VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
STUDIJŲ PROGRAMA: INFORMATIKA

Pusiau prižiūrimo mokymosi metodai kasos vėžiui identifikuoti kompiuterinės tomografijos vaizduose

Semi-supervised learning methods to solve the tasks of analyzing medical images of computed tomography images of the pancreas

Baigiamasis magistro darbas

Atliko: Ruslanas Gailiušas
VU e-paštas: ruslanas.gailiusas@mif.stud.vu.lt
Vadovas: dr. Olga Kurasova
Recenzentas: dr. Jolita Bernatavičienė

Vilnius – 2025

TURINYS

Santrauka 6
Summary 7
Įvadas 8
1. Pusiau prižiūrimas mokymasis 10
1.1. Istorinė raida 11
1.2. Pusiau prižiūrimo mokymosi veikimo sąlygos 12
2. Kompiuterinė tomografija 13
2.1. Kompiuterinės tomografijos vaizdų rekonstrukcija 13
2.2. Hounsfieldo skalė kompiuterinėje tomografijoje 14
2.3. Kompiuterinės tomografijos pjūviai 15
3. Duomenų rinkiniai 16
3.1. Duomenų rinkinys: Medicinos segmentavimo dekatlonas 16
3.1.1. Duomenų rinkinio aprašas 16
3.2. Duomenų rinkinys: Nacionalinis vėžio archyvas 17
3.2.1. Duomenų rinkinio aprašas 17
3.3. Duomenų rinkinys: Kaggle – kasos segmentacija 17
3.3.1. Duomenų rinkinio aprašas 18
3.4. DICOM ar NIfTI 18
3.5. Duomenų rinkinio pasirinkimas 19
4. Susijusių darbų analizė 20
4.1. Pusiau prižiūrimo mokymosi metodai 20
4.1.1. Nuoseklumo reguliavimo metodai 21
4.1.2. Generatyvinis besipriešinantis tinklas 26
4.1.3. Priešpriešos nuoseklumo mokymasis 27
4.1.4. Kelių kadrų mokymasis 29
5. Eksperimentiniai tyrimai 32
5.1. Eksperimentų metodika 32
5.2. Vidutinio mokytojo metodo praktinė analizė 34
5.2.1. Duomenų paruošimas 35
5.2.2. Mokymosi etapas 36
5.2.3. VM–bazinis 37
5.2.4. VM–raiška 38
5.2.5. VM–partija 39
5.2.6. VM–duomenys 40
5.2.7. VM–sparta 41
5.2.8. Validavimo etapas 42
5.2.9. Testavimo etapas 44
5.3. Vidutinio mokytojo metodas grįstas neapibrėžtumu praktinė analizė 45
5.3.1. Duomenų paruošimas 45
5.3.2. Mokymosi etapas 46
5.3.3. NVM–bazinis 47
5.3.4. NVM–partija 47
5.3.5. NVM–duomenys 48
5.3.6. NVM–sparta 49
5.3.7. NVM–raiška 50
5.3.8. Validavimo etapas 51
5.3.9. Testavimo etapas 54
5.4. Fiksuoto atitikmens metodo praktinė analizė 54

5.4.1. Duomenų paruošimas 54
5.4.2. FA–bazinis 55
5.4.3. FA–sparta 55
5.4.4. FA–duomenys 56
5.4.5. FA–nuoseklumas 57
5.4.6. FA–partija 58
5.4.7. Validavimo etapas 59
5.4.8. Testavimo etapas 60
5.5. Apibendrinimas 61
Išvados 64
Šaltinių sąrašas 66

Lentelių sąrašas

1 Hounsfieldo skalė 14
2 DICOM ir NIfTi aprašymas 19
3 Duomenų rinkinių palyginamoji lentelė 19
4 Gautų klaidų rezultatai atlikus dešimt iteracijų su SVHN duomenimis [TV17] . . . 24
5 Bendradarbiaujančio vidutinio mokytojo metodo tikslumas [SCY+23] 26
6 Eksperimentas - vaizdų santykis 10 % / 90 % [LZD+23] 29
7 Kiekybiniai 1 bandymo segmentavimo rezultatai ISIC ir PH2 duomenų rinkiniuose [FAP+20] 31
8 Kiekybiniai 5 bandymų segmentavimo rezultatai ISIC ir PH2 duomenų rinkiniuose [FAP+20] 31
9 Eksperimentų santrumpos 33
10 Validacijos metrikų dinamika visuose 5 eksperimentuose (kas 200 iteracijų) 43
11 Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–bazinis ir NVM–bazinis 51
12 Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–partija ir NVM–partija 52
13 Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–duomenys ir NVM–duomenys 52
14 Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–sparta ir NVM–sparta 53
15 Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–raiška ir NVM–raiška 53
16 Validacijos metrikų dinamika visuose 5 eksperimentuose (kas 200 iteracijų) 60

Iliustracijų sąrašas

1 Mašininio mokymosi metodai . . . 11
2 Klasterių struktūros mašininio mokymosi kontekste . . . 12
3 Kompiuterinės tomografijos kasos vėžio 2D pjūvis . . . 13
4 Supaprastinta filtruota atgalinė projekcija . . . 14
5 Ašininis pjūvis . . . 15
6 Koronarinis pjūvis . . . 15
7 Sagitalinis pjūvis . . . 15
8 Kompiuterinės tomografijos pjūviai . . . 15
9 Pusiau prižiūrimo mokymosi metodai, skirti medicininių vaizdų segmentavimui . . 20
10 Fiksuoto atitikmens modelis (FixMatch) . . . 22
11 Vidutinio mokytojo modelis . . . 23
12 Bendradarbiaujantis vidutinio mokytojo modelis . . . 24
13 Supaprastintas ASE-Net modelis . . . 28
14 Supaprastintas kelių kadrų mokymosi modelis . . . 30
15 UML diagrama atspindinti eksperimentų metodiką . . . 34
16 Dominančių sričių išskyrimo procedūra . . . 36
17 VM–bazinis nuostolių kreivė . . . 37
18 Nuostolių kreivių palyginimas VM–bazinis ir VM–raiška eksperimentuose . . . 39
19 Nuostolių kreivių palyginimas VM–bazinis ir VM–partija eksperimentuose . . . 40
20 Nuostolių kreivių palyginimas VM–bazinis ir VM–duomenys eksperimentuose . . 41
21 Nuostolių kreivių palyginimas VM–bazinis ir VM–sparta eksperimentuose . . . 42
22 Kasos vaizdas – 336: Pradinis vaizdas – Vaizdo Etiketė – VM–sparta segmentavimo rezultatas . . . 43
23 Kasos vaizdas – 186: Pradinis vaizdas – Vaizdo Etiketė – VM–duomenys segmentavimo rezultatas . . . 43
24 Kasos vaizdas – 145: Pradinis vaizdas – Vaizdo Etiketė – VM–partija segmentavimo rezultatas . . . 44
25 Kasos vaizdas – 065, VM–sparta . . . 45
26 Kasos vaizdas – 151, VM–duomenys . . . 45
27 Kasos vaizdas – 363, VM–bazinis . . . 45
28 Kasos vaizdas – 396, VM–partija . . . 45
29 Testavimo metu gauti įvairūs segmentavimo vizualus rezultatai . . . 45
30 Duomenų paruošimo procesas – augmentacija . . . 46
31 VM-bazinis mokymosi nuostolių kreivių palyginimas su NVM–bazinis . . . 47
32 VM–partija mokymosi nuostolių kreivių palyginimas su NVM–partija . . . 48
33 VM-duomenys mokymosi nuostolių kreivių palyginimas su NVM–duomenys . . . 49
34 VM–sparta mokymosi nuostolių kreivių palyginimas su NVM–sparta . . . 50
35 VM–raiška mokymosi nuostolių kreivių palyginimas su NVM–raiška . . . 51
36 Kasos vaizdas – 023, NVM–sparta . . . 54

37 Kasos vaizdas – 174, NVM–partija 54
38 Testavimo metu gauti įvairūs segmentavimo vizualus rezultatai 54
39 FA–bazinis mokymosi nuostolių kreivė 55
40 FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–sparta 56
41 FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–duomenys 57
42 FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–nuoseklumas 58
43 FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–partija 59
44 Kasos pjūviai ir jų segmentacijos rezultatas – 180 pavyzdys, FA–nuoseklumas . . . 60
45 Kasos pjūviai ir jų segmentacijos rezultatas – 414 pavyzdys, FA–partija 61

Santrauka

Šiame magistro baigiamajame darbe nagrinėjami pusiau prižiūrimo mokymosi metodai, skirti kasos vėžiui identifikuoti kompiuterinės tomografijos vaizduose. Kasos vėžys yra viena sunkiausiai diagnozuojamų onkologinių ligų, todėl dirbtinio intelekto taikymas ankstyvai diagnostikai turi didelę praktinę reikšmę. Visgi, pažymėtų medicininių vaizdų trūkumas riboja mokymosi modelių taikymą, todėl darbe analizuojamos galimybės taikyti pusiau prižiūrimo mokymosi metodus, leidžiančius pasitelkti ir nežymėtus duomenis. Tyrimo pradžioje atlikta literatūros analizė, kurioje aptarti pusiau prižiūrimo mokymosi principai, jų raida, taikymo ypatumai medicininių vaizdų analizėje bei pagrindiniai algoritmai, tokie kaip vidutinis mokytojo metodas, jo patobulinta versija, grįsta neapibrėžtumu ir fiksuoto atitikmens metodas. Taip pat įvertinti viešai prieinami kompiuterinės tomografijos vaizdų duomenų rinkiniai pagal kelis kriterijus, taikymo sritį, žymėjimų kokybę, prieinamumą, vaizdų įvairovę ir sudėtingumą, ir atrinkti tinkamiausi eksperimentiniai daliai. Eksperimentų metu minėti trys metodai buvo pritaikyti kasos srities segmentavimo uždaviniui, siekiant įvertinti jų efektyvumą esant ribotam pažymėtų duomenų kiekiui. Visi modeliai mokyti su ta pačia architektūra ir vertinti vienodais tikslumo rodikliais, Dice koeficientu ir HD95 metrika. Rezultatai parodė, kad visi pusiau prižiūrimo mokymosi metodai ženkliai pagerina segmentavimo kokybę. Pasiekti rezultatai patvirtina, kad pusiau prižiūrimo mokymosi taikymas yra perspektyvus sprendimas medicininių vaizdų analizėje.

Summary

This master's thesis investigates semi-supervised learning methods for the identification of pancreatic cancer in computed tomography images. Pancreatic cancer remains one of the most challenging oncological diseases to diagnose, making the application of artificial intelligence for early detection highly valuable. However, the limited availability of annotated medical images constrains the development of accurate learning models. To address this, the study explores the use of semi-supervised learning techniques that can leverage both labeled and unlabeled data. The research begins with a literature review, analyzing the fundamentals of semi-supervised learning, its historical development, application challenges in medical image analysis, and the key algorithms considered, the Mean Teacher method, its uncertainty-based extension, and the FixMatch approach. Publicly available computed tomography image datasets were also evaluated against several criteria, including clinical relevance, annotation quality, accessibility, image diversity, and complexity, to select the most suitable datasets for experimentation. In the experimental phase, the three selected methods were applied to pancreas segmentation tasks, aiming to assess their effectiveness under conditions of limited labeled data. All models were trained using the same network architecture and evaluated with consistent metrics, the Dice coefficient and the 95th percentile Hausdorff Distance. The results demonstrated that all semi-supervised learning methods significantly improved segmentation quality. Overall, the findings confirm that semi-supervised learning presents a promising solution for enhancing medical image analysis, particularly in scenarios where annotated data are scarce.

Įvadas

Medicininių vaizdų analizė yra svarbus medicinos tyrimų ir klinikinės praktikos elementas. Ši sritis apima įvairių vaizdinių duomenų, tokių kaip rentgeno, kompiuterinės tomografijos, magnetinio rezonanso ir ultragarsinio tyrimo vaizdų interpretavimą. Medicininio vaizdo segmentavimas, kuris apima organų ir pažeidimų pikselių identifikavimą iš medicininių vaizdų, pavyzdžiui, kompiuterinės ar magnetinės rezonanso tomografijos, yra vienas iš sudėtingiausių uždavinių medicininių vaizdų analizėje, teikiantis kritiškai svarbią informaciją apie šių organų formą ir tūrį [MK19]. Tačiau, dėl didelio vaizdų kiekio ir jų sudėtingumo, šis procesas tampa iššūkiu net ir patyrusiems šios srities tyrėjams.

Naujausi moksliniai tyrimai rodo, kad dirbtinio intelekto metodai, įskaitant mašininį mokymąsi ir ypač pusiau prižiūrimą mokymąsi (*semi-supervised learning*), gali ženkliai prisidėti prie medicininių vaizdų analizės efektyvumo ir tikslumo gerinimo. Pusiau prižiūrimo mokymosi metodai yra ypač vertingi medicininių vaizdų analizės srityje dėl jų gebėjimo mokytis iš riboto sužymėtų duomenų kiekio, kartu pasitelkiant didelius nežymėtus duomenų kiekius. Tai yra svarbu, nes duomenų žymėjimas yra laiko ir išteklių reikalaujantis procesas, kurio metu duomenims yra priskiriamos etiketės ar žymos. Šis procesas gali būti atliekamas žmonių, automatiškai arba per pusiau automatines sistemas. Sužymėti duomenys leidžia mašininio mokymosi modeliams mokytis iš konkrečių pavyzdžių ir taikyti išmoktas žinias atpažįstant ar klasifikuojant naujus duomenis. Pavyzdžiui, medicininių vaizdų atveju, kiekvienam vaizdui gali būti priskirtas žymėjimas, nurodantis tam tikrą ligos buvimą ar ne. Tai leidžia algoritmui mokytis atpažinti ligas ar kitas savybes iš naujų, nežymėtų duomenų, remiantis anksčiau sužymėtu duomenų rinkiniu. Tačiau, medicininio vaizdo segmentavimo metodai vis dar labai priklauso nuo didelio kiekio aukštos kokybės pažymėtų duomenų, kurie yra sunkiai prieinami, kadangi tik medicinos srities ekspertas gali pateikti patikimus ir tikslius pažymėjimus. Dėl šios priežasties pusiau prižiūrimas mokymasis tapo patraukliu sprendimu, leidžiančiu mokytis iš riboto pažymėtų duomenų kiekio, kartu panaudojant didelius nežymėtų duomenų kiekius, kurie yra lengviau prieinami ir turi didelę reikšmę realiose klinikinėse taikymo srityse. Nepaisant to, svarbu pabrėžti, kad norint sumažinti rankinio žymėjimo naštą, buvo įdėtos reikšmingos pastangos sukuriant įvairius metodus medicininių vaizdų segmentavimo užduotims, didinant mokymo duomenis per etikečių generavimą, duomenų augmentaciją, naudojant išorines susijusias pažymėtas duomenų bazes ir naudojant nežymėtus duomenis su pusiau prižiūrimu mokymusi [JZD+23].

Egzistuojant medicininių duomenų tipų įvairovei, kompiuterinė tomografija yra puikus pasirinkimas dėl keletos priežasčių. Pirma, kompiuterinės tomografijos vaizdai suteikia aukštos raiškos struktūrinę informaciją apie kūno vidinius organus ir audinius, kas yra esminė savybė norint tiksliai nustatyti ir analizuoti įvairias patologijas. Antra, kompiuterinės tomografijos technologija yra plačiai paplitusi ir prieinama daugelyje medicinos įstaigų, todėl duomenų rinkinys, reikalingas pusiau prižiūrimo mokymosi tyrimams, yra lengviau prieinamas. Šios savybės leidžia efektyviai taikyti pusiau prižiūrimo mokymosi metodus medicininių vaizdų analizėje, siekiant pagerinti diagnozavimo procesų automatizavimą ir tikslumą.

Šio magistro baigiamajame darbe naujumas glūdi ne tik pusiau prižiūrimo mokymosi metodų

taikyme medicininių vaizdų analizėje, bet ir specifinių algoritmų bei jų derinių tyrimo aspektuose. Nors pusiau prižiūrimo mokymosi taikymas yra žinomas mašininio mokymosi srityje, jo efektyvus pritaikymas medicininių vaizdų analizėje dar nėra išsamiai ištirtas. Tad šiuo darbu siekiama užpildyti šią mokslinę spragą, pateikiant išsamų pusiau prižiūrimo mokymosi metodų tyrimą ir jų taikymo medicininių vaizdų analizėje vertinimą.

Šio magistro baigiamojo darbo **tikslas** yra atlikti išsamią pusiau prižiūrimo mokymosi metodų, skirtų kasos vėžiui identifikuoti kompiuterinės tomografijos vaizduose, palyginamąją analizę, siekiant nustatyti jų efektyvumą ir pritaikomumą diagnozavimo tikslumo atžvilgiu.

Norint pasiekti nustatytą tikslą, bus atlikti šie uždaviniai:

- Atlikti išsamią literatūros apžvalgą, nagrinėjant pusiau prižiūrimo mokymosi metodų taikymą medicininių vaizdų analizėje, įskaitant jų pagrindines tendencijas, iššūkius ir galimybes.
- Pasirinkti kelis medicininių vaizdų duomenų rinkinius ir atlikti jų kriterinę duomenų rinkinių analizę siekiant nustatyti geriausiai tinkantį duomenų rinkinį, leidžiantį įgyvendinti analizės metu iškeltus uždavinius.
- Nustatyti kriterijus, pagal kuriuos bus atlikta pusiau prižiūrimo mokymosi metodų palyginamoji analizė.
- Atlikti išsamų skirtingų pusiau prižiūrimo mokymosi metodų palyginimą, remiantis jų veikimo efektyvumu, tikslumu ir kitais svarbiais kokybės matavimo kriterijais.
- Įvertinti gautus rezultatus, siekiant nustatyti stipriąsias ir silpnąsias pusiau prižiūrimo mokymosi metodų puses kompiuterinės tomografijos kasos vėžio medicininių vaizdų analizėje.
- Pateikti išvadas apie pusiau prižiūrimo mokymosi metodų efektyvumą ir pritaikomumą kasos vėžio medicininių vaizdų analizėje, siūlyti rekomendacijas tolesnėms tyrimų kryptims ir praktinio taikymo galimybėms.

1. Pusiau prižiūrimas mokymasis

Pusiau prižiūrimas mokymasis (*semi-supervised learning*) yra tarpinis mokymosi metodas, kuris sujungia prižiūrimo mokymosi, naudojančio pažymėtus duomenis ir neprižiūrimo mokymosi, naudojančio tik nepažymėtus duomenis principus. Tai leidžia sumažinti pažymėtų duomenų poreikį, tuo pačiu išlaikant modelio efektyvumą. Pusiau prižiūrimo mokymosi privalumas yra jo gebėjimas geriau generalizuoti nei neprižiūrimas mokymasis dėl turimų pažymėtų duomenų. Tačiau ši paradigma priklauso nuo tam tikrų prielaidų, pavyzdžiui, kad panašūs duomenys turėtų panašias etiketes, kas ne visada gali būti garantuota. Taip pat pusiau prižiūrimo mokymosi modeliai dažnai yra sudėtingesni nei grynai prižiūrimi ar neprižiūrimi modeliai, kas gali reikalauti papildomų išteklių. Ir galiausiai, kadangi dalis mokymosi vyksta naudojant nežymėtus duomenis, gali kilti papildomų sunkumų įvertinant modelio patikimumą ir sprendimų aiškumą [ZG09].

Prižiūrimas mokymasis (*supervised learning*) yra mašininio mokymosi paradigma, kurioje modelis mokomas naudojant iš anksto pažymėtus duomenis. Tai reiškia, kad kiekvienam įvesties duomeniui yra žinomas norimas išvesties rezultatas. Prižiūrimas mokymasis yra labai efektyvus, kai turime didelį kiekį kokybiškai pažymėtų duomenų. Tai leidžia sukurti labai tikslų modelį. Tačiau pagrindinis šios paradigmos trūkumas yra tas, kad pažymėti duomenys gavimo atžvilgiu yra laiko reikalaujantys, o tai apsunkina modelio pritaikomumą sritims, kur duomenų pažymėjimas yra sudėtingas. Prižiūrimas mokymasis yra labai svarbus ir plačiai naudojamas mašininio mokymosi metodas, turintis daugybę pritaikymo galimybių įvairiose srityse.

Neprižiūrimas mokymasis (*unsupervised learning*), skirtingai nuo prižiūrimo remiasi duomenimis, kuriems trūksta etikečių ar pažymėjimų. Šis metodas naudojamas atrasti paslėptas duomenų struktūras ar modelius be išankstinio nurodymo, ką būtent reikėtų ieškoti. Neprižiūrimo mokymosi privalumas yra gebėjimas dirbti su dideliais nepažymėtų duomenų kiekiais, tačiau šios paradigmos mokymo pagrindinis trūkumas yra mažesnis modelio tikslumas, ypač lyginat su prižiūrimu mokymusi, ir sunkumai validuojant gautus rezultatus, nes nėra aiškaus atsakymo, ar modelis teisingai apdoroja duomenis. Neprižiūrimas mokymasis yra svarbus įrankis duomenų analizėje ir sprendimų priėmime, ypač kai turimi duomenys nėra pažymėti arba kai norima automatiškai atskleisti slypinčias duomenų savybes. Tai suteikia galimybę giliau suprasti duomenų rinkinius be išankstinių žinių apie juos.

Kiekviena iš šių mokymosi paradigmų turi savo stiprybes ir silpnybes, į kurias reikia atsižvelgti sprendžiant konkrečius uždavinius. Tačiau turint omenyje medicininių vaizdų analizę, pusiau prižiūrimas mokymasis yra ypač naudingas, kadangi šitoje srityje duomenys gali būti sunkiai prieinami, tačiau pačių duomenų kiekiai yra dideli. Šis metodas leidžia išnaudoti tiek pažymėtus, tiek nepažymėtus duomenis, siekiant sukurti efektyvų ir tikslų modelį, pagerinant diagnozes ir gydymo procesus [ZG09]. Taigi, pasirenkant tinkamą mokymosi paradigmą, svarbu atsižvelgti į konkrečias sąlygas ir poreikius, siekiant maksimaliai išnaudoti turimus resursus. Visi aprašyti mokymosi metodai yra pateikti 1 paveikslėlyje.

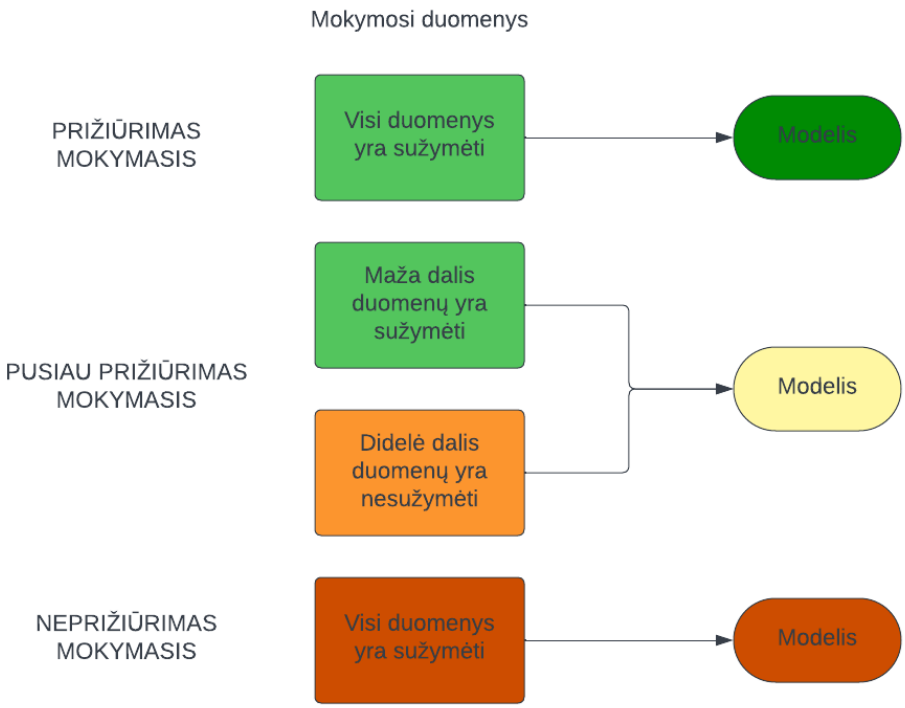

1 pav. Mašininio mokymosi metodai

1.1. Istorinė raida

Pusiau prižiūrimo mokymosi pirmtakai siekia tokius metodus kaip savęs mokymasis (self-learning), kitaip žinomas kaip savęs ženklinimas ar sprendimais grįstas mokymasis. Tai veikė pasitelkiant prižiūrimo mokymosi metodus, tai yra, mokymasis prasideda tik su žymėtais duomenimis. Vėliau naudojant modelio sprendimo funkciją, dalis nežymėtų duomenų yra žymima, kuri tada įtraukiama atgal į mokymosi rinkinį, leidžiant prižiūrimam metodui iš naujo mokytis naudojant savo pačių prognozes kaip naujai žymėtus duomenis. Vienas iš pastebimų savęs mokymosi trukumu yra jo priklausomybė nuo pasirinkto prižiūrimo mokymosi metodo. Pavyzdžiui, naudojant empirinės rizikos minimizavimą ir 1-0 nuostolius, nežymėti duomenys visai nedaro įtakos rezultatui [ZG09]. Kita vertus, jei naudojamas ribas didinantis metodas, sprendimo riba yra stumiama toliau nuo nežymėtų taškų, žymiai keičiant modelio elgseną.

1970-ieji buvo reikšmingas laikotarpis, kai pusiau prižiūrimas mokymasis pradėjo įgyti pagreitį, ypač kai problema susijusi su Fisher tiesinio diskriminanto taisyklės įvertinimu naudojant nežymėtus duomenis buvo iškelta tokių mokslininkų, kaip Hosher (1973), McLachlan (1977), O'Neill (1978), McLachlan ir Ganesalingam (1982). Metodai buvo tyrinėjami naudojant iteratyvius algoritmus, pavyzdžiui: lūkesčių-maksimizavimo algoritmą (*expectation-maximization algorithm*), maksimizuojant modelio tikimybę naudojant žymėtus ir nežymėtus duomenis. Vėlesniais dešimtmečiais požiūris buvo plėtojamas ir bendrinamas, taip užtikrinant kelių klasių komponentų modelių kūrimą, didinant pusiau prižiūrimo mokymosi metodų lankstumą ir tikslumą.

Pusiau prižiūrimo mokymosi, tokios kaip srities susidomėjimas atgijo 1990-aisiais, daugiausia dėl jo taikymo natūralios kalbos apdorojimo ir teksto klasifikavimo srityse, parodant jo praktinę

naudą įvairiose srityse. Šis laikotarpis įtvirtino pusiau prižiūrimo mokymosi pozicijas kaip pagrindinį metodą mašininio mokymosi srityje [ZG09].

Merz et al. (1992) buvo pirmasis mokslininkas, kuris paminėjo sąvoką "pusiau prižiūrimas" klasifikavimo atžvilgiu susiejant pažymėtus ir nepažymėtus duomenis.

1.2. Pusiau prižiūrimo mokymosi veikimo sąlygos

Natūraliai kyla klausimas, ar pusiau prižiūrimas mokymasis iš tikrųjų turi prasmę? Ar galime tikėtis tiksliau prognozuoti lyginant su algoritmais, naudojančiais tik žymėtus duomenis? Kaip ne keista, tačiau atsakymas yra „taip“ esant tam tikroms prielaidoms. Viena iš tokių prielaidų yra duomenų klasterių struktūros, kurios yra pateiktos 2 paveikslėlyje. Paveikslėlyje galima pastebėti trys skirtingas spalvas, kur kiekviena iš jų atitinka tam tikrą duomenų klasę. Ši prielaida teigia, kad duomenys toje pačioje klasėje yra linkę būti arčiau vienas kito duomenų erdvėje, nei duomenys iš skirtingų klasių. Tai yra viena iš esminių segmentavimo uždaviniuose naudojamų prielaidų [YSK+23].

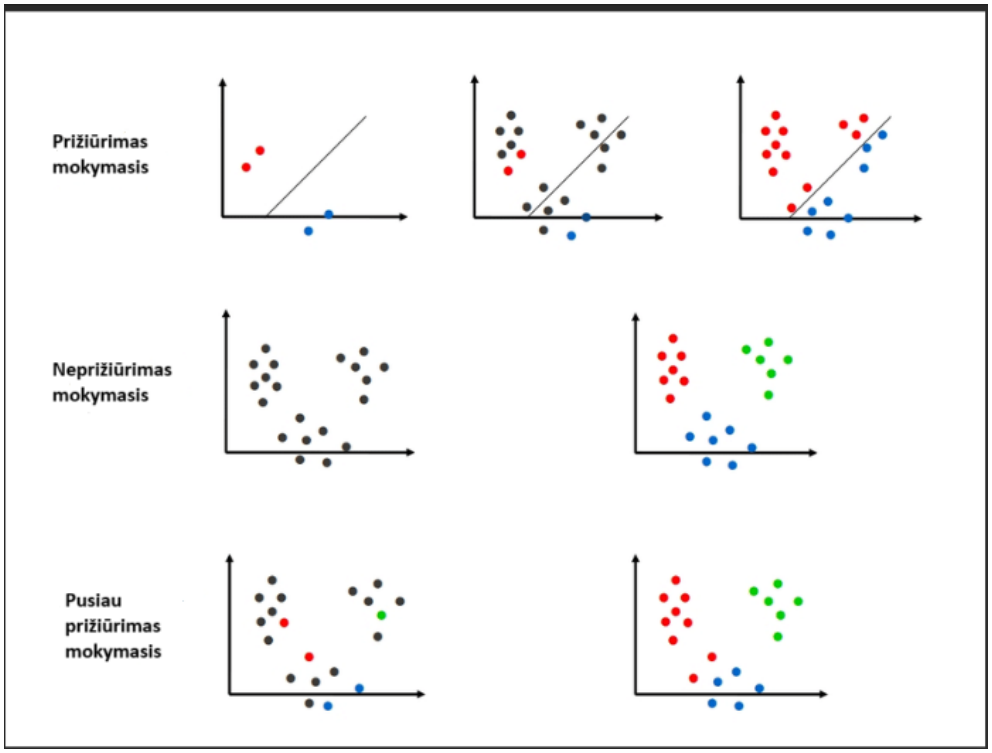

2 pav. Klasterių struktūros mašininio mokymosi kontekste

2. Kompiuterinė tomografija

Kompiuterinė tomografija yra medicininės srities vaizdavimo technologija, kuri naudojama detaliam kūno vidinių struktūrų vaizdavimui. Ši technologija pradėta taikyti medicinoje 1970-aisiais metais, kai britų inžinierius Godfrey Hounsfield ir fizikas Allan Cormack sukūrė pirmąjį kompiuterinės tomografijos prietaisą. Kompiuterinės tomografijos skenavimas naudoja rentgeno spindulius, kurie per kūną keliauja iš įvairių kampų, o gauti duomenys apdorojami kompiuterio, kuris sukuria sluoksniuotus, detalias kūno sritis vaizduojančias nuotraukas. Kompiuterinės tomografijos pavyzdys yra pateiktas 3 paveikslėlyje. Ši technologija yra itin vertinga diagnozuojant įvairias traumas, vėžį, kraujagyslių ligas ir kitas patologijas. Dėl savo gebėjimo teikti aukštos raiškos vaizdus, kompiuterinė tomografija yra laikoma viena iš svarbiausių ir dažniausiai naudojamų diagnostikos priemonių šiuolaikinėje medicinoje. Be to, naujausi technologiniai patobulinimai leidžia dar labiau sumažinti pacientams skiriamą radiacijos dozę, tuo pačiu išlaikant aukštą vaizdų kokybę [SSP21].

3 pav. Kompiuterinės tomografijos kasos vėžio 2D pjūvis

2.1. Kompiuterinės tomografijos vaizdų rekonstrukcija

Populiariausias kompiuterinės tomografijos vaizdų rekonstrukcijos metodas yra filtruota atgalinė projekcija [SSP21], kuri yra pagrįsta Radono transformacijos principu. Supaprastinta šio metodo reprezentacija pateikta 4 paveikslėlyje. Radono transformacija yra matematinis procesas, kuris transformuoja projekcijos duomenis gautus į tomogramų duomenis. Ši transformacija gali būti išreikšta 1 formule.

$$f(x,y) = \int_{-\infty}^{\infty} p(xcos\theta + ysin\theta,\theta)d\theta \tag{1}$$

Čia *f(x,y)* rekonstruoto vaizdo intensyvumas taške, $p(xcos\theta + ysin\theta,\theta)$ yra projekcijos matrica, esant konkrečiam kampui, θ – projekcijos kampas, $d\theta$ – diferencialinis kampo pokytis. Norint pagerinti vaizdų kokybę ir sumažinti pacientui skiriamą spinduliuotės dozę, pastaraisiais metais buvo pradėti naudoti įvairūs technologiniai patobulinimai. Vienas iš tokių patobulinimu yra dualinės energijos kompiuterinė tomografija, kuri leidžia atskirti medžiagos tipus pagal jų rentgeno spindulių absorbciją. Taip pat, naujausi kompiuterinės tomografijos aparatai turi automatinius dozės mažinimo mechanizmus, kurie prisitaiko prie paciento kūno sudėties ir sumažina spinduliuotės

dozę ten, kur ji nėra būtina.

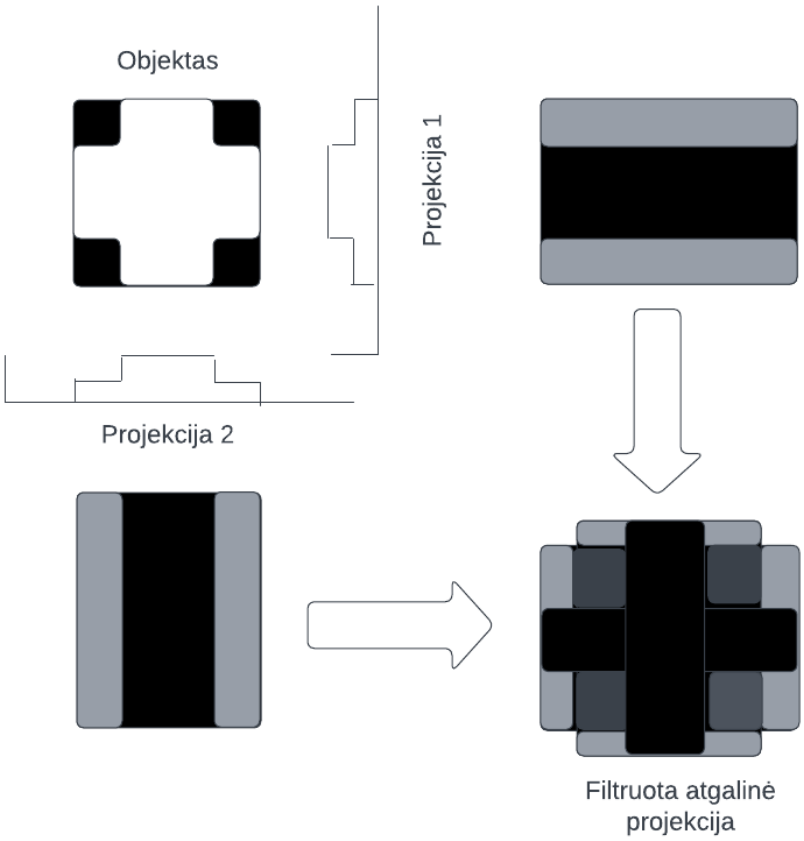

4 pav. Supaprastinta filtruota atgalinė projekcija

2.2. Hounsfieldo skalė kompiuterinėje tomografijoje

Hounsfieldo skalė yra standartizuotas matavimo vienetas, kuris naudojamas kompiuterinėje tomografijoje skirti audinių ir medžiagų radiotankį [Hou73]. Keli medžiagų ir vienetu deriniai yra pateikti 1 lentelėje. Hounsfieldo vienetai yra pagrindinis diagnostikos rodiklis, leidžiantis radiologams ir gydytojams interpretuoti kompiuterinės tomografijos vaizdus, nes Hounsfieldo vienetai nurodo, kaip stipriai rentgeno spinduliai absorbuojami skirtinguose kūno audiniuose.

1 lentelė. Hounsfieldo skalė

Medžiaga	**Vienetai**
Oras	-1000
Riebalai	-120 iki -90
Audiniai	+100 iki +300
Vanduo	0
Kraujas	+40 iki +60
Kaulas	+300 iki +400

2.3. Kompiuterinės tomografijos pjūviai

Kompiuterinės tomografijos metu galima gauti tris skirtingų tipų pjūvius [SSP21], kur kiekvienas iš jų suteikia unikalų požiūrį į skenuojamą struktūrą, kuri yra pateikta 8 paveikslėlyje:

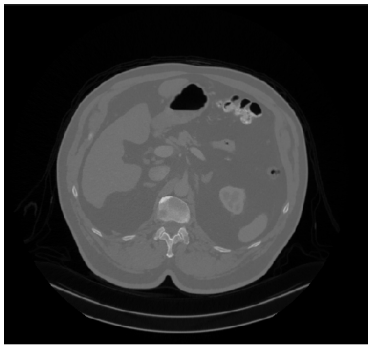

5 pav. Ašininis pjūvis

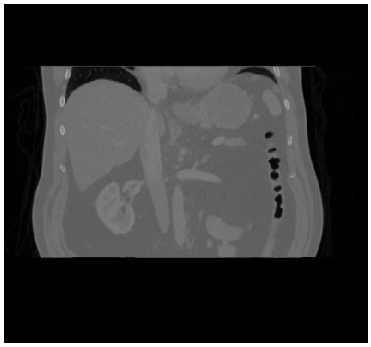

6 pav. Koronarinis pjūvis

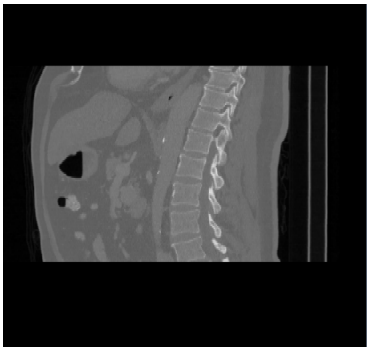

7 pav. Sagitalinis pjūvis

8 pav. Kompiuterinės tomografijos pjūviai

- Ašininis pjūvis – pjūvis, gautas skiriant kūną horizontaliai nuo galvos iki kojų. Ašininiai pjūviai yra ypatingai naudingi vertinant erdvines sąsajas tarp organų tam tikroje kūno plokštumoje (5 pav.)
- Koronarinis pjūvis – pjūvis, gautas skiriant kūną vertikaliai iš priekio į galą arba atvirkščiai. Tokie pjūviai dažnai yra naudojami širdies bei ortopediniams tyrimams (6 pav.)
- Sagitalinis pjūvis – pjūvis, gautas skiriant kūną vertikaliai iš kairės į dešinę arba iš dešinės į kairę. Tokie pjūviai yra vertingi vertinant struktūras, tokias kaip smegenys, stuburas ar sąnariai, nes galima detaliai vizualizuoti struktūras pagal jų ilgį (7 pav.)

3. Duomenų rinkiniai

Pasirinkimas ir analizė tinkamų medicininių vaizdų duomenų rinkinių pusiau prižiūrimo mokymosi kontekste yra svarbus veiksnys, turintis esminę įtaką mokymosi proceso efektyvumui bei modelių prognozių tikslumui. Tokio rinkinio pasirinkimas yra sudėtingas, reikalaujantis gilaus supratimo apie žymėjimų kokybę, vaizdų įvairovę ir specifinius tyrimo tikslus. Medicininiai vaizdai, turintys aukštą raišką ir ekspertų atliktus tikslius žymėjimus, yra būtini modelio mokymui, kuris remiasi tiek pažymėtais, tiek nepažymėtais duomenimis. Kiekvienas duomenų rinkinys kruopščiai išnagrinėtas, siekiant įsitikinti, jog duomenų rinkiniai atitinka nustatytus kriterijus. Duomenų rinkinio pasirinkimas bus grindžiamas išsamia duomenų analize. Tinkamai pasirinktas duomenų rinkinys leis maksimaliai išnaudoti pusiau prižiūrimo mokymosi metodų privalumus, užtikrinant efektyvesnius ir tiksliau prognozuojančius modelius.

3.1. Duomenų rinkinys: Medicinos segmentavimo dekatlonas

Medicinos segmentavimo dekatlono (*The Medical Segmentation Decathlon*) duomenų rinkinys yra plačiai aprašytas prestižiniame "*Nature*" žurnale publikuotame straipsnyje [ARB+22], kuriame detaliai išnagrinėtas medicininių vaizdų rinkinių panaudojimas mokymosi procesuose. Šis duomenų rinkinys sudarytas iš įvairių medicininių vaizdų, kuriuose vaizduojami specifiniai sveikatos sutrikimai. Rinkinio įvairovė ir žymėjimų detalumas leidžia efektyviai mokyti mašininio mokymosi modelius, kurie gali atpažinti ir segmentuoti įvairias patologijas, suteikiant svarbią informaciją diagnozei ir gydymo planavimui.

Kiekvienas vaizdas šiame duomenų rinkinyje yra tiksliai pažymėtas, o tai suteikia nepaprastai vertingą pagrindą pusiau prižiūrimam mokymuisi. Aukštos kokybės žymėjimai yra neatsiejama šio duomenų rinkinio dalis, leidžianti modeliams efektyviau mokytis ir geriau generalizuoti išmoktas žinias pritaikant jas dirbant su nežymėtais duomenimis. Tokie duomenys yra itin svarbūs pusiau prižiūrimo mokymosi kontekste, nes modeliai turi galimybę naudotis ribotu pažymėtų duomenų kiekiu kartu pasitelkiant didelius nežymėtų duomenų kiekius, kurie yra lengviau prieinami.

3.1.1. Duomenų rinkinio aprašas

Medicinos segmentavimo dekatlono duomenų rinkinys yra itin išsamus ir apima tūkstančius atskirų medicininių vaizdų, kuriuose pavaizduoti įvairūs organai ir jų patologijos. Kiekvienas vaizdas šiame rinkinyje yra kruopščiai pažymėtas medicinos ekspertų, suteikiant tikslius aprašymus ir diagnozes. O būtent kasos segmentavimui skirtas duomenų rinkinys yra sudarytas iš 420 trimačių kompiuterinės tomografijos vaizdų, kuriuose nurodomos trys pagrindinės sritys: fonas, kasa ir navikai kasoje. Svarbu paminėti, kad duomenų rinkinys pasižymi didelių klasių disbalansu, nes kasa užima tik 1–2 % viso vaizdo tūrio, o pačių navikų tūris dar mažesnis. Tokios ypatybės sukuria papildomus iššūkius segmentavimo modeliams. Duomenys buvo surinkti *Memorial Sloan Kettering Cancer Center*, Niujorke, JAV [ARB+22].

Vaizdų saugojimas vyksta naudojant NIfTI (*Neuroimaging Informatics Technology Initiative*) formatą, kuris yra labai populiarus neurologiniuose ir kituose medicininiuose tyrimuose. Šis for-

matas palaiko trimačių duomenų ir metaduomenų saugojimą, kas suteikia didelį lankstumą ir palengvina duomenų analizės procesus, ypač kai reikia tvarkyti didelio tūrio vaizdus. NIfTI formatas yra vertinimas dėl savo gebėjimų efektyviai apdoroti ir pateikti kompleksinę informaciją, todėl jis idealiai tinka sudėtingoms medicininių vaizdų analizės užduotims atlikti.

3.2. Duomenų rinkinys: Nacionalinis vėžio archyvas

Kasos kompiuterinės tomografijos duomenų rinkinys, kuris yra viešai prieinamas nacionalinio vėžio vaizdų archyve (*The Cancer Imaging Archive, TCIA*) [RFT+16], gali būti pritaikytas kasos ligų diagnozavimo ir gydymo srityje. Šis duomenų rinkinys apima detalius kompiuterinės tomografijos vaizdus, kurie skirti būtent kasos tyrimams. Aukštos raiškos ir tikslių žymėjimų vaizdai suteikia reikalingus duomenis ne tik ligų nustatymui, bet ir vaizdų analizės algoritmų kūrimui bei testavimui. Dėl šių ypatybių, rinkinys yra ypač naudingas pusiau prižiūrimo mokymosi metodams, leidžiantis efektyviai naudoti ir pažymėtus, ir nepažymėtus duomenis, bandant pagerinti diagnostinius algoritmus ir jų adaptacijų galimybes.

3.2.1. Duomenų rinkinio aprašas

Kasos kompiuterinės tomografijos duomenų rinkinys sudarytas iš 82 kontrastinių trimačių kompiuterinės tomografijos vaizdų. Šie medicininiai vaizdai gauti iš 53 vyrų ir 23 moterų, kurių amžius svyravo nuo 18 iki 76 metų, vidutiniškai 46,8 ± 16,7 metų. Iš šių tiriamųjų 17 buvo sveiki inkstų donorai, skenuoti prieš nefrektomiją, o likę 65 pacientai buvo atrinkti radiologo, neturėję didelių pilvo patologijų ar kasos vėžio požymių. Kompiuteriniai tomografiniai vaizdai turi 512x512 pikselių skiriamąją gebą, su kintančiu pikselių dydžiu ir sluoksnių storiu nuo 1,5 iki 2,5 milimetrų [RFT+16]. Vaizdai buvo gauti naudojant Philiphs ir Siemiens MDCT skenerius. Kiekvieno vaizdo kasos segmentacija buvo atlikta medicinos studento rankiniu būdu, sluoksnis po sluoksnio, o vėliau patikrinta ir, jei reikia, pakoreguota patyrusio radiologo. Visi vaizdai pateikti DICOM (*Digital Imaging and Communications In Medicine*) formatu, kuris yra plačiai naudojamas medicinos srityje dėl savo gebėjimo išlaikyti aukštą vaizdų kokybę ir detalumą.

3.3. Duomenų rinkinys: Kaggle – kasos segmentacija

Kaggle platforma yra duomenų mokslo konkursų platforma ir internetinė duomenų mokslininkų ir mašininio mokymosi praktikų bendruomenė, priklausanti ”*Google LLC*”. Platforma leidžia vartotojams rasti ir publikuoti duomenų rinkinius, tyrinėti ir kurti modelius, dirbti su kitais duomenų mokslininkais ir mašininio mokymosi inžinieriais bei dalyvauti konkursuose, siekiant išspręsti duomenų mokslo iššūkius. Viena iš platformos teikiamų galimybių yra medicininių vaizdų segmentavimo duomenų rinkinys (*Pancreas segmentation – Task002:Pancreas*) [MOR+22], kuris pateikia išsamų įvairių medicininių vaizdų kolekciją. Šie duomenys skirti ne tik vaizdų segmentavimo algoritmų kūrimui, bet ir jų efektyvumo įvertinimui.

3.3.1. Duomenų rinkinio aprašas

Kaggle – kasos segmentacijos duomenų rinkinys, sudarytas iš 73 segmentavimo uždaviniams skirtų medicininių vaizdų, apimant įvairius vaizdavimo modelius, tokius kaip magnetinio rezonanso tomografija, kompiuterinė tomografija ir ultragarsas. Medicininiuose vaizduose yra pažymėtos dvi pagrindinės klasės: 0 - fonas ir 1 - kasa [MOR+22]. Kiekvienas vaizdas pridedamas su atitinkamomis segmentavimo kaukėmis, kurios nurodo specifines savybes ir patologijas, kurios yra pateiktos tokiu formatu, kuris yra suderinamas su dauguma vaizdų apdorojimo bibliotekų, todėl algoritmų kūrėjai gali lengvai integruoti šiuos duomenis į savo sistemas. Duomenų rinkinys struktūrizuotas taip, kad užtikrintų lengvą prieigą ir valdymą, palengvinant mokymosi procesą, kas daro jį idealiai tinkamu tiek tradicinių, tiek inovatyvių pusiau prižiūrimo mokymosi metodų bandymams.

3.4. DICOM ar NIfTI

DICOM (*Digital Imaging and Communications in Medicine*) yra plačiai naudojamas standartas medicininiuose vaizduose ir susijusiose srityse. Standartas buvo sukurtas siekiant užtikrinti sklandų vaizdų ir kitos medicininės informacijos keitimąsi tarp įvairių medicininių įrenginių ir sistemų. DICOM ne tik apima pačius vaizdus, bet ir svarbią pacientų, įvykių ir procedūrų informaciją. Tai leidžia DICOM formatu saugomus vaizdus naudoti ne tik diagnostikai, bet ir įvairiose medicininių tyrimų srityse, garantuojant aukštą duomenų saugumo ir suderinamumo lygį [MBS+20].

NIfTI formatas (*Neuromaging Informatics Technology Initiative*) dažniausiai naudojamas neurologiniams vaizdams ir moksliniams tyrimams. Sukurtas neurologijos informacijos technologijų iniciatyvos, šis formatas yra patogus dirbant su 3D ir 4D vaizdais. NIfTI palaiko ne tik vaizdų, bet ir metaduomenų, tokių kaip dimensijos, orientacija, plėtimasis ir kita saugojimą. Dėl savo lankstumo ir orientacijos į mokslinus tyrimus NIfTI yra labai populiarus akademinėje bendruomenėje, ypač tarp tyrėjų, dirbančių su funkciniu magnetinio rezonanso tomografu ir kitais panašiais vaizdavimo metodais. NIfTI lankstumas leidžia mokslininkams efektyviai dirbti su didelio tūrio duomenimis, kuriems reikalinga sudėtinga analizė [MBS+20].

Pasirinkimas tarp DICOM ir NIfTI formatų priklauso nuo keletos veiksnių, įskaitant konkrečius tyrimo reikalavimus ir naudojamą įrangą. DICOM yra būtinas formatas medicininių įstaigų infrastruktūroje, nes leidžia sklandžiai dalintis vaizdais ir informacija tarp skirtingų sveikatos priežiūros teikėjų. Tuo tarpu NIfTI pasirenkamas dažniausiai akademiniuose tyrimuose, nes jo lankstumas ir orientacija į mokslinius tyrimus suteikia galimybę efektyviai analizuoti ir tvarkyti sudėtingus vaizdų rinkinius. Kiekvienas formatas turi savo privalumų ir apribojimų, todėl formato pasirinkimas turi būti atliekamas atsižvelgiant į specifines užduotis ir reikalavimus. Glaustas formatų aprašymas yra pateiktas 2 lentelėje.

2 lentelė. DICOM ir NIfTi aprašymas

Atributas	DICOM	NIfTI
Failo plėtinys		.nii .nii.gz
Atvaizdavimas	Vienas sluoksnis	3D vaizdas
Antraštė	Daug laukų Privati pacientų informacija Pateikiama ligoninės informacija	Nėra paciento informacijos Vaizdo metaduomenis
Saugojimas	Atskira direktorija vaizdams Sudėtinga duomenų struktūra	Skirtingi failai toje pačioje direktorijoje

3.5. Duomenų rinkinio pasirinkimas

Atlikus išsamią trijų duomenų rinkinių analizę, kuri buvo atliekama pagal 5 pasirinktus kriterijus: taikymo sritis, vaizdų įvairovė, vaizdų sudėtingumas, žymėjimų kokybė bei žymėjimų prieinamumas. Visi šie kriterijai buvo vertinami 0 arba 1 priklausant nuo to ar duomenų rinkinys atitinka pasirinktą atributą. Rezultatai yra pateikti 3 lentelėje, iš kurios galima matyti, kad būtent medicinos segmentavimo dekatlono duomenų rinkinys vienintelis atitinka visus 5 kriterijus. Šis sprendimas buvo priimtas dėl rinkinio universalumo ir įvairiapusiškumo, leidžiančio taikyti modelius plačiame ligų ir organų spektre. Šis duomenų rinkinys apima įvairius medicininius vaizdus, kurie tinka tiek segmentavimo, tiek kitoms sudėtingoms analizėms, taip suteikiant galimybę atlikti išsamius tyrimus. Be to, duomenų žymėjimus atliko patyrė ekspertai, o tai garantuoja jų tikslumą ir patikimumą, kas yra ypač svarbu medicininių vaizdų analizėje. Kita vertus, kiti du rinkinių variantai neatitiko visų kriterijų - jų taikymų sritys buvo siauresnės, o žymėjimų prieinamumas ir kokybė riboti. Šie trūkumai galėtų neigiamai paveikti mokymo procesą ir modelio efektyvumą. Todėl medicinos segmentavimo dekatlono rinkinys pasirinktas kaip tinkamiausias šio tyrimo tikslams pasiekti.

3 lentelė. Duomenų rinkinių palyginamoji lentelė

Atributas	Dekatlonas	Vėžio archyvas	Kaggle
Taikymo sritis	1	0	1
Vaizdų įvairovė	1	1	1
Vaizdų sudėtingumas	1	1	1
Žymėjimų kokybė	1	1	0
Žymėjimų prieinamumas	1	0	0

4. Susijusių darbų analizė

Medicininių vaizdų segmentavimo srityje pusiau prižiūrimi mokymosi metodai atlieka esminį vaidmenį sprendžiant ribotų pažymėtų duomenų problemą. Šiame skyriuje nagrinėjami reikšmingi pusiau prižiūrimo mokymosi metodai, tokie kaip, generatyviniai besipriešinantys tinklų modeliai, nuoseklumo reguliavimo metodai bei kelių kadrų mokymasis.

4.1. Pusiau prižiūrimo mokymosi metodai

Pusiau prižiūrimas mokymasis yra tarpinis metodas tarp prižiūrimo ir neprižiūrimo mokymosi, naudojantis tiek pažymėtus, tiek nepažymėtus duomenis. Šis mokymasis sumažina pažymėtų duomenų poreikį, kartu išlaikydamas aukštą modelio našumą. 9 paveikslėlyje pateikiami egzistuojantys pusiau prižiūrimo mokymosi metodai, skirti medicininių vaizdų segmentavimui [JZD+23].

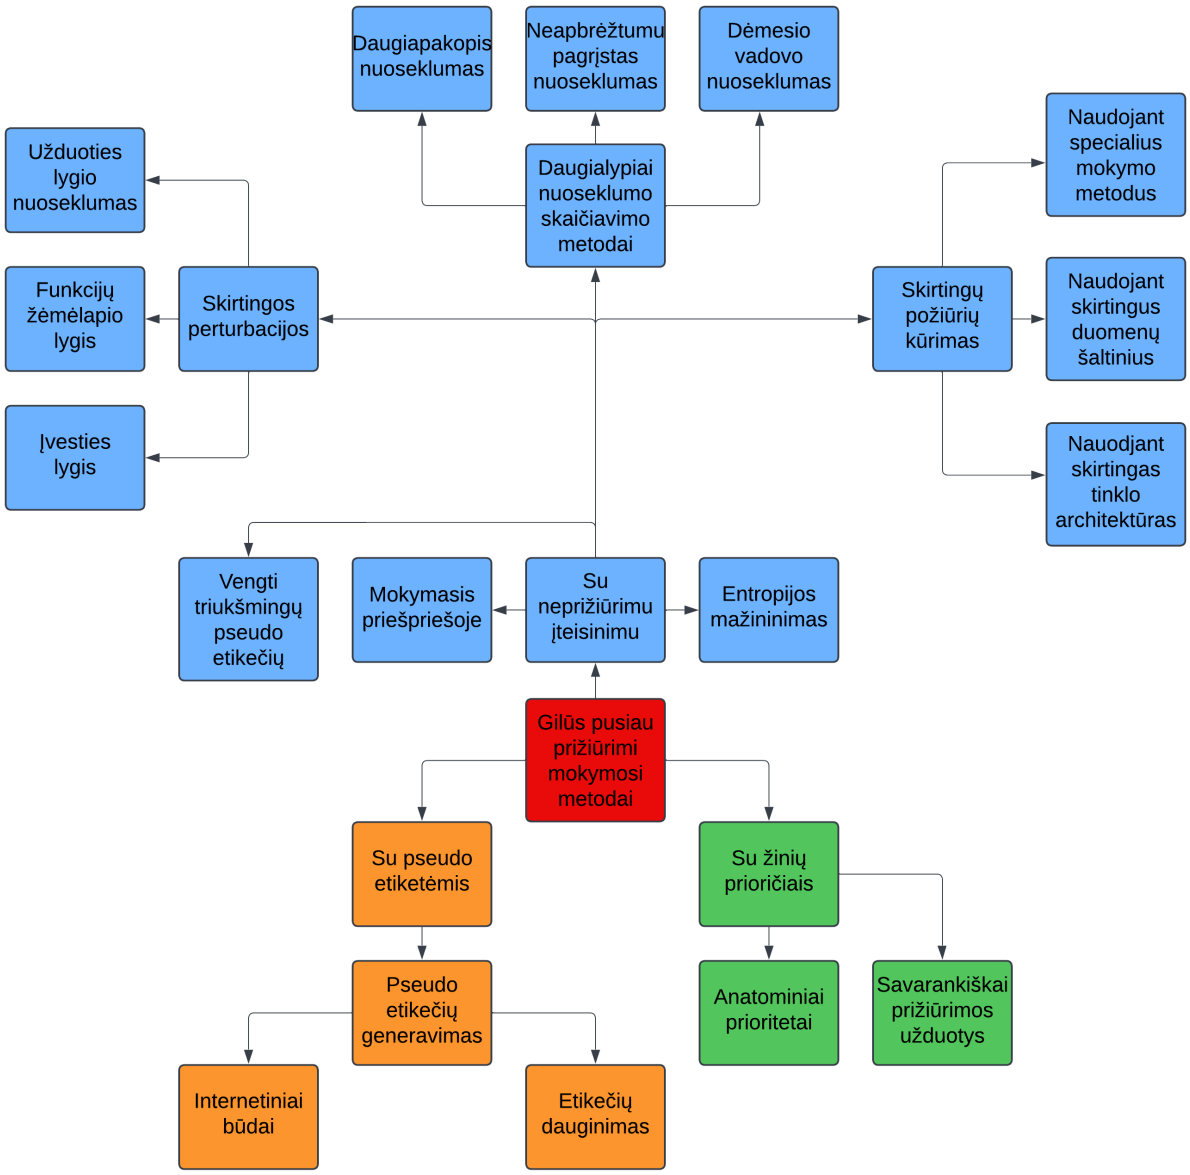

9 pav. Pusiau prižiūrimo mokymosi metodai, skirti medicininių vaizdų segmentavimui

4.1.1. Nuoseklumo reguliavimo metodai

Pagrindinis nuoseklumo reguliavimo metodų (*Consistency Regularization Methods*) principas yra užtikrinimas, kad esant įvairioms įvesties modifikacijoms modelio prognozės išliktų nepasikeitusios. Vienas iš tokių metodų yra fiksuotas atitikmuo (*FixMatch*) [SBL+20]. Neprižiūrimo mokymosi nuostolio funkcija, kurią siekiama optimizuoti taikant fiksuoto atitikmens metodą atitinka procesą, kurio metu nepažymėtas vaizdas yra per naudojamas dviejuose srautuose, kuriuose vaizdas yra skirtingai augmentuojamas. Pirmame sraute pradinis vaizdas yra silpnai augmentuojamas bandant vaizdą apkarpyti, pasukti kampu ar apversti vertikaliai arba horizontaliai. Tikslas yra sukurti naujų vaizdų papildančių mokymosį imtį. Turint pakankamai vaizdų, duomenys yra perleidžiami per modelį, kuriant įvairiausias prognozes, o geriausia iš jų yra pasirenkama kaip pseudo etiketė. Tuo tarpu antrame sraute vaizdas yra stipriai augmentuojamas, kurio metu siekiama kuo drastiškiau pakeisti pradinį vaizdą, kad generuojamas vaizdas taptų kuo neįprastesnis. Tai bandoma pasiekti keičiant spalvas, pikselius vietomis, vaizdo ryškumo modifikacijomis bei kontrasto pakeitimais. Taip pat kaip ir pirmame sraute esant pakankamai duomenų, jie yra perleidžiami per tą patį modelį. Ir būtent šitoje vietoje yra panaudojama pirmame sraute pasirinkta pseudo etiketė, kuri yra pritaikoma tarytum tikroji vaizdo žymė skaičiuojant nuostolio funkcijos koeficientą, kuris yra išreikštas 2 formule.

$$l = \mathrm{l}_s + \lambda_u \mathrm{l}_u \tag{2}$$

Formulėje yra panaudojama silpnai augmentuotų pažymėtų vaizdų kryžminės entropijos nuostolio funkcija, kuri yra išreikšta 3 formule.

$$\mathrm{l}_s = \frac{1}{B} \sum_{b=1}^{B} H(\mathrm{p}_b, \mathrm{p}_m(y|a(\mathrm{x}_b))) \tag{3}$$

Čia *B* – pažymėtų vaizdų imtis, *H(p, q)* – kryžminė entropija, p_b – etiketės, $p_m(y|x)$ – prognozuojamas klasės pasiskirstymas, gautas pagal modelį x, *a* – silpnoji augmentacija. Tada yra pridedama sandauga, skaliarinio hiperparametro – λ_u, kuris žymi nepažymėto nuostolio svorį, ir neprižiūrimo nuostolio funkcijos koeficiento, kuris yra išreikštas 4 formule.

$$\mathrm{l}_\mu = \frac{1}{\mu B} \sum_{b=1}^{\mu B} 1(max(\mathrm{q}_b \geq \tau) H(\mathrm{q}^*{}_b, \mathrm{p}_m(y|A(\mu_b)))) \tag{4}$$

Čia μB – nepažymėtų vaizdų imtis, q_b – pseudo etiketė, τ – pseudo etiketės kokybės slenkstis, *A* – stiprioji augmentacija, *H(p, q)* – kryžminė entropija, $p_m(y|x)$ – prognozuojamas klasės pasiskirstymas, gautas pagal modelį x, $q^*{}_b$ – pseudo etiketė.

Metodą galima suprasti ir kitaip, įsivaizduokime, kad du srautai būtų pasirinkti taip, kad pirmame vaizdas būtų iš vis nepakeistas ir skirtas tik pseudo etiketės generavimui. Tada antrame sraute pradinis vaizdas būtų augmentuotas ir modelio vykdymo metu būtų panaudota pseudo etiketė skaičiuojant nuostolio koeficientą. Iš esmės fiksuoto atitikmens metodas naudoja dvigubą augmentaciją dėl mokymosi imties papildymo esant mažam kiekiui pradinių duomenų. Pagrindinė šio metodo

esmė yra mokėjimas priskirti tą pačią etiketę stipriai bei silpnai augmentuotui vaizdui su prielaida, kad abiejų vaizdų pradinis vaizdas yra tas pats, nepriklausomai ant kiek stipriai yra pasikeitęs stipriai augmentuotas vaizdas. Kitaip sakant, siekiama ignoruoti įvesties modifikacijas modelio prognozavimo metu. Atliktų eksperimentų [SBL+20] metu buvo pastebėti veikimo efektyvumo proveržiai taikant fiksuoto atitikmens metodą su CIFAR-10 duomenų rinkiniu, kuriame buvo tik 250 pažymėtų duomenų. Metodas sugebėjo pasiekti 94,93 % tikslumą. Tai yra įspūdingas tikslumas, kadangi kiti metodai, kurie modelio mokymosi procesui buvo panaudoję apie 50000 vaizdų sugebėjo pasiekti tik 97 % tikslumą, kas yra 2 % daugiau, tačiau esant 200 kartų daugiau duomenų [SBL+20]. Kito eksperimento metu modelis turėjo tiktai 10 vaizdų su tikrosiomis etiketėmis ir netgi esant tokiems mažiems skaičiams, modelio tikslumas siekė 78 %, o labiausiai tai įtakojo, kad pradiniai 10 vaizdų buvo pasirinkti taip, kad jie būtų geriausi savo klasės atstovai su geriausiai klasifikuojamu vaizdu. Viena iš priežasčių dėl kurių šitas metodas yra ant tiek efektyvus yra teisingai pasirinkta augmentacijos strategija [SBL+20], kurios pasirinkimas lėmė tai, kad klaidos koeficientas esant 250 vaizdams su etiketėmis siekė tik 4 %, tuo tarpu pasirenkant kitas strategijas koeficientas išauga per 2 % kas yra nemažai. Modelio reprezentacija yra pateikta 10 paveikslėlyje.

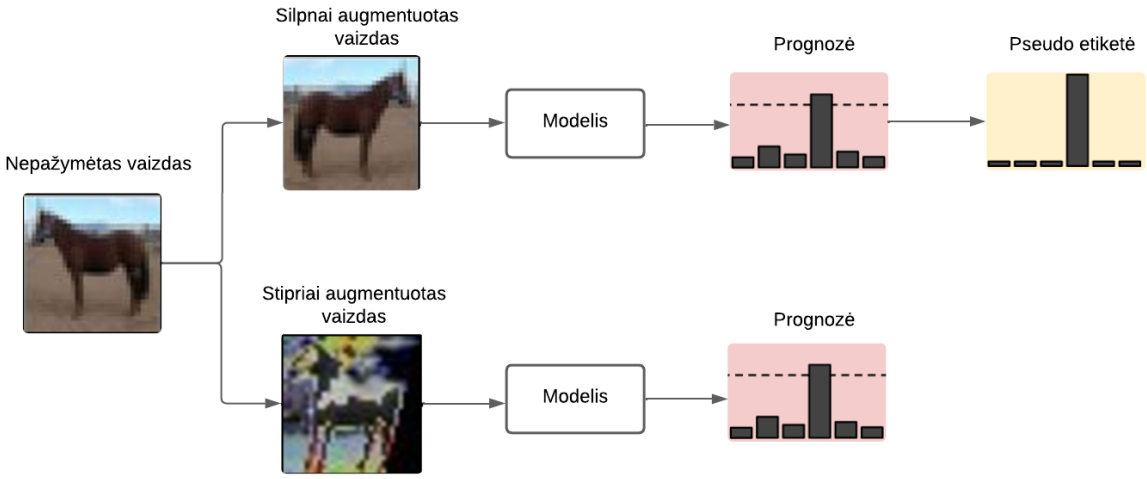

10 pav. Fiksuoto atitikmens modelis (FixMatch)

Sekantis metodas priklausantis nuoseklumo reguliavimo metodams yra vidutinio mokytojo (*Mean Teacher*) metodas [TV17]. Šio metodo įvestis susideda iš vaizdo bei to vaizdo žymės. Metodas tikisi, kad jeigu vienas modelis atlieka tam tikrą prognozę tai ant tų pačių duomenų ir kitas metodas turi atlikti tokias pačias prognozės bandant išlaikyti bendrą nuoseklumą. Būtent šis principas leidžia apskaičiuoti nuoseklumo nuostolio koeficientą. Pirmasis modelis yra laikomas studento, kuris pastoviai bando mokytis iš antrojo modelio, kuris yra laikomas mokytojo. Studento modelio pagrindinė užduotys yra dirbti su pažymėtais duomenimis ir nuolatos lyginant su mokytojo modelio prognozėmis bandyti išlikti nuosekliam. Abu šie modeliai turi skirtingus parametrus bei triukšmo koeficientus. Nuoseklumo sąvoka šiame kontekste apibrėžiama per nuostolio funkciją, kuri įvertina, kiek mokytojo modelio prognozės yra suderintos su studento modelio prognozėmis. Šis suderinamumas vertinimas, kai abu modeliai dirba su tais pačiais vaizdais, tačiau skirtingais taikomais triukšmo lygiais. Ši nuoseklumo nuostolio funkcija išreikšta 5 formule.

$$J(\theta) = \mathrm{E}_{x,\eta',\eta}[||f(x,\theta',\eta') - f(x,\theta,\eta)||^2] \tag{5}$$

Čia J – nuostolio funkcija, θ – studento modelio svoriai, θ' – mokytojo modelio svoriai, η – studento modelio triukšmas, η' – mokytojo modelio triukšmas, x – duomenų pavyzdys, naudojamas prognozei apskaičiuoti.

Tačiau tik nuostolio paskaičiavimo neužtenka kadangi jeigu mokytojo modelio svoriai yra lygūs studento modelio svoriams ir abiejuose modeliuose nėra pritaikytas joks triukšmas tai reiškia, kad pagal formulę gautas skirtumas yra lygus savęs atimčiai. O tai reiškia, kad esant tokioms sąlygoms mokymosi metu modelis suras patį paprasčiausią modelį, kuris bus gautas tuomet kai formulėje esanti funkcija f bus lygi kažkokiai konstantai arba dar paprasčiau lygi nuliui. O tai reiškia, kad modelis ne bus sėkmingas. Norint išvengti tokio scenarijaus reikalingas triukšmo įvedimas į mokymosi procesą, o tai gali būti pasiekta su duomenų augmentacija, pavyzdžiui: duomenų pasukimas, apvertimas, Gauso triukšmo pritaikymas, atmetimo koeficiento panaudojimas. Bet netgi visų šių pakeitimų nėra gana norint garantuoti, kad modelis nesuras pačio primityviausio sprendimo. Norint garantuoti efektyvų modelio veikimą būtina atsižvelgti į dar kelis faktorius, tokius kaip, studento modelis visada turės savyje kryžminės entropijos koeficientą, kuri reikia sudėti su mokytojo modelio nuostolio funkcija, kuri dar yra padauginta iš svorių pirmumo koeficiento apibrėžiant pirmumą, kuri bandome suteikti modelio nuostolio koeficientui. Tai reiškia, kad mokymosi pradžioje mes absoliučiai ignoruojame nuoseklumą tarp dviejų modelių, tačiau proceso metu mes po truputį nuosekliai bandome suvienodinti studento ir mokytojo modelius. Vidutinio mokytojo modelio reprezentacija yra pateikta 11 paveikslėlyje.

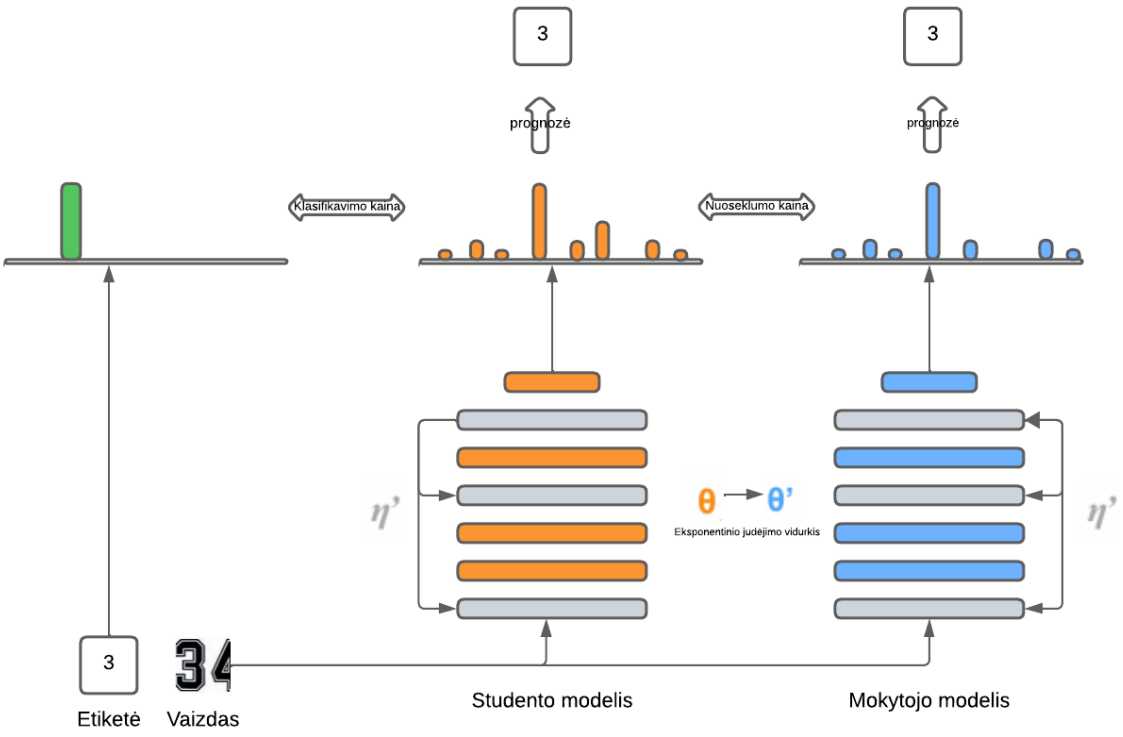

11 pav. Vidutinio mokytojo modelis

Eksperimentai [TV17], atlikti naudojant vidutinio mokytojo metodą, buvo skirti patikrinti metodo veiksmingumą ir palyginti jį su kitais pusiau prižiūrimo mokymosi metodais. Eksperimentai buvo atliekami su SVHN ir CIFAR-10 duomenų rinkiniais, kuriuose naudojamos 32x32 pikselių RGB vaizdai, priskirti dešimčiai skirtingų klasių. SVHN duomenų rinkinys sudarytas iš 73257 mokymo pavyzdžių ir 26032 testavimo pavyzdžių, o CIFAR-10 sudarytas iš 50000 mokymo pavyzdžių ir 10000 testavimo pavyzdžių. Eksperimentai buvo atlikti naudojant 13 sluoksnių konvoliucinių tinklų (*ConvNet*) architektūrą, kurioje buvo taikomi trijų tipų triukšmai: atsitiktinės įvesties paveikslėlių transformacijos ir horizontali inversija, Gauso triukšmas įvesties sluoksnyje ir atmetimo funkcijos (*dropout*) naudojimas tinklo viduje. 4 lentelėje pateikti vidutinio mokytojo metodo eksperimentų rezultatai, kuriuose parodyta, kaip keičiasi metodo tikslumas naudojant SVHN duomenų rinkinį su įvairiais papildomų nepažymėtų vaizdų kiekiais modelio mokymuisi.

4 lentelė. Gautų klaidų rezultatai atlikus dešimt iteracijų su SVHN duomenimis [TV17]

Metodas	500 etikečių 73257 vaizdai	500 etikečių 173257 vaizdai	500 etikečių 573257 vaizdai
Vidutinis mokytojas	$4{,}18 \pm 0{,}27$	$3{,}02 \pm 0{,}16$	$2{,}46 \pm 0{,}06$

Dar vienas metodas grįstas nuoseklumo reguliavimo mokymusi ir pseudo žymėjimais yra netikrumu grįstas bendradarbiaujantis vidutinio mokytojo metodas (Uncertainty-guided Collaborative Mean-Teacher) [SCY+23]. Ši metodą sudaro du pagrindiniai komponentai, bendradarbiaujantis vidutinis mokytojas, kuris yra atsakingas už modelio nesutarimų skatinimą ir už bendrą mokymą tarp potinklių bei neapibrėžtumu grindžiamas regionų mišinys, kuris skirtas manipuliuoti įvesties vaizdais pagal bendradarbiaujančio vidutinio mokytojo neapibrėžtumo kuriamais žemėlapiais ir palankesnių sąlygų sudarymas tam, kad būtų sukurtos aukšto tikslumo pseudo etiketės. Modelio mokymosi etapas pateiktas 12 paveikslėlyje.

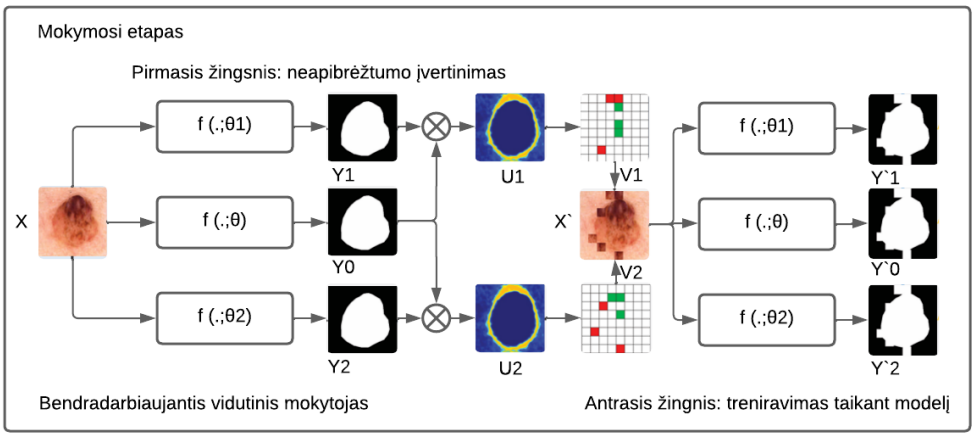

12 pav. Bendradarbiaujantis vidutinio mokytojo modelis

Modelis susideda iš vieno mokytojo modelio ($f(.;\theta)$) ir dviejų studentų modelių ($f(.;\theta 1)$) ir ($f(.;\theta 2)$). Visi trys modeliai turi tokią pačią architektūrą, tačiau inicializuoti skirtingai pritaikant

skirtingus svorius įvesties modifikacijoms. Pažymėtiems duomenims, visi modeliai yra optimizuoti taikant prižiūrimą mokymąsi. Dirbant su nepažymėtais duomenimis, atsižvelgiama į du svarbius aspektus, vykdomas abipusis mokymasis tarp dviejų studentų modelių ir taikoma tiesioginė mokytojo modelio priežiūra studentų modeliams. Ši priežiūra reiškia, kad mokytojo modelio prognozės naudojamos kaip papildomas mokymosi signalas studentų modeliams, siekiant pagerinti jų bendrą mokymosi kokybę ir stabilumą. Tokiu būdu studentų modeliai ne tik mokosi vienas iš kito, bet ir siekia išlikti nuoseklūs su mokytojo modelio prognozėmis, net kai yra taikomi skirtingi triukšmo lygiai ar duomenų transformacijos. Analizuojant tiek pažymėtus duomenis, tiek nepažymėtus norint apskaičiuoti nuostolio funkciją bendradarbiaujančio vidutinio mokytojo metodo yra taikoma 6 formulė.

$$L = \mathrm{L}_s + \lambda \mathrm{L}_u \tag{6}$$

Pažymėtiems duomenims skaičiuojant prižiūrimą nuostolio koeficientą yra naudojama 7 formulė.

$$\mathrm{L}_s = \frac{1}{N} \sum_{i=1}^{N} \mathrm{L}_{seg}(f(\mathrm{X}_i; \theta_1), \mathrm{Y}_i) + \mathrm{L}_{seg}(f(\mathrm{X}_i; \theta_2), \mathrm{Y}_i) \tag{7}$$

Čia L_{seg} – gali būti bet koks prižiūrimo semantinio segmentavimo nuostolis, pavyzdžiui, kryžminės entropijos nuostolis ar Dice nuostolis, Y_i – tikroji vaizdo žymė, N – nepažymėtų duomenų imtis, $f(X_i; \theta_1)$ – pirmas studento modelis, $f(X_i; \theta_2)$ – antras studento modelis, X_i – įvesties duomenys, tai yra, vaizdai.

Taikyto metodo atveju buvo pasirinkta naudoti Dice nuostolį [SCY+23]. Tuo tarpu neprižiūrimas nuostolis yra išreikštas 8 formule, kurioje yra skaičiuojama suma, kryžminio pseudo nuostolio tarp dviejų studentų modelių, kuris yra išreikštas 9 formule ir vidutinio mokytojo nuostolio, kuris yra apskaičiuojamas pagal 10 formule.

$$\mathrm{L}_u = \mathrm{L}_{cps} + \mathrm{L}_{mts} \tag{8}$$

Kryžminės pseudo priežiūros nuostolio tikslas yra priversti studentų modelius mokytis vienas iš kito išlaikant nuoseklumą.

$$\mathrm{L}_{cps[1/2]} = \frac{1}{M-N} \sum_{j=1}^{M-N} \mathrm{L}_{seg}(f(\mathrm{X}_j; \theta_{[1/2]}), \mathrm{Y}_j^{[2/1]}) \tag{9}$$

Čia M – pažymėtų duomenų imtis, N – nepažymėtų duomenų imtis, L_{seg} – gali būti bet koks prižiūrimo semantinio segmentavimo nuostolis, $f(X_j; \theta_{[1/2]})$ – pirmo ir antro studento modeliai, $Y^{[2/1]}{}_j$ – pseudo segmentavimo žemėlapiai išprognozuoti studentų modelių, X_j – nepažymėti duomenys.

Vidutinio mokytojo priežiūros nuostolio užduotis yra neleisti studentų modeliams blogai bendradarbiauti, kitaip sakant tikslas yra valdyti ir optimizuoti studentų modelių veikimą.

$$\mathrm{L}_{mts[1/2]} = \frac{1}{M-N} \sum_{j=1}^{M-N} \mathrm{L}_{seg}(f(\mathrm{X}_j; \theta_{[1/2]}), \mathrm{Y}_j^0) \tag{10}$$

Čia M – pažymėtų duomenų imtis, N – nepažymėtų duomenų imtis, L_{seg} – bet koks prižiūrimo semantinio segmentavimo nuostolis, $f(X_j; \theta_{[1/2]})$ – pirmo ir antro studento modeliai, ${Y^0}_j$ – segmentavimo žemėlapis išgautas iš mokytojo modelio, X_j – nepažymėti duomenys.

Eksperimentai [SCY+23] buvo atlikti naudojant tokius duomenų rinkinius, kaip ISIC, kuris yra sudarytas iš 2594 dermoskopijos vaizdų bei Kvasir-SEG, kuris yra sudarytas iš 1000 kolonoskopijos vaizdų. Taikant šiuos duomenų rinkinius buvo pasiekti rezultatai, kurie yra pateikti 5 lentelėje skaičiuojant Dice koeficientą su 5 % ir 10 % pažymėtų duomenų pritaikant trys skirtingus metodus.

5 lentelė. Bendradarbiaujančio vidutinio mokytojo metodo tikslumas [SCY+23]

Metodas	5 % pažymėtų duomenų	10 % pažymėtų duomenų
Netikrumu grįstas bendradarbiaujantis vidutinio mokytojo metodas	88,22	88,46
Netikrumu grįstas bendradarbiaujantis vidutinio mokytojo metodas (U-Net)	82,14	83,33
Bendradarbiaujantis vidutinio mokytojo metodas	87,86	88,10

4.1.2. Generatyvinis besipriešinantis tinklas

Generatyvinis besipriešinantis tinklas (*Generative Adversarial Network*) yra dalis neprižiūrimo mokymosi, kuris yra sudarytas iš dviejų submodelių: generatoriaus modelio bei diskriminatoriaus modelio [YSK+23]. Generatoriaus tikslas yra kurti netikrus vaizdus, tuo tarpu diskriminatoriaus modelio tikslas yra nustatyti ar analizuojamas vaizdas yra paimtas iš tikrojo duomenų rinkinio ar vaizdas buvo sugeneruotas generatoriaus modelio. Ir būtent šitame procese ir glūdi besipriešinančio tinklo apibrėžimas. Toks procesas dažniausiai yra sutinkamas ir pritaikomas vaizdų generavime [Ode16]. Šio procesu metu diskriminatoriaus modelis yra mokomas paduodant tikruosius vaizdus iš duomenų rinkinio analizuojant spalvas, formas, šešėlius. Ir tik tada kai diskriminatoriaus modelis sugeba gerai atpažinti vaizdus į jį yra paduodami papildomi vaizdai, kurie nėra sugeneruoti, tačiau jie priklauso visai kitai analizuojamai klasei, norint užsitikrinti, kad diskrimatorius susidoroja su savo darbu. Ir būtent tada kai yra užtikrinta, kad diskriminatoriaus modelis yra pakankamai geras į procesą įsijungia generatoriaus modelis, kuris pradeda generuoti netikrus vaizdus. Šie vaizdai tada keliauja į patį diskriminatoriaus modelį, kuriame atliekamas sprendimas ar gautas vaizdas yra tikras, paimtas iš duomenų rinkinio, ar jis buvo sugeneruotas. Visas šis tinklas yra grįstas nulinės sumos žaidimu (*Zero Sum Game*), tai reiškia, kad tinkle visada yra laimėtojas bei pralaimėtojas. Laimėjimo atveju vienas iš modelių neturės nieko keisti, tuo tarpu pralaimėtojas turės patobulinti esamą modelį. Kitaip sakant, jeigu diskriminatorius nusprendžia, kad vaizdas buvo sugeneruotas, tai reiškia, kad generatorius turi atsinaujinti taip, kad sekantis sugeneruotas vaizdas būtų nebe

atspėtas, ir atvirkščiai, jeigu generatorius sugeneravo tokį vaizdą, kuris sugebėjo apgauti diskriminatorių, tai reiškia, kad būtent diskrimatoriaus modelis turi būti atnaujintas. Ir toks procesas yra kartojamas daug iteracijų, iki tol kol generatoriaus modelis moka sugeneruoti tokius vaizdus, kurie nėra atpažįstami teisingai diskriminatoriaus modelio. Tačiau generatyvinis besipriešinantis tinklas nėra tiesiog asocijuojamas su gebėjimu generuoti vaizdus, kurie būtų nebeatpažįstami diskriminatoriaus. Toks tinklas gali būti pritaikytas ir kitiems poreikiams, pavyzdžiui: bandymas nuspėti labai artimą ateitį, kai į tinklą yra paduodama vaizdo įrašo tam tikra dalis, taip pat vaizdo rezoliucijos perdarymas iš prastos į gerą bei galiausiai tinklo panaudojamumas šifravimo algoritmo kūrimo procese.

4.1.3. Priešpriešos nuoseklumo mokymasis

Priešpriešos nuoseklumo mokymosi (*Adversarial Consistency Learning*) vienas iš metodų yra ASE-Net, kuris susideda iš segmentavimo tinklo bei diskriminatoriaus tinklo [LZD+23]. Segmentavimo tinkle yra pritaikomi du modeliai, studento bei mokytojo. Studento modelis turi tokią pat struktūrą kaip ir mokytojo ir abu jie yra grindžiami koduotojo-dekoduotojo struktūra. Skirtumas tik tas, kad studento modelis mokosi pagal nuostolio funkciją, o mokytojo modelis pagal eksponentinį slankųjį studento modelio svorių vidurkį (*EMA*). Tuo tarpu diskriminatoriaus tinklas susideda iš konvoliucinių sluoksnių ir globalaus vidurkio buferizavimo. Šiame modelyje yra naudojama priešpriešos nuoseklumo mokymosi strategija (*ACTS*) išgaunant išankstines žinias iš nepažymėtų duomenų. Modelis naudoja du diskriminatorius, turinčius vienodą struktūrą, tačiau jų atliekamas darbas yra skirtingas. Pirmasis diskriminatorius išmoksta informaciją apie prognozuojamą kokybės nuoseklumą segmentavimo tinkle skirta tiek nepažymėtiems, tiek pažymėtiems duomenims. Tuo tarpu antrasis diskriminatorius išmoksta informaciją apie studento ir mokytojo tinklų prognozuojamą nuoseklumą su tais pačiais įvesties duomenimis tačiau su skirtingomis modifikacijomis. Svarbu paminėti, kad ASE-Net diskriminatorių tinklas kaip įvestį naudoja ne tik originalius vaizdus, tačiau ir segmentuotus rezultatus. Tokiu būdu, segmentavimo rezultatų kokybę galima vertinti naudojant originalų vaizdą kaip lyginamąjį standartą. Kalbant apie pačią tinklo struktūrą, tai yra pritaikytas DyBAC [LZD+23] vietoj konvoliucinių sluoksnių išskyrus pirmąjį sluoksnį segmentavimo bei diskriminatoriaus tinkle. Toks DyBAC panaudojamumus suteikia galimybę pagerinti savybių reprezentaciją tinkle bei sumažinti persimokymo riziką (*overfitting*). Be to, segmentavimo ir diskriminatoriaus tinklas yra mokomas pakaitomis, tačiau pradiniame etape diskriminatoriai iš vis nėra taikomi, taip sumažinant skaičiavimų resursų išlaidas.

Nors nuoseklus mokymasis ir priešiškas mokymasis yra naudingi atliekant pusiau prižiūrimo vaizdo segmentavimo užduotis, šie metodai vis dar turi tam tikrų apribojimų. Visų pirma, standartinis pusiau prižiūrimas vaizdo segmentavimo tinklas naudoja nuoseklumo strategijas taikant tam tikras įvesties modifikacijas bandant kontroliuoti modelio mokymąsi. Tokie tinklai dažniausiai ignoruoja ankstesnį ryšį tarp pažymėto ir nepažymėto vaizdo. Be to, tokie metodai skaičiuoja tik pikselių lygio nuoseklumą dirbant su nepažymėtais duomenimis kas gali privesti prie netikslingų prognozių. Taip pat, priešpriešos mokymusi pagrįsti metodai pernelyg priklauso nuo vieno segmentavimo bei vieno diskriminatoriaus tinklo. Būtent šioms problemoms spręsti buvo pasiūlytas

ASE-Net metodas, kurio reprezentacija yra pateikta 13 paveikslėlyje. Visų pirmą, medicininiai vaizdai yra pateikiami į segmentavimo tinklą, kad būtų išgauti segmentavimo prognozių žemėlapiai. Tada, šie prognozių žemėlapiai yra sujungiami su originaliu vaizdu ir pateikiami į diskriminatoriaus tinklą. Viskas ką padaro diskriminatoriaus tinklas yra priimtas sprendimas ant kiek vaizdas yra kokybiškas, jeigu jis yra prastas, tai reikšmė bus arčiau 0 ir atvirkščiai, jeigu geras, tai arčiau 1. ASE-Net modelio nuostolis yra išreikšta 11 formule.

$$\mathrm{L}_g(\theta) = \mathrm{L}_s(\mathrm{y}^*{}_i,\mathrm{y}_i) + \lambda(\mathrm{L}_{semi}(\mathrm{y}^*{}_u, \mathrm{y}^*{}_{ema})) + \mathrm{L}_{ad1}(\mathrm{D}_1(\mathrm{x}_u,\mathrm{y}^*{}_u),1)) + \mathrm{L}_{ad2}(\mathrm{D}_2(\mathrm{x}_u,\mathrm{y}^*{}_u),1)) \quad (11)$$

Čia D_1 – pirmasis diskriminatorius, D_2 – antrasis diskriminatorius, L_s – priežiūros nuostolis, L_{semi} – nuoseklumo nuostolis, (L_{ad1}, L_{ad2}) – priešpriešos nuostolis, y_i – vaizdo etiketė atitinkanti x_i, x_u – nepažymėtas vaizdas pritaikant modifikacijas, $y^*{}_i$ – pažymėtų duomenų segmentavimo rezultatai, $y^*{}_u$ – nepažymėtų duomenų segmentavimo rezultatai, $y^*{}_{ema}$ – mokytojo modelio prognozė, λ – svorio koeficientas.

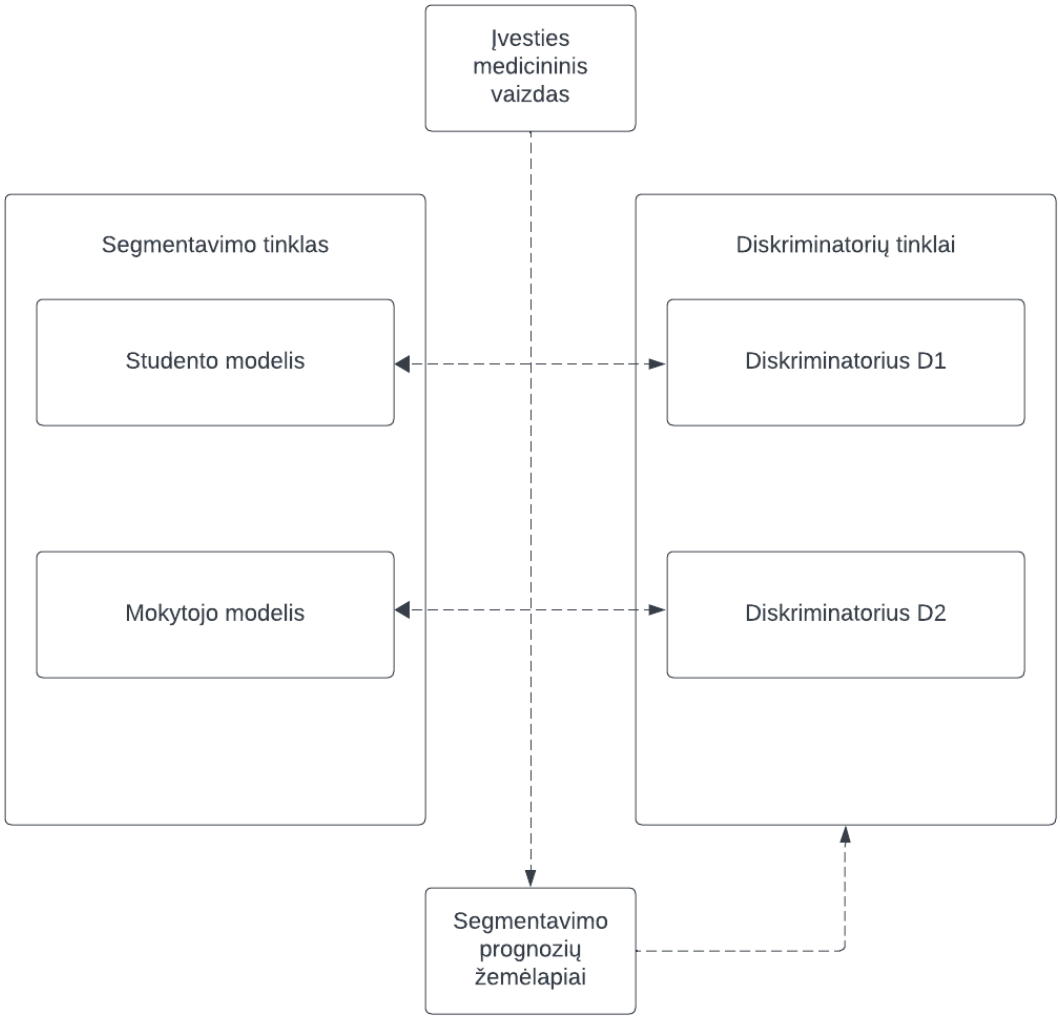

13 pav. Supaprastintas ASE-Net modelis

Eksperimentai [LZD+23] buvo atliekami su trimis skirtingais medicininių vaizdų duomenų rinkiniais: kepenų kompiuterinės tomografijos vaizdais, dermatoskopijos vaizdais ir kairiojo prieširdžio magnetinio rezonanso vaizdais. Eksperimentiniai rezultatai parodė, kad siūlomas metodas žymiai pagerina segmentavimo tikslumą ir bendrą veikimą, lyginant su kitais metodais. Tai atsispindi 6 lentelėje, kur matome, kad ASE-Net pasiekė 94,12 % tikslumą, kas žymiai pagerino rezultatus lyginant su kitais metodais. Šiame eksperimente buvo naudojami 10 % pažymėtų duomenų ir 90 % nepažymėtų duomenų skaičiuojant Dice koeficientą pritaikant penkis skirtingus metodus.

6 lentelė. Eksperimentas - vaizdų santykis 10 % / 90 % [LZD+23]

Metodas	Tikslumas %
MT	92,39
UA-MT	93,14
U-Net	88,17
DTC	93,67
ASE-Net	94,12

4.1.4. Kelių kadrų mokymasis

Kelių kadrų mokymasis (*Few-Shot Learning*) pasirodė kaip veiksminga alternatyva tradicinėms visiškai prižiūrimoms mokymosi strategijoms [FAP+20]. Kelių kadrų mokymosi supaprastina reprezentacija pateikta 14 paveikslėlyje. Mokymasis vyksta pasitelkiant į pagalbą konvoliucinį tinklą (*CNN*) tam, kad modelis galėtų mokytis naujų kategorijų turint tik keletą pažymėtų vaizdų, kurie paprastai vadinami palaikymo vaizdais. Tada žinios gautos iš pagalbinių vaizdų yra panaudojamos segmentuojant vaizdus turinčius naujų kategorijų, klasių, dažniausiai vadinamų užklausomis. Tam, kad modelis galėtų atkurti scenarijų, kuris buvo rastas mokymosi metu, pats tinklas yra apmokytas su pažymėtais duomenimis, o pats procesas yra grįstas epizodinių mokymusi. Kiekviename tokiame žingsnyje yra imama k pažymėtų vaizdų iš n kategorijų formuojant vieną naują epizodą, kuris kaip tik ir yra naudojamas segmentavimo tinklo mokymosi proceso metu. Toks principas, leidžia tinklui mokytis ištraukti naudingą informaciją iš skirtingų epizodų, tačiau neleidžia modeliui specializuotis ties esama užduotimi. Standartiniame kelių kadrų semantiniame segmentavime dalyvauja trys duomenų rinkiniai - mokymosi imtis, pagalbinė imtis bei testinė imtis. Pagrindinis šio mokymosi iššūkis yra susijęs su vaizdų savybių ištraukimu ir jų pritaikymu klasėms kai yra tik keletas pažymėtų duomenų. Norint išspręsti šitą problemą yra siūloma naudoti pagalbinio nuostolio funkcijos integravimą, kuris kompensuotų pažymėtų duomenų trūkumą tam tikrose duomenų klasėse. Be to, kitas variantas būtų surogatinių užduočių integravimas, tokių kaip vaizdo triukšmo šalinimas. Tokiu atveju yra kuriamas naujas papildomas duomenų rinkinys, kuris sudarytas iš nepažymėtų vaizdų pridedant triukšmą, taip sukuriant sintetinius vaizdus. Tikslas tokio duomenų rinkinio yra leisti koduotojo-dekoduotojo tinklui išmokti apjungti sintetinius vaizdus su jų originalais. Visa tai gali būti išreikšta 12 formule, kurioje apibrėžta kryžminės entropijos nuostolio funkcija.

$$\mathrm{L}_{sur}(\theta, \phi; Y^u) = -\frac{1}{\mathrm{N}_u} \sum_{i}^{\mathrm{N}_u} \sum_{J}^{H \times W} \mathrm{X}^U_{i,j} log \mathrm{Y}^{\times U}_{i,j} \tag{12}$$

Čia N_u – nepažymėtų duomenų imtis, $X^U{}_{i,j}$ – duomenų imties vaizdas, $Y^{*U}{}_{i,j}$ – sugeneruotas pažeistas vaizdas, H – vaizdo aukštis, W – vaizdo plotis, ϕ – modelio parametras susijęs su surogatinėmis užduotimis, θ – modelio svoriai, Y^u – nepažymėtų duomenų segmentavimo žemėlapis.

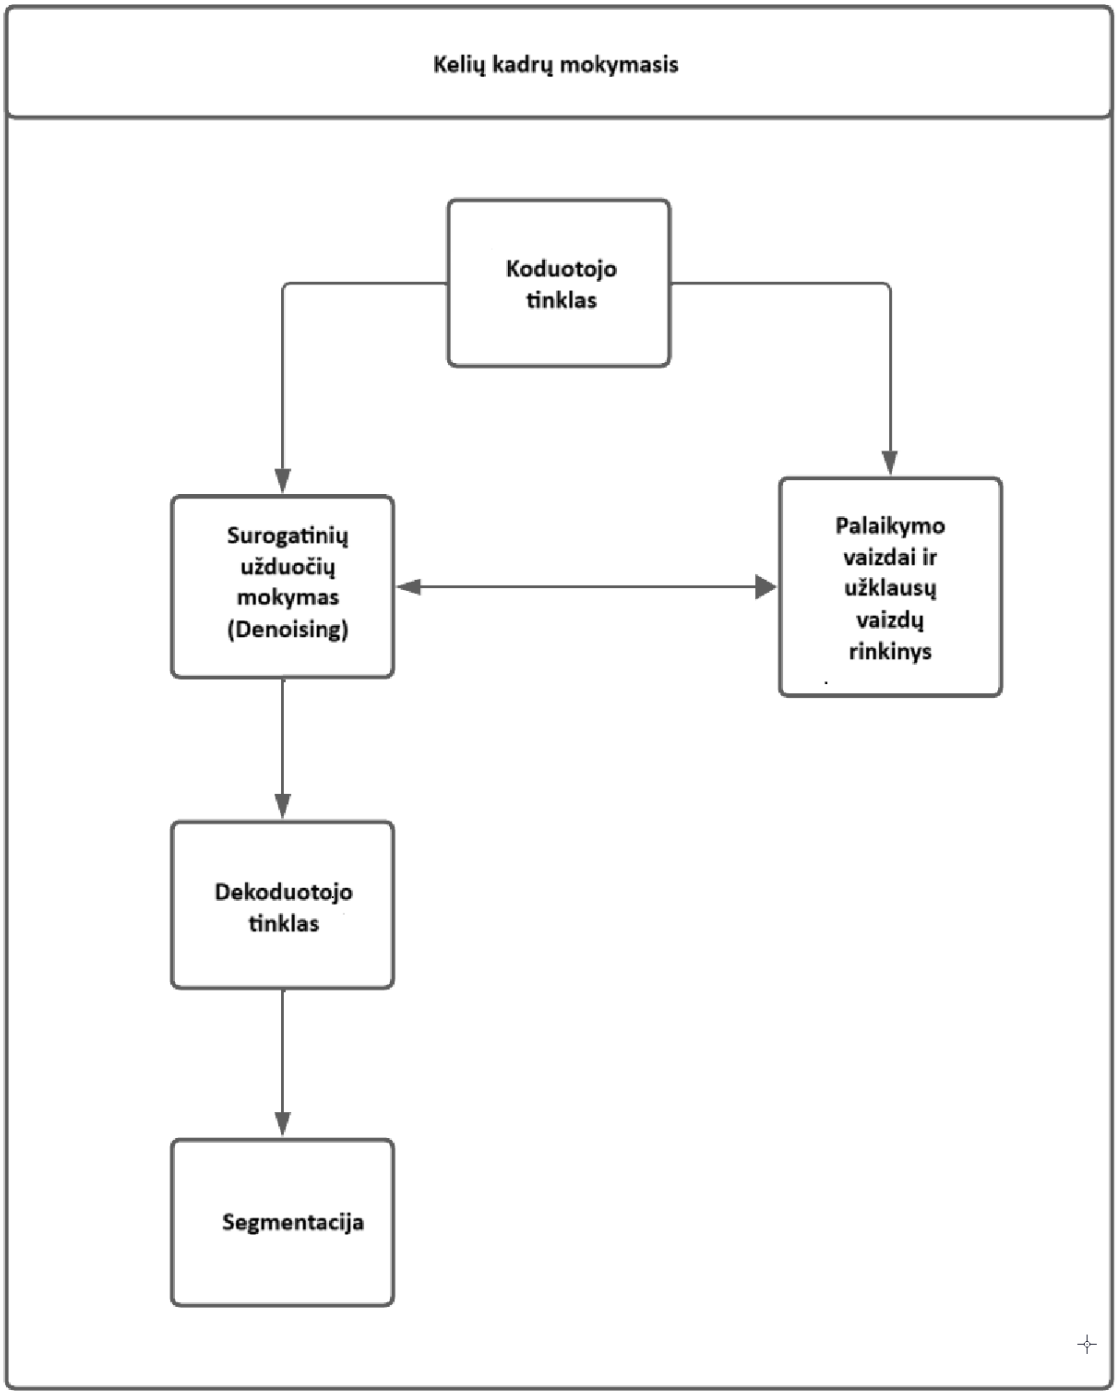

14 pav. Supaprastintas kelių kadrų mokymosi modelis

Siūlomo metodo [FAP+20] veiksmingumas buvo įvertintas naudojant du viešai prieinamus mediciniinių vaizdų rinkinius – ISIC ir PH2, kurie apima odos pažeidimų, melanomų ir kitų odos

darinių vaizdus. Rezultatai parodė reikšmingus patobulinimus lyginant su baziniais modeliais. Rezultatai pateikti 7 ir 8 lentelėse.

7 lentelė. Kiekybiniai 1 bandymo segmentavimo rezultatai ISIC ir PH2 duomenų rinkiniuose [FAP+20]

Modelis	Papildomi pavyzdžiai	ISIC (%)	PH2 (%)
Reguliarus (apatinė riba)	-	48,32	64,72
Keli kadrai	-	54,07	68,13
Keli kadrai + triukšmas	5	61,38	74,12
Keli kadrai + triukšmas	10	61,40	74,67
Keli kadrai + triukšmas	20	60,79	74,77
Reguliarus (viršutine riba)	-	86,65	89,94

8 lentelė. Kiekybiniai 5 bandymų segmentavimo rezultatai ISIC ir PH2 duomenų rinkiniuose [FAP+20]

Modelis	ISIC (%)	PH2 (%)
Keli kadrai	59,63	71,15
Keli kadrai + triukšmas	62,40	75,54

Kaip matome iš rezultatų, įtraukus surogatinę užduotį, skirtą vaizdo triukšmo šalinimui, reikšmingai pagerėja segmentavimo tikslumas tiek 1 bandymo, tiek 5 bandymų scenarijuose. Patobulinimas yra labiau pastebimas 1 bandymo scenarijuje, pabrėžiant metodo efektyvumą.

5. Eksperimentiniai tyrimai

Šiame skyriuje pristatoma išsami pusiau prižiūrimo mokymosi metodų analizė, skirta kasos vėžio segmentavimui kompiuterinės tomografijos vaizduose. Tyrimo esmė – išsiaiškinti, kaip įvairius metodiniai sprendimai, naudojant ribotą pažymėtų duomenų kiekį ir didelį nepažymėtų duomenų kiekį įtakoja segmentavimo tikslumą. Pradiniai modeliai buvo paimti iš viešai prieinamų *Github* šaltinių [LHS+22] [LLC+21] [LCS+21] [LWL+22] ir vėliau modifikuoti bei pritaikyti kompiuterinės tomografijos kasos vėžio segmentavimo uždaviniams spręsti.

5.1. Eksperimentų metodika

Eksperimentiniuose tyrimuose vykdoma pusiau prižiūrimo mokymosi metodų analizė, skirta kasos naviko segmentavimui kompiuterinės tomografijos vaizduose. Tyrimo metu lyginami trys metodai, vidutinio mokytojo metodas, jo patobulinta versija, paremta neapibrėžtumu, ir fiksuoto atitikmens metodas. Siekiant užtikrinti hiperparametrų palyginamumą, visi eksperimentai atliekami naudojant tą pačią duomenų aibę, kiek įmanoma identiškus hiperparametrus ir vienodą mokymosi eigą. Kiekvienas metodas mokomas skirtinguose scenarijuose, kuriuose sistemingai keistas tik vienas veiksnys, pavyzdžiui, duomenų kiekis ar modelio mokymosi sparta, kad būtų galima kiek įmanoma aiškiai įvertinti jo įtaką modelio veikimui.

Eksperimento struktūra prasidėjo nuo duomenų paruošimo, tai yra, vaizdų normalizavimo, augmentavimo ir padalinimo į mokymosi, validavimo ir testavimo aibes. Eksperimentuose iš viso naudota 224 mokymosi vaizdų. Priklausomai nuo scenarijaus, buvo naudojami 7, 21, 25 arba 50 pažymėtų vaizdų, o likusieji – kaip nepažymėti duomenys. Mokymosi etape modeliai treniruojami su mokymosi aibe. Pasibaigus mokymuisi, modeliai vertinami validacijos etape, kurio metu stebimi mokymosi procesą atspindintys rodikliai. Galiausiai testavimo etape modelių veikimas buvo tikrinamas naudojant nematytus duomenis, siekiant objektyviai įvertinti pusiau prižiūrimo mokymosi metodų segmentavimo gebėjimą.

Modelių palyginimui buvo pasirinktos dvi pagrindinės metrikos. Dice koeficientas, kuris nusako segmentų sutapimą tarp modelio rezultato ir teisingo žymėjimo, bei Hausdorff atstumas, parodantis maksimalios paklaidos tarp segmentuotų sričių vidutinę reikšmę. Šios metrikos leido išsamiai įvertinti modelių tikslumą tiek validacijos, tiek testavimo etapuose. Taip pat buvo analizuojamos mokymosi nuostolių kreivės, tokios kaip kryžminės entropijos ir nuoseklumo nuostoliai.

Eksperimentų metu visi metodai buvo vertinami tapačiomis sąlygomis, naudojant vienodus duomenų paruošimo procesus, iteracijų skaičių ir keletas bendrųjų hiperparametrų. Palyginimo struktūra buvo griežtai sisteminga, pirmiausia nustatyti kiekvieno metodo baziniai rezultatai, o vėliau, keičiant skirtingus veiksnius, buvo stebima, kaip šie pokyčiai veikia modelių veikimą. Galiausiai buvo apibendrinti ir palyginti geriausi pasiekti rezultatai tarp skirtingų metodų, leidžiant daryti išvadas apie jų efektyvumą.

Žemiau pateiktoje 9 lentelėje surašyti visų atliktų eksperimentų pavadinimai ir atitinkamos jų santrumpos.

9 lentelė. Eksperimentų santrumpos

Eksperimento pavadinimas	**Santrumpa**
Bazinis vidutinio mokytojo metodas	VM–bazinis
Vidutinio mokytojo metodas – padidinti įvesties vaizdo matmenys	VM–raiška
Vidutinio mokytojo metodas – padidinta pažymėtų duomenų dalis partijoje	VM–partija
Vidutinio mokytojo metodas – padvigubintas pažymėtų duomenų kiekis	VM–duomenys
Vidutinio mokytojo metodas – padidinta mokymosi sparta	VM–sparta
Bazinis neapibrėžtumu grįstas VM metodas	NVM–bazinis
Neapibrėžtumu grįstas VM metodas – padidinti įvesties vaizdo matmenys	NVM–raiška
Neapibrėžtumu grįstas VM metodas – padidinta pažymėtų duomenų dalis partijoje	NVM–partija
Neapibrėžtumu grįstas VM metodas – padvigubintas pažymėtų duomenų kiekis	NVM–duomenys
Neapibrėžtumu grįstas VM metodas – padidinta mokymosi sparta	NVM–sparta
Bazinis fiksuoto atitikmens metodas	FA–bazinis
Fiksuoto atitikmens metodas – koreguota mokymosi sparta	FA–sparta
Fiksuoto atitikmens metodas – padidintas partijos dydis	FA–partija
Fiksuoto atitikmens metodas – patrigubintas pažymėtų duomenų kiekis	FA–duomenys
Fiksuoto atitikmens metodas – nuoseklumas ir jo pagreitis	FA–nuoseklumas

Toliau pateikta UML diagrama apibendrinanti eksperimentų metodiką 15 paveikslėlyje.

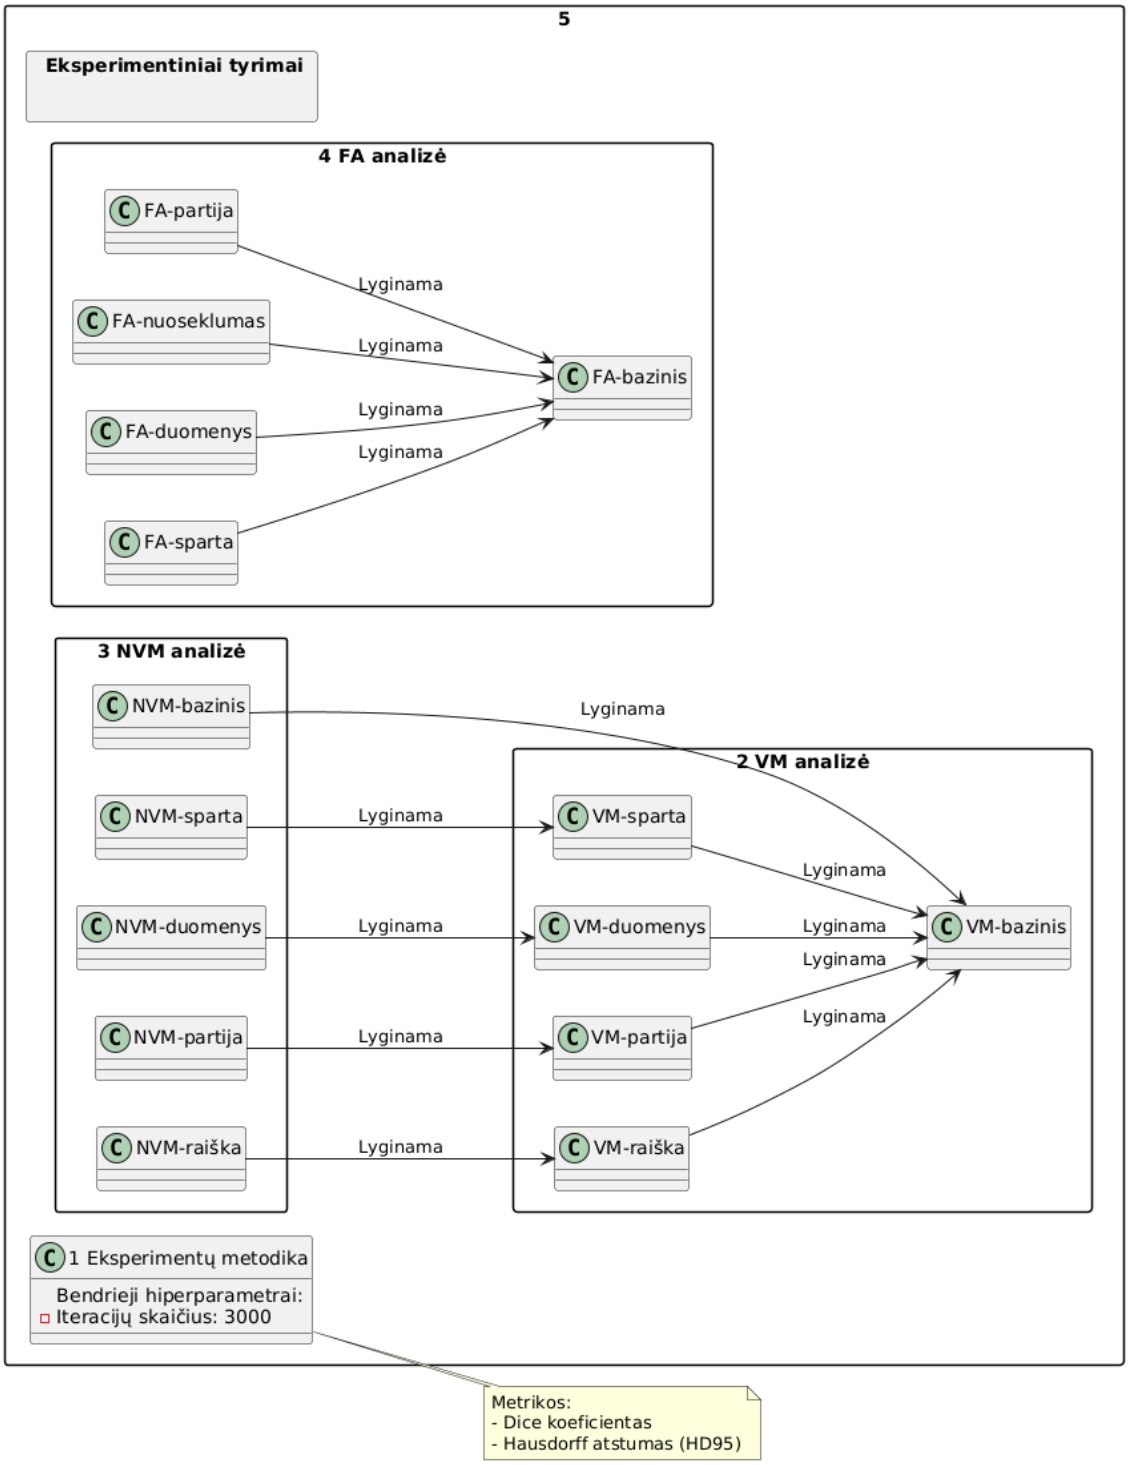

15 pav. UML diagrama atspindinti eksperimentų metodiką

5.2. Vidutinio mokytojo metodo praktinė analizė

Šiame poskyryje išsamiai nagrinėjamas vidutinio mokytojo metodas, pritaikytas kasos vėžio segmentavimo uždaviniams spręsti.

5.2.1. Duomenų paruošimas

Pradiniuose eksperimentuose labai svarbu buvo tinkamai paruošti duomenų rinkinį. Pirminis duomenų apdorojimas prasidėjo nuo kompiuterinės tomografijos vaizdų intensyvumo normalizacijos, siekiant sumažinti pikselių intensyvumo reikšmių skirtumus, kurie galėjo kilti dėl skirtingų skenavimo parametrų ar naudojamos įrangos vaizdų gavimo metu. Be intensyvumo normalizacijos, buvo įgyvendintos ir dominančių regionų (*region of iterest*) išskyrimo procedūros, kurios padeda atskirti kasos audinius nuo likusios pilvo ertmės. Prieš padalijant vaizdus į mažesnius fragmentus, pirmiausia buvo išskirti dominantys regionai pagal turimas vaizdų etiketes, kurios padėjo identifikuoti kasos audinius ir galimus navikus. Tuo tarpu tiems vaizdams, kuriuose etikečių nebuvo, buvo taikomas statistinis metodas, naudojant pažymėtų vaizdų regionų minimumo ir maksimumo ribas, buvo bandoma nustatyti galimus dominančius regionus ir nepažymėtuose vaizduose. Vis dėlto, taikant šį metodą nepažymėtiems vaizdams, išliko rizika, kad išskirtas regionas gali praleisti svarbius darinius ar nepakankamai tiksliai apimti norimus anatominius plotus. Ši procedūra leido sumažinti nereikalingų vaizdo dalių įtaką, sutelkiant dėmesį į svarbiausias sritis, kuriose naviko požymiai labiausiai išryškėja. Tokiu būdų atlikti duomenų paruošimo etapai – intensyvumo normavimo, dominančių regionų identifikavimo procedūros sudarė tvirtą pagrindą tolesniems eksperimentas. Dominančių regionų išskyrimo procedūra pateikta 16 paveikslėlyje.

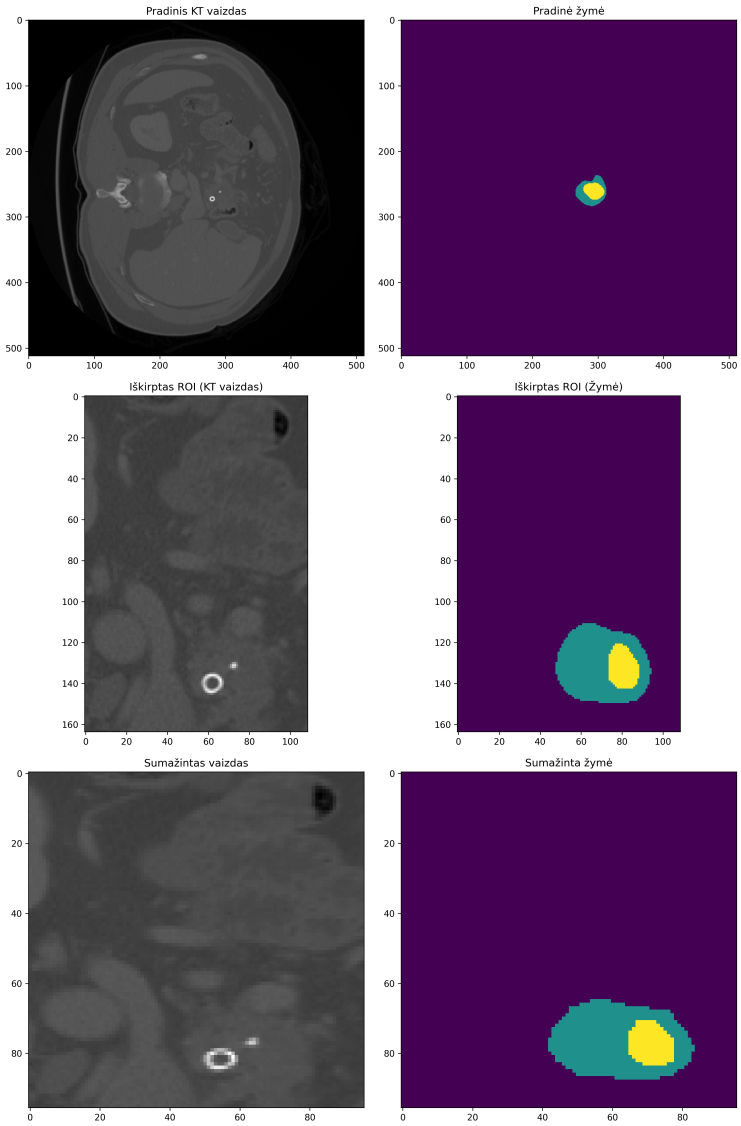

16 pav. Dominančių sričių išskyrimo procedūra

5.2.2. Mokymosi etapas

Mokymosi etapas prasidėjo nuo kompiuterinės tomografijos vaizdų atsitiktinio suskirstymo į mokymosį, validavimo ir testavimo aibes – atitinkamai 224, 57 ir 139 vaizdai. Visi eksperimentai buvo vykdomi su tuo pačiu bendruoju hiperparametru, siekiant užtikrinti rezultatų palyginamumą, tai yra iteracijų skaičius fiksuotas – 3000.

Mokymosi proceso metu buvo skaičiuojamas Dice koeficientas, kuris leido analizuoti duomenų segmentavimo tikslumą, ir kryžminės entropijos nuostolio reikšmės, leidžiančios įvertinti modelio efektyvumą pažymėtuose duomenyse. Kiekvieno eksperimento metu šie parametrai buvo užfiksuoti ir vizualizuoti mokymosi eigoje, siekiant pavaizduoti, kaip jie kinta didėjant iteracijų skaičiui. Rezultatai leido analizuoti Dice koeficiento ir kryžminės entropijos nuostolio tarpusavio ryšį bei tai, kaip šiuos parametrus įtakoja hiperparametrų pasirinkimai. Šios vizualizacijos padėjo suprasti modelio tikslumo ir klaidų mažėjimo dinamiką per visą mokymosį procesą bei leido nustatyti, kurie hiperparametrai užtikrina geriausią segmentavimo tikslumo ir mokymosi stabilumo balansą.

5.2.3. VM–bazinis

Šiame eksperimente siekta išanalizuoti, kaip perimti iš ankstesnių medicininių vaizdų segmentavimo uždavinių [Luo20] hiperparametrai gali būti pritaikyti naujam modeliui, dirbančiam su kasos vėžio medicininiais vaizdais. Pirmiausia, pradinės hiperparametrų reikšmės buvo parinktos remiantis ankstesnių tyrimų patirtimi, kuriose naudojami segmentavimo tinklai, dirbantys su panašaus pobūdžio medicininiais vaizdais. Konkrečiai, pasirinkta mokymosi sparta 0,01 leido greitai pradėti optimizacijos procesą, o mini partijos dydis – 4 vaizdai, iš kurių 2 buvo pažymėti, o 2 nepažymėti, užtikrino pusiausvyrą tarp pažymėtų ir nepažymėtų duomenų. Taip pat naudotas eksponentinio slankaus vidurkio metodas, kuris lėtai atnaujino mokytojo modelio svorius, taip palaikant stabilų atnaujinimo tempą. Nuoseklumo nuostolio svoris, pradžioje laipsniškai didinimas nuo 0 iki 0,1 per pirmas 200 iteracijų, buvo įvestas siekiant, kad modelis pirma išmoktų iš aiškių pažymėtų duomenų savybių, o vėliau palaipsniui įtrauktų ir nepažymėtus duomenis.

Mokymosi eigoje nuostolio funkcijos, Dice nuostolio ir kryžminės entropijos nuostolio reikšmės greitai mažėjo, pavyzdžiui, pirmos iteracijos metu bendras nuostolis siekė apie 1,14, o vos po 10 iteracijų jis sumažėjo iki 0,98. Per 50 iteracijų bendras nuostolis nukrito iki maždaug 0,55, o per 1000 iteracijų pasiekė apie 0,185. Tolimesnėse iteracijose, nuo maždaug 1000-os iteracijos, pokyčiai tapo labai minimalūs, o mokymosi pabaigoje bendras nuostolis stabiliai pasiekė ribą apie 0,09-0,10. Pastebima, kad tiek kryžminės entropijos, tiek Dice nuostolio reikšmės demonstruoja panašią tendenciją, kryžminės entropijos reikšmė nuo maždaug pradinės 1,50 sumažėjo iki 0,084 paskutinėje iteracijoje, o Dice nuostolis sumažėjo nuo maždaug 0,80 iki apie 0,094. Šie duomenys, iliustruojami mokymosi kreivėse, rodo, kad didžiausias nuostolio kritimas įvyko per pirmas 10-500 iteracijų, po to pokyčiai tapo daug subtilesni. Rezultatai pateikti 17 paveikslėlyje.

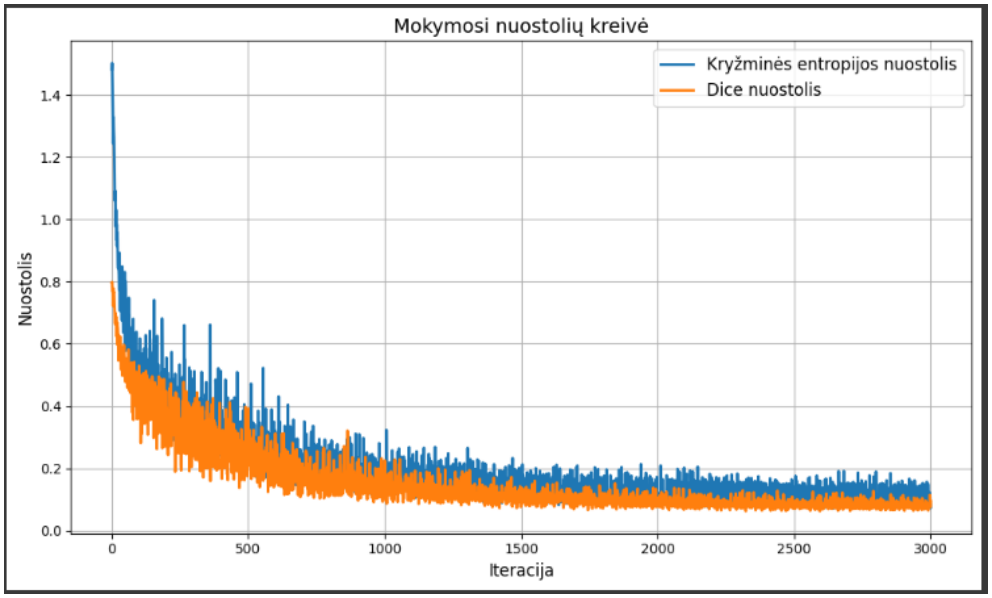

17 pav. VM–bazinis nuostolių kreivė

Apibendrinant, hiperparametrų perkėlimas iš ankstesnių uždavinių pasiteisino, modelis mokėsi stabiliai ir efektyviai išnaudodamas tiek pažymėtus, tiek nepažymėtus duomenis. Analizuojant mokymosi kreives bei nuostolio funkcijų dinamiką, galima teigti, kad pasirinkti parametrai užtikrino

greitą ir stabilų modelio konvergavimą.

5.2.4. VM–raiška

Šiame eksperimente pagrindinis tikslas buvo išnagrinėti, kaip įvesties vaizdų matmenų padidinimas daro įtaka trimačiam segmentavimo modelio mokymosi procesui ir galutiniam tikslumui. VM—bazinis eksperimente modelis mokėsi su [96, 96, 96] dydžio vaizdų blokais, tačiau pastebėta, kad toks ribotas matmenų tūris gali nepilnai atspindėti visų svarbių anatominės struktūros savybių, todėl priimtas sprendimas padidinti vaizdo įvesties dydį iki [128, 128, 128]. Toks pakeitimas buvo įgyvendintas vien pakeitus modelio konfigūraciją, išlaikant tą pačia trimačią U-Net architektūrą ir visus kitus hiperparametrus, siekiant izoliuoti vaizdų matmenų įtaką modelio segmentavimo tikslumui.

Didesnėms vaizdams apdoroti būtina turėti galingesnę skaičiavimo infrastruktūrą. Todėl Google Colab aplinkoje buvo pasirinkta Nvidia L4 GPU, turinti apie 24 GB VRAM, kas leido saugiai naudoti [128, 128, 128] vaizdų blokus užtikrinant pakankamą skaičiavimo galios kiekį. Tokia infrastruktūros atnaujinimo sąlyga leido modelį mokyti be papildomų kompromisų dėl duomenų apimties, kas yra itin svarbu esant didesnėms įvesties dimensijoms.

Mokymosi eiga vyko pagal tą pačią pusiau prižiūrimo mokymo metodą, kaip ir VM–bazinis eksperimente. Modelio mokymosi metu stebėtos dvi pagrindinės nuostolio funkcijos – kryžminės entropijos nuostolis ir Dice nuostolis. VM–raiška, palyginti su VM–bazinis, nuostolių kritimo tendencija buvo ženkliai pagerinta, modelis jau ankstyvose iteracijose pasiekė aukštesnį validacijos Dice rodiklį, apie 0,25, kai VM–bazinis eksperimente jis buvo apie 0,14, o vėliau kreivė išliko aukštesnėje srityje, vidutiniškai apie 0,30–0,32. Pastebima, kad didesni vaizdų blokai suteikė modeliui platesnį kontekstą, o tai leido jam greičiau ir geriau išmokti atpažinti globalias struktūras. Lyginant su VM–bazinis eksperimentu, kur modelis mokytas su mažesniais vaizdais rodė ribotą tikslumą ir validacijos Dice rodiklis išliko labai žemas, apie 0,13–0,15, VM–raiška eksperimente pastebėta, kad didesni vaizdų matmenys suteikė modelio mokymuisi daugiau informacijos, kas atsispindėjo tiek greitesnėje nuostolių sumažėjimo dinamikoje, tiek geresnėje segmentacijos kokybėje. Nors mokymosi metu nuostoliai, tiek kryžminės entropijos, tiek Dice sumažėjo iki panašių minimalių reikšmių kaip ir ankščiau, tačiau validacijos rezultatai leido daryti išvadą, kad modelio gebėjimas generalizuoti žymiai pagerėjo. Rezultatai pateikti 18 paveikslėlyje.

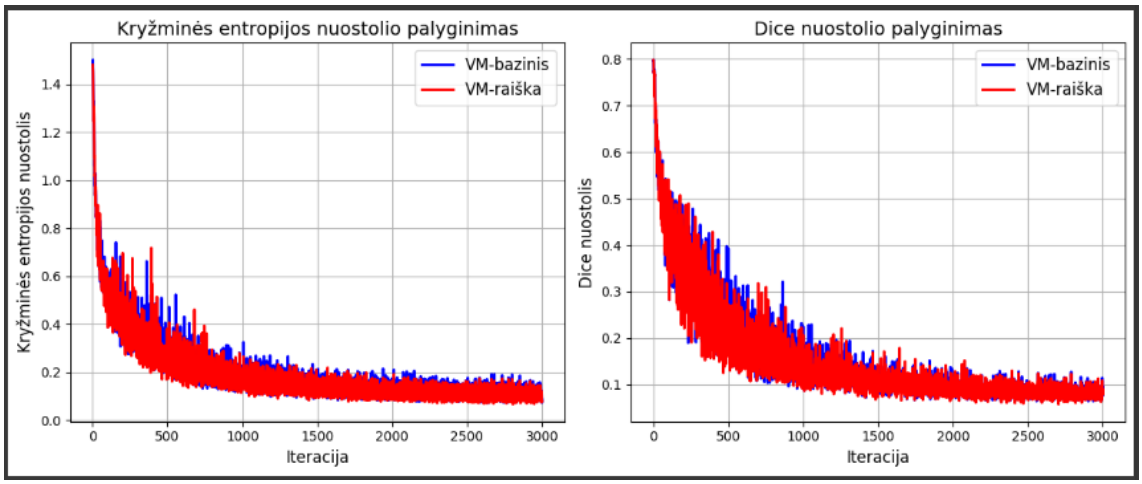

18 pav. Nuostolių kreivių palyginimas VM–bazinis ir VM–raiška eksperimentuose

Šis eksperimentas patvirtina, kad įvesties vaizdo matmenų padidinimas suteikia reikšmingą naudą segmentavimo modelio tikslumui. Modelis gavo platesnį kontekstinį vaizdą, o tai leido modeliui išmokti teisingiau atspindėti sudėtingas anatomines struktūras. Tuo pačiu metu infrastruktūros atnaujinimas, naudojant galingesnę Nvidia L4 GPU plokštę, užtikrino, kad padidinus įvesties matmenis, mokymosi procesas nepatirtų ribojimų dėl atminties ar skaičiavimo laiko. Pastebėta, kad VM–raiška eksperimente validacijos Dice rodiklis pakilo iki maždaug 0,32, kas lyginant su VM–bazinis eksperimento rezultatais, rodo beveik 2,5 karto geresnį segmentavimo tikslumą.

5.2.5. VM–partija

VM–partija eksperimento esmė buvo išnagrinėti, kaip padidinus prižiūrimų vaizdų kiekį kiekvienoje mokymo partijoje yra paveikiamas segmentavimo modelio tikslumas. VM–bazinis ir VM–raiška bandymuose partijoje iš keturių vaizdų buvo naudojami tik 2 pažymėti vaizdai. Siekiant pagerinti modelio mokymosi tikslumą ir leisti modeliui daugiau remtis pažymėtais duomenimis, nuspręsta padidint pažymėtų vaizdų skaičių partijoje nuo 2 iki 3, paliekant bendrą partijos dydį lygų 4. Toks pokytis turėjo kelis esminius privalumus. Pirma, didesnė proporcija pažymėtų duomenų leido modeliui greičiau ir efektyviau pritaikyti mokymosi metu gautus rezultatus. Antra, modelis per kiekvieną iteraciją turėjo galimybę daugiau kartų peržiūrėti pažymėtus vaizdus, o tai prisidėjo prie stabilesnio duomenų konvergavimo.

Analizuojant gautus rezultatus bandymo metu, pastebėta, kad pirmąsias iteracijas kryžminės entropijos nuostolio ir Dice nuostolio kreivės kritimas vyko greičiau nei VM–bazinis ir VM–raiška eksperimentuose. Pavyzdžiui, pradiniu etapu modelio nuostoliai buvo panašus į ankstesnių bandymų pradžios reikšmes, tačiau su padidintu prižiūrimų pavyzdžių skaičiumi modelis pasiekė žymiai mažesnius nuostolius greičiau, o segmentavimo tikslumo rodiklis validacijos aibėje ženkliai išaugo. Lyginant su VM–bazinis ir VM–raiška eksperimentais, kur partijoje naudojama buvo mažesnė pažymėtų duomenų dalis, VM–partija eksperimento rezultatai parodė aiškų progresą. Validacijos metu Dice koeficientas, matuojantis modelio segmentavimo tikslumą, pasiekė geresnes vertes ir stabiliai išliko aukštesnis viso mokymo proceso metu. Nors mokymosi metu nuostoliai mažėjo panašiai kaip ir ankstesniuose bandymuose, didesnis pažymėtų duomenų kiekis kiekvienoje parti-

joje, leido modeliui bendrą optimizacijos procesą paversti tolygesniu ir labiau generalizuojančiu. Rezultatai pateikti 19 paveikslėlyje.

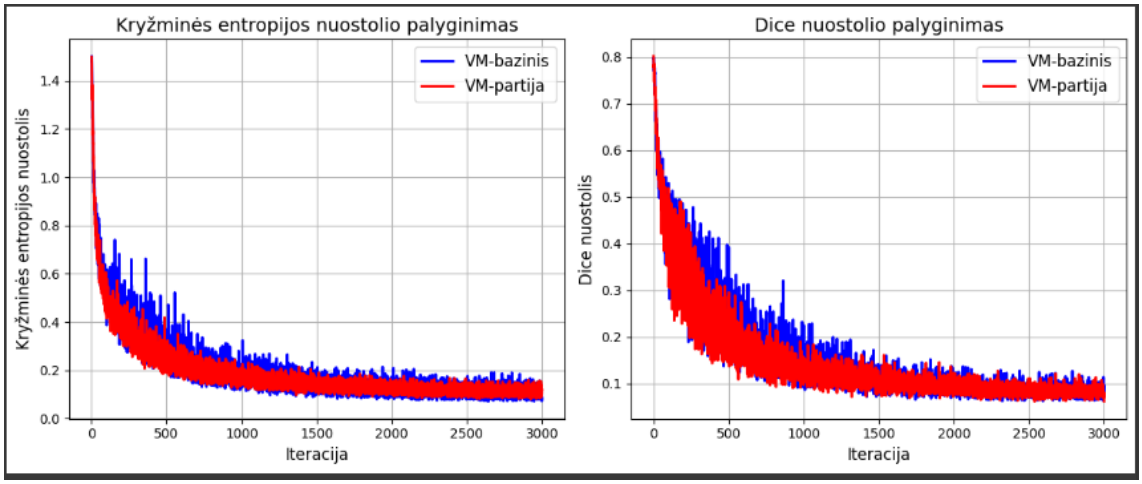

19 pav. Nuostolių kreivių palyginimas VM–bazinis ir VM–partija eksperimentuose

Apibendrinant, pastebėta, kad prižiūrimų vaizdų kiekio padidinimas yra efektyvus būdas pagerinti pusiau prižiūrimo mokymo rezultatus. Didinant pažymėtų duomenų dalį partijoje, modelio konvergavimo greitis padidėja, nuostolių kreivės tampa tolygesnės, o segmentavimo tikslumas mokymosi aibėje žymiai pagerėja. Tačiau pastebima, kad tolesnis prižiūrimų vaizdų skaičiaus didinimas partijoje, nebūtinai suteiktų neribotą naudingą poveikį.

5.2.6. VM–duomenys

Šiame eksperimente buvo siekiama įvertinti, kaip padidintas bendras pažymėtų vaizdų kiekis mokymosi proceso metu veikia trimačio segmentavimo modelio mokymosi eigą ir galutinį segmentavimo tikslumą. Skirtingai nuo ankstesnių bandymų, kuriuose mokymosi metu buvo naudojami 25 pažymėti kompiuterinės tomografijos vaizdai, šio bandymo metų į mokymosi duomenų rinkinį įtraukta 50 trimačių pažymėtų vaizdų. Toks pokytis leido modeliui pasinaudoti didesniu pažymėtų duomenų skaičiumi, sumažinant priklausomybę nuo pseudo etikečių, kurių generavimas iš nepažymėtų duomenų gali būti nepatikimas, ir taip pagerinant bendrą mokymosi proceso stabilumą.

Padidinus bendrą pažymėtų vaizdų skaičių, modelio mokymosi metu pastebėta, kad tiek kryžminės entropijos nuostolio, tiek Dice nuostolio kreivės pradžioje greitai mažėjo ir stabilizavosi. Kryžminės entropijos reikšmės sumažėjo ir stabilizavosi ties maždaug 0,3, o Dice nuostolis pasiekė mažesnę vertę, artima 0,2. Tai rodo, kad modelis, turėdamas daugiau pažymėtų vaizdų, efektyviau išmoksta segmentavimo principus ir greičiau konverguoja. Taip pat pastebėta, jog didesnis pažymėtų duomenų kiekis padėjo modelio parametrams išmokti bendresnius, labiau generalizuojančius dėsningumus.

Mokymosi proceso dinamika rodo, kad modelis su padidintu pažymėtų duomenų kiekių stabiliau mažino nuostolius, o mokymosi kreivės, tiek kryžminės entropijos, tiek Dice nuostolio tapo tolygesnės ir nuoseklesnės. Daugiau pažymėtų vaizdų padėjo išvengti pernelyg stipraus persimokimo efekto, kurio metu modelis per daug prisitaikytų prie nedidelio duomenų pavyzdžių aibės.

Todėl pastebimas reikšmingas bendro modelio generalizacijos pagerėjimas, validacijos Dice rodiklis aukštesnis ir stabilus per visą mokymo procesą. Rezultatai pateikti 20 paveikslėlyje.

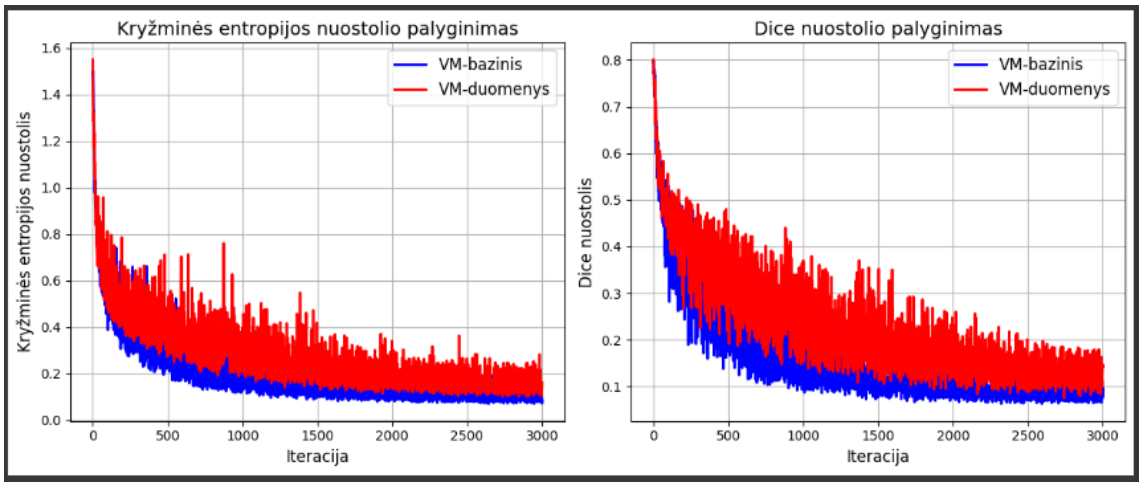

20 pav. Nuostolių kreivių palyginimas VM–bazinis ir VM–duomenys eksperimentuose

Apibendrinant, VM–duomenys eksperimentas rodo, kad padidinus pažymėtų vaizdų kiekį mokymosi metu, modelio segmentavimo tikslumas bei mokymo stabilumas žymiai pagerėjo. Gauti rezultatai patvirtina, jog papildomi pažymėti duomenys leidžia modeliui greičiau išmokti svarbiausius segmentavimo dėsningumus, o tai pasireiškia tiek greitesniu nuostolių mažėjimu, tiek aukštesniu bendru segmentavimo tikslumu. Nors galutinių nuostolių reikšmės buvo panašios į ankstesnius bandymus, naujoji modelio konfigūracija leido pasiekti stabilų generalizacijos lygį ir sumažino mokymosi skirtumus.

5.2.7. VM–sparta

Šiame eksperimente siekta ištirti, kaip padidinus mokymosi spartą nuo 0,01 iki 0,1 keičiasi pusiau prižiūrimo mokymosi modelio eiga ir segmentavimo tikslumas. Mokymosi sparta yra vienas iš esminių hiperparametrų, lemiantis, kaip greitai modelis atnaujina savo svorius pagal apskaičiuotus gradientus. Tikėtasi, kad aukštesnė sparta leis paspartinti mokymosi procesą, modelis greičiau sumažins nuostolius ir anksčiau įgaus pagrindines segmentavimo savybes. Tačiau tuo pačiu tikėtasi pamatyti nestabilumo požymių, nes didesni svyravimai atnaujinimų metų gali paveikti galutinį modelio rezultatą.

Eksperimento metu pastebėta, kad pradiniuose iteracijų etapuose, naudojant mokymosi spartą 0,1, tiek kryžminės entropijos, tiek Dice nuostolių kreivės krito greičiau. Pavyzdžiui, modelio kryžminės entropijos nuostolio reikšmė greitai sumažėjo ir stabilizavosi ties apytiksliai 0,2, o Dice nuostolis pasiekė maždaug 0,1. Tai rodo, kad aukštesnė sparta leido modeliui greičiau įsisavinti pagrindinius segmentavimo principus ir pasiekti geresnius mokymosi rezultatus per trumpesnį laiką. Vis dėlto, padidinus mokymosi spartą, stebima, kad mokymosi pradžioje atsirado nedideli svyravimai nuostolių kreivėse. Šie šiek tiek nepastovūs atnaujinimai, rodo, kad aukštesnė sparta, nors ir pagreitina mokymosi procesą, gali kartu sumažinti jo stabilumą. Taigi, VM–sparta eksperimentas parodė kompromisą tarp mokymosi greičio ir proceso stabilumo, modelis greičiau konver-

guoja, tačiau pradiniuose etapuose pasireiškia didesni nuostolių svyravimai. Rezultatai pateikti 21 paveikslėlyje.

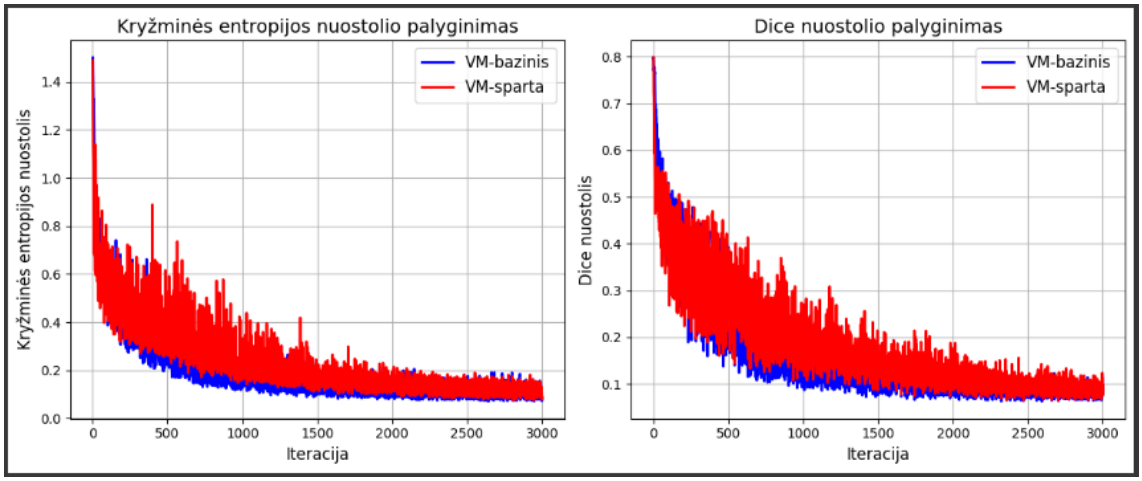

21 pav. Nuostolių kreivių palyginimas VM–bazinis ir VM–sparta eksperimentuose

Apibendrinant, eksperimentas atskleidė, kad padidinus mokymosi spartą galima paspartinti modelio mokymosi eigą ir greičiau sumažinti nuostolius, kas leidžia modeliui sparčiau išmokti segmentavimo principus. Tačiau aukštesnė sparta kartu su nedideliais nuostolių kreivių svyravimais, rodo, jog reikia atidžiai stebėti proceso stabilumą.

5.2.8. Validavimo etapas

Visų eksperimentų metu, kas 200 iteracijų, buvo atliekama validacija naudojant 57 kompiuterinės tomografijos kasos medicininius vaizdus siekiant objektyviai įvertinti modelio gebėjimą segmentuoti kasą ir naviką. Segmentavimo tikslumas buvo matuojamas pasitelkus Dice koeficientą bei HD95 metriką.

Iš 10 lentelės matyti, kad pradinėse iteracijose, ties 200 iteracija, Dice koeficientai skirtinguose eksperimentuose varijuoja maždaug nuo 0,19 iki 0,47, o HD95 reikšmės siekia net iki 25,91. Tai rodo, kad modelis pradiniame etape dar nėra pakankamai išmokęs apibendrinti segmentacijos dėsningumus, todėl dalies eksperimentų tikslumas būna gerokai mažesnis, o geometrijos atitikimas prastesnis. Visgi, mokymosi eigai tęsiantis, jau ties 1000 ir 1200 iteracija, didžiosios dalies eksperimentų Dice koeficientai pakyla iki 0,50–0,59 ribos, o HD95 reikšmės, kurios iš pradžių galėjo viršyti 20, mažėja iki maždaug 15–19 diapazono. Tai rodo akivaizdų modelio segmentacijos gebėjimo tobulėjimą.

Be kiekybinių rodiklių, validacijos etape pateikti vizualiniai segmentavimo pavyzdžiai, pateikti 22, 23 ir 24 paveikslėliuose, papildomai patvirtina statistinius duomenis. Vizualiai modelis dažniausiai tiksliai atpažįsta kasos ir naviko ribas, nors kai kuriais atvejais naviko segmentacija gali būti šiek tiek sudėtingesnė dėl panašių audinių kontrastų.

10 lentelė. Validacijos metrikų dinamika visuose 5 eksperimentuose (kas 200 iteracijų)

Iteracija	**VM–bazinis**		**VM–raiška**		**VM–partija**		**VM–duomenys**		**VM–sparta**	
	Dice	HD95	Dice	HD95	Dice	HD95	Dice	HD95	Dice	HD95
200	0,19	**22,89**	0,43	22,51	0,46	20,50	0,42	20,27	0,47	23,69
400	0,19	24,51	0,46	18,96	0,48	19,80	0,43	19,26	0,50	23,10
600	0,18	25,91	0,45	19,96	0,49	**17,99**	0,49	18,54	0,55	21,31
800	0,20	23,75	0,54	16,55	0,52	18,93	0,50	17,41	0,56	21,15
1000	**0,20**	24,08	0,51	19,66	0,55	18,11	0,54	**15,78**	0,59	21,63
1200	0,19	25,27	**0,57**	**15,37**	0,54	18,81	0,55	16,81	0,58	22,55
1400	**0,20**	24,90	0,54	19,83	0,54	18,99	0,55	16,63	0,59	20,23
1600	0,19	25,06	0,55	16,69	**0,55**	18,07	0,54	18,15	0,59	20,97
1800	0,19	25,10	**0,57**	15,81	**0,55**	18,31	0,55	17,30	0,59	20,85
2000	0,19	25,23	0,56	17,11	**0,55**	18,51	0,55	17,53	**0,60**	19,29
2200	0,19	24,83	**0,57**	15,52	**0,55**	19,32	**0,56**	17,53	0,59	20,25
2400	0,19	24,92	**0,57**	16,37	**0,55**	18,50	0,54	17,78	0,59	**19,26**
2600	0,19	25,06	**0,57**	15,88	**0,55**	18,55	0,54	17,92	0,59	19,42
2800	0,19	25,02	**0,57**	15,89	**0,55**	18,70	0,55	17,95	0,59	19,98
3000	0,19	25,02	**0,57**	15,80	**0,55**	18,44	0,55	17,93	0,59	19,69

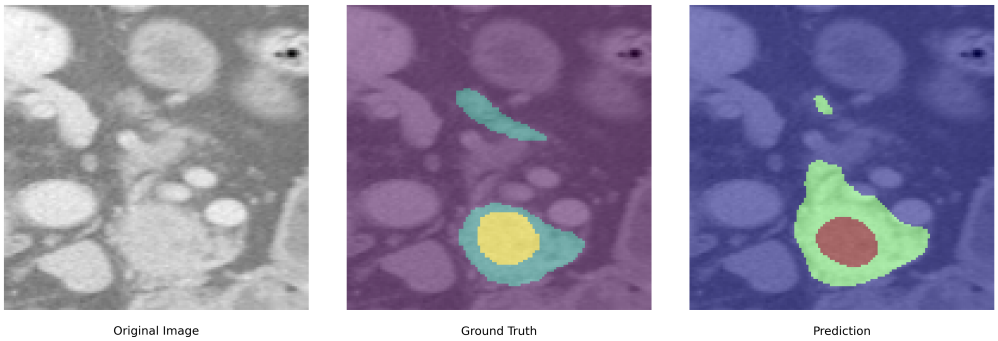

22 pav. Kasos vaizdas – 336: Pradinis vaizdas – Vaizdo Etiketė – VM–sparta segmentavimo rezultatas

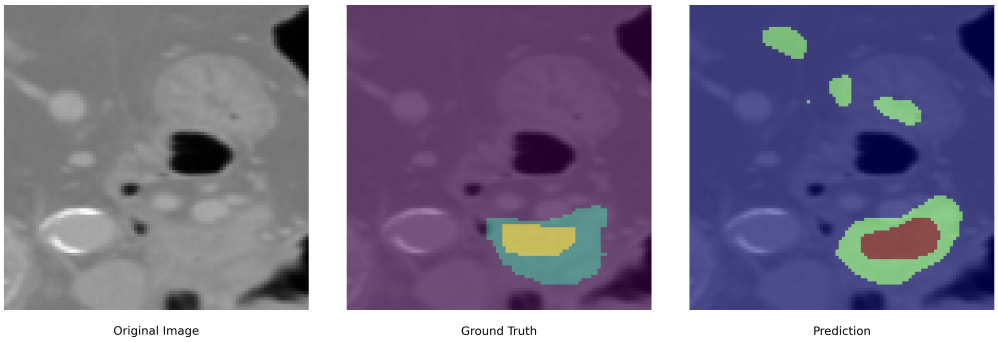

23 pav. Kasos vaizdas – 186: Pradinis vaizdas – Vaizdo Etiketė – VM–duomenys segmentavimo rezultatas

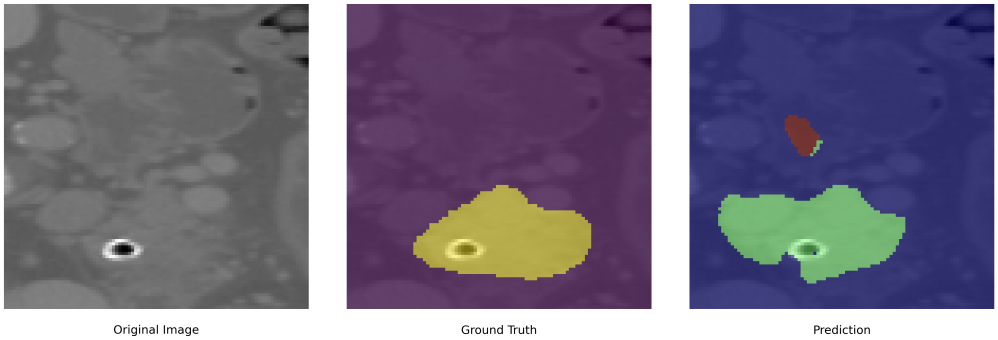

24 pav. Kasos vaizdas – 145: Pradinis vaizdas – Vaizdo Etiketė – VM–partija segmentavimo rezultatas

Apibendrinant, visų penkių eksperimentų validacijos rezultatai rodo, kad modelis nuosekliai tobulėja, nuo pradinės iteracijos, kai Dice koeficientas siekia maždaug 0,40, iki paskutinio vertinimo, kai Dice koeficientas padidėja iki 0,57-0,60, o HD95 reikšmės nuosekliai mažėja. Šie rezultatai, tiek kokybiniai, tiek kiekybiniai, parodo, kad vidutinio mokytojo metodas užtikrina pastovų segmentacijos tikslumo gerėjimą per visą mokymosi procesą. Be to, surinkti duomenys suteikia galimybę objektyviai palyginti skirtingų hiperparametrų pakeitimų įtaką modelio veikimui.

5.2.9. Testavimo etapas

Testavimo etapas yra paskutinis ir itin svarbus modelio vertinimo žingsnis, atskleidžiantis, kaip vidutinio mokytojo metodo modelis susidoroja su anksčiau nematytais kompiuterinės tomografijos kasos medicininiais vaizdais.

Norint pavaizduoti šių bandymų rezultatus, 29 paveikslėlyje pateikti 4 vizualus segmentavimo rezultatai. Spalvinis žymėjimas, naudojamas šiame paveikslėlyje, žalia spalva rodo numatoma kasos sritį, o raudona spalva žymi numatomą naviką.

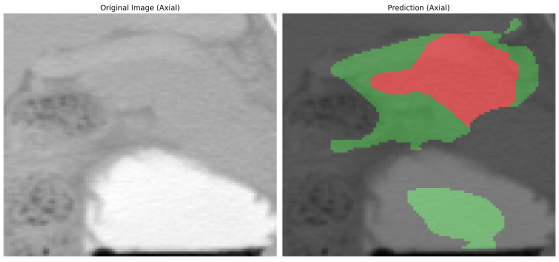

25 pav. Kasos vaizdas – 065, VM–sparta

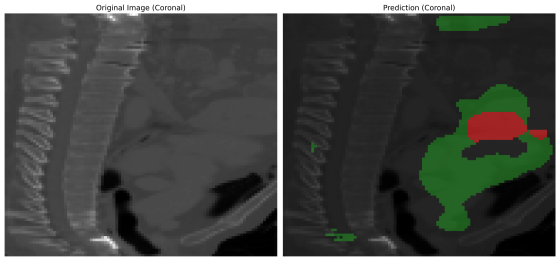

26 pav. Kasos vaizdas – 151, VM–duomenys

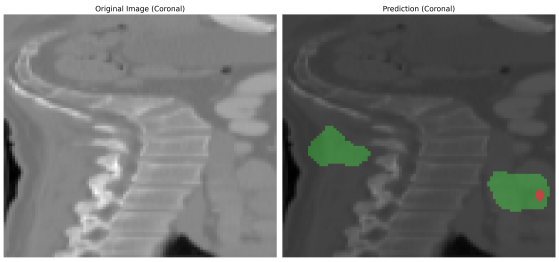

27 pav. Kasos vaizdas – 363, VM–bazinis

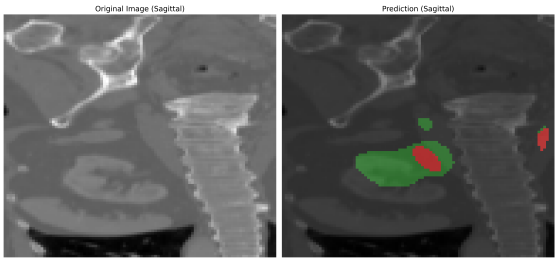

28 pav. Kasos vaizdas – 396, VM–partija

29 pav. Testavimo metu gauti įvairūs segmentavimo vizualus rezultatai

Apibendrinant, testavimo metu modelis buvo išbandytas su analogiškai paruoštais apkarpytais vaizdais, kaip ir mokymosi metu. Gauti rezultatai rodo, kad modelio segmentavimo kokybė yra patenkinama. Tai patvirtina, kad apkarpytų vaizdų naudojimas tiek mokymosi, tiek testavimo etapuose neprieštarauja modelio gebėjimui apibendrinti segmentacijos dėsningumus ir pasiekti stabilų segmentavimo tikslumą.

5.3. Vidutinio mokytojo metodas grįstas neapibrėžtumu praktinė analizė

Neapibrėžtumu grįstas vidutinio mokytojo metodas yra išplėstas pusiau prižiūrimo mokymosi metodo variantas, skirtas pagerinti modelio gebėjimą mokytis iš riboto pažymėtų duomenų kiekio. Tradicinis vidutinio mokytojo metodas remiasi nuoseklumo principu, kuriuo studento ir mokytojo modeliai stengiasi generuoti panašias prognozes net ir esant įvairioms įvesties modifikacijoms. Tačiau standartinis metodas neatsižvelgia į prognozių neapibrėžtumą, kuris gali turėti įtakos pseudo etikečių kokybei ir, kaip pasekmė, bendram mokymosi proceso stabilumui.

Šiame skyriuje bus išsamiai aptarta, kaip įtraukus neapibrėžtumo vertinimo metodus galima dar labiau patobulinti vidutinio mokytojo metodą, bus parodyta ir aptarta kaip toks metodas prisideda prie modelio konvergavimo ir segmentacijos rezultatų patikimumo. Taip pat bus aptariami eksperimentų rezultatai tiek kiekybiškai, tiek vizualiai.

5.3.1. Duomenų paruošimas

Duomenų paruošimo etapas atlieka esminį vaidmenį siekiant užtikrinti, kad modelio įvesties duomenys būtų tinkami mokymosi procesui. Pirmiausia, atliktas duomenų normalizavimas, šis žingsnis yra kritiškai svarbus, nes skirtingais laikotarpiais ir naudojant įvairius įrenginius gauti kompiuterinės tomografijos vaizdai gali turėti skirtingus intensyvumo ir kontrasto savybes. Normalizavimas užtikrina, kad visi vaizdai bus interpretuojami vienodai, sumažinant įtaką kintančioms

techninėms charakteristikoms. Po normalizavimo duomenys yra toliau paruošiami pritaikant augmentaciją. Augmentacijos procesas apima atsitiktinį vaizdų pasukimą bei vaizdų apkarpymą, kurių metų yra generuojami nauji pavyzdžiai iš originalių kompiuterinės tomografijos vaizdų. Tokiu būdu padidėja duomenų įvairovė, o modelis tampa atsparesnis įvesties kintamumams. Augmentacija pateikta 30 paveikslėlyje, kuriame vaizduojami pradiniai duomenys, jų etiketės ir atitinkami SDF (*signed distance function*) žemėlapiai prieš ir po duomenų transformacijų.

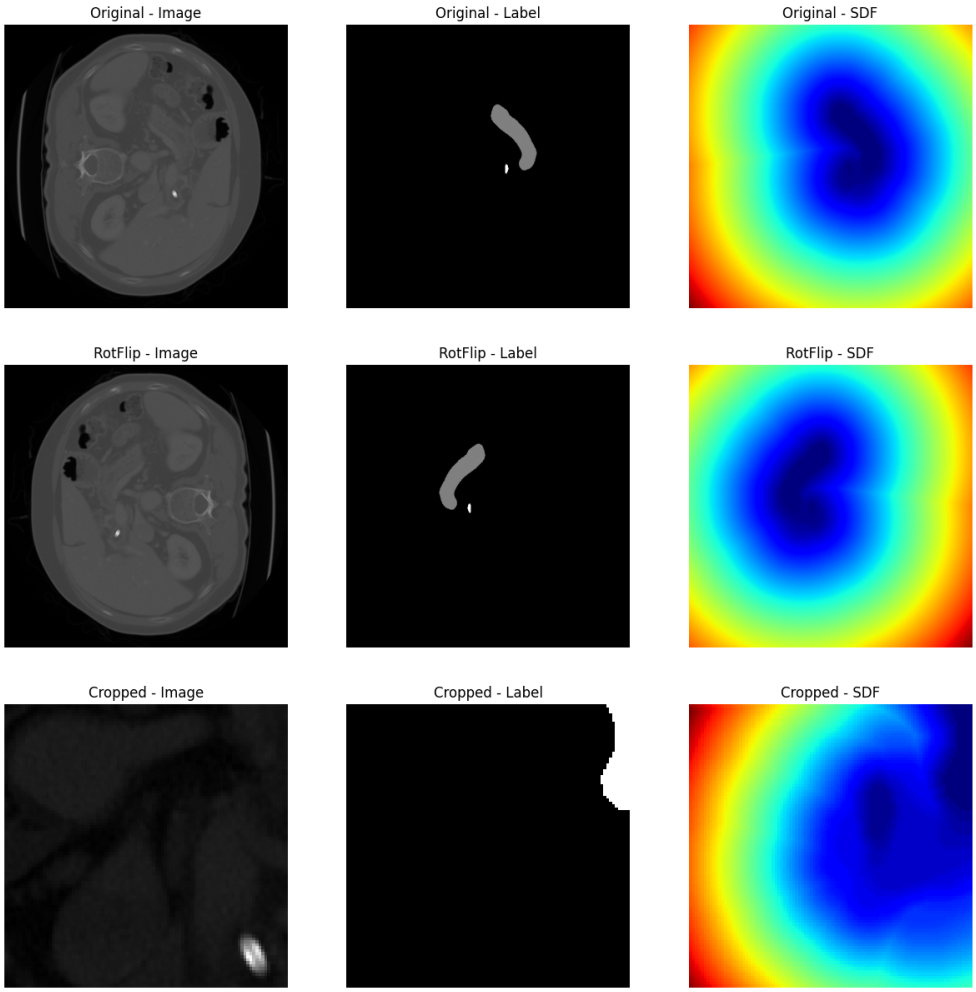

30 pav. Duomenų paruošimo procesas – augmentacija

Galiausiai, svarbus duomenų paruošimo žingsnis yra jų apkarpymas iki fiksuotų matmenų, tai gali būti, pavyzdžiui, 96x96x96 arba 128x128x128 pikselių tūrio vaizdai. Šis žingsnis užtikrina, kad visi duomenys pateikiami modeliui yra pateikiami vienodo dydžio, leidžiant efektyviau naudoti turimus skaičiavimo resursus ir optimizuoti mokymosi procesą.

Apibendrinant, duomenų paruošimo etapas apima normalizavimą, atsitiktinę augmentaciją ir duomenų apkarpymą. Šie žingsniai užtikrina, kad mokymosi metu naudojami vaizdai yra nuoseklūs, vienodi ir praturtinti papildoma įvairove.

5.3.2. Mokymosi etapas

Mokymosi etapas prasidėjo nuo kompiuterinės tomografijos vaizdų atsitiktinio suskirstymo į mokymosį, validavimo ir testavimo aibes – atitinkamai 224, 57 ir 139 vaizdai. Visi eksperimentai

buvo vykdomi su tuo pačiu bendruoju hiperparametru, siekiant užtikrinti rezultatų palyginamumą, tai yra iteracijų skaičius fiksuotas – 3000.

5.3.3. NVM–bazinis

VM–bazinis ir NVM–bazinis eksperimentuose pradinės iteracijos rezultatai yra beveik identiški. Pavyzdžiui, iteracijoje 1 bendras nuostolis buvo apie 1,1396, tuo pačiu metu kryžminės entropijos nuostoliai siekė maždaug 1,4818, o Dice nuostoliai – apie 0,7973. Iki 25-os iteracijos skirtumai išliko nedideli. Vidutinio mokytojo metodo atveju bendras nuostolis sumažėjo iki maždaug 0,7026, kai kryžminės entropijos nuostoliai pasiekė apie 0,8580, o Dice nuostoliai – apie 0,5470. Metode, grįstu neapibrėžtumu 25-os iteracijos metu bendras nuostolis buvo maždaug 0,6933, kryžminės entropijos nuostoliai – apie 0,8383, o Dice nuostoliai apie 0,5481. Esant 100-os iteracijos etapui, vidutinio mokytojo metodo metu bendras nuostolis buvo 0,5489, o kryžminės entropijos nuostoliai sumažėjo iki 0,5287, tuo tarpu Dice nuostoliai pakilo iki 0,5673. Tuo tarpu neapibrėžtumu grįstame metode, iteracijoje 100, bendras nuostolis buvo apie 0,5603, kryžminės entropijos nuostoliai liko aukštesni – apie 0,6007, o Dice nuostoliai sumažėjo iki 0,5185. Rezultatai pateikti 31 paveikslėlyje.

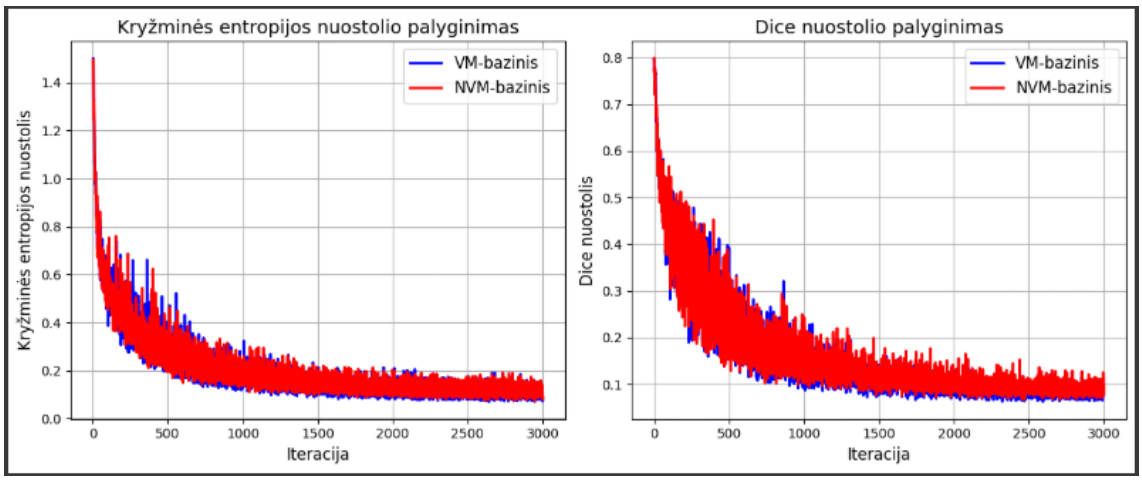

31 pav. VM-bazinis mokymosi nuostolių kreivių palyginimas su NVM–bazinis

Šie rezultatai rodo, kad vidutinio mokytojo metodo atveju nuostolių mažėjimas vyksta stabilesniu tempu, o Dice nuostolių sumažėjimas rodo geresnį segmentacijos atitikimą. Neapibrėžtumu grįstame metode, kur hiperparametrai koreguojami pagal modelio prognozuojamą neapibrėžtumą, segmentacijos tikslumo vertės išlaikomos aukštesnės, o Dice nuostoliai yra mažesni iteracijų pradžioje, tačiau jie nepasiekia tokio lygio kaip vidutinio mokytojo metodo atveju.

5.3.4. NVM–partija

VM–partija ir NVM–partija eksperimentai, tiek vidutinio mokytojo metodas, tiek metodas, grįstas neapibrėžtumu, kuriuose naudojama partijoje trys pažymėti vaizdai, iteracijų pradžioje demonstruoja beveik identišką mokymosi eigą. Pavyzdžiui, pirmos iteracijos metu abiejų eksperimentų bendras nuostolis siekia apie 1,15, o kryžminės entropijos nuostoliai apie 1,50. o Dice nuostoliai apie 0,80. Visi rodikliai yra beveik identiški, kas rodo, kad pradiniuose etapuose, kai

modelio neapibrėžtumo įvertinimai dar nėra pakankamai adaptyvus, tai abu metodai veikia labai panašiai. Toliau artėjant prie 4-os iteracijos, matomi švelnūs pokyčiai, vidutinio mokytojo metodo metu bendras nuostolis sumažėja iki maždaug 1,03, o metode, grįstu neapibrėžtumu iki 1,0327, o atitinkamai kryžminės entropijos ir Dice nuostoliai mažėja beveik vienodai. Iki 25-os iteracijos skirtumai vis dar išlieka minimalūs, standartinio metodo rezultatai rodo bendrą nuostolį apie 0,7471,o metode, grįstu neapibrėžtumu – apie 0,7345, taip pat ir kryžminės entropijos nuostoliai bei Dice nuostoliai yra labai artimi abiem atvejais. Rezultatai pateikti 32 paveikslėlyje.

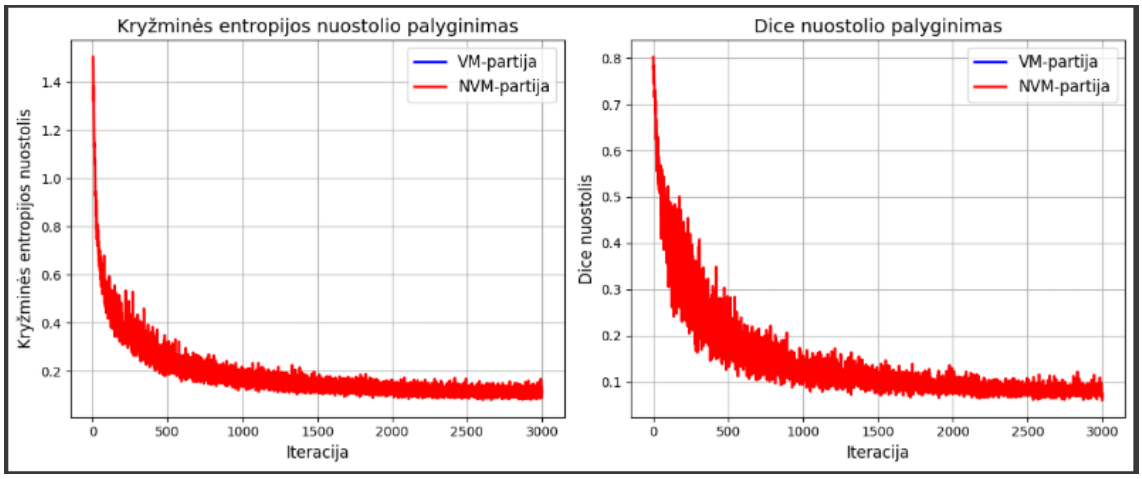

32 pav. VM–partija mokymosi nuostolių kreivių palyginimas su NVM–partija

Tai rodo, kad padidinus prižiūrimų vaizdų kiekį partijoje, tiek vidutinio mokytojo metodo, tiek metodo, grįsto neapibrėžtumu, pradinė mokymosi eiga yra labai panaši. Tačiau, iš ankstesnių analizės rezultatų matome, kad naudojant neapibrėžtumu grįstą metodą, vėlesnėse mokymosi fazėse sutinkamas dinamiškesnis mokymosi verčių augimas. Apibendrinant, naudojant partijoje tris pažymėtus vaizdus, abiejų metodų pradiniai rezultatai yra labai artimi, iteracijų pradžioje abiem metodams bendras nuostolis svyruoja apie 1,15, o toliau abu metodai rodo nuoseklų nuostolių mažėjimą. Vidutinio mokytojo metodas demonstruoja stabilų nuostolių kritimą ir augančius segmentacijos tikslumo rodiklius, o metodas, grįstas neapibrėžtumu, iš pradžių veikia panašiai, tačiau iteracijų skaičiui augant dinamiškai tobulėja.

5.3.5. NVM–duomenys

NVM–duomenys eksperimente, kuriame naudojama 50 pažymėtų vaizdų, pastebima, kad tiek vidutinio mokytojo metodo, tiek neapibrėžtumu grįsto metodo pradinis mokymosi procesas išlieka beveik identiškas. Pavyzdžiui, pirmoje iteracijoje bendras nuostolis abiejuose metoduose svyruoja apie 1,17, o kryžminės entropijos nuostoliai apie 1,55, o Dice nuostoliai apie 0,80. Didėjant iteracijų skaičiui, bendras nuostolis palaipsniui mažėja, o Dice nuostolių rodiklis, rodo geresnį segmentacijos atitikimą. Rezultatai pateikti 33 paveikslėlyje.

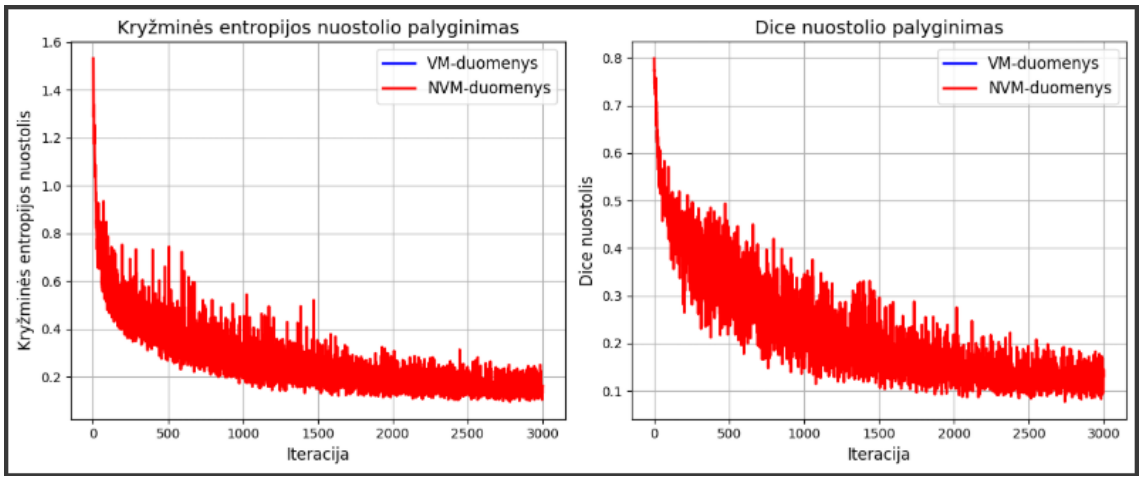

33 pav. VM-duomenys mokymosi nuostolių kreivių palyginimas su NVM–duomenys

Abu metodai demonstruoja nuoseklų kritimą nuo pradinės reikšmės iki iteracijų pabaigos, ir ankstyvoje mokymosi fazėje skirtumai tarp jų beveik neišryškėja. Tai rodo, kad padidinus pažymėtų vaizdų kiekį, modelis gauna daugiau duomenų mokymuisi, dėl to metodo, grįsto neapibrėžtumu, kuris iš esmės koreguoja nuoseklumo nuostolius pagal prognozuojamą neapibrėžtumą, teikiamas pranašumas tampa mažiau ryškus, abiejų metodų pradiniai nuostolių pokyčiai yra labai artimi. Vis dėlto, vidutinio mokytojo metodo eigoje nuostolių mažėjimas išlieka šiek tiek stabilesnis, o segmentacijos tikslumo rodiklis pasiekia aukštesnes vertes. Tai rodo, kad kai pakankamai pažymėtų duomenų yra prieinami, modelis gali pasiekti geresnį balansą, o hiperparametrų adaptavimas, kuris yra naudingas esant ypatingai mažam duomenų kiekiui, tampa mažiau reikšmingas.

Iš esmės, NVM–duomenys eksperimente, kai naudojama 50 pažymėtų duomenų, abiejų metodų mokymosi procesai tampa artimi vienas kitam, abiejuose pradiniai nuostolių rodikliai yra beveik identiški, o didesnis pažymėtų duomenų kiekis lemia stabilesnį ir nuoseklesnį mokymosį procesą. Vidutinio mokytojo metodo atveju nuostolių mažėjimas yra šiek tiek labiau prognozuojamas ir stabilus, o metodo, grįsto neapibrėžtumu, dinamika tampa mažiau ryški, nes papildomi pažymėti duomenys kompensuoja metodo įtaką mokymosi rezultatams.

5.3.6. NVM–sparta

Šiuose 3000 iteracijų trukmės eksperimentuose, kuriuose lyginamas vidutinio mokytojo metodas ir neapibrėžtumu gristas vidutinio mokytojo metodas, abu modeliai ankstyvuose mokymosi etapuose demonstruoja labai panašias charakteristikas. Bendras nuostolis per pirmas kelias dešimtis iteracijų svyruoja apie 1,15, o kryžminės entropijos ir Dice nuostoliai taip pat rodo beveik tapačias reikšmes, tai yra apie 1,50 ir 0,80. Kadangi pradiniuose etapuose modelis dar nespėja prisitaikyti prie neapibrėžtumo požymių, šie rodikliai iš esmės sutampa nepriklausomai nuo to, ar naudojamas standartinis, ar neapibrėžtumu grįstas metodas.

Vėliau, pasiekus maždaug 50–100 iteracijų intervalą, abu metodai stabiliai mažina nuostolius iki maždaug 0,55–0,60, o kryžminės entropijos ir Dice nuostoliai sumažėja dar labiau. Šioje fazėje pastebėta, kad mokymosi spartos koregavimas nuo 0,01 iki 0,1 padeda modeliams dar efektyviau pereiti prie stabilesnio mokymosi.

Kai mokymasis vyksta ilgesnėje perspektyvoje, maždaug apie 500–1000 iteracijų, nedideli neatitikimai išryškėja, tačiau jie išlieka gana nedideli. Vis dėlto, artėjant prie 2000–3000 intervalo, metodas, grįstas neapibrėžtumu, dažniau parodo dinamiškesnį mokymosi verčių augimą ir išlaiko kiek žemesnį bendrą nuostolį. Tai rodo, kad tinkamai sureguliavus mokymosi spartą ir panaudojus neapibrėžtumo aspektus, modelis efektyviau pasinaudoja nepažymėtų duomenų dalimi. Galiausiai abu metodai pasiekia artimą galutinį segmentavimo tikslumą, tačiau neapibrėžtumu grįstas metodas dažniau demonstruoja kiek geresnę bendrąją nuostolių kreivę ir stabiliau siekia mažesnio kryžminės entropijos ir Dice nuostolio. Rezultatai pateikti 34 paveikslėlyje.

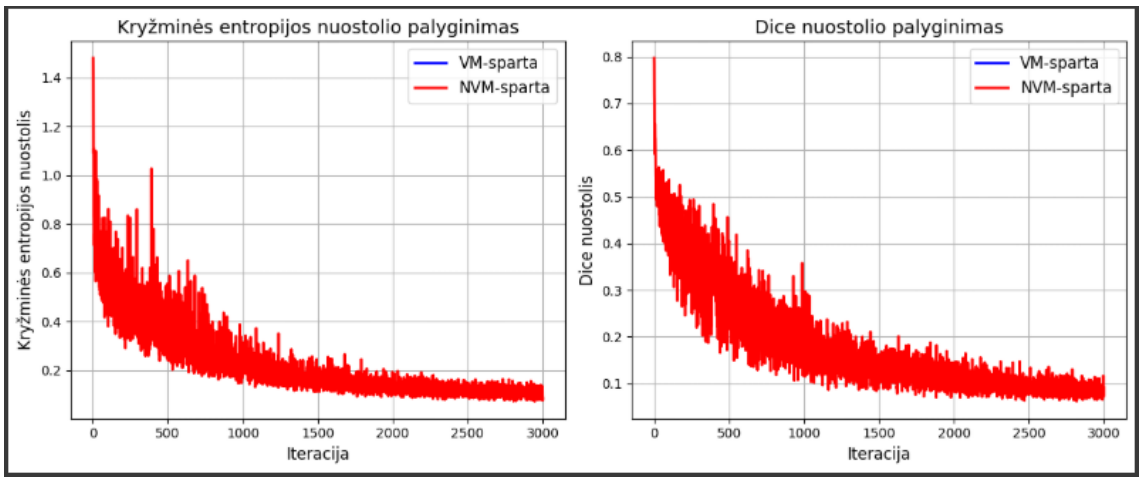

34 pav. VM–sparta mokymosi nuostolių kreivių palyginimas su NVM–sparta

5.3.7. NVM–raiška

Šio eksperimento metu maždaug nuo 100–200 iteracijų intervalo standartinis vidutinio mokytojo metodas rodo, kad nuostolių reikšmės mažėja vidutiniškai tolygiau, tačiau gana retai pašoka aukštyn. Apie 500–600 iteraciją, kai dalis mokymosi jau praeita, bendras nuostolis stabilizuojasi ties maždaug 0,50–0,55, o periodiškai pasiekiamas ir 0,48. Tokiu metu Dice koeficientas neretai viršija 0,70, kas reiškia, kad modelis vis geriau segmentuoja kasą ir naviką. Tiesa, net ir vėlesnėse iteracijose matyti, kad modelio kreivė vis dar gali svyruoti. Iki 2000 iteracijos daugelis nuostolio kreivių jau atrodo gana horizontaliai, rodydamas, kad modelis iš esmės pasiekė ribą. Neapibrėžtumu grįstas vidutinio mokytojo metodas taip pat perima bazinius bruožus, po 200–300 iteracijų kreivė įsibėgėja, o bendras nuostolis dažnai tampa mažesnis nei standartinio metodo. Maždaug ties 500 iteracija Dice koeficientas kiek dažniau viršija 0,75 lyginant su standartiniu metodu. iki 2000–2500 iteracijos metodas pasiekia geresnį stabilumą, o ties 3000 iteracija kreivė jau beveik nebesvyruoja. Tuo metu skirtumai tarp standartinio vidutinio mokytojo metodo ir grįsto neapibrėžtumu nebūna milžiniški, tačiau paprastai vis dar išlieka kelių procentų persvara Dice koeficiento ar mažesnio HD95 požiūriu.

Taigi, per ilgesnį, kelių tūkstančių iteracijų, mokymosi procesą abiejų metodų kreivės ima panašėti, tačiau neapibrėžtumu grįstas metodas paprastai geriau pasiekia pagrindinį stabilumą ir kiek rečiau susiduria su nuostolių svyravimais vidurinėje mokymosi stadijoje. Baigiamosiose 2000–3000 iteracijų fazėse abu metodai yra gerai adaptavęsi prie padidintų vaizdų matmenų, o segmen-

tavimo rezultatas, rodo minimalus svyravimus ir pasiekia bendrą, artimą, bet ne identišką tikslumo lygį. Rezultatai pateikti 35 paveikslėlyje.

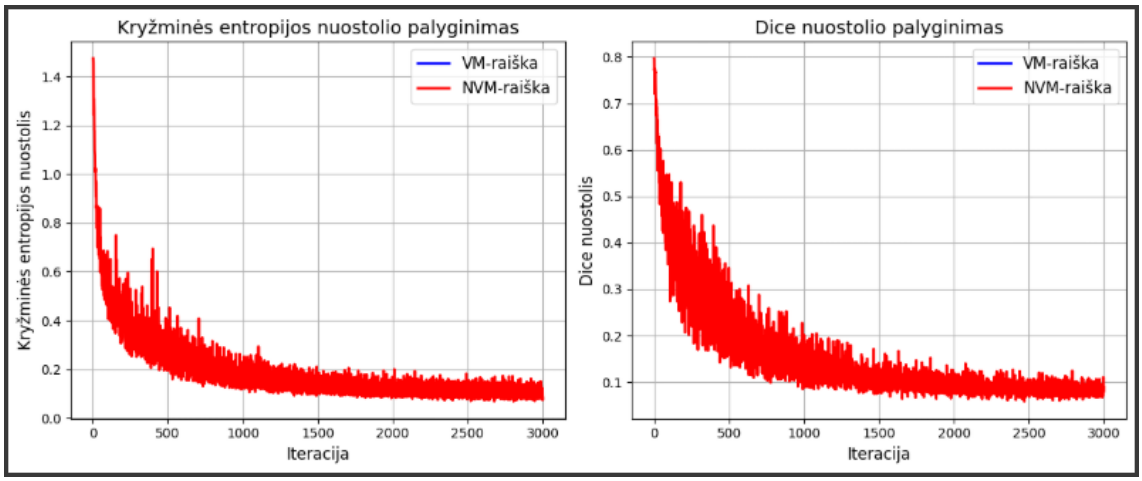

35 pav. VM–raiška mokymosi nuostolių kreivių palyginimas su NVM–raiška

5.3.8. Validavimo etapas

Šiame skyriuje pateikiamos kelios lentelės, tai yra 11, 12, 13, 14 ir 15, kuriose atvaizduojami vidutinio mokytojo metodo ir vidutinio mokytojo metodo grįsto neapibrėžtumu rezultatai. Kiekvienoje lentelėje lyginamos metrikos, Dice koeficiento ir HD95, gautos skirtingų iteracijų metų.

11 lentelė. Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–bazinis ir NVM–bazinis

Iteracija	**VM–bazinis**		**NVM–bazinis**	
	Dice	**HD95**	**Dice**	**HD95**
200	0,4305	19,26014	0,3854	23,13204
400	0,4924	18,53826	0,4530	20,44336
600	0,4984	17,41238	0,5245	17,02318
800	0,5394	**15,78221**	0,5370	17,99681
1000	0,5467	16,80641	0,5475	17,60901
1200	0,5509	16,63231	0,5505	16,55491
1400	0,5421	18,15452	**0,5680**	15,91262
1600	0,5459	17,30232	0,5554	16,06812
1800	0,5541	17,52732	0,5647	15,88602
2000	**0,5566**	17,52992	0,5563	16,37802
2200	0,5405	17,78292	0,5543	**15,72522**
2400	0,5414	17,92403	0,5590	16,05743
2600	0,5462	17,95133	0,5538	16,15473
2800	0,5482	18,03023	0,5565	16,02293
3000	0,5465	17,92500	0,5565	15,90250

12 lentelė. Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–partija ir NVM–partija

Iteracija	**VM–partija**		**NVM–partija**	
	Dice	**HD95**	**Dice**	**HD95**
200	0,4558	20,49794	0,4543	20,03574
400	0,4834	19,79686	0,4783	18,43386
600	0,4943	**17,98588**	0,5292	16,52528
800	0,523	18,93131	0,5375	18,07001
1000	0,5483	18,105412	0,5348	17,246212
1200	0,5352	18,810314	0,5542	17,223914
1400	0,5408	18,985616	0,5577	15,902416
1600	0,5482	18,074118	0,5606	15,808118
1800	0,5503	18,30522	0,5545	15,77892
2000	0,5468	18,513222	0,5543	15,826322
2200	0,5473	19,315624	**0,5639**	**15,264024**
2400	0,5497	18,495826	0,5578	15,359926
2600	0,5501	18,554428	0,5554	15,729728
2800	0,5484	18,70453	0,5564	15,64403
3000	**0,551**	18,4388	0,5566	15,5782

13 lentelė. Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–duomenys ir NVM–duomenys

Iteracija	**VM–duomenys**		**NVM–duomenys**	
	Dice	**HD95**	**Dice**	**HD95**
200	0,4558	20,49794	0,4543	20,03574
400	0,4834	19,79686	0,4783	18,43386
600	0,4943	**17,98588**	0,5292	16,52528
800	0,523	18,93131	0,5375	18,07001
1000	0,5483	18,105412	0,5348	17,246212
1200	0,5352	18,810314	0,5542	17,223914
1400	0,5408	18,985616	0,5577	15,902416
1600	0,5482	18,074118	0,5606	15,808118
1800	0,5503	18,30522	0,5545	15,77892
2000	0,5468	18,513222	0,5543	15,826322
2200	0,5473	19,315624	**0,5639**	**15,264024**
2400	0,5497	18,495826	0,5578	15,359926
2600	0,5501	18,554428	0,5554	15,729728
2800	0,5484	18,70453	0,5564	15,64403
3000	**0,551**	18,4388	0,5566	15,5782

14 lentelė. Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–sparta ir NVM–sparta

Iteracija	**VM–sparta**		**NVM–sparta**	
	Dice	**HD95**	**Dice**	**HD95**
200	0,3972	21,65884	0,4248	20,54584
400	0,4596	19,55856	0,4043	24,11766
600	0,4560	20,26158	0,5133	18,22048
800	0,5055	18,84791	0,5506	17,15841
1000	0,5586	15,744012	0,5546	16,796512
1200	0,5506	15,873514	0,5686	15,598214
1400	0,5767	16,057316	0,5902	13,520516
1600	0,6140	12,919318	0,5675	16,479018
1800	0,6013	14,222920	0,5966	13,634520
2000	**0,6229**	12,388122	0,5974	13,575922
2200	0,6206	12,585924	0,6021	13,198424
2400	0,6094	13,174726	0,5905	13,825426
2600	0,6137	12,842728	**0,6041**	13,021328
2800	0,6152	12,833830	0,6009	12,985830
3000	0,6171	**12,543300**	0,6039	**12,834000**

15 lentelė. Validacijos metrikų dinamika (kas 200 iteracijų) naudojant VM–raiška ir NVM–raiška

Iteracija	**VM–raiška**		**NVM–raiška**	
	Dice	**HD95**	**Dice**	**HD95**
200	0,4683	23,68984	0,4229	25,72944
400	0,4974	23,10366	0,5134	23,50146
600	0,5545	21,30578	0,5281	20,55578
800	0,558	21,14521	0,5506	**19,14271**
1000	0,5883	21,630612	0,5758	19,821312
1200	0,5829	22,554514	0,5778	20,792514
1400	0,5883	20,227416	0,5809	20,158116
1600	0,5936	20,965918	0,5782	19,615318
1800	0,5871	20,85382	0,5772	21,46172
2000	**0,5975**	19,289922	**0,5868**	20,018822
2200	0,5902	20,251124	0,5798	19,706124
2400	0,5927	**19,259526**	0,5815	19,789326
2600	0,5914	19,417328	0,5821	20,434928
2800	0,5898	19,97723	0,5843	20,03913
3000	0,5919	19,6864	0,5822	20,1977

5.3.9. Testavimo etapas

Šiame skyriuje pateikti vidutinio mokytojo metodo grįsto neapibrėžtumu vizualiniai segmentavimo rezultatai, kuriuose spalvinis atrodo būtent taip, žalia nurodo numatomą kasą, o raudona numatomą naviką. Rezultatai pateikti 38 paveikslėlyje.

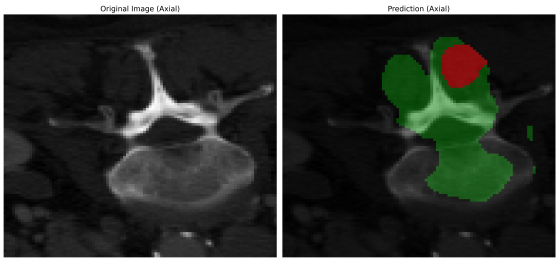

36 pav. Kasos vaizdas – 023, NVM–sparta

37 pav. Kasos vaizdas – 174, NVM–partija

38 pav. Testavimo metu gauti įvairūs segmentavimo vizualus rezultatai

5.4. Fiksuoto atitikmens metodo praktinė analizė

Šiame skyriuje pristatomas fiksuoto atitikmens metodas, kuris yra vienas iš esminių nuoseklumo reguliavimo metodu pusiau prižiūrimo mokymosi kontekste. Metodas remiasi principu, kad modelio prognozės turėtų išlikti stabilios net ir esant stiprioms duomenų manipuliacijoms, todėl vienu metu naudojami du skirtingi augmentacijos lygiai. Pirmoje stadijoje atliekama silpnoji augmentacija, kurios metu generuojamos pseudo etiketės iš nepažymėtų duomenų, o antroje stiprioji augmentacija, kurios tikslas yra patikrinti, ar modelis išlaiko prognozių nuoseklumą. Tokiu būdų fiksuoto atitikmens metodas padeda efektyviai išnaudoti ribotą pažymėtų duomenų kiekį, stiprindamas modelio mokymosi procesą ir gerindamas segmentavimo tikslumą. Toliau bus išsamiai nagrinėjami praktiniai eksperimentų rezultatai.

5.4.1. Duomenų paruošimas

Šiame skyriuje aprašomas duomenų paruošimo procesas. Pirmiausia, duomenys kopijuojami iš pirminių saugyklų, *Google Drive*, į skaičiavimo aplinką, *Google Colab*, užtikrinant, kad visos reikalingos duomenų struktūros būtų teisingai sukurtos ir patalpintos. Toliau vykdomas trimačių medicininių vaizdų ir atitinkamų etikečių apkarpymas pagal dominančios srities paiešką. Šis etapas apima tikslų turimų etikečių panaudojimą, siekiant išskirti tik aktualias vaizdo dalis. Gauti rezultatai išsaugomi *HDF5* formatu, tiek kaip pilnos trimatės apimties duomenys, tiek kaip atskirti dvimačiai pjūviai, kas suteikia lankstumo tolesniam duomenų apdorojimui.

Galiausiai, sugeneruojami duomenų sąrašai, kurie padalina turimus duomenis į mokymosi, validacijos ir testavimo aibes. Duomenys suskirstyti taip: 180 mokymuisi, 44 validavimui, 224 testavimui ir 21504 pjūviai.

5.4.2. FA–bazinis

Per visas 3000 iteracijų stebimas modelio mokymosi procesas. Pirmuosiuose 1000 iteracijų vyrauja agresyvus mokymasis, nuostoliai staigiai krito nuo 2,28 iki 0,87, tačiau vėliau įstrigo cikliškuose svyravimuose tarp 0,4–0,85. 600–1000 iteracijų etape nuostoliai periodiškai viršijo 0,72. Tolesniuose 1001–-2000 iteracijų metu svyravimai išliko, nuostoliai siekė nuo 0,358 iki 0,783, tačiau vidutinė tendencija buvo lėtas mažėjimas nuo maždaug 0,55 iki 0,42. Šis pokytis atsispindėjo metrikose, Dice koeficientas pagerėjo nuo 0,355 iki 0,414, o Hausdorff atstumas sumažėjo nuo 34,87 iki 31,35. Tačiau net 2000 iteracijoje pastebimi staigūs nuostolių šuoliai, pavyzdžiui 0,661 ties 1755 iteracija ir dideli HD95 svyravimai. Ribotas pažymėtų pavyzdžių skaičius lygus 7, neleido išmokti smulkios anatomijos, kas paaiškina, kodėl Dice progresas buvo lėtesnis už HD95 pagerėjimą. Paskutiniame etape, 2001–3000 iteracijos, modelis pasiekė minimalų stabilumą, nuostoliai svyravo tarp 0,08 ir 0,78, bet jų vidurkis stabiliai mažėjo maždaug nuo 0,42 iki 0,15. Metrikos taip pat parodė inkrementinį pagerėjimą, Dice koeficientas pakilo iki 0,411, o HD95 sumažėjo iki 30,28. Tačiau net 3000 iteracijoje išliko struktūrinės problemos, staigūs nuostolių šuoliai, pavyzdžiui, 0,78 ties 2641 iteracija, ir HD95 reikšmių atotrūkiai, pavyzdžiui, 30,28 prieš 34,16 ankstesniuose iteracijų etapuose. Galutiniai rezultatai patvirtina, kad esamas hiperparametrų derinys, mokymosi greitis 0,01, pseudo žymėjimų slenkstis 0,8 yra per agresyvus pilnai pasinaudoti pusiau prižiūrimo mokymosi privalumais, ypač dirbant su mažu pažymėtų duomenų kiekiu. Rezultatai pateikti 39 paveikslėlyje.

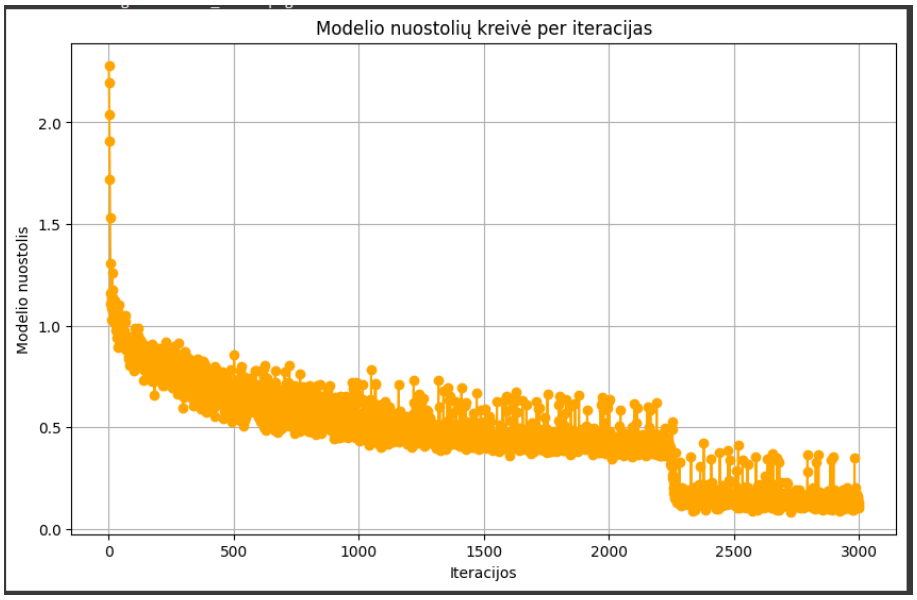

39 pav. FA–bazinis mokymosi nuostolių kreivė

5.4.3. FA–sparta

FA–bazinis eksperimento pradžioje, kai modelio svoriai dar neturėjo išsivysčiusios adaptacijos, pastebima, kad 1 iteracijos metu modelio nuostolis siekė apie 2,28. Per pirmąsias 50 iteracijų nuostolių kreivė rodo greitą kritimą, nuostoliai sumažėjo iki maždaug 0,91. Vėliau, tolstant nuo 50 iteracijų iki 300 iteracijų, modelio nuostoliai toliau mažėjo ir svyravo maždaug tarp 0,94 ir 1,06,

o vėlesniuose etapuose, iki 3000 iteracijų, stabilizavosi ir svyravo apie 0,75–1,0. Galutiniuose etapuose, kai mokymasis pasiekė 3000 iteracijų, vidutinis Dice koeficientas buvo lygus 0,38, o 95 % Hausdorff atstumas apie 30,28.

FA–sparta eksperimento metu, naudojant mažesnę mokymosi spartą, 0,001, pradinės iteracijos rodikliai išlieka panašūs, pradiniu momentu modelio nuostolis taip pat prasideda apie 2,28. Tačiau per pirmąsias 50 iteracijų nuostolių kritimas vyksta lėčiau, modelio nuostoliai sumažėja iki maždaug 1,00, o per iteracijas 100–200 vidutinės reikšmės pasiekia apie 0,55–0,65. Viduriniame mokymosi etape, apie 2000 iteracijų, modelio nuostoliai svyravo apie 0,55, o artėjant prie 3000 iteracijų, vidutinis nuostolis sumažėjo iki maždaug 0,486.

Lyginant abu variantus, matyti, kad abu eksperimentai pasiekia panašią vidutinę Dice vertę, apie 0,38, tačiau svarbus skirtumas pastebimas HD95 rodikliuose. FA–bazinis eksperimento metu galutinis HD95 siekė apie 30,28, o FA–sparta eksperimento pradžioje, apie iteraciją 2000, HD95 buvo vertinamas apie 26,03. Tai rodo, kad nors lėtesnė mokymosi sparta leidžia modelio nuostoliams toliau mažėti ir išlaikyti vidutinę vertę šiek tiek žemesnę, pseudo žymėjimų generavimo tikslumas, ypač segmentacijos ribų apibrėžimas, lieka nepakankamai aukštas.

Galutinė išvada yra ta, kad abiejuose eksperimentuose bendras vidutinis Dice koeficientas pasiekia apie 0,38, tačiau pasirinkta mokymosi sparta daro reikšmingą įtaką nuostolių dinamikai, aukštesnė sparta lygi 0,01, leidžia greičiau atlikti didelius svorių atnaujinimus ir greitą pradinį pseudo etikečių generavimą, o mažesnė sparta lygi 0,001, pasiekia žemesnes nuostolio vertes, bet galutiniame etape pseudo etikečių tikslumas, ypač segmentacijos ribų apibrėžimas, lieka neidealus. Rezultatai pateikti 40 paveikslėlyje.

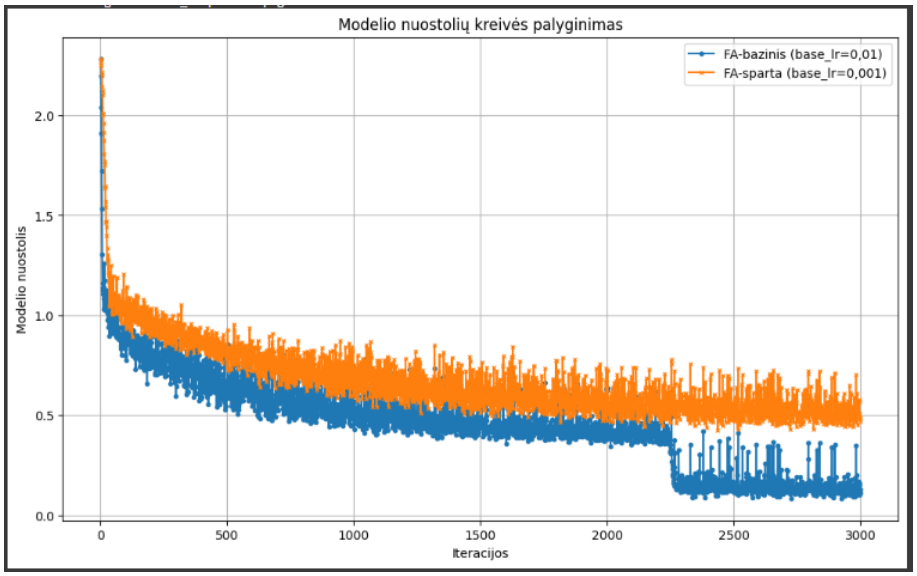

40 pav. FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–sparta

5.4.4. FA–duomenys

FA–duomenys eksperimento atveju, naudojant daugiau pažymėtų duomenų, tai yra, 21, ir 512 iteracijas per epocha, pradinės iteracijos rodikliai buvo panašūs, pradinė nuostolio vertė apie 2,285, o per pirmąsias 50 iteracijų nuostolis sumažėjo iki maždaug 0,95. Nors abiejuose eksperimen-

tuose, tiek FA–bazinis, tiek FA–duomenys, pradiniai nuostolių rodikliai yra beveik identiški, FA–duomenys eksperimento galutiniame etape pasiektas vidutinis Dice koeficientas išliko apie 0,38, tuo tarpu 95 % Hausdorff atstumas sumažėjo iki maždaug 25,27. Tai rodo, kad papildomų pažymėtų duomenų naudojimas ir didesnis iteracijų skaičius per epochą leidžia modelio mokymosi proceso metu pagerinti segmentacijos tikslumą.

Apibendrinant, nors abiejuose eksperimentuose modeliai pasiekia panašų vidutinį Dice koeficientą, FA–duomenys eksperimentas dėl didesnio pažymėtų duomenų kiekio ir didesnio iteracijų skaičiaus per epocha demonstruoja geresnį segmentacijos tikslumą. Rezultatai pateikti 41 paveikslėlyje.

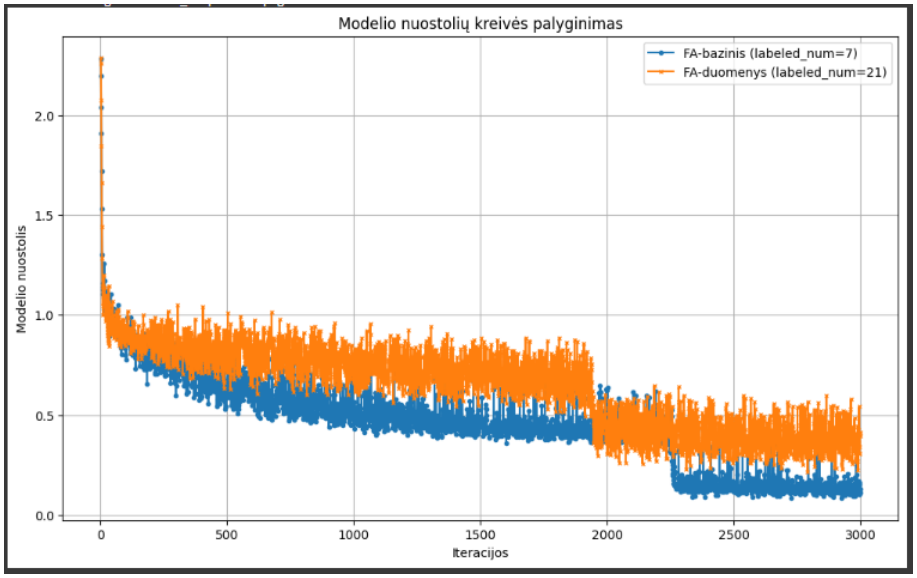

41 pav. FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–duomenys

5.4.5. FA–nuoseklumas

Atliktame eksperimente, kuriame buvo įvykdytos 3000 iteracijos, pagrindinis skirtumas su FA–bazinis eksperimentu glūdi skirtinguose hiperparametruose. FA–bazinis eksperimente, reikšmingas nuoseklumo hiperparametras buvo lygus 0.1, o jo pagreitis 200. Tuo tarpu FA–nuoseklumas eksperimente, nuoseklumas buvo lygus 10,0, o pagreitis buvo padidintas iki 400. Tai reiškia, kad FA–nuoseklumas eksperimente naudojama kur kas didesnė nuoseklumo vertė ir ilgesnis laiko tarpas jai pasiekti, o FA–bazinis eksperimente ši vertė buvo mažesnė ir lėčiau užauganti.

Lyginant abiejų eksperimentų eigą, žvelgiant į keletą atskaitos taškų, ties 200 iteracija, FA–bazinis eksperimente matyti, kad Dice nuostolis yra lygus 0,355, o HD95 lygus 12,3543, tuo tarpu FA–nuoseklumas eksperimente, Dice nuostolis lygus 0,363 ir HD95 lygus 12,93. Vėliau, ties 600 iteracija, FA–bazinis eksperimente modelis pasiekė Dice nuostolį lygu 0,40 bei HD95 32,35, o FA–nuoseklumas Dice nuostolis buvo lygus 0,40, o HD95 – 30,46. Ties 800 iteracija, Dice nuostolių rodikliai taip pat buvo labai artimi, FA–bazinis eksperimente 0,3937, FA–nuoseklumas 0,3922. Įdomu tai, kad ties 2000 iteracija, FA–bazinis eksperimente, Dice nuostolis pakilo iki 0,41, O HD95 nukrito iki 31,34, tuo tarpu FA–nuoseklumas eksperimente, Dice nuostolis siekė 0,40, o HD95 buvo 31,72. Taigi ties šita iteracija, FA-bazinis eksperimento rodikliai buvo šiek tiek geresni.

Apibendrinant, abu eksperimentai parodė panašius rezultatus, Dice nuostolių reikšmės ganėtinai artimos. FA–nuoseklumas eksperimento metu panaudota aukšta nuoseklumo reikšmė kartais greičiau pakeldavo Dice vertę, bet tuo pačiu įtakodavo HD95 svyravimus, ypač ankstyvose iteracijose. FA–bazinis eksperimente panaudota žemesnė nuoseklumo reikšmė suteikė stabilesnį HD95 kai kuriose vėlesnėse iteracijose, bet Dice rodiklis iš esmės išliko panašus. Taigi pagrindinis pokytis tarp eksperimentų glūdi būtent hiperparametrų nustatymuose, o bendras segmentavimo tikslumas abiejuose eksperimentuose yra gana artimas. Rezultatai pateikti 42 paveikslėlyje.

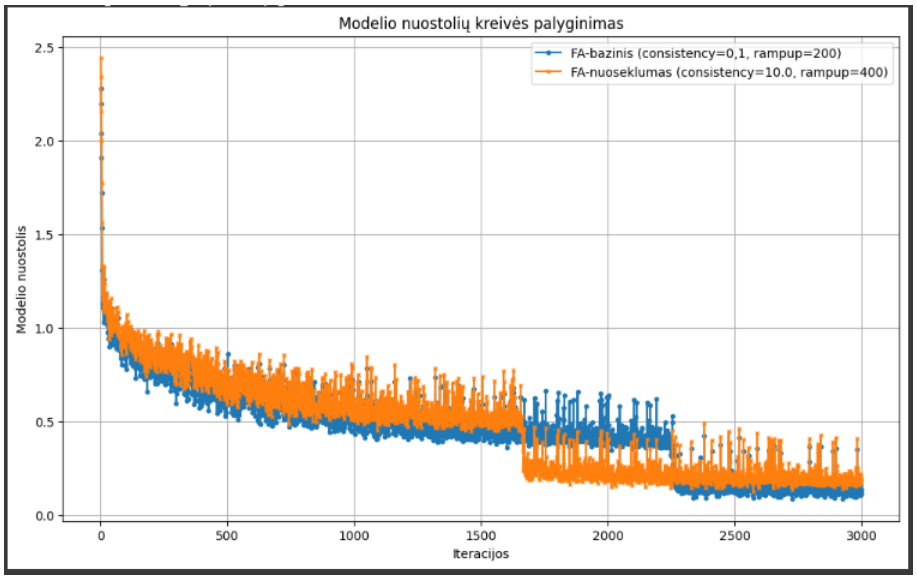

42 pav. FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–nuoseklumas

5.4.6. FA–partija

Šio eksperimento pagrindinis hiperparametrų skirtumas yra partijos dydis. FA–bazinis eksperimente naudojamas 256x256, o FA–partija 384x384, tuo tarpu kiti svarbiausi hiperparametrai yra tokie patys. Šis didesnis partijos dydis reiškia, kad iteracijos metu modelis apdoroja platesnę vaizdo sritį.

Pirmajame eksperimente, ties 200 iteracija modelio vidutinė Dice reikšmė buvo apie 0,3558, o HD95 apie 12,354. FA–partija eksperimente tuo pačiu metu Dice nuostolis buvo lygus 0,36, tačiau HD95 reikšmė siekė apie 16,50. Matyti, kad su didesniais iškirptais vaizdo plotais modelis anksti pasiekia aukštesnę vidutinę Dice reikšmę, tačiau tuo pačiu aptinkamas didesnis HD95, rodantis, kad modeliui yra sunkiau tiksliai atkartoti smulkesnes struktūras. Ties 300 iteracija, FA–bazinis eksperimente pastebima, kad modelio nuostolis vidutiniškai sukasi apie 0,74. FA–partija eksperimente ties 300 iteracija, modelio nuostolis būna apie 0,77, Dice ir HD95 taip pat tarpiniuose taškuose išlieka panašaus lygio, kur Dice perkopia 0,36–0,37, o HD95 kartais pakyla virš 16. Vėlesnėse iteracijose, abiejuose eksperimentuose Dice stengiasi kilti virš 0,38–0,40 ribos, o HD95 paprastai svyruoja gana plačiose ribose. FA–partija eksperimente HD95 ilgiau išlieka didesnė, nes didesnis partijos dydis, reiškia, kad segmentavimo klaidos vaizdų kraštuose gali būti labiau akcentuojamos ir modeliui reikia daugiau iteracijų, kad surastų optimalų svorių išdėstymą. FA–bazinis eksperimente HD95 savo ruoštu buvo mažesnė anksčiau, bet Dice vertė nebuvo ženkliai aukštesnė.

Galutinės 3000 iteracijos rezultatai rodo, kad abiejuose eksperimentuose Dice nuostolis priartėja prie gana mažos reikšmės, tik FA–partija eksperimente vietomis pastebimi staigesni HD95 svyravimai, o FA–bazinis, stabilesnis, tačiau vidutiniškai nedaug kuo besiskiriantis. Esminis pokytis tarp FA–bazinis ir FA–partija eksperimento, gerokai didesnis iškirpto vaizdo plotas FA–partija, kuris ankstyvose iteracijose pakelia Dice vertė, bet tuo pat ir sukelia didesnį HD95, ir tik vėlesnėse iteracijose modelis labiau stabilizuojasi. Rezultatai pateikti 43 paveikslėlyje.

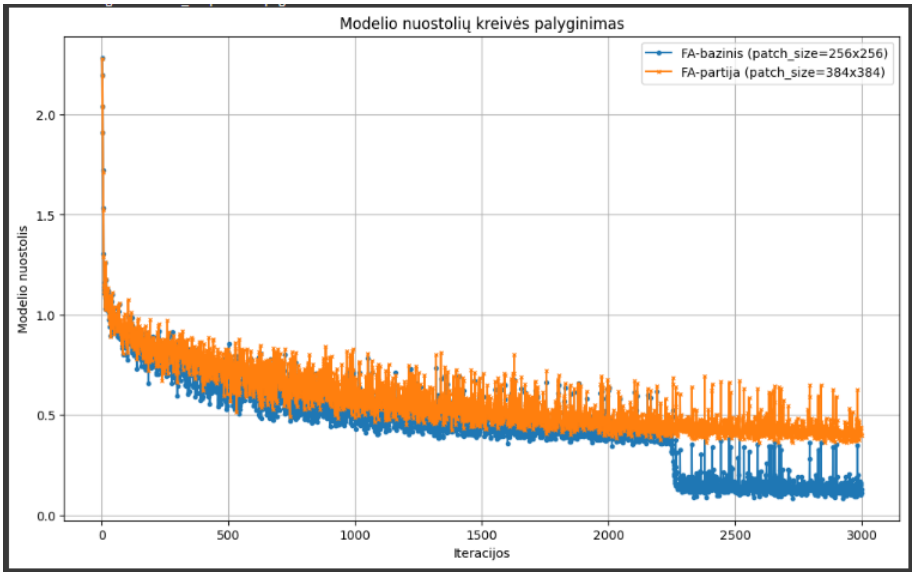

43 pav. FA–bazinis mokymosi nuostolių kreivės palyginimas su FA–partija

5.4.7. Validavimo etapas

Eksperimentų rezultatai parodė, kaip išmokyti penki fiksuoto atitikmens metodo modeliai atliko segmentavimo užduotį per 3000 iteracijų. Geriausiai pagal segmentavimo tikslumą, Dice koeficientą, pasirodė FA–partija atitikmens metodas, kurio Dice vertė siekė 0,4214. Tai rodo, kad šio eksperimento modelis geriausiai sugebėjo atkartoti norimą segmentavimo struktūrą. Blogiausią rezultatą pagal Dice koeficientą gavo antrasis eksperimentas, kurio Dice vertė siekė vos 0,3801, tai reiškia, kad modelio segmentavimo tikslumas buvo prasčiausias.

Vertinant HD95, kur mažesnė reikšmė yra geriau, geriausią ribų tikslumą pademonstravo FA–duomenys eksperimentas su HD95 reikšme lygi 21,35. Tai reiškia, kad šiame eksperimente modelio segmentavimo ribos buvo tiksliausiai atkartotos.

Bendrai, eksperimentai rodo, kad modelio našumas priklauso nuo naudojamų hiperparametrų ir kiekvienas eksperimentas turėjo skirtingą efektyvumą. Rezultatai pateikti 16 lentelėje.

16 lentelė. Validacijos metrikų dinamika visuose 5 eksperimentuose (kas 200 iteracijų)

Iteracija	**FA–bazinis**		**FA–sparta**		**FA–duomenys**		**FA–nuoseklumas**		**FA–partija**	
	Dice	HD95	Dice	HD95	Dice	HD95	Dice	HD95	Dice	HD95
200	0,3558	12,35	0,4155	13,70	0,3482	**16,30**	0,3635	**12,93**	0,3664	16,50
400	0,3718	16,79	0,3917	**11,23**	0,3769	19,84	0,3693	23,30	0,3585	**15,80**
600	0,4084	32,35	0,3615	11,56	0,3790	25,27	0,4032	30,47	0,3982	16,48
800	0,3938	**27,89**	0,3592	24,30	0,3764	28,22	0,3923	29,74	0,4031	19,35
1000	0,4136	34,87	**0,3917**	29,39	0,3877	25,85	0,3909	33,67	**0,4214**	27,47
1200	0,3970	34,17	0,3840	31,91	0,4005	29,47	0,3816	35,65	0,4189	29,00
1400	0,4079	34,16	0,3792	21,34	0,3950	24,98	0,3749	34,26	0,4051	21,14
1600	0,4095	33,64	0,3834	32,69	0,3646	25,94	0,3792	29,68	0,3981	26,62
1800	0,4088	33,23	0,3749	25,85	0,3747	28,58	0,3830	32,50	0,4084	27,58
2000	0,4140	31,35	0,3783	26,03	**0,4161**	24,66	**0,4062**	31,72	0,4134	24,24
2200	0,4044	32,72	0,3728	27,65	0,3961	26,46	0,3879	32,00	0,3979	24,18
2400	0,4154	30,70	0,3755	27,75	0,3963	24,06	0,3864	31,06	0,4105	28,27
2600	**0,4186**	30,78	0,3790	31,14	0,3930	22,51	0,3920	32,14	0,4140	28,61
2800	0,4021	30,99	0,3803	30,84	0,3978	22,20	0,3798	30,96	0,4106	28,27
3000	0,4109	30,28	0,3801	30,28	0,3924	21,35	0,3852	31,38	0,4106	27,43

5.4.8. Testavimo etapas

Šiame skyriuje pateikiama fiksuoto atitikmens metodo testavimo rezultatų vizualinė analizė, kurioje matomi segmentavimo rezultatai įvairiems kompiuterinės tomografijos kasos mediciniams vaizdams. Kiekvienas pavaizduotas vaizdas rodo modelio segmentuotą kasos sritį kartu su numatomomis ribomis ir palyginimu su vaizdo etikete. Tai leidžia vizualiai įvertinti modelio tikslumą skirtingose situacijose.

Vizualizacijose galima pastebėti, kad tam tikruose pavyzdžiuose modelis tiksliai atkartoja naviko ribas, tačiau kai kuriuose atvejuose yra neatitikimų tarp numatytos ir realios segmentacijos. Pavyzdžiai pateikti 44 ir 45 paveikslėliuose.

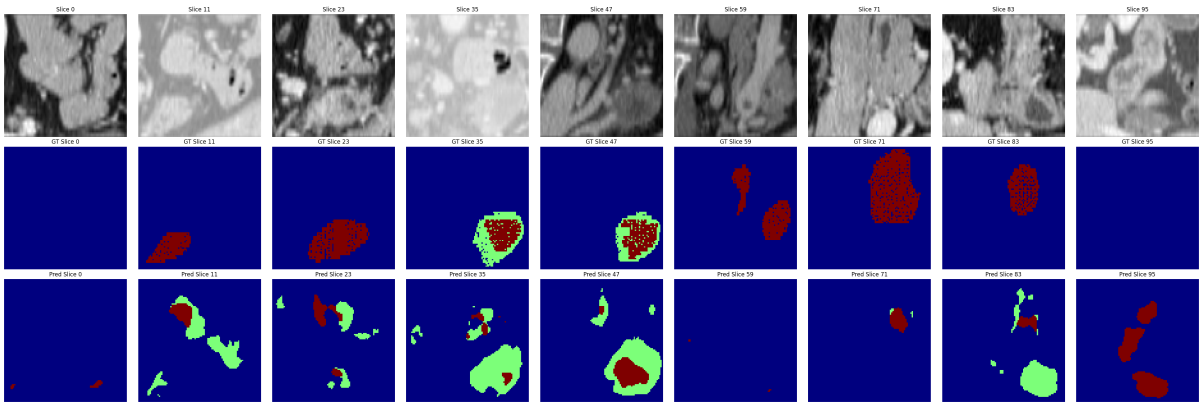

44 pav. Kasos pjūviai ir jų segmentacijos rezultatas – 180 pavyzdys, FA–nuoseklumas

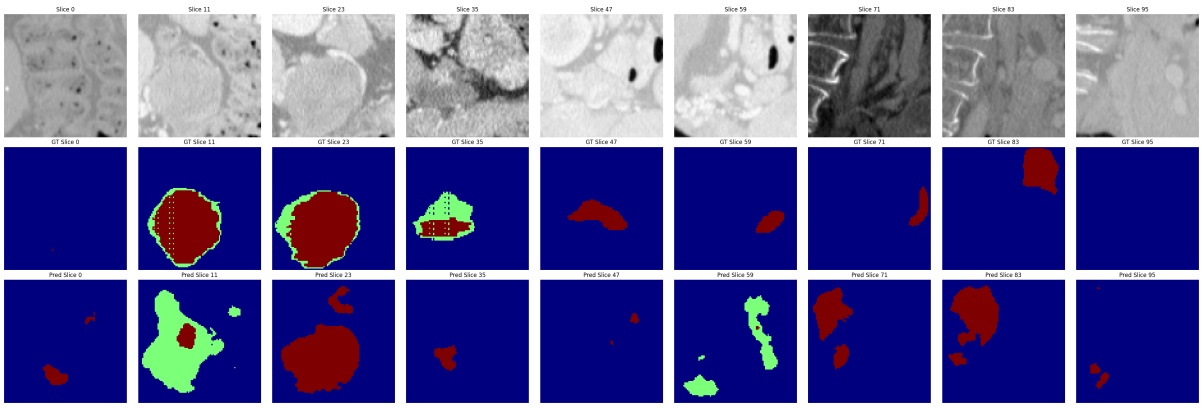

45 pav. Kasos pjūviai ir jų segmentacijos rezultatas – 414 pavyzdys, FA–partija

5.5. Apibendrinimas

Tyrimo metu buvo atlikta išsami pusiau prižiūrimo mokymosi metodų praktinė analizė, skirta kasos vėžio kompiuterinės tomografijos vaizdų segmentavimo uždaviniams spręsti. Analizės metu buvo įvertinti trys skirtingi metodai, vidutinio mokytojo metodas, jo patobulinta versija, grįsta neapibrėžtumu ir fiksuoto atitikmens metodas. Kiekvienas metodas buvo išbandytas keliais eksperimento scenarijais, siekiant išnagrinėti skirtingus aspektus, duomenų paruošimą, tai yra, įvesties vaizdo dydį, skirtingas hiperparametrų vertes, mokymosi spartą, pažymėtų duomenų dalies kitimą, tiek partijos sudėtyje, tiek bendrą kiekį, bei taip pat buvo atlikti modelių validavimo ir testavimo etapai. Toks eksperimentų planas leido sistemiškai įvertinti, kaip kiekvienas prieš tai minėtas veiksnys veikia modelio segmentavimo tikslumą bei mokymosi proceso efektyvumą.

VM–bazinis eksperimente buvo nustatytas bazinis modelio veikimas esant ribotam pažymėtų vaizdų kiekiui. Vėlesniuose bandymuose šis metodas buvo adaptuotas, VM–raiška eksperimente padidinti įvesties vaizdų matmenys, siekiant suteikti modeliui daugiau kontekstinės informacijos, VM–partija, padidinta pažymėtų vaizdų dalis kiekvienoje mokymosi partijoje, VM–duomenys, padvigubintas bendras pažymėtų vaizdų skaičius mokymosi aibėje, nuo 25 iki 50, taip sumažinant priklausomybę nuo pseudo etikečių, VM–sparta, padidinta mokymosi sparta nuo nuo 0,01 iki 0,1, siekiant stabilesnio konvergavimo. Analogiški eksperimentai buvo pritaikyti ir neapibrėžtumu grįsto vidutinio mokytojo metodo vertinimui, kad būtų galima palyginti, ar papildomos modelio konfigūracijos pagerina mokymosi rezultatus. Galiausiai, fiksuoto atitikmens metodui taip pat buvo pritaikyti penki eksperimentų variantai, bazinis modelio mokymasis su numatytais hiperparametrais, bei keturi adaptuoti bandymai keičiant mokymosi spartą, bendrą pažymėtų duomenų kiekį, pseudo etikečių generavimo nuoseklumo parametrus bei mokymosi partijos dydį. Kiekvieno metodo atveju po mokymosi etapo buvo atlikta modelių validacija ir testavimas, siekiant objektyviai įvertinti segmentavimo tikslumo rodiklius, tokius kaip Dice koeficientas ir 95 % Hausdorff atstumas skirtingomis sąlygomis.

Visų atliktų eksperimentų rezultatai parodė, kad pusiau prižiūrimo mokymosi metodais galima sėkmingai apmokyti segmentavimo modelį net ir turint labai ribotą pažymėtų duomenų kiekį, tačiau galutinis tikslumas šiuo atveju yra vidutinis. VM–bazinis su mažos apimties įvesties duomenimis pasiekė gana ribotą segmentavimo tikslumą, validacijos metu Dice rodiklis tesiekė apie

0,13–0,15. Padidinus įvesties vaizdo matmenis, modelio veikimas ženkliai pagerėjo, jau ankstyvose iteracijose Dice koeficientas padidėjo iki maždaug 0,25, o vėlesniu mokymosi etapu stabilizavosi ties maždaug 0,30–0,32. Tai patvirtina, jos platesnis kontekstinis vaizdas padeda modeliui geriau atpažinti sudėtingas anatomines struktūras. Didesnė vaizdo raiška suteikė maždaug 2 kartus aukštesnį segmentavimo tikslumą lyginant su VM–bazinis modeliu. Padidinus pažymėtų duomenų dalį partijoje, taip pat stebėtas reikšmingas šuolis, modelis greičiau sumažino nuostolio funkcijos reikšmes ir validacijos metu pasiekė žymiai aukštesnį Dice koeficientą. Pavyzdžiui, su 3 pažymėtais vaizdais partijoje segmentavimo tikslumas augo sparčiau ir pralenkė ankstesnį VM–bazinis bandymą su 2 pažymėtais vaizdais, o konvergavimas tapo tolygesnis. Bendro pažymėtų vaizdų skaičiaus didinimas nuo 25 iki 50 davė dar didesnę naudą, modelis mokymosi metu konvergavo stabiliau, kryžminės entropijos ir Dice nuostolio kreivės greičiau nusistovėjo ties mažesnėmis reikšmėmis. Šiuo atveju segmentavimo modelis, turėdamas dvigubai daugiau pažymėtų vaizdų, sugebėjo efektyviau išmokti pagrindinius segmentavimo dėsningumus, mokymosi pabaigoje Dice nuostolis sumažėjo iki maždaug 0,2, o validacijos tikslumas buvo akivaizdžiai geresnis nei naudojant tik 25 pažymėtus vaizdus. Tai rodo, kad papildomi pažymėti vaizdai ženkliai pagerina modelio gebėjimą generalizuoti, modelis mažiau persimoko ir gali patikimiau segmentuoti nematytus vaizdus. Galiausiai, VM–sparta eksperimente padidinus mokymosi spartą dešimteriopai, pastebėta, kad abiem atvejais modeliai pasiekė panašų galutinį Dice koeficientą, tačiau mokymosi dinamika skyrėsi. Didesnė mokymosi sparta leido sparčiau sumažinti nuostolius pradžioje ir greičiau generuoti pseudo etiketes, tačiau mažesnė sparta užtikrino žemesnes nuostolių reikšmes vėlesnėse iteracijose ir šiek tiek pagerino segmentavimo tikslumą.

Lyginant neapibrėžtumu grįstą vidutinio mokytojo metodą su standartiniu vidutinio mokytojo metodu, nustatyta, kad išplėstinė architektūra, padeda pasiekti stabilesnį mokymosi procesą. Šis metodas generavo patikimesnes pseudo etiketes, pastebėta, kad ankstyvose mokymosi stadijose nuostolių kreivės krito tolygiau, o modelių tarpusavio bendras mokymasis sumažino atsitiktinių svyravimų įtaką. Tai indikuoja, kad įtraukiant neapibrėžtumu įvertinimus galima efektyviau išnaudoti nepažymėtus duomenis, modelis rečiau klysta dėl neaiškių regionų, nes neapibrėžtumo pokyčiai padeda fokusuotis į patikimesnes sritis mokymosi metu. Dėl to ir validacijos metu šis metodas demonstravo šiek tiek aukštesnius rezultatus palyginus su standartiniu vidutinio mokytojo metodu.

Fiksuoto atitikmens metodas taip pat buvo pritaikytas medicininių vaizdų segmentavimui. Tyrimo rezultatai parodė, kad fiksuoto atitikmens metodo taikymas, naudojant numatytuosius hiperparametrus, mokymosi greiti lygu 0,01 ir pseudo etikečių generavimo slenkstį lygu 0,8, suteikia agresyvų modelio mokymąsi, modelis greitai priima galbūt klaidingas pseudo etiketes, todėl mokymosi kreivė tampa nestabili ir konvergavimas lėtėja. Atlikus hiperparametrų derinimą, fiksuoto atitikmens metodas ėmė veikti panašiai efektyviai kaip ir vidutinio mokytojo metodas. Sumažinus mokymosi spartą ir pritaikius tinkamesnį pseudo etikečių generavimo slenkstį, mokymosi nuostoliai mažėjo stabiliau, o galutinis Dice koeficientas priartėjo prie maždaug 0,4. Papildomas pažymėtų duomenų įtraukimas bei didesnė pažymėtų pavyzdžių dalis partijoje, modelio atveju lėmė analogiškas tendencijas, modelio tikslumas ūgtelėjo, o mokymosi kreivės tapo tolygesnės. Taigi,

tinkamai pritaikius fiksuoto atitikmens metodą segmentavimo uždaviniams, gauti rezultatai nenusileido vidutinio mokytojo metodui, abu metodai geriausiu atveju pasiekė apie 0,45–0,55 Dice koeficientą testavimo duomenyse. Šie rodikliai atskleidžia, kad kasos naviko segmentavimo uždavinys, esant ribotam pažymėtų duomenų kiekiui, išlieka sudėtingas, pasiektas tikslumas kol kas nėra pakankamas praktiniam taikymui. Vis dėlto, metodų palyginimas patvirtina pusiau prižiūrimo mokymosi naudingumą, net ir esant vos keletui dešimčių pažymėtų vaizdų, modelis geba mokytis iš šimtų nežymėtų vaizdų ir segmentuoti kasos srities navikus geriau, nei tai būtų įmanoma taikant vien tik pilnai prižiūrimą mokymąsi su tokiais pat mažais duomenų kiekiais.

Išvados

Atlikus išsamų pusiau prižiūrimo mokymosi metodų tyrimą kasos vėžio segmentavimui kompiuterinės tomografijos vaizduose, patvirtinta šių metodų praktinė nauda ir efektyvumas. Darbe išnagrinėtos mokslinės literatūros įžvalgos, atrinktas tinkamiausias duomenų rinkinys ir pritaikyti modernūs algoritmai leido įvertinti pusiau prižiūrimo mokymosi taikymo galimybes. Toliau pateiktos pagrindinės išvados atlikus magistro baigiamąjį darbą.

- Literatūros analizė parodė, kad pusiau prižiūrimas mokymasis leidžia efektyviai išnaudoti nežymėtus duomenis, sumažinant priklausomybę nuo žymėjimo proceso. Tačiau pabrėžiama, kad būtini kokybiški pseudo žymėjimo mechanizmai siekiant išvengti modelio nuosmukių dėl klaidingų žymėjimų.
- Išanalizavus kelis viešus kompiuterinės tomografijos duomenų rinkinius, tinkamiausiu pasirinktas rinkinys su 420 trimačiais kompiuterinės tomografijos vaizdais dėl rinkinyje esančios žymėjimų kokybės ir atitikimo tyrimo tikslams pasiekti.
- Visi pusiau prižiūrimo mokymosi metodai buvo vertinami vienodomis sąlygomis, naudojant Dice ir HD95 metrikas, leidusias objektyviai įvertinti segmentavimo tikslumą ir formų atitikimą.
- Vidutinio mokytojo, nuoseklumu grįsto vidutinio mokytojo ir fiksuoto atitikmens metodų baziniai variantai parodė, kad net su vos 10–20 % pažymėtų duomenų galima pasiekti Dice koeficientą tarp 0,45 ir 0,60.
- Vidutinio mokytojo metodas grįstas neapibrėžtumu pasiekė kiek stabilesnius rezultatus, ypač esant padidintai įvesties raiškai. Fiksuoto atitikmens metodo rezultatai, nors ir silpnesni pradžioje, po hiperparametrų korekcijos priartėjo prie kitų metodų efektyvumo.
- Vidutinio mokytojo metodas pasižymėjimo stabiliu konvergavimu, o duomenų kiekio padvigubinimas ir spartesnis mokymasis gana smarkiai pagerino rezultatus.
- Vidutinio mokytojo metodas grįstas neapibrėžtumu atskleidė potencialą efektyvesniam mokymuisi iš mažiau pažymėtų duomenų, tačiau reikalavo papildomų skaičiavimo resursų.

Atsižvelgiant į gautus rezultatus, tolesniuose tyrimuose verta tirti būdus, kaip pagerinti pusiau prižiūrimus segmentavimo metodus ir padidinti modelio segmentavimo tikslumą. Pirmiausia, akivaizdi sritys, didinti pažymėtų duomenų apimtį. Kaip parodė eksperimentai, papildomi pažymėti duomenys reikšmingai pagerina modelio mokymąsi, todėl investicija į duomenų žymėjimą turėtų tiesioginę naudą. Kitas žingsnis, modelio schemos, tinklo patobulinimas, galimybė integruoti modernesnes giliojo mokymosi architektūras. Tokių architektūrų derinimas su pusiau prižiūrimo mokymosi principais galėtų padėti modeliui geriau išmokti globalius vaizdo požymius ir padidinti segmentavimo tikslumą. Trečia, ateityje verta išbandyti ir kitus pusiau prižiūrimo mokymosi metodus ar jų derinius, pavyzdžiui, savęs mokymosi (*self-training*) algoritmus, kai modelis iteratyviai

tobulinamas pridedant pažymėtus duomenis. Apibendrinant, tolimesni tyrimai turėtų koncentruotis ties pažangesnių modelio architektūrų bei mokymosi strategijų diegimu ir duomenų kiekio plėtimu, toks derinys, galėtų priartinti pusiau prižiūrimo mokymosi metodų veikimą prie praktinių poreikių, užtikrinant ženkliai tikslesnį ir patikimesnį kasos vėžio segmentavimą iš kompiuterinės tomografijos medicininių vaizdų.

Šaltinių sąrašas

[ARB+22] Michela Antonelli, Annika Reinke, Spyridon Bakas, Keyvan Farahani ir k.t. The Medical Segmentation Decathlon. *Nature Communications*, 13(1), 2022-07. ISSN: 2041-1723. DOI: 10.1038/s41467-022-30695-9. http://dx.doi.org/10.1038/s41467-022-30695-9 and https://drive.google.com/drive/folders/1HqEgzS8BV2c7xYNrZdEAnrHk7osJJ--2.

[FAP+20] Abdur R. Fayjie, Reza Azad, Marco Pedersoli, Claude Kauffmann, Ismail Ben Ayed ir Jose Dolz. Semi-supervised few-shot learning for medical image segmentation. *CoRR*, abs/2003.08462, 2020. arXiv: 2003.08462. URL: https://arxiv.org/abs/2003.08462.

[Hou73] Godfrey Newbold Hounsfield. Computerized transverse axial scanning (tomography): Part I. Description of system. 1973. *The British journal of radiology*, 68 815:H166–72, 1973. URL: https://api.semanticscholar.org/CorpusID:5820281.

[YSK+23] Xiangli Yang, Zixing Song, Irwin King ir Zenglin Xu. A Survey on Deep Semi-Supervised Learning. *IEEE Transactions on Knowledge and Data Engineering*, 35(9):8934–8954, 2023-09. ISSN: 2326-3865. DOI: 10.1109/tkde.2022.3220219. URL: http://dx.doi.org/10.1109/TKDE.2022.3220219.

[JZD+23] Rushi Jiao, Yichi Zhang, Le Ding, Rong Cai ir Jicong Zhang. Learning with Limited Annotations: A Survey on Deep Semi-Supervised Learning for Medical Image Segmentation, 2023. arXiv: 2207.14191 [cs.CV].

[LCS+21] Xiangde Luo, Jieneng Chen, Tao Song ir Guotai Wang. Semi-supervised Medical Image Segmentation through Dual-task Consistency. P.p. 8801–8809, 2021.

[LHS+22] Xiangde Luo, Minhao Hu, Tao Song, Guotai Wang ir Shaoting Zhang. Semi-supervised medical image segmentation via cross teaching between cnn and transformer. *International Conference on Medical Imaging with Deep Learning*, p.p. 820–833. PMLR, 2022.

[LLC+21] Xiangde Luo, Wenjun Liao, Jieneng Chen, Tao Song, Yinan Chen, Shichuan Zhang, Nianyong Chen, Guotai Wang ir Shaoting Zhang. Efficient Semi-supervised Gross Target Volume of Nasopharyngeal Carcinoma Segmentation via Uncertainty Rectified Pyramid Consistency. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2021*, p.p. 318–329, 2021.

[Luo20] Xiangde Luo. SSL4MIS. https://github.com/HiLab-git/SSL4MIS, 2020.

[LWL+22] Xiangde Luo, Guotai Wang, Wenjun Liao, Jieneng Chen, Tao Song ir Chen. Semi-Supervised Medical Image Segmentation via Uncertainty Rectified Pyramid Consistency. *Medical Image Analysis*, 80:102517, 2022.

[LZD+23] Tao Lei, Dong Zhang, Xiaogang Du, Xuan Wang, Yong Wan ir Asoke K. Nandi. Semi-Supervised Medical Image Segmentation Using Adversarial Consistency Learning and Dynamic Convolution Network. *IEEE Transactions on Medical Imaging*, 42(5):1265–1277, 2023. DOI: 10.1109/TMI.2022.3225687.

[MBS+20] Moore Michael, Patterson Brandon, Samuel Sara, Sheridan, Helenmary ir Sorensen Chris. Neuroimaging DICOM and NIfTI Data Curation Primer, 2020. URL: http://hdl.handle.net/11299/216582.

[MK19] Xiangjian He Mohammad Hesam Hesamian Wenjing Jia ir Paul Kennedy. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *Journal of Digital Imaging*, 32(2):582–596, 2019. URL: https://link.springer.com/article/10.1007/s10278-019-00227-x.

[MOR+22] Seyed Modaresi, Aomar Osmani, Mohammadreza Razzazi ir Abdelghani Chibani. Medical Image Segmentation: Evaluation, 2022. DOI: 10.34740/KAGGLE/DSV/4728423. URL: https://www.kaggle.com/dsv/4728423.

[Ode16] Augustus Odena. Semi-Supervised Learning with Generative Adversarial Networks, 2016. arXiv: 1606.01583 [stat.ML].

[RFT+16] Roth, H. Farag, A. Turkbey, E. B. Lu, L. Liu, J. ir Summers R. M. Data From Pancreas-CT, The Cancer Imaging Archive. Version 2:Dataset, 2016. URL: https://www.cancerimagingarchive.net/collection/pancreas-ct/.

[SBL+20] Kihyuk Sohn, David Berthelot, Chun-Liang Li, Zizhao Zhang, Nicholas Carlini, Ekin D. Cubuk, Alex Kurakin, Han Zhang ir Colin Raffel. FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence. *CoRR*, abs/2001.07685, 2020. arXiv: 2001.07685. URL: https://arxiv.org/abs/2001.07685.

[SCY+23] Zhiqiang Shen, Peng Cao, Hua Yang, Xiaoli Liu, Jinzhu Yang ir Osmar R. Zaiane. Co-training with High-Confidence Pseudo Labels for Semi-supervised Medical Image Segmentation, 2023. arXiv: 2301.04465 [cs.CV].

[SSP21] Raymond A. Schulz, Jay Stein ir Norbert J. Pelc. How CT happened: the early development of medical computed tomography. *Journal of Medical Imaging*, 8, 2021. URL: https://api.semanticscholar.org/CorpusID:240230432.

[TV17] Antti Tarvainen ir Harri Valpola. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results. I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan ir R. Garnett, redaktoriai, *Advances in Neural Information Processing Systems*, tom. 30. Curran Associates, Inc., 2017. URL: https://proceedings.neurips.cc/paper_files/paper/2017/file/68053af2923e00204c3ca7c6a3150cf7-Paper.pdf.

[ZG09] Xiaojin Zhu ir Andrew B. Goldberg. Introduction to Semi-Supervised Learning:1–18, 2009. URL: http://mitp-content-server.mit.edu:18180/books/content/sectbyfn?collid=books_pres_0&id=6173&fn=9780262033589_sch_0001.pdf.