmų vaizdus. Viršutiniame kairiajame paveiksle matomas pradinis smegenų sluoksniu vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, o apatiniame vaizde – U-Net-27 tinklu segmentuotas vaizdas. 74 paveiksle matome gana tikslią segmentavimo prognozę – tinklo segmentuota aneurizma yra toje pačioje vietoje kaip ir originaliame segmentuotame vaizde, jų dydis taip pat yra panašus. Kitame paveiksle (žr. 75 pav.) matome, jog aneurizma rasta, bet tinklo segmentuotame vaizde ji yra žymiai didesnė nei originale. Paskutiniame paveiksle (žr. 76 pav.) pavaizduota, jog tinklui aneurizmos nepavyko aptikti.



74 pav. U-Net-27 tinklu gauti rezultatai Nr. 1: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksniu vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas




75 pav. U-Net-27 tinklu gauti rezultatai Nr. 2: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame kampe – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas



76 pav. U-Net-27 tinklu gauti rezultatai Nr. 3: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksnio vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-27 tinklu segmentuotas vaizdas


77-94 paveiksluose bei 10 lentelėje yra pateikti U-Net-36 tinklo rezultatai. Pirmuose penkiuose paveiksluose (77-81 pav.) yra pavaizduotos apmokymo (mėlyna linija) bei validavimo imties (raudona linija) nuostolių funkcijos. Galime matyti, jog, kaip ir U-Net-15 bei U-Net-27 tinkle, apmokymo nuostolių funkcijos reikšmės po truputį mažėja visas 200 epochų bei yra labai panašios su visomis penkiomis kryžminės validacijos dalimis, kai validavimo nuostolių funkcijos reikšmės

mažėja ne su visomis kryžminės validacijos duomenų dalimis. Iš 5 dalies paveikslo galime matyti, jog kaip ir su prieš tai aprašytais tinklais, nuostolių funkcijos reikšmės beveik nemažėja, o su trečios dalies duomenimis yra matomas sparčiausias nuostolių funkcijos reikšmių mažėjimas.




77 pav. U-Net-36 tinklo 1 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos


linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




80 pav. U-Net-36 tinklo 4 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos



78 pav. U-Net-36 tinklo 2 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




81 pav. U-Net-36 tinklo 5 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna linija – apmokymo nuostolių funkcijos reikšmės, raudona – validacijos




79 pav. U-Net-36 tinklo 3 dalies kryžminės validacijos nuostolių funkcijos reikšmės. Mėlyna


82-86 paveiksluose yra pateiktas vidutinės IoU reikšmės kitimas per epochas. Mėlyna linija žymi apmokymo IoU reikšmes, o raudona – validacijos. Grafikuose galime matyti, jog pirmų keturių kryžminės validacijos dalių IoU reikšmės, kintant epochų skaičiui, stipriai varijuoja, o penktosios kryžminės validacijos dalies IoU reikšmės yra labai mažos – tik apie 0,5 ir kintant epochų skaičiui nelabai keičiasi.




82 pav. U-Net-36 tinklo 1 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




85 pav. U-Net-36 tinklo 4 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos



83 pav. U-Net-36 tinklo 2 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




86 pav. U-Net-36 tinklo 5 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos




84 pav. U-Net-36 tinklo 3 dalies kryžminės validacijos IoU reikšmės. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos


87-91 paveiksluose yra pateiktos U-Net-36 tinklo ROC kreivės. Galime matyti, jog su pirmomis keturiomis kryžminės validacijos dalimis aneurizmos yra segmentuojamos pakankamai gerai, o penktoje dalyje modelio prognozė yra priešinga, kaip ir su pirmais dviem U-Net tinklais, – dėl šios priežasties skaičiuojant AUC reikšmę ją pakoreguosime turimą AUC reikšmę atimdami iš 1.




87 pav. U-Net-36 1 dalies kryžminės validacijos ROC kreivė




90 pav. U-Net-36 4 dalies kryžminės validacijos ROC kreivė



88 pav. U-Net-36 2 dalies kryžminės validacijos ROC kreivė




91 pav. U-Net-36 5 dalies kryžminės validacijos ROC kreivė




89 pav. U-Net-36 3 dalies kryžminės validacijos ROC kreivė

Žemiau pateiktame paveiksle yra pavaizduotos IoU reikšmės kiekvienai kryžminės validacijos daliai. Mėlyna linija pažymėtos apmokymo IoU reikšmės, o raudona – validacijos. Kaip ir iš aukščiau aprašytų IoU reikšmių grafikų, galime matyti, jog 5 kryžminės validacijos dalies apmokymo IoU reikšmė yra didžiausia, o validavimo – mažiausia. Validavimo imties IoU didžiausias yra su 3 kryžminės validacijos dalimi.



92 pav. U-Net-36 tinklo IoU reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – apmokymo IoU reikšmės, raudona – validacijos

93 paveiksle mėlyna linija žymi pakoreguotas AUC reikšmes su skirtingomis kryžminės validacijos dalimis, o raudoni taškai – pradinės reikšmės. Modifikavus paskutinės kryžminės validacijos dalies AUC reikšmę, visų dalių AUC reikšmės tapo ganėtinai panašios.




93 pav. U-Net-36 tinklo AUC reikšmės visoms kryžminės validacijos dalims. Mėlyna linija – modifikuotos AUC reikšmės, raudoni taškai – pradinės AUC reikšmės

Žemiau esančioje lentelėje yra pateikti visi U-Net-36 tinklo rezultatai. Kaip galime matyti, apmokymo IoU standartinis nuokrypis yra 0,0191, o vidurkis – 0,9233. Validavimo IoU vidurkis yra 0,7596, o standartinis nuokrypis – 0,1250. Didžiausia AUC reikšmė yra 3 kryžminės validacijos dalies – 0,9249, o mažiausia – antros dalies, t. y. 0,7364. Vidutinė AUC reikšmė yra 0,8350, todėl pagal gautas metrikas galime teigti, jog U-Net-36 tinklas gerai segmentuoja mūsų turimą duomenų imtį.

10 lentelė. U-Net-36 rezultatai

	Kryžminės validacijos dalis					Vidurkis	Standartinis nuokrypis
	1	2	3	4	5		
Apmokymo IoU	0,9364	0,9217	0,8882	0,9269	0,9433	0,9233	0,0191
Validavimo IoU	0,8468	0,7715	0,8755	0,7820	0,5220	0,7596	0,1250
AUC reikmė	0,8751	0,7364	0,9249	0,8350	0,8038	0,8350	0,0639

Žemiau esančiame 94 paveiksle pateikti U-Net-36 tinklo segmentuotus aneurizmų vaizdai. Viršutiniame kairiajame paveiksle matomas pradinis smegenų sluoksniu vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-36 tinklu segmentuotas vaizdas. Paveiksle matome, jog tinklas aneurizmą aptiko, bet, kaip ir su U-Net-27 tinklu, segmentuotame vaizde ji yra žymiai didesnė nei originale.



94 pav. U-Net-36 tinklu gauti rezultatai: paveikslas viršutiniame kairiajame kampe – pradinis smegenų sluoksniu vaizdas, viršutiniame dešiniajame – pradinis ekspertiniu būdu segmentuotas vaizdas, apatinis paveikslas – U-Net-36 tinklu segmentuotas vaizdas

Segmentavimo metodų rezultatų palyginimas yra pateiktas 11 lentelėje. Galime matyti, jog U-Net-36 tinklas tiksliausiai segmentuoja vaizdus su aneurizmomis, šio tinklo tiek vidutinė validavimo IoU reikšmė ($IoU_{val} = 0,7596$), tiek vidutinė AUC reikšmė ($AUC = 0,8350$) yra didžiausios. Segmentavimą blogiausiai atlieka U-Net-15 tinklas ($IoU_{val} = 0,7169$, $AUC = 0,7515$).

11 lentelė. Segmentavimo metodų rezultatų palyginimas

Tinklo architektūra	Tikslumo metrika		
	Vidutinė apmokymo IoU reikšmė	Vidutinė validavimo IoU reikšmė	Vidutinė AUC reikšmė
U-Net-15	0,9606	0,7169	0,7515
U-Net-27	0,9420	0,7262	0,7734
U-Net-36	0,9233	0,7596	0,8350

Geriausiai vaizdus segmentuoja tinklas, turintis daugiausiai sluoksnių – U-Net-36 tinklas, o prasčiausiai – mažiausias tinklas, t. y. U-Net-15. Atitinkamai, galime daryti išvadą, kad intracerebrinių aneurizmų segmentavimui naudojant nedidelį duomenų rinkinį yra reikalingas didžiulis U-Net tinklas.

Norint pagerinti gautus intracerebrinių aneurizmų aptikimo ir segmentavimo rezultatus, vertėtų išplėsti duomenų imtį. Visgi, kadangi aneurizmos yra mažos, o jų segmentavimas ekspertiniu būdu reikalauja daug atidumo, duomenų imties didinimas yra nelengva užduotis, reikalaujanti laiko kaštų bei papildomų išlaidų, t. y. reikia samdyti neurologus, atliksiančius vaizdų segmentavimą. Taip pat, išplėtus duomenų imtį, vertėtų aptikimo ir segmentavimo problemai spręsti naudoti trimačius sąsūkų neuroninius tinklus, nes naudojant 3D CNN būtų atsižvelgiama į sąryšius tarp pikselių gretimame tūrio sluoksnyje.

Išvados

- Magnetinio rezonanso angiografijos tyrimo metu gautiems galvos tūrio vaizdams klasifikuoti darbe buvo naudotas klasikinis (5 sąsūkų sluoksnių) sąsūkų neuroninis tinklas bei ResNet-34 tinklas. Išanalizavus rezultatus nustatyta, jog klasikinis sąsūkų neuroninis tinklas geriau atpažįsta, ar galvos smegenų skenavimo sluoksnyje yra aneurizma, ar jos nėra: klasikinio sąsūkų neuroninio tinklo: $acc_{test} = 0,7539$, $AUC = 0,8487$, kai ResNet-34: $acc_{test} = 0,7249$, $AUC = 0,8076$.
- Magnetinio rezonanso angiografijos tyrimo metu gautiems galvos tūrio vaizdams segmentuoti darbe buvo naudoti trys skirtingo dydžio U-Net tinklai: U-Net-15, U-Net-27, U-Net-36. Atlikus rezultatų analizę pastebėta, jog geriausiai vaizdus su intracerebrinėmis aneurizmomis segmentuoja U-Net-36 sąsūkų neuroninis tinklas. Atlikus penkių dalių kryžminę validaciją, šio tinklo gautos validavimo tikslumo reikšmės: vidutinė IoU reikšmė $IoU_{val} = 0,7596$, o vidutinė AUC reikšmė $AUC = 0,8350$.
- Segmentavimo problemos sprendimo rezultatai atskleidė, jog naudojantis aprašytais U-Net architektūromis, tinklai dažniausiai aneurizmas aptikdavo, bet segmentuodavo jas didesnio ploto nei iš tiesų pati aneurizma yra. Išanalizavus klasifikavimo problemos rezultatus, galime pastebėti, jog nepriklausomai nuo tinklo architektūros kompleksškumo, geresnių rezultatų pasiekti nepavyko, todėl galima daryti išvadą, kad reikėtų plėsti duomenų imtį bei įvesti papildomų duomenų apdorojimo žingsnių.

Literatūros sąrašas

1. KONCZALLA J., P. SCHUSS, J. PLATZ, H. VATTER, V. SEIFER ir E. GURESIR. Clinical outcomes and prognosis factors of patients with angiogram–negative and non–perimesencephalic subarachnoid hemorrhage: benign prognosis like perimesencephalic SAH or same risk as aneurysmal SAH. *Neurosurg Rev* [interaktyvus]. 2014, 38(1): 121-7. [žiūrėta 2021-03-04] Pieiga per: <http://tinyurl.com/osfnmbe>
2. RAHMAN M., J. SMIETANA, E. HAUCK, B. HOH, N. HOPKINS, A. SIDDIQUI ir kt.. Size ratio correlates with intracranial aneurysm rupture status. *Stroke* [interaktyvus]. 2010, 41(5); 916-41(5); 916-. [žiūrėta 2021-03-04] Pieiga per: <http://tinyurl.com/pb42z94>
3. STARKE R. ir E. CONNOLLY. Rebleeding after aneurysmal subarachnoid hemorrhage. *Neurocrit care* [interaktyvus]. 2011, 15(2):241-6. [žiūrėta 2021-03-09]. Pieiga per: <http://tinyurl.com/hz5o6bk>
4. BAKUČIONYTĖ E. ir M. VISOKINSKAS. Subarachnoidinių hemoragijų, kurių priežastis intracerebrinės aneurizmos, diagnostikos ir gydymo rezultatų analizė. *Jaunųjų mokslininkų ir tyrėjų konferencija : tezių knyga 2014 / Lietuvos sveikatos mokslų universiteto studentų mokslinė draugija* [interaktyvus]. 2014, 1047-1049 [žiūrėta 2021-03-04]. Prieiga per: <https://www.lsmu.lt/cris/handle/20.500.12512/96204>
5. NIH: NATIONAL INSTITUTE OF NEUROLOGICAL DISORDERS AND STROKE: Cerebral Aneurysms Fact Sheet [interaktyvus]. 2020 [žiūrėta 2021-03-02] Prieiga per: <https://www.ninds.nih.gov/Disorders/Patient-Caregiver-Education/Fact-Sheets/Cerebral-Aneurysms-Fact-Sheet#1>
6. ŠMITAITĖ S. Galvos smegenų kompiuterinės tomografijos angiografijos galimybės diagnozuojant galvos smegenų arterines aneurizmas. *Lietuvos Sveikatos Mokslų Universitetas* [interaktyvus]. 2016. [žiūrėta 2021-03-04] Pieiga per: <https://webcache.googleusercontent.com/search?q=cache:QdNupjCTrbwJ:https://publications.lsmuni.lt/object/elaba:15848415/15848415.pdf+%&cd=4&hl=en&ct=clnk&gl=lt>. [Kreiptasi 05 03 2021].
7. KUMAR R, K. DAS, R. SAHU, P. SHARMA, A. MEHROTA, A. SRIVASTAVA ir kt.. Angio negative spontaneous subarachnoid hemorrhage: is repeat angiogram required in all cases? *Surg Neurol Int* [interaktyvus]. 2014. [žiūrėta 2021-03-04] Pieiga per: <http://tinyurl.com/pee3a52>
8. AMBROZAITIS A, E. BROVSLAVSKIS, V. BUDRYS, G. DAUBARAS, M. ENDZINIENĖ, R. GLEIZNIENĖ ir kt. Klinikinė neurologija. 2-asis pataisytas ir papildytas leidimas. Vilnius: Vaistų žinios; 2009.
9. AZHARI S., H. NAYEB AGHAEI, H. GHANAATI, K. FIROUZANIA, S. ZANDI. The Diagnostic Value of CT Angiography in the Diagnosis of Residual Aneurysm After Brain Aneurysm Surgery. *Iran J Radiol* [interaktyvus]. 2018, 15(1):e15843. Prieiga per: doi: [10.5812/iranjradiol.15843](https://doi.org/10.5812/iranjradiol.15843).
10. UŠINSKIENĖ J., N. R. VALAKEVIČIENĖ, G. ŠUSTICKAS, V. GAIGALAITĖ. Intrakranijinių aneurizmų tyrimas magnetinio rezonanso angiografijos metodu. *Originalūs moksliniai darbai* [interaktyvus]. 2006; 10(28): 76–81. [žiūrėta 2021-04-04] Pieiga per: http://www.neuroseminarai.lt/wp-content/uploads/2017/02//Neuro_2006_Nr2_076-081.pdf
11. OKAHARA M., H. KIYOSUE, M. YAMASHITA ir kt. Diagnostic accuracy of magnetic resonance angiography for cerebral aneurysms in correlation with 3D-digital subtraction angiographic images: a study of 133 aneurysms. *Stroke*, 2002; 33: 1803–8.

12. SATO M., M. NAKANO, J. SASANUMA ir kt.. Preoperative cerebral aneurysm assessment by three-dimensional magnetic resonance angiography: feasibility of surgery with out conventional catheter angiography. *Neurosurgery*, 2005; 56: 903–12.
13. WESTERLAAN H. E., A. M. VAN DER VLIET, J. M. HEW ir kt. Magnetic resonance angiography in the selection of patients suitable for neurosurgical intervention of ruptured intracranial aneurysms. *Neuroradiology*, 2004; 46: 867–75.
14. BOTZ B. ir U. BASHIR. Time of flight angiography. *Radiopaedia* [interaktyvus]. 2021. [žiūrėta 2021-05-05] Pieiga per: <https://radiopaedia.org/articles/time-of-flight-angiography-1>
15. QUESTIONS AND ANSWERS IN MRI: TOF MRA Artifacts [interaktyvus]. 2021. [žiūrėta 2021-05-05] Pieiga per: <http://mriquestions.com/tof-mra-artifacts.html>
16. QUESTIONS AND ANSWERS IN MRI: Time-of-Flight (TOF) MRA Artifacts [interaktyvus]. 2021. [žiūrėta 2021-05-05] Pieiga per: <http://mriquestions.com/time-of-flight-tof-mra.html>
17. PIOTIN M., P. GAILLOUD, L. BIDAUT ir kt. CT angiography, MR angiography and rotational digital subtraction angiography for volumetric assessment of intracranial aneurysms. An experimental study. *Neuroradiology* 2003; 45:404–09
18. JOU L. D., A. MOHAMED, D. H. LEE ir M. E. MAWAD. 3D Rotational Digital Subtraction Angiography May Underestimate Intracranial Aneurysms: Findings from Two Basilar Aneurysms. *American Journal of Neuroradiology* [interaktyvus], 2007, 28 (9) 1690-1692; [žiūrėta 2021-04-02] Prieiga per: doi: DOI: <https://doi.org/10.3174/ajnr.A0652>
19. BIDAUT L. M., C. LAURENT, M. PIOTIN ir kt. Second-generation three-dimensional reconstruction for rotational three-dimensional angiography. *Acad Radiol* 1998; 5:836–49
20. WONG S. C., O. NAWAWI, N. RAMLI ir K. A. KADIR. Benefits of 3D Rotational DSA Compared with 2D DSA in the Evaluation of Intracranial Aneurysm. *Academic Radiology* [interaktyvus], 2012, 19(6), 701–707. [žiūrėta 2021-04-12] Prieiga per: doi: doi:10.1016/j.acra.2012.02.012
21. WENGUANG H., M. SHAOJIE, G. QIULING, Z. YINGCHENG, W. YIFAN ir kt. 1DCNN-Based Intracranial Aneurysms Detection in 3D TOF-MRA. *Coplexity, Hindawi* [interaktyvus], 2020. [žiūrėta 2021-05-02]. Prieiga per: doi: <https://doi.org/10.1155/2020/7023754>
22. PADERVINSKIENĖ L. ir A. JANKAUSKAS. Magnetinio rezonanso aortografija. *Kardiologijos praktika : Kauno krašto kardiologų draugijos konferencija "Vaizdo metodai kardiologijoje" : 2013 m. balandžio mėn. 23 d. : konferencijos pranešimų tezės/straipsniai / Kauno krašto kardiologų draugija. LSMU Medicinos akademijos Kardiologijos klinika. Kaunas : UAB "Kardiologijos projektai", 2013, Nr. 3* [interaktyvus]. 2013, 17-20. [žiūrėta 2021-04-14]. Prieiga per: <https://www.lsmuni.lt/cris/handle/20.500.12512/91245>
23. KER J., S. P. SINGH, Y. BAI, J. RAO, T. LIM ir kt. Image Thresholding Improves 3-Dimensional Convolutional Neural Network Diagnosis of Different Acute Brain Hemorrhages on Computed Tomography Scans. *Sensors, Basel* Vol. 19, Iss. 9 [interaktyvus], 2019. [žiūrėta 2021-04-14] Prieiga per: doi: DOI:10.3390/s19092167
24. ZHAO S., C. MIAO ir kt. A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature Communications*; London Vol. 11, Iss. 1 [interaktyvus]. 2020. [žiūrėta 2021-04-14] Prieiga per: doi: DOI:10.1038/s41467-020-19527-w
25. RAHIL S., P. LENHARD, L. GOERTZ, F. THIELE, C. KABBASCH ir kt. Fully automated detection and segmentation of intracranial aneurysms in subarachnoid hemorrhage on CTA using deep learning. *Scientific Reports (Nature Publisher Group)* [interaktyvus] London Vol. 10, Iss. 1, 2020. [žiūrėta 2021-04-14] Prieiga per: doi: DOI:10.1038/s41598-020-78384-1

26. KAMNITSAS K. ir kt. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Med. Image Anal.* 2017, 36, 61–78.
27. LIU X., J. FENG, Z. WU ir kt. Deep neural network-based detection and segmentation of intracranial aneurysms on 3D rotational DSA. *Interventional Neuroradiology*, [interaktyvus], 2021. [žiūrėta 2021-05-14] Prieiga per: doi: DOI:10.1177/15910199211000956
28. Gosselin G. ir M. Fagan. Effects of cervical muscle fatigue on the perception of the subjective vertical and horizontal. *SpringerPlus*, [interaktyvus], 2014, 3(1):78. [žiūrėta 2021-05-14] Prieiga per: doi: DOI:10.1186/2193-1801-3-78
29. ABRAHAM A. UNGAR. Bi-gyrogroups and Bi-gyrovector Spaces – P. *ScienceDirect*, [interaktyvus], 2018. [žiūrėta 2021-05-02] Prieiga per: <https://www.sciencedirect.com/topics/mathematics/identity-transformation>
30. HUANG G., Z. LIU, L. VAN DER MAATEN ir kt. Densely connected convolutional networks. *eprint arXiv:160806993*. 2016.
31. CiCek O., A. Abdulkadir, S. S. Lienkamp ir kt. 3D U-Net: learning dense volumetric segmentation from sparse annotation. *arXiv e-prints*. [interaktyvus] 2016. [žiūrėta 2021-04-02] Prieiga per: <https://ui.adsabs.harvard.edu/abs/2016arXiv160606650C>.
32. ALHUSSEIN M., K. AURANGZEB, S. I. HAIDER. An unsupervised retinal vessel segmentation using Hessian and intensity based approach. *IEEE Access* 2020; 8: 165056–165070.
33. LECUN Y., B. BOSER, J. S. DENKER ir kt. Backpropagation applied to handwritten zip code recognition. *Neural Comput* 1989; 1: 541–551.
34. LONG J., E. SHELHAMER ir T. DARRELL. Fully convolutional networks for semantic segmentation. *eprint arXiv:14114038*. 2014.
35. FARON A., T. SICHTERMANN, N. TEICHERT ir kt. Performance of a Deep-Learning Neural Network to Detect Intracranial Aneurysms from 3D TOF-MRA Compared to Human Readers. *Clin Neuroradiol* [interaktyvus], 2020, 30, 591–598. [žiūrėta 2021-04-12] Prieiga per: doi: <https://doi-org.ezproxy.ktu.edu/10.1007/s00062-019-00809-w>
36. SICHTERMANN T., A. FARON, R. SIJZEN, N. TEICHERT, J. FREIHERR ir M. WIESMANN. Deep Learning–Based Detection of Intracranial Aneurysms in 3D TOF-MRA. *American Journal of Neuroradiology December* [interaktyvus], 2018. [žiūrėta 2021-04-19] Prieiga per: doi: DOI: <https://doi.org/10.3174/ajnr.A5911>
37. DUAN H., Y. HUANG, L. LIU ir kt.. Automatic detection on intracranial aneurysm from digital subtraction angiography with cascade convolutional neural networks. *BioMed Eng OnLine* [interaktyvus], 2019, 18, 110. [žiūrėta 2021-04-19] Prieiga per: doi: <https://doi-org.ezproxy.ktu.edu/10.1186/s12938-019-0726-2>
38. LIN T. Y., P. GOYAL, R. GIRSHICK, K. HE, P. DOLLAR. Focal loss for dense object detection. *IEEE transactions on pattern analysis and machine intelligence*. 2018.
39. ADAM: Aneurysm Detection And segMentation Challenge [interaktyvus]. [žiūrėta 2021-02-05] Prieiga per: <http://adam.isi.uu.nl/details/>
40. GAIŽAUSKAS, Mantas. Prognozavimo metodų analizės sistema. *Kauno technologijos universitetas* [interaktyvus], 2009. [žiūrėta 2021-05-15] Prieiga per: <https://webcache.googleusercontent.com/search?q=cache:YeUZERw4tcoJ:https://epubl.ktu.edu/object/elaba:1792725/1792725.pdf+%&cd=1&hl=en&ct=clnk&gl=lt>
41. WEN Z., NANCY Z. ir NING W. Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations. *Nesug, Health Care and Life Sciences* [interaktyvus] 2010. [žiūrėta 2021-05-15] Prieiga per: <https://www.lexjansen.com/nesug/nesug10/hl/hl07.pdf>

42. PYIMAGESSEARCH: Intersection over Union (IoU) for object detection [interaktyvus]. [žiūrēta 2021-05-15] Pieiga per: <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>