



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

**Nanodalelių segmentavimas SEM eksperimentiniuose
vaizduose taikant giliojo mokymosi metodus**

Baigiamasis magistro studijų projektas

Monika Bakaitė
Projekto autorė

Doc. Dr. Paulius Palevičius
Vadovas

Kaunas, 2022



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Nanodalelių segmentavimas SEM eksperimentiniuose vaizduose taikant giliojo mokymosi metodus

Baigiamasis magistro studijų projektas
Taikomoji matematika (6211AX006)

Monika Bakaitė

Projekto autorė

Doc. Dr. Paulius Palevičius

Vadovas

Doc. Dr. Tomas Ruzgas

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Monika Bakaitė

Nanodalelių segmentavimas SEM eksperimentiniuose vaizduose taikant giliojo mokymosi metodus

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Monika Bakaitė

Patvirtinta elektroniniu būdu

Bakaitė Monika. Nanodalelių segmentavimas SEM eksperimentiniuose vaizduose taikant giliojo mokymosi metodus. Magistro studijų baigiamasis projektas / vadovas doc. dr. Paulius Palevičius; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

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

Reikšminiai žodžiai: SEM vaizdai, gilusis mokymasis, konvoliuciniai neruoniniai tinklai, segmentavimas, U-Net architektūra.

Kaunas, 2022. 51 p.

Santrauka

Dirbtiniai neuroniniai tinklai – mašininio mokymo skaičiavimo būdų, kurių pagalba apdorojama į modelį pateikiama informacija, kai ryšiai esantys tarp įvesties ir išvesties yra sudėtingi ir nevienodi. Naudojant dirbtinius neuroninius tinklus išgaunama informacija iš pateikiamų duomenų, šiuo atveju vaizdų, kas padeda analizuoti duomenų rinkinius ir juos pritaikyti tolimesniam naudojimui. Neuroninius tinklus galima panaudoti ant paviršių esančių mikrodalelių atpažinimui, bakterijų aptikimas kraujyje ar suskirstyti objektus esančius gamybos linijose ar kitose situacijose.

Magistro baigiamajame darbe realizuoti konvoliuciniai neuroniniai tinklai, kurie pritaikomi SEM eksperimentiniuose vaizduose. Šie vaizdai savyje talpina nanodaleles, kurias siekiama tinklų pagalba segmentuoti. Šios nanostrukūtos užfiksuotos ant atkaitintų TiO₂ plonų plėvelių paviršių, kurios užfiksuotos skaitmeniniu elektroniniu mikroskopu. Duomenų rinkinyje esamoms nanodalelės sukuriama kaukė nuotrauka, kurioje kiekviena nanodalelės kaukė sužymėta atskirai. Gautus vaizdus patogiu būdu pateikti į neuroninį tinklą ir jį apmokyti. Konvoliuciniam neuroniniame tinkle naudojama U-Net architektūra, kuri pritaikoma dviem skirtingiems tyrimo uždaviniams. Viename iš tyrimų segmentuojamos nanodalelės, o kitame tyrime segmentuojama pora klasių: nanodalelė, jos kraštas ir fonas. Ši architektūra padeda konvoliuciniam neuroniniam tinklui susidoroti su triukšmu esančiu vaizduose. Pritaikius tik globalią slenkstinę vertę, atpažįstama daug triukšmo vaizduose arba prarandama daug naudingos informacijos, kai slenkstis keičiamas. Lyginami du metodai, kai klasifikuojamos trys klasės ir klasifikuojama nanodalelė, tačiau pritaikomas ir vandens baseinų metodas. Pritaikius pastarąjį metodą, modelis atskiria besiliečiančias nanodaleles, tačiau kartais nesegmentuoja mažesnių dalelių. Tuo tarpu trijų klasių segmentavimas atnešė labai gerus rezultatus, kurių metu pasiektas 94% tikslumas. Šis tyrimas parodė, jog neuroninių tinklų struktūra su papildomais pakeitimais lengvai pritaikoma vaizdų atpažinimo pagerinimui bei analizei.

Bakaitė Monika. Application of deep learning methods for segmentation of nanoparticles in SEM experimental images. Master's Final Degree Project / supervisor assoc. prof. Dr Paulius Palevičius; Faculty of Mathematics and Natural Sciences

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

Keywords: SEM images, deep learning, convolutional neural network, U-Net architecture, segmentation, multi class segmentation.

Kaunas, 2022. 51 p.

Summary

Artificial neural networks are machine learning computational techniques that process information presented in a model when the relationships between input and output are complex and uneven. The use of artificial neural networks extracts information from the data presented, in this case images, that helps to analyze the data sets and adapt them for further use. Neural networks can be used to identify microparticles on surfaces, to detect bacteria in blood, or to break down objects in production lines and other situations.

In the master 's thesis, convolutional neural networks are realized and applied in SEM experimental images. Aforementioned images contain nanoparticles that are intended to be segmented with the help of networks. These nanostructures were captured on the surfaces of annealed TiO₂ thin films, which were captured under a digital electron microscope. A mask image was created for existing nanoparticles in the dataset, with each nano-particle mask marked separately. The obtained images are convenient to present in the neural network and to train it. The convolutional neural network uses the U-Net architecture, which is adapted to two different research tasks. One study segment nanoparticles, and other studies segment a couple of classes: nanoparticle, its edge, and background. This architecture helps the convolutional neural network cope with the noise in the images. Applying only a global threshold value recognizes a lot of noise in the images or loses a lot of useful information when the threshold is changed. Two methods are compared, classifying three classes, and classifying the nanoparticle, but the water-basin method is also applied. Using the latter method, the model separates the contacting nanoparticles, but sometimes does not segment the smaller particles. The segmentation of the three classes, meanwhile, yielded exceptionally satisfactory results with an accuracy of 94%. This study showed that the structure of neural networks with additional modification is easily adapted for image recognition improvement and analysis.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Įvadas.....	10
1. Literatūros apžvalga	11
1.1. SEM eksperimentiniai vaizdai.....	11
1.2. Vaizdų apdorojimas ir metodai	14
1.2.1. Išankstinis vaizdo apdorojimas.....	15
1.2.2. Vaizdų segmentavimas	16
1.2.3. Ypatybių išskyrimas	16
1.2.4. Vaizdo klasifikavimas	16
1.3. Vaizdų segmentavimas	17
1.3.1. Slenkstinis segmentavimas.....	18
1.3.2. Kraštų aptikimo segmentavimas.....	18
1.3.2.1. Sobel operatorius	19
1.3.2.2. Laplaso operatorius.....	19
1.3.3. Segmentation based on clustering	19
1.4. Neuroniniais tinklais paremti metodai vaizdų apdorojimui	20
1.5. Vaizdų segmentavimas taikant konvoliucinius neuroninius tinklus	24
1.5.1. U-Net.....	25
1.5.2. FastFCN —Fast Fully Convolutional Network.....	25
1.5.3. Deep – lab.....	26
1.5.4. R-CNN.....	26
1.6. Uždaviniai.....	27
2. Duomenys ir tyrimo metodai.....	27
2.1. Vaizdų apdirbimo metodai	28
2.1.1. Global threshold	28
2.2. Dirbtinis neuroninis tinklas	29
2.3. Konvoliuciniai neuroniniai tinklai.....	30
2.3.1. „U-Net“ architektūra	32
2.3.1.1. Loss – Nuostolių funkcija.....	33
2.3.1.2. Mean IoU.....	34
2.3.1.3. Adam optimizatorius	34
2.3.1.4. Kategorinė kryžminė entropija	35
2.4. Vandens baseinas.....	35
2.5. Duomenų paskirstymas	36
2.6. Programinė įranga	36
2.7. Duomenų paruošimas	37
3. Tyrimų rezultatai ir jų aptarimas.....	39
3.1. Pradiniai kintamieji konvoliuciniame neuroniniame tinkle	39
3.2. U-Net architektūra	39
3.3. Segmentavimas pritaikius U-Net architektūrą.....	40
3.3.1. Globalios slenkstinės vertės pritaikymas.....	42
3.4. Vaizdų segmentavimas U-Net architektūra.....	43

3.5. Vandens baseino pritaikymas segmentuotiems vaizdams	44
3.6. Segmentavimas pritaikius U-Net (segmentuojamos 3 klasės)	44
Išvados	46
Literatūros sąrašas	47
Priedai.....	Error! Bookmark not defined.
1 priedas.....	Error! Bookmark not defined.

Lentelių sąrašas

1 lentelė. Segmentavimo modelių rezultatai	40
2 lentelė. Funkcijų vertės, kai naudojamos 25 epochos	41

Paveikslų sąrašas

1 pav. Vaizdo atkūrimo modelis	14
2 pav. Nuotraukos apdorojimas naudojant slenksčio metodą	18
3 pav. Sobel operatoriaus pavyzdys	19
4 pav. Laplaso operatoriaus pavyzdys	19
5 pav. Skirtingų K vidurkių vaizdų pavyzdžiai ($k = 3$).....	20
6 pav. Dirbtinis neuroninis tinklas	22
7 pav. R-CNN architektūra	26
8 pav. Visuotinės svertinės vertės pavyzdys	29
9 pav. Dirbtinio neuroninio tinklo stuktūra.....	30
10 pav. Konvoliucinio neuroninio tinklo struktūra	30
11 pav. Konvoliucinio tinklo operacija	31
12 pav. Maksimali operacija konvoliuciniame tinkle	31
13 pav. Visiškai sujungtas sluoksnis	32
14 pav. U-Net architektūra.....	33
15 pav. Pradinis vaizdas, Topografinis paviršius ir Galutiniai vandens baseinų vaizdas	36
16 pav. Duomenys pateikiami į modelį.....	37
17 pav. 1. Orginali nuotrauka 2. Išsaugotos nuotraukos	38
18 pav. Nuotraukos pateikiamos į modelį.....	42
19 pav. Globali slenkstinė vertė pritaikyta originaliems vaizdams.....	43
20 pav. Konvoliucinio neuroninio tinklo su U-Net architektūra segmentavimas.....	43
21 pav. Vandens baseinų pritaikymas segmentuotiems vaizdams.....	44
22 pav. Konvoliucinių neuroninių tinklų su U-Net architektūra 3 klasių segmentavimas	44

Įvadas

Temos aktualumas. Skanuojantis elektroninis mikroskopas (angl. *scanning electron microscope* – SEM) sugeba priartinti net pačias mažiausias daleles. Šis prietaisas gali užfiksuoti skirtingų paviršių ar objektų vaizdus, todėl dėl šio funkcionalumo jis pritaikomas itin plačiai, nuo medicinos atradimų iki pramonės – norint atpažinti pažeistus produktus. Efektyviai naudojant skanuojančius elektroninius mikroskopo vaizdus reikia pritaikyti automatizuotas priemones, kurios padėtų juos analizuoti. Vienas iš būdų skirtas analizuoti SEM vaizdus – giliojo mokymosi metodai (angl. *deep learning methods*). Jie apdoroja pateiktus vaizdus ir pateikia tik tokią išvestį, kokios reikalauja naudotojas. Automatizuoti giliojo mokymosi metodai nereikalauja daug pastangų ir suteikia reikalingą informaciją norimuose skanuojančio elektroninio mikroskopo duomenų rinkiniuose, todėl svarbu, kad modelis būtų našus ir tikslus. Dirbtinis neuroninis tinklas (angl. *artificial neural network*) – vienas populiariausių netiesinių giliojo mokymosi skaičiavimo metodų. Šis tinklas imituoja žmogaus smegenų veikimo principą neuronais ir jų tinklais perduodami impulsai nešantys informaciją. Neuroninių tinklų metodo pritaikymas palengvina vaizdų analizę, balso apdorojimą ir kitas sudėtingai sprendžiamas problemas. Dirbtiniai neuroniniai tinklai gali atlikti dvi pagrindines funkcijas: vaizdų klasifikavimą ir segmentavimą. Klasifikavimas – visų pikelių esančių vaizde priskyrimas į tam tikras grupes, pagal nurodytus kriterijus. Segmentavimas, tai objektų išskyrimas pagal tam tikrus parametrus ar ypatybes. Šiame darbe siekiama SEM eksperimentiniuose vaizduose rasti nanodaleles, šiai problemai spręsti pritaikomas konvoliucinis neuroninis tinklas su U-Net architektūra, kuris padeda segmentuoti vaizdų rinkinį.

Problematika. Standartiniai kompiuterinės regos įrankiai nekorektiškai segmentuoja SEM eksperimentinius vaizdus, kadangi juose yra triukšmo, kurį standartiniais metodais, tokiais kaip globalia slenkstine verte, sunku išvengti. Atsižvelgiant į šią problemą darbe taikomi mašininio mokymo metodai, kurie padėtų išvengti triukšmo.

Tyrimų objektas. SEM eksperimentiniuose vaizduose esančios nanodalelės. Jos užfiksuotos naudojant Hitachi S-3400N. Šios nuotraukos užfiksuotos tyrime „Nanostruktūrų susidarymas ant atkaitintų TiO₂ plonų plėvelių paviršių“, kurį vykdė Kauno Technologijų Universitete.

Darbo tikslas. Naudojant mašininio mokymosi metodus segmentuoti SEM eksperimentiniuose vaizduose esančias nanodaleles.

Uždaviniai:

1. Atlikti literatūrinę analizę eksperimentinių vaizdų, naudojamų giliesiems mokymosi metodams. Apžvelgti dirbtinių neuroninių tinklų architektūras ir metodus jų kūrimui bei pritaikymui.
2. Paruošti SEM eksperimentinius vaizdus naudojimui modelyje. Kiekvienam naudojamam vaizdai sukurti kaukes (angl. *masks*), dirbtinių neuroninių tinklų apmokymui.
3. Realizuoti U-Net architektūrą SEM eksperimentinių vaizdų segmentavimui. Sukurtą architektūrą panaudoti segmentuoti vaizduose dvi ir tris klases bei jas palyginti.
4. Realizuoti vandens baseinų metodą (angl. *watershed*) dviejų klasių segmentavimui.
5. Palyginti gautus segmentavimo rezultatus tarpusavyje ir pagrįsti globalios slenkstinės vertės metodo netinkamumą šių vaizdų segmentavimui.

1. Literatūros apžvalga

1.1. SEM eksperimentiniai vaizdai

Žmogaus noras pažinti ir atrasti naujus dalykus neribotas. Tai verčia giliau pažvelgti į materiją ir visą supančią aplinką. Pažangią technologijų evoliuciją paskatino besivystantis intelektas, susijęs su žmogaus nuolatinio smalsumu. Žmonės sukūrė Hablo kosminį teleskopą, kad matytų tolimiausius ir nepastebimus kosmoso taškus, o vėliau sukūrė perdavimo elektronų mikroskopą (angl. transmission electron microscopy - TEM), kad pamatytų atomų išsidėstymą kristalinėse ir kvazikristalinėse medžiagose. Abu instrumentai yra kelių komponentų rinkinys, pagamintas iš įvairių medžiagų, kurios parenkamos pagal reikiamas savybes, todėl ją taikant svarbu rasti struktūros ir savybių koreliaciją. Dėl šios struktūros ir savybių koreliacijos reikia tobulinti ir savybių tikrinimo įrangą (pvz., mechaninę, elektrinę ir magnetinę savybes), atitinkamai mikroskopus, kad stebėtume pagrindinę mikrostruktūrą. [1]

Mikroskopijos vystymasis prasidėjo XVI amžiuje, kai buvo išrasti stikliniai lęšiai, kurie kaip apšvietimo šaltinį naudojo matomą šviesą. Šie lęšiai pradžioje buvo naudojami kaip padidinamieji stiklai. Šie vieno lęšio didinamieji stiklai galėjo padidinti tik iki 10 kartų. Fizikai pradėjo eksperimentuoti su šviesos lūžio reiškiniu ir kartu su lęšio geometrija, todėl šis padidinimas buvo sukurtas naudojant paprastas spindulių diagramas. Antony van Leeuwenhoek, nyderlandų mokslininkas, išsiaiškino, jog padidinus stiklo lęšio išgaubimą, objektą įmanoma padidinti iki 250 daugiau kartų, nei naudojant paprastus lęšius ar žiūrint plika akimi. Šio mokslininko eksperimentai pelnė jam „mikroskopo tėvo“ titulą ir padėjo pamatyti bakterijas. [2]

Vėliau tirti serijiniu būdu sujungti lęšiai, kurie buvo žinomi kaip sudėtiniai mikroskopai naudojami ir šiandien. Šie mikroskopai sukurti, kad būtų vaizdas galėtų padidinti beveik 1000 kartų. Nors šie mikroskopai naudojami tiriant ląstelių detales, tačiau laikui bėgant jie pradėti naudoti ir tiriant medžiagas. Optiniai mikroskopai buvo panaudojami vidinei metalinių medžiagų struktūrai (mikrostruktūra) tirti, kai jos apdorojamos skirtingomis sąlygomis. Šios sąlygos laikomos nuo liejimo, terminio apdorojimo, nes tokiu būdu stengiasi suvokti ryšį tarp mechaninių savybių ir mikrostruktūros. Tačiau optinė mikroskopija buvo susijusi su daugybe apribojimų, kurių pagrindinis buvo didelis šviesos bangos ilgis, apribojęs jo teorinę skiriamąją gebą iki 2000 angstromų, o kartu taikomi apribojimai – naudojamo stiklo kokybė ir objektyvo formos tobulumas. [1]

Devynioliktojo amžiaus fizikų tyrimai atnešė į šviesą elektronus, kurie yra neigiamo krūvio dalelės, kurias galėjo išsklaidyti atomai. Tokius eksperimentus vykdė garsusis Rutherfordo. Jo vykdomi sklaidos eksperimentai leido geriau suprasti vidinę atomo struktūrą kaip nevienalytę. Tai parodė, jog didelę atomo tūrio dalį sudaro tuščia erdvė. Dėl to pakankamai kinetinės energijos turintys elektronai gali prasiskverbti per plonas folijas (ši sąlyga vadinama elektronų skaidrumu). Tai reiškė, kad elektronai, pagreitinti esant aukštai įtampai, gali prasiskverbti pro kietąsias medžiagas, kad išvystų jų sub-mikroskopines savybes. [3]

Elektroninį mikroskopą išrado Maxas Knollas ir Ernstas Ruska 1931 metais, kuris davė net 10 nm skiriamąją gebą, kuri, toliau didėjant įtampai ir tobulėjant objektyvo bei apšvietimo technologijoms, iki XX amžiaus ketvirtojo dešimtmečio vidurio galėjo būti dar sumažinta iki 2 nm [4]

Tačiau, kaip ir bet kokį mokslinį instrumentą reikėjo patobulinti, kad sumažinti aberacijos ir padidinti skiriamąją gebą. Atominės mastelio skiriamosios gebos pasiekimas užtruko kelis

dešimtmečius ir buvo susijęs su lęšių technologijos, elektronų patrankų, elektronų detektorių / kameros ir geresnių vakuuminių sistemų atnaujinimu. Iki septintojo dešimtmečio elektronų pistoletas išsivystė iš volframo gijų, kuris davė grubiausią skiriamąją gebą. Taip pat elektromagnetiniai lęšiai, kurie iš pradžių veikė kaip elektronų pluoštą fokusuojantys prietaisai, patobulinti taip, kad būtų galima atlikti pluošto rastravimą plokštumoj, kad būtų nuskaitytas mėginys. Šie TEM plačiau žinomi kaip skanavimo perdavimo elektronų mikroskopai (STEM). [5]

Tolimesnė objektyvų technologijos pažanga paskatino sukurti ir išbandyti dvigubos aberacijos koreguotus ir chromatinės aberacijos korekcijos STEM. Atominės skiriamosios gebos vaizdų tobulinimas taip pat leido atlikti atominio masto elementų analizę naudojant spektroskopinius metodus, tokius kaip energijos dispersinė rentgeno spektroskopija, bangos ilgio dispersinė rentgeno spektroskopija ir elektronų energijos nuostolių spektroskopija. [6]

Vienas iš TEM apribojimų tai, jog elektronai bandinyje stipriai išsklaidomi arba netgi absorbuojami, o ne perduodami. Šis suvaržymas paskatino kurti elektroninius mikroskopus, galinčius tirti santykinai storus, vadinamuosius birius, mėginius.

Pagrindinius skenuojamojo elektroninio mikroskopo (SEM) principus XX amžiaus trečiajame dešimtmetyje ir 1940-ųjų pradžioje nustatė Knoll, vėliau von Ardenne Vokietijoje ir Zworykin, Hillier ir kiti JAV. SEM atgaivino Charlesas Oatley, vykdydamas keletą doktorantūros projektų Kembridžo universiteto Elektros inžinerijos katedroje Anglijoje. Pirmasis pramoninis pritaikymas atsirado po ankstyvo McMullano ir Smitho darbo Kembridže ir atliktas Kanados celiuliozės ir popieriaus institute. Netrukus po to sekė SEM pritaikymas integriniams grandynams Westinghouse Amerikoje ir komercinės SEM Anglijoje ir Japonijoje. [4]

Objektų vaizdai formuojami dviem iš esmės skirtingais būdais. Vaizdas kaip visuma vienu metu projektuojamas ant įrašomojo paviršiaus, kaip rodo fotokameros, arba jis formuojamas nuosekliai įrašant jo elementus, kai paveikslas įgauna formą nuosekliais menininko potėpiais. Praktiškai visi optiniai instrumentai, įskaitant standartinį RCA elektroninį mikroskopą, naudoja pirmąjį vaizdo atkūrimo metodą. Kita vertus, televizija ir elektrinis vaizdo perdavimas analizuoja perduodamą vaizdą į daugybę mažų vaizdo elementų, nuoseklių signalų, gaunamų iš gretimų elementų ir proporcingai jų ryškumui, kad valdyti intensyvumo pasiskirstymą. Skenuojantis elektroninis mikroskopas priklauso tai pačiai vaizdo formavimo įrenginių klasei. [7]

Skenuojančio elektroninio mikroskopo nauda - nepermatomų objektų paviršių stebėjimas, nes standartinis elektroninis mikroskopas pirmiausia pritaikytas skaidriems mėginiams tirti. Riba tarp skaidrumo ir neskaidrumo elektronams, kurių greitis paprastai naudojamas elektroniniuose mikroskopuose, maždaug 400000 cm. Standartinio elektroninio mikroskopo negalima pritaikyti tiesioginiam paviršių stebėjimui be didelių skiriamosios gebos praradimų. Taigi skenuojančio elektroninio mikroskopo praplečia metalografinės mikroskopijos stebėjimo diapazoną, nes standartinis elektroninis mikroskopas jau pagerino jį bakteriologinėse, cheminėse ir susijusiose srityse. [8]

Įvairūs tyrimai, susiję su elektroninės televizijos metodų taikymu sprendžiant mikroskopijos problemas, vyko RCA laboratorijose daugiau nei aštuonerius metus. Ankstyvoje stadijoje tiesiogiai sujungtas televizoriaus imtuvas su ultravioletiniu mikroskopu, kad pamatyti lengvai kontroliuojamo ryškumo ir padidinimo vaizdus. Čia televizijos įranga pirmiausia naudojama nematomam vaizdui paversti matomu vaizdu ir formuojant originalų padidintą vaizdą.

Kad ir koks paprastas skenuojamojo elektroninio mikroskopo pagrindinis principas, tačiau prietaiso, kurio skiriamoji geba panaši į standartinio elektroninio mikroskopo skiriamąją gebą, įgyvendinimas susiduria su labai dideliais sunkumais. Problemos kyla dėl būtinybės nuskaityti tašką

padaryti ne didesnę už mažiausią atstumą, kurį reikia išspręsti, tai padaryti jį ne didesnę nei maždaug viena dvi milijonoji centimetro skersmens. Šaltinis yra didelės galios sudėtinio elektroninio mikroskopo vaizdo plokštumos centre, o taškas susidaro ten, kur paprastai yra objektas. Kadangi šio „mikroskopo“ elektroniniai lęšiai paveikiami sferinės aberacijos taip pat, kaip ir kiti elektroniniai lęšiai, dėl smulkios dėmės reikia ne tik didelio mažinimo koeficiento, bet ir labai siaurų vaizdo spindulių apribojimo. [9]

Skenuojamas elektroninis mikroskopas naudojamas įvairiose pramonės, komercijos ir tyrimų srityse. Biologijos moksluose skenuojamas elektroninis mikroskopas naudojamas analizuoti nuo vabzdžių ir gyvūnų audinių, iki bakterijų ir virusų. Naudojimas apima: naujų bakterijų ir jų naujų požymių nustatymams, vakcinų testams ar atskleidžiant naujas rūšis. Apskritai, skenuojantis elektroninis mikroskopas naudojamas medicinos moksle kraujo ar audinių mėginiams palyginti, nustatant ligos priežastį ar matuojant gydymo poveikį ir veiksmingumą pacientams. Tačiau svarbiausia, kad analizuojant šiuos duomenis prisidedama prie naujų gydymo būdų kūrimo ir pritaikymo. Naudojami įprasti būdai: naujų vakcinų ir vaistų išbandymas esamiems virusams ir ligoms, stebima kaip paveikia ląsteles ar organizmus, lyginant audinių mėginius tarp kontrolinės ir tiriamosios grupės pacientų. [10]

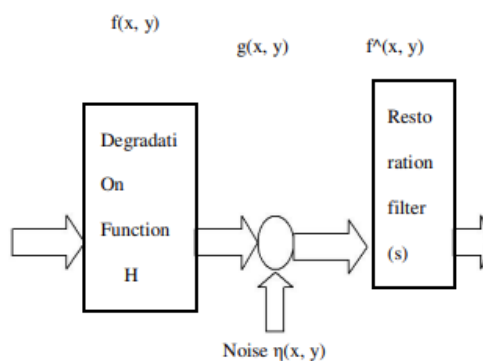
Cybèle Borg, Michèle Muller-bolla 2005 metais JAV teismo medicinos ir patologijos žurnale aprašė elektronų mikroskopijos pritaikymą eksperimentinės apatinio žandikaulio traumai. Autoriai gilinasi į makroskopinį ir mikroskopinį kaulų pažeidimų tyrimą, kurie gauti naudojant aštrios jėgos instrumentą ir aštraus buko instrumento, klasifikuojamo kaip kapojimo ginklas (kirvį). Kiekvienas ginklas, norint pasiekti tikslesnius tyrimo rezultatus, panaudojamas ant žmogaus kaulų. Šiuo darbu siekiama identifikuoti instrumentą, kuriuo buvo padarytas pažeidimas, analizuojant pjūvių klases charakteristikas. Rezultatai parodė, kad sunkiau atrasti ir analizuoti tuos pjūvius, kurie užfiksuoja makroskopine analize. Atliekant mikroskopinę analizę, įvertinta, kad ištirtos charakteristikos veiksmingos atskiriant aštrų kaulo sužalojimą nuo aštraus buko. Skenuojamas elektroninis mikroskopas palengvina analizę, kurios neįmanoma atlikti naudojant makroskopinius metodus, kai kurios plika akimi nematomos trimatės charakteristikos aiškiai apibrėžtos naudojant jį. Šiame tyrime pastebėta, jog naudojant silpną jėgą pažeidimams padaryti, skenuojančio elektroninio mikroskopo pagalba galima pamatyti ir mažiausius pažeidimus ir atskirti kuriuo instrumentu pažeidimas atliktas. Atlikus šį tyrimą, nustatyta didelės skenuojamo elektroninio mikroskopo svarba, kaip antropologinio įrankio pastebint ir gydant kaulų pažeidimus. [11]

Guangui Zou, Jiasheng She, Suping Peng, Quanchun Yin, Hongbin Liu, Yuyan Che 2019 metais straipsnyje „Dvimatė SEM vaizdu pagrįsta anglies poringumo analizė ir jo porų struktūra“ pristatyta kiekybinė porų poringumo, porų dydžio pasiskirstymo ir fraktalinių matmenų analizė tiriant anglies porų struktūros charakteristikas. Šiame tyrime panaudota 12 antracito anglies mėginių iš kasybos srities, siekiant ištirti anglies porų struktūros ypatybes. Šimtai atsitiktinai atrinktų taškų kiekviename supjaustyto anglies mėginyje vaizduojami naudojant skenuojančią elektroninę mikroskopiją, o analizei panaudota daugiau nei tūkstantis vaizdų. Naudojant skaitmeninio vaizdo apdorojimą analizuojamas visų anglies mėginių poringumas ir matmenys. Dėžių skaičiavimo matmenų metodas pasižymi plačia grafine analize. O šios analizės rezultatai pagrįsti statistiniais metodais. Vaizdo apdorojimas taip pat panaudotas anglies mikroskopinių porų vystymo charakteristikos analizei. Atlikus analizę, rezultatai parodė, matuojant eksperimentiškai paviršiau poringumą, gauta 16,11% didesnis rezultatas nei naudojant skaitmeninio vaizdo apdorojimą. Porų matmens kitimo greitis priklauso nuo poringumo, kadangi didesnis poringumas susijęs su sudėtingesnėmis struktūromis, didesniu mikroporų išsivystymo laipsniu bei porų jungiamumu. [12]

1.2. Vaizdų apdorojimas ir metodai

Laikraščių pramonėje pirmą kartą pritaikyti skaitmeniniai vaizdai. Taip viena pirmųjų nuotraukų pirmą kartą išsiuntė povandeniniu kabeliu tarp Londono ir Niujorko. Įdiegus Barto juostos kabelių vaizdo perdavimo sistemą, dvidešimtojo amžiaus paskutiniojo dešimtmečio pradžioje sumažėjo nuotraukos persiuntimo laikas per Atlanto vandenyną. Persiuntimas dažniausiai trukdavo nuo trijų valandų iki savaitės. Specializuota spausdinimo įranga užkodavo paveikslėlius, o vėliau juos atkurdavo priėmimo gale. Norint pagerinti šių siunčiamų nuotraukų kokybę, reikalinga atsižvelgti į intensyvumo lygių paskirstymą. Kadangi norint persiųsti skaitmeninius vaizdus reikėjo didelės skaičiavimo galios ir didelių apimčių saugyklų, todėl visa skaitmeninių vaizdo apdorojimo pažanga priklausė nuo kompiuterių galingumų ir pagalbinių technologijų saugant duomenis bei juos atvaizduojant. Skaitmeninius vaizdus sudaro riboti skaičiai elementų, kurie vadinami pikseliais. Kiekvienas iš jų turi savo vietą ir reikšmės. Sritys, kurios naudoja tekstą, vaizdo gavimą, išankstinį jo apdorojimą, atskirų simbolių ištraukimą, simbolio aprašymo kompiuteriniam apdorojimui tinkamą formą naudoja vaizdo apdorojimo metodus. Aštunto dešimtmečio pradžioje pradėti naudoti skaitmeninių vaizdų apdorojimai, kuriais siekta pagerinti medicininių nuotraukų vaizdavimą bei Žemės išteklių stebėjimus. [13]

Devintajame dešimtmetyje ir dešimtojo dešimtmečio pradžioje rinka perėjo prie vaizdo apdorojimo įrangos – tai pavienių plokščių, kurios sukurtos taip, jog tilptų į asmeninius kompiuterius. Šis rinkos pokytis ne tik sumažino išlaidas, bet ir buvo perversmas daugeliui įmonių, kurių specializacija programinės įrangos naudojamos specialiai vaizdo apdorojimui. Nors didelės apimties paveikslėlių apdorojimo sistema vis dar parduodama masinei apdorojimo programai, tokiai kaip palydovinių vaizdų apdorojimas, tendencija ir toliau miniatiūrizuoti ir sujungti bendrosios paskirties mažus kompiuterius su specializuota vaizdo apdorojimo sistema. 1 paveikslėlis rodo tipinę bendrosios paskirties sistemą, naudojamą skaitmeniniam vaizdų apdorojimui.



1 pav. Vaizdo atkūrimo modelis

Norint gauti skaitmeninius vaizdus, reikia turėti du svarbius elementus. Pirmiausiai, reikalingas prietaisas, kuris jautrus energijai ir objektas, kuris spinduliuoja energiją nuskaitomą prietaiso. Antra, reikalingas skaitmeninis įrenginys, kuris yra pritaikytas į skaitmeninę formą konvertuoti su prietaisu gautą išvestį. Specializuotą vaizdų apdorojimo aparatūrą dažniausiai sudaro skaitmenizatorius ir primityvias operacijas atliekanti įranga. Šią apdorojimo įrangą sudaro moduliai, kurie parinkti atlikti konkrečias užduotis. Didelės atminties talpa būtina vaizdo apdorojimo

programose, kad apdorotų 1024 * 1024 pikselių dydžio vaizdus, kuriuose kiekvieno pikselio intensyvumas 8 bitai, prireikė vieno megabaito saugyklos vietos nesuspaustam vaizdui. [14]

Šiomis dienomis sunku atrasti techninę sritį, kuriai neprireiktų skaitmeninių vaizdų apdorojimo. Egzistuoja daug į taikymą orientuotų analizatorių, kurie patenkinamai veikia realioje aplinkoje. Svarbiausia išsiugdyti bendrą supratimą apie vaizdo apdorojimo programas ar metodus, kad būtų lengviau suskirstyti turimas nuotraukas į kategorijas pagal egzistuojančius išteklius. Pagrindinis šiandien naudojamų vaizdų energijos šaltinis - elektromagnetinės energijos spektras. [15]

Per pastaruosius keturis dešimtmečius vaizdo apdorojimo srityje sukurta įvairiausių metodų. Dauguma jų siekia pagerinti nuotraukas, gautas iš nepilotuojamų erdvėlaivių ar karinių žvalgybinių skrydžių. Visos sistemos naudojamos vaizdo apdorojimui vis labiau populiarėja, kadangi jos lengvai prieinamos, didelių atminties įrenginių bei programinių įrangų. Vieni iš pagrindinių metodų pranašumų – universalumas bei lengvas atkartojimas su duomenų tikslumo išsaugojimu. [16]

Bet kokių dvimačių duomenų apdorojimas, dar kitaip vadinamas skaitmeniniu vaizdo apdorojimu. Skaitmeninis vaizdas, tai tikrojo masyvo skaičiai, vaizduojami baigtiniu bitų skaičiumi. Įvairios apdorojimo technikos, kurios pritaikomos apdoroti skaitmeninius vaizdus:

- išankstinis vaizdo apdorojimas (angl. image preprocessing)
- vaizdo segmentavimas (angl. image segmentation)
- ypatybių išskyrimas (angl. feature extraction)
- vaizdo klasifikavimas (angl. image classification)

1.2.1. Išankstinis vaizdo apdorojimas

Išankstinio vaizdo apdorojimo metu palydovo jutiklių įrašyti vaizdo duomenys sulaiko suvaržymo klaidas, susijusias su pikselių geometrija ir ryškumo reikšmėmis. Netikslumai užfiksuojami vaizduose pataisomi naudojant matematinius arba statistinius modelius. Vaizdo pagerinimas – modifikuojant pikselių ryškumo reikšmes, pagerinti vizualinę poveikį turimam modeliui. Vaizdo pagerinimas apima metodų rinkinį, kuris naudojamas gerinant vizualinę išvaizdą arba paversti vaizdą į formą, kuri geriau tinka žmogaus ar kompiuterio interpretacijai. [17]

Dažniausiai vaizduose, kurie gauti iš įprastų skaitmeninių fotoaparatus ar palydovų, trūksta ryškumo ir kontrasto, kadangi gaunant tokius vaizdus gali kilti apribojimų dėl apšvietimo sąlygų ar gavimo posistemių. Vaizdo tobulinimo tikslas pabrėžti tam tikras ypatybes, kad vėliau panaudotų analizuojant ar rodant vaizdą. [18] Tokiu atveju naudinga taikyti kontrasto ir kraštų pagerinimą, triukšmo filtravimo ryškinimą ar padidinimą. Vaizdo pagerinimas naudingas funkcijų ištraukimui, vaizdų analizei ar jų atvaizdavimui, svarbu suprasti, kad visi vaizdui taikomi patobulinimo procesai, nepakeičia ir nepadidina informacijos turinio. Visi šie procesai, padeda aiškiau atskirti ir nurodyti tam tikras norimas vaizdo ypatybes. Visi algoritmai skirti patobulinti vaizdus priklausomi nuo naudojamos programos ir interaktyvūs, kad naudotojas lengvai galėtų atlikti procesus pats. Kai kurie tobulinimo būdai :

- a. Histogramos modifikavimas (angl. Histogram modification)
- b. Triukšmo filtravimas (angl. Noise filtering)
- c. Kontrastinis tempimas (angl. Contrast stretching)

1.2.2. Vaizdų segmentavimas

Vaizdo segmentavimo proceso metu siekiama vaizdą padalinti į jame esančius objektus ar kitas sudedamąsias dalis. Padalijimo sudėtingumas (lygis) priklauso sprendžiamos problemos sudėtingumo, segmentavimas sustabdomas, kai taikomosios programos objektai izoliuoti. Tarkime, kad interesas identifikuoti kelyje esančias transporto priemones. Pirmiausia atliekamas kelio segmentavimas, o tik tada segmentuoti kelio turinį, kuriame ieškoma norimų transporto priemonių. Vaizdo slenkščio nustatymo metodai naudojami vaizdo segmentavimui.

Nustačius slenkštį, susidaro dvejetainis vaizdas, kuriame visi objekto pikseliai turi vieną pilkumo lygį, o visi fono pikseliai kitą – paprastai objekto pikseliai yra „juodi“, o fonas – „baltas“. Slenkštis apibrėžtas kaip pilkos skalės susiejimas su dvejetainiu rinkiniu $\{0, 1\}$:

$$S(x, y) = \begin{cases} 0, & \text{if } g(x, y) < T(x, y) \\ 1, & \text{if } g(x, y) \geq T(x, y) \end{cases}$$

kur $S(x, y)$ segmentuoto vaizdo reikšmė, $g(x, y)$ pikselio pilkumo lygis (x, y) , o $T(x, y)$ slenkstinė reikšmė koordinatėse (x, y) . [19]

1.2.3. Ypatybių išskyrimas

Funkcijų ištraukimo metodai sukurti vaizdų ypatybėms išgauti. Šis metodas išgauna aukšto lygio savybes, reikalingas taikiniams klasifikuoti. Šios savybės tai tie elementai, kurios apibūdina norimą objektą, kaip forma, spalva, dydis, kompozicija ir t.t. Segmentavimo metodas panaudojamas izoliuoti reikiamą objektą nuo aplinkinių objektų ar fono, kad atlikti jo matavimus ar kitus skaičiavimus. Kiekybiniai objekto ypatybių matavimai leidžia klasifikuoti ir apibūdinti vaizdą.

Pasiekus išankstinę apdorojimą ir pageidaujamą segmentavimo lygį, segmentams taikoma tam tikra požymių išskyrimo technika, kad išgautų savybes, o po to taikyti klasifikavimo ir papildomo apdoravimo techniką. Savybių (ypatybių) ištraukimo metuose, parametrų pasirinkimas svarbus veiksnys norint pasiekti gerą atpažinimo našumą. Funkcijų išskyrimas pateiktas kaip klasifikavimo tikslams tinkamiausios informacijos ištraukimas iš neapdorotų duomenų, tuo pačiu sumažinant klasės modelio kintamumą ir padidinant klasių modelių kintamumą. Taigi reikia labai atsargiai parinkti tinkamą savybių ištraukimo techniką atkreipiant dėmesį į taikomą įvestį. Atsižvelgiant į visus šiuos veiksnius, labai svarbu pažvelgti į įvairius galimus bruožų išgavimo būdus tam tikroje srityje, apimančius didžiules atvejų galimybes. [20]

1.2.4. Vaizdo klasifikavimas

Vaizdo klasifikavimas – vaizde esančio pikselio arba pikselių grupės pažymėjimas pagal pilkąją reikšmę. [21] Šiuo būdu dažniausiai naudojamos išgaunant norimą informaciją iš vaizdų. Klasifikacijoje paprastai pikselių rinkiniui naudojamos kelios funkcijos, reikia daug konkrečių objekto vaizdų. Aptikimo srityse šios procedūros daro prielaidą, kad tam tikri srities vaizdai renkami keliuose spektro regionuose ir gerai užregistruojami. Dauguma informacijos gavimo metodų remiasi tokių vaizdų spektrinio atspindžio savybių analize ir naudoja specialius algoritmus, skirtus įvairių tipų „spektrinei analizei“ atlikti. Daugiaspektrinio klasifikavimo procesas atliekamas naudojant vieną iš dviejų metodų: prižiūrimą (angl. supervised) arba neprižiūrimą (angl. unsupervised). [23]

Prižiūrėtoje klasifikacijoje kai kurių žemės dangos tipų: miesto, pelkių, miškų, tapatybė ir vieta žinomi kaip priori derinant lauko darbus ir topografinius lapus. Bandoma rasti konkrečias vietas nuotoliniu būdu aptinkamuose duomenyse, kurie vienarūšiai šių žemės dangos tipų pavyzdžiai. Šios sritys paprastai vadinamos mokymosi vieta, nes jų spektrinės charakteristikos naudojamos klasifikavimo algoritmui „išmokyti“, kad sudarytų žemės dangos žemėlapius ir priiminti vaizdą. Kiekvienai mokymo vietai skaičiuojami daugiamatiai statistiniai parametrai. Tada kiekvienas pikselis tiek šiose mokymo vietose, tiek už jų ribų įvertinamas ir priskiriamas klasei, su kurios nariu jis turi didžiausią tikimybę. [24]

Neprižiūrime klasifikacijoje žemės dangos tipų tapatybės nurodomos, nes klasės paprastai nėra žinomos kaip priori, nes paviršiaus ypatybės nėra tiksliai apibrėžtos. Šioje klasifikacijoje sugrupuojami vaizduose esantys pikseliai į skirtingas spektrines klases, pagal nurodytus kriterijus. Pavyzdžiui medicinos srityse, ląstelės ženklinamos pagal jų formą, dydį, spalvą ar tekstūrą, kurios veikia kaip kriterijai-savybės, taip pat atliekant MRT tyrimus šis metodas duoda labai gerus rezultatus. [23]

1.3. Vaizdų segmentavimas

Vaizdo supratimas ir informacijos iš jo gavimas, svarbi skaitmeninių technologijų taikymo sritis. Segmentavimas tai pirmas žingsnis, kuris padeda suprasti vaizdą. Šis metodo privalumas, jog orientuojamasi į sritis, kurias sieja panašios savybės, vietoj visų vaizde esančių dalių. Remiantis tam tikrais kriterijais, įvesties vaizdas suskirstomas į tos pačios rūšies kategorijos skaičių, kad išskirtų žmones dominančią sritį. [24]


Vaizdų segmentavimas – pagrindinis žingsnis juos analizuojant ir išgaunant iš jų norimus duomenis. Šis metodas naudojamas vaizdui analizuoti ar klasifikuoti. Toks vidutinio lygio apdoravimo metodas suteikia galimybę grupuojant pikselius sugrupuoti vaizdą į kelias dalis. Tokiu būdu pasitvirtina homogeniškumas, kai pikseliai priskiriami pagal skirtingas charakteristikas. Šios charakteristikos gali būti atskiriamos pagal tekstūrą, intensyvumą, spalvą. Segmentavimo proceso tikslas – išgauti kuo daugiau vaizde dominančios informacijos dominančioje, kuri padėtų anotuoti objekto sceną. Vaizdo segmentavimas skirtas nuo domeno nepriklausomo vaizdo padalijimo į vizualiai skirtingų ir vienalyčių sričių rinkinį, atsižvelgiant į tam tikras savybes. Vienas pagrindinių segmentavimo tikslų atskirai ir aiškiai vaizde išskirti foną ir objektą. [25]

Egzistuoja daug naudojamų vaizdų segmentavimo algoritmų. Slenkstinis segmentavimo metodas – vienas iš dažniausiai naudojamų segmentavimo metodų regiono segmentavimo algoritmuose. [19] Šio metodo tikslas automatiškai nustatyti optimaliausią slenkstį pagal tam tikrus kriterijus, kad atliktų klasterizavimą, naudojami pikseliai pagal pilkumo lygį. Po to seka regioninio augimo segmentacija. Pagrindinė regioninio augimo algoritmo idėja, sujungti pikselius su panašiomis savybėmis, kad sudarytų regionus ir kiekvienas regionas padalinamas taip, jog randamas pradinis pikselis kaip augimo taškas, o tada sujungiamos kaimynystėje su panašiomis savybėmis pikseliais. Kraštų aptikimo segmentavimo algoritmas, kad suskaidytų vaizdą į norimus objektus, leidžia naudoti skirtingų pilkumo pikselių arba nepertraukiamumo spalvos aptikimo krašto regionus. [27] Klasterizavimu pagrįstas algoritmas apibrėžtas daiktų panašumu kaip klasių padalijimo kriterijumi. Pagal imties rinkinio vidinę struktūrą, vaizdas suskirstomas į keletą poklasių, kad tokios pačios rūšies imtys supanašėtų. [28] Nėra pripažinto vieningo standarto segmentavimui, kadangi šis procesas yra įvairus ir sudėtingas. Kiekviena skirtinga situacija reikalauja skirtingų modelių ir metodų parinkimo, jog gautas rezultatas būtų tikslus.

1.3.1. Slenkstinis segmentavimas

Slenkstinis segmentavimas – vienas iš paprasčiausių bei labiausiai paplitusių lygiagreto vaizdo segmentavimo metodų. Šis segmentavimo algoritmas paprastas, kadangi pagal skirtingų objektų pilkos spalvos vertę padalija vaizdo pilkosios skalės informacijos apdorojimą. Jis skiriamas į du pagrindinius metodus: vietinis (angl. *local*) ir visuotinis (angl. *global*). Visuotinio slenksčio metodo principas padalinti vaizde esančius pikselius į dvi sritis pagal vieną pasirinktą slenksčių. [29] Taikant vietinio slenksčio metodą reikia pasirinkti kelis segmentavimo slenksčius ir padalinti vaizdą į kelias tikslias sritis, ir fonus pagal kelis slenksčius.

Otsu – vienas dažniausiai naudojamų slenksčių segmentavimo algortimų. Jo tikslas maksimaliai padidinti dispersiją tarp esančių klasių ir parinkti optimaliausią slenksčių. Be to, entropija pagrįstas slenksčio segmentavimui naudojamas minimalios paklaidos, momento išsaugojimo, paprastas statistinis, tikimybių atsipalaidavimo, neaiškios aibės ir slenksčio metodai, derinami su kitais papildomais metodais.



2 pav. Nuotraukos apdorojimas naudojant slenksčio metodą

Privalumas taikant slenksčio metodą, jog operacijos atliekamos greitai bei apskaičiavimas paprastas. Taikant šį metodą, galima pasiekti segmentavimo efektą, tačiau norimas objektas ir fonas aplink jį turi būti kontrastingi. Metodo trūkumas, jog labai sunku išskirti tikslius vaizdo segmentavimo metu norimus gauti objektus, kai neegzistuoja reikšmingas pilkos spalvos skirtumas. [30] Kadangi atsižvelgiama tik į pilką vaizdo informaciją, nekreipiant dėmesio į erdvinę vaizdo informaciją, jis jautrus triukšmui ir pilkų atspalvių netolygumams, todėl dažnai derinamas su kitais metodais.

1.3.2. Kraštų aptikimo segmentavimas

Objekto kraštas - nenutrūkstamų vietinių vaizdo ypatybių pavidalu, reikšmingiausia vaizdo dalis keičia vietinį ryškumą, pvz., mutacijos pilkumo reikšmė, spalvos mutacija ir tekstūros pokyčiai. Norint pasiekti segmentavimo tikslą, naudojamas krašto aptikimas (angl. *edge* detection). [31]

Šis nepertraukiamumas aptinkamas panaudojus išvestines operacijas, o išvestinės apskaičiuojamos panaudojus diferencialinius operatorius. Lygiagrečios briaunos aptikimas atliekamas naudojant erdvinio domeno diferencialinį operatorių, kad segmentuotų vaizdą, susukant jo šabloną. Kaip išankstinio vaizdo apdorojimo metodas, naudojamas lygiagrečių (angl. *parallel*) kraštų aptikimas. Prewitt, Roberts ir Sobel operatoriai tai pirmosios eilės operatoriai, kurie plačiai

naudojami. Antros eilės diferencialiniai operatoriai - netiesiniai, kaip Laplacian, Wallis ir Kirsch operatoriai. [32]

1.3.2.1. Sobel operatorius

Šis operatorius dažniausiai naudojamas aptikti briaunas, o iš tiesių naudojamas vaizdo funkcijos gradiento aproksimavimui apskaičiuoti, todėl jis laikomas kaip atskiras diferencialinis briaunų aptikimo operatorius pagrįstas pirmąja išvestine. Operatorius tinkamas pašalinti triukšmą esanti vaizde, kadangi naudojama vietinė vidutinė operacija. Sobel operatorius sudaro dviejų matricių 3x3 rinkiniai, kurie pasveria pikselio padėti. Tai didelė persvara nei naudojant Prewitt ar Robert operatorius. Vienas iš jų laikomas skersiniu, o kitas išilginiu šablonu. Aptinkant briaunas šie šablonai nubrėžiami kartu su vaizdo plokštuma, tokiu būdu gaunamas skirtumas tarp horizontalaus ir išilginio skirtumo. [25]



3 pav. Sobel operatoriaus pavyzdys

1.3.2.2. Laplaso operatorius

Tai antros eilės diferencialinis operatorius. Jis naudojamas su krašto padėtimi, taip nepaisoma pikselių pilkumo skalės, kuri yra aplink jį. [18] Šis operatorius taikomas vaizdams, kuriuose nėra daug triukšmo, kadangi jo atsakas stipresnis į izoliuotus pikselius. Jei vaizdas turi daug triukšmo, reikalingas atlikti žemųjų dažnių filtravimas, siekiant rasti objekto kraštą. Norint pasiekti geriausią rezultatą, segmentavimo algoritmas sujungiamas Laplaso operatorių su išlyginimo (angl. *smoothing*) operatoriumi.

Taip pat, Laplaso operatorius turi sukimosi invariancija. Dvimačio vaizdo funkcijos Laplaso transformacija izotropinė antroji darinė, kuri labiau tinka skaitmeniniam vaizdo apdorojimui. [25]



4 pav. Laplaso operatoriaus pavyzdys


1.3.3. Segmentation based on clustering

Nėra bendros vaizdų segmentavimo teorijos. Su laiku diegiant naujų teorijų ir metodų, atrasta tokių vaizdų segmentavimo metodų, kuriuos derinant su tam tikrais metodais, galima pasiekti gerų

rezultatų. Klasterizavimas atitinka tam tikrus klasifikavimo dėsnius ir reikalavimus. Metodus naudojamus vaizdo erdvės pikseliams segmentuoti vadinamus funkcijų erdvės klasterizacijos metodus, kuri pagal pikselių apibendrinimą objektų erdvėje, suskirsto juos į segmentus. Tada jie gražinami atgal į pagrindinę vaizdo erdvę, kad būtų galima matyti ir gauti segmentavimo rezultatą.

Vienas dažniausiai naudojamų klasterizacijos algoritmų – K vidurkių metodas (angl. *K-means*). Pagrindinis šio metodo tikslas pagal atstumą surinkti visus esamus mėginus į skirtingas grupes. K-means įgyvendinimo procesas išreiškiamas taip:

- (1) K-klasterizacijos centrai pasirenkami atsitiktinai;
- (2) Nuo kiekvieno mėginio atskirai apskaičiuojamas atstumas iki kiekvieno klasterio centro. Tokiu būdu kiekvienas pasirinktas mėginys gražinamas į artimiausią klasterių centrą;
- (3) Kiekvienam klasteriui kuris turi klasterių centrą, perskaičiuojamas imčių vidurkis, ir tai laikoma kaip naujų klasterizacijos centrų grupė;
- (4) 2–3 veiksmi kartojami vienas po kito tiek kartų, kol kol klasterio centras nebesikeičia arba pasiekia nustatytą iteracijų skaičių. [33]



5 pav. Skirtingų K vidurkių vaizdų pavyzdžiai ($k = 3$)

K-Means grupavimo algoritmo pranašumas – algoritmas paprastas ir labai efektyvus dideliems duomenų rinkiniams. K-means algoritmas atstumais pagrįstas skaidymo metodas, kuris netinkamas naudoti neišgaubtiems klasteriams grupuoti. K-mean trūkumas – jį sunku įvertinti, kadangi K klasterizacijos skaičius neturi konkrečių ir lengvai įvertinimų atrankos kriterijų. Taip pat, algoritmas kerta visus mėginus esančius vaizde, su kiekviena iteracija. [34]

1.4. Neuroniniais tinklais paremti metodai vaizdų apdorojimui

Dirbtinio intelekto (AI) taikymas tampa realybe, kuri įprasta visose šiuolaikinio žmogaus gyvenimo srityse. Prieš dvidešimt metų dirbtinis intelektas tam tikru laipsniu buvo apribotas. Tyrimų raida per pastaruosius du dešimtmečius buvo labai sparti, todėl sunku rasti vietą, kur dirbtinis intelektas apskritai nebūtų naudojamas įprastoje ar profesinėje veikloje, susijusioje su skaitmeniniais įrenginiais. Priklausomybė nuo dirbtinio intelekto ypatingai didelė tose srityse, kuriose reikia įveikti problemas, kylančias dėl loginės išraiškos sudėtingumo ir sprendžiant itin didelį kintamųjų neapibrėžtumą, kuriems reikalingas didelis tikslumas.

Dėl patobulinto didelio duomenų kiekio tvarkymo metodo, siekiant surasti logines lygtis atitinkančius parametrus, pastaraisiais metais ši sritis išpopuliarėjo. Techninės įrangos per


pastaruosius metus pažanga, bei algoritmų inovatyvumas paspartino dirbtinio intelekto naudojimą visose veiklose. Vieni iš pavyzdžių apimtų modeliavimo, projektavimo ir valdymo darbus, tokiose srityse kaip architektūra, civilinė inžinerija, programavimo architektūrų programavimas, žmogiškieji ištekliai ar klientų valdymas. Taip pat panaudojama prognozuojant veiklas, kaip orus, finansinių institucijų prognozes. Bei informacijos sintezėje, kai kuriamos duomenų bazės ir reikalingų duomenų apdorojimui. [28]

Dažni dirbtinio intelektų programų pavyzdžiai, kai pritaikomas atpažinimas ir identifikavimas veiklai (vaizdo, kūno ar balso atpažinimui) ar veikloms, kurios pakeičia kasdieninį gyvenimą. [29] Šiuo metu pasaulinis žiniatinklis kartu su mašininio mokymusi labai prisidėjo prie spartaus dirbtinio intelekto panaudojimo augimo. Įvairios dirbtinio intelekto programos kuriamos ir panaudojamos optimizuojant internetinio elgesio formas, tokias kaip apsipirkimas, paieška ir bendras interneto tinklo valdymas.

Kita ypatybė, kuri pastebima naujausiose dirbtinio intelekto programose – derinys su robotų inžinerija. Nuolat dedamos pastangos kuriant dirbtinio intelekto valdomus robotus, siekiant maksimaliai padidinti žmonių patogumą ir saugumą bei tokių veiklų kaip išmaniosios gamyklos, nepilotuojamas žemės ūkis ir nepilotuojami gynybos robotai efektyvumą.[30] Medicinos srityje pasirodė įvairių tipų diagnostikos robotai, kaip ne pilnai automatinių chirurginių dirbtinio intelektų robotų, padedančių gydytojams įvairiose situacijose.[31]

Dirbtinis neuronų tinklas (ANN) – jau nuo devintojo dešimtmečio aktuali dirbtinio intelekto tema, kadangi šis tinklas yra paremtas ir apibrėžtas žmogaus smegenų neuroniniu tinklu, pagal šį požiūrį sukuria paprastą modelį ir sudaro tinklus pagal skirtingus ryšius. [34] Bandoma imituoti smegenų neuroninio tinklo apdorojimą, atminties informacijos apdorojimo būdu. Akademiniėje bendruomenėje ir inžinerijoje jie tiesiogiai vadinami neuroniniu tinklu. Neuroninis tinklas tai tokios struktūros skaičiavimo modelis, kurį sudaro daugelis neuronai ir jie vienas su kitu yra sujungti. [35] Kiekvienam neuronui-mazgui esančiam tinkle, priklauso aktyvavimo funkcija (išvesties funkcija). Svoris, tai ryšys tarp bet kurių dviejų mazgų, kuris lygiavertis dirbtinio neuroninio tinklo atminčiai. Neuroninio tinklo išvestis visada skirsis priklausomai kaip tinkle sujungti neuronai tarpusavyje, kokios tinkle esančios svorio vertės ir kokio parinktos aktyvavimo funkcijos. [36]

Dirbtiniame neuroniniame tinkle pasirinktas apdorojimo blokas (angl. *processing unit*) atstovauja skirtingus objektus. Šie objektai gali būti sąvokos, raidės, tekstūra. Apdorojimo bloko tipas tinkle skirstomas į tris kategorijas: įvesties blokas – jis priima signalus ir duomenis, kurie pateikiami į modelį, išvesties blokas – realizuoja sistemos apdorojamo rezultato išvestį ir paslėptas blokas – esantis tarp įvesties ir išvesties blokų, kurio negalima stebėti už sistemos ribų, kadangi jis yra viduje. [37] Jungties tarp neuronų svoriai atspindi ryšio tarp ląstelių stiprumą. Dirbtinis neuroninis tinklas neprograminis, adaptyvus, smegenų stiliaus informacijos apdorojimas, kurio esmė – tinklo transformacija ir dinamiškas lygiagrečiai paskirstytų informacijos apdorojimo funkcijų elgesys bei įvairaus laipsnio žmonių smegenų ir nervų informacijos apdorojimo sistema, kuri nuolat dalyvauja įvairiose dirbtinio intelekto, neurologijos ir informatikos srityse. [37]



6 pav. Dirbtinis neuroninis tinklas

Dirbtinis neuroninis tinklas tai lygiagrečiai paskirstyta sistema, kurios idėja paremta patobulintu mechanizmu, nei dažnai naudojamu dirbtiniu intelektu. Šis neuroninis tinklas pritaikius informacijos apdorojimo technologijas sugeba prisitaikyti ir įveikti dirbtinio intelekto trūkumus. [38]

Per pastaruosius 10 metų tiriant dirbtinius neuroninius tinklus buvo pasiekta didelė pažanga, kadangi šis tinklas labai padėjo tokiose srityse kaip automatinis valdymas, numatymas ir įvertinimas. Taip pat, dirbtinis neuroninius tinklas pasireiškė ir modelio atpažinimuose bei išmaniųjų robotų tobulėjime. [39]

Pirmieji prisilietimai prie neuroninio tinklo ir jo tyrinėjimo prasidėjo 1940-aisiais metais. Amerikiečių psichologas Mccullochas ir matematikas Pittsas 1943 m. pasiūlė labai paprastą, bet labai naudingą M-P modelį. Modelyje algoritmas realizuotas neuroną laikant funkciniu loginiu įrenginiu. 1949 m. psichologas Hebbas paskelbė knygą „Elgesio organizacija“, kurioje iškėlė hipotezę, kad sinapsinių ryšių intensyvumas įvairus. Ši hipotezė rodo, kad mokymosi procesas galiausiai vyksta sinapsinėje sąsajoje tarp neuronų, o sinapsinių jungčių intensyvumas skiriasi priklausomai nuo neuronų aktyvumo prieš ir po sinapsės. Tai išsivystė į taisyklę, kuri teigia, jog sinapsinių jungčių tarp neuronų stiprumas įvairus. Taip pat pabrėžė, jog nuolatinis pokytis tai atminties ir mokymosi pagrindas, bet kurio šis tinklas negali egzistuoti. Dar ir iki šių laikų Hebbos dėsnis naudojamas kurti neuroninių tinklų modelius, kuriuose pritaikomos mokymosi funkcijos, kad modelis nuolatos tobulėtų. [40]

Su kiekvienais metais, neuroninio tinklo modeliai supratimas vis didėjo ir jie vis tobulėjo. Perceptron modelis, kuris pagrįstas primuoju M-P modeliu, pristatė psichologas Rosenblatt. Šiuolaikinis neuroninis tinklas remiasi šiuo pasiūlyto tinklo principu, kuris padarė didelį technologijų proveržį. Tai M-P neuroninio tinklo modelis su nuolat reguliuojamais svoriais, kurio tikslas klasifikuoti po apsimokymo, kitaip tai pats pirmosios generacijos dirbtinis neuroninis tinklas. Įrodyta, kad klasifikuoti įvestis gali ir dviejų sluoksnių (angl. *two layer*) jutikliai. Rosenblattas taip pat pasiūlė tyrimą su paslėptaisiais sluoksniais. Vėliau B. Widrowas ir M. Hoffas pasiūlė adaptyvaus tiesinio elementu (Adaline) ir mažiausio vidutinio kvadratinio nuokrypio algoritmu paremtą neuroninio tinklo mokymo metodą. Pritaikydami šį metodą, tai tapo pirmasis neuroninis

tinklas, kuri išsprendė praktines problemas. Tai paskatino dar didesnę neuroninių tinklų taikymą ir tobulinimą. Adeline tinklo modelis nuolatinės vertės adaptyvaus linijinio neuronų tinklo modelis, kuris naudojamas adaptyvioms sistemoms. [41]

1982 m. amerikiečių fizikas Hopfieldas pasiūlė diskrečiąjį Hopfieldo neuroninį tinklą, kuris veiksmingai skatino neuroninių tinklų tyrimus. Tinkle pirmą kartą pristatoma Lyapunov funkcija. Vėliau mokslininkai Lyapunov funkciją taip pat pavadino energijos funkcija, kuri įrodė tinklo stabilumą. Dar po penkių metų Hopfieldas ir Tankas panaudojo prieš tai pristatytą Hopfield neuroninį tinklą, jo pagalba jie sugebėjo išspręsti garsiąją keliaujančio pirklio problemą. Šis neuroninis tinklas sudarytas iš diferencialinių lygčių, kurio modelis pateikia dinamines bei mokymosi lygtis. Taip pat pateikiamos svarbios tinklo algoritmo formulės ir parametrai, dirbtinio neuroninio tinklo konstravimas ir mokymasis, dėl kurių daugybė mokslininkų skatino neuroninių tinklų tyrimo entuziazmą ir aktyviai dalyvavo šioje akademinėje veikloje. Vis daugiau žmonių pradėjo tyrinėti neuroninius tinklus ir skatino neuroninio tinklo plėtrą. 1983 m. Kirkpatrick suprato, kad imituotas atkaitinimo algoritmas (angl. *simulated annealing algorithm*) gali padėti kombinatorinio optimizavimo problemai išspręsti. Hintonas bendradarbiaudamas su jaunu mokslininku Swjnowski 1984 metais pristatė mokymosi mašiną ir su paslėpto vieneto koncepcija. Jie pasinaudojo pasinaudojo statistinės fizikos koncepcija ir daugiasluoksnio tinklo mokymosi algoritmu (Boltzmanno mašinos modelis). D. E. Rumelhartas po dviejų metų po imituoto atkaitinimo algoritmo pasiūlė atgalinio sklidimo algoritmą BP (angl. *back propagation*), naudodamas daugiasluksnį neuroninio tinklo modelį, kuriuo stengtasi išvengti svorio pataisymų problemą. Daugiasluksnis neuroninis tinklas turi didelį gebėjimą mokytis ir jo pagalba galima atlikti daug užduočių kurios reikalauja nuolatinio mokymosi ir išspręsti daug praktinių problemų. Taip pirmasis konvoliucinis neuroninis tinklas (CNN) pirmą kartą buvo pristatytas 1988 metais. Taip pat dvikryptis asociatyvus saugojimo modelis (BAM angl. *bi-directional associative storage model*), kurį pristatė Kosko turėjo neprižiūrimo (angl. *unsupervised*) mokymosi galimybes. 1991 m. Hakenas pristatė neuroninių tinklų sinergiją, kuria teigė, jog pažinimo procesas spontaniškas. Po poros metų pritatytą Liao Xiaoxin matematinė teorija apie korinio neuroninio tinklo pagrindą atnešė didelę pažangą. Tikslas kuo labiau išplėsti aktyvinimo funkcijų klases. Vieni iš labiausiai naudojamų tuo metu tinklų tai BAM, Hopfield neuroniniai tinklai ir uždelsti koriniai neuronų tinklai (DCNN). Bėgant metams, neuroninių tinklų architektūros ir modeliai vis keitėsi ir tobulėjo, todėl buvo galima rinktis iš šimtų skirtingų neuroninių tinklų modelių. [40]

Carlos A. Parra, Khan Iftekharuddin and Robert Kozma 2003 metais pristatė projektą „Automatizuotas smegenų duomenų segmentavimas ir modelių atpažinimas naudojant ANN“. Tyrime dirbtinio neuroninio tinklo (ANN) algoritmas pritaikytas smegenų MRT duomenų segmentavimui atlikti. Naudojami daugiaspektrinės MRT vaizdai, charakteristikos naudojamos skirtingiems smegenų audiniams segmentuoti. Šiame projekte naudojamas ANN algoritmas su vektorių kvantavimo (LVQ) tinklu. Mokymui ir bandymui reikalingi vaizdai gaunami iš imituojamos smegenų duomenų bazės, integruotos McGill universiteto Monrealio neurologinio instituto McConell smegenų vaizdų centre (McBIC). Segmentavimo algoritmų rezultatai kokybiškai lyginami su fantominiais vaizdais, siekiant užmaskuoti kiekvieną audinį. Rezultatai parodė puikų smegenų audinio segmentavimą. LVQ pagrįsta ANN pasiūlė daug žadančių rezultatų klasifikuojant smegenų audinį. Atsižvelgiant į tai, kad teisinga audinių klasifikacija labai priklauso nuo vietinės tekstūros verčių, todėl būtina įtraukti ypatybes, kurios gali išmatuoti šį indeksą. [42]

1.5. Vaizdų segmentavimas taikant konvoliucinius neuroninius tinklus

Konvoliucinis neuroninis tinklas (CNN) – neuroninių tinklų struktūra, kuri taikoma vaizdų atpažinimui ar objektų klasifikavimui. Konvoliucinis neuroninis tinklas padarė didelį proveržį tyrimuose susijusiuose su veido atpažinimu, sakinių klasifikavimu ir semantiniu segmentavimu. [43]

Konvoliucinio neuroninio tinklo struktūra įkvėpta regos žievės ląstelių, kadangi ne visos esančios ląstelės jautrios tam tikros dalies sričiai. Įdomus Hubelio ir Wieselio eksperimentas 1962 m. išsamiai iliustruoja šią koncepciją. Jie parodė, kad kai kurie atskiri neuronai smegenyse reaguoja tik tada, kai tam tikros krypties kraštuose, kai kuriuos neuronus jaudina tik vertikalios briaunos, o kitus – horizontalios arba įstrižinės. Hubelis ir Wieselis pastebėjo, kad sukurti regimąjį suvokimą, visi esantys neuronai privalo išsidėstyti stulpelių pavidalu ir tarpusavį turėti susiejimą, kad galėtų veikti kartu. Idėja, kad konkretus tokios sistemos komponentas turi tam tikrą užduotį (regimosios žievės neuroninės ląstelės ieško specifinių savybių), taip pat tinka ir mašinos, kurios laikoma CNN pagrindu. [44]

Šąsuka turi svarbių taškų, susijusių su vietiniu ryšiu (angl. *local connection*) ir svorio pasidalijimu (angl. *weight sharing*). Jie sumažina parametrų skaičių, mokymosi sudėtingumą ir persimokymą. Svorio padalijimas taip pat pagerina konvoliucinio neuroninio tinklo įvertinimo toleranciją. [43]

Po daugelio metų plėtos konvoliucinis neuroninis tinklas buvo palaipsniui išplėstas į sudėtingesnes sritis, tokias kaip pėsčiųjų aptikimas, elgesio ir laikysenos atpažinimas nuo pradinio paprastesnio ranka parašyto simbolio atpažinimo. Pastaraisiais metais konvoliucinių neuronų tinklų pritaikymas ir toliau sparčiai plečiasi natūralios kalbos apdorojimui ir atpažinimui. Neseniai „Google“ sukurta dirbtinio intelekto programa „Alpha go“ sėkmingai panaudojo konvoliucinį neuroninį tinklą „Go“ lentos informacijai analizuoti. Atsižvelgiant į dabartinę tyrimų tendenciją, kadangi konvoliucinio neuroninio tinklo taikymo perspektyva pilna galimybių, ji taip pat susiduria su kai kuriomis tyrimo problemomis, pavyzdžiui, kaip pagerinti konvoliucinio neuronų tinklo struktūrą, kad padidintų mokymosi gebėjimą ir kaip konvertuoti konvoliucinį neuroninį tinklą. [45]

Parul Sharma, Yash Paul Singh Berwal ir Wiqas Ghai 2019 metais straipsnyje „Giluminio mokymosi CNN modelių, skirtų augalų ligų aptikimui naudojant vaizdo segmentavimą, našumo analizė“ analizavo konvoliucinių neuroninių tinklų architektūras pastebint ankstesnes augalų ligas, taip siekiant sumažinti žalą pasėliams. Dauguma giliojo mokymosi modelių, skirtų automatizuotam augalų ligų aptikimui, turi mirtiną ydą, kuri, patikrinus nepriklausomus duomenis, gerokai sumažėja. Palyginami S-CNN, modelis apmokytas naudojant segmentuotus vaizdus, su F-CNN, modelis, kuriam naudojami pilni-visi vaizdai. S-CNN tikslumas padidėja iki 98,6%, kai šis modelis pritaikytas pagal nepriklausomus duomenis, kurių anksčiau F-CNN nematė, net turint 10 skirtingų ligų klasių. Nėgana to, kaip pavyzdį naudodami pomidorų augalą ir tikslinės dėmės ligos tipą, parodoma, kad S-CNN modelio saviklasifikavimo pasitikėjimas žymiai pagerėja, palyginti su F-CNN modeliu. Šis mokslinis darbas priartino automatizuotų metodų pritaikomumą prie ne specialistų, siekiant laiku nustatyti ligas. Vietoj pilnų vaizdų, naudojama anotuoti ir segmentuoti vaizdai, nes daugelis modelių, skirtų ligų aptikimui, našumas ir tikslumas sumažėja, kai modeliai pritaikomi anksčiau nepritaikytiems ir nematytiems vaizdams. Naudojant segmentuotus vaizdus (S-CNN) apmokyti konvoliucinį neuroninį tinklą, modelio našumas padidėja beveik dvigubai nuo 42,3% iki 98,6%, lyginant su apmokymu, kai naudojami visi vaizdai (F-CNN). Be to, kiekybinė savęs klasifikavimo pasitikėjimo analizė parodė reikšmingą pagerėjimą – 82% bandymo duomenų

rinkinio parodė pasitikėjimo padidėjimą. Esant didesniems ir geresniems duomenų rinkiniams, išankstinis vaizdų rinkinių apdorojimas prieš apmokant konvoliucinį neuroninį tinklą padės pasiekti aukštą modelio tikslumą bei geresnius rezultatus sprendžiant realias problemas. [46]

Mo Zhang, Xiang Li, Mengjia Xu ir Quanzheng Li 2017 metais pristatė „Vaizdo segmentavimas ir klasifikacija dėl pjautuvinių ląstelių ligos, naudojant deformuotą U-Net“ straipsnį, kuriame aprašė patikimą ląstelių segmentavimą ir klasifikavimą pagal biomedicininis vaizdus, kuris yra esminis žingsnis tiek atliekant mokslinius tyrimus, tiek atliekant klinikinę praktiką. Pagrindinis iššūkis taikant patikimesnius segmentavimo ir klasifikavimo metodus dideli ląstelių dydžio, formos ir požiūrio skirtumai, kartu su žema vaizdo kokybe, kurią sukelia triukšmas ir artefaktai. Norėdami išspręsti šią problemą, pasiūlyta mokymu pagrįstas, segmentavimo ir klasifikavimo metodas, grįstas gilia U-Net struktūra, su deformuojamais konvoliucijos sluoksniais. Įrodyta, kad gilus mokymosi U-Net architektūra siūlo tikslią vaizdo semantinio segmentavimo lokalizaciją. Be to, deformuojamas konvoliucijos sluoksnis leidžia laisvai deformuoti funkcijų mokymosi procesą, todėl visas tinklas atsparesnis įvairioms ląstelių morfologijoms ir vaizdo parametrų. Metodas išbandytas naudojant mikroskopinius raudonųjų kraujo kūnelių vaizdus iš pacientų, sergančių pjautuvine anemija. Rezultatai parodė, jog pasiekiamas geriausias segmentavimo bei klasifikavimo tikslumas, naudojant U-Net su deformuotą konvoliuciją. [47]

Visos CNN architektūros laikosi tų pačių bendrųjų projektavimo principų, kai įvestyje paeiliui taikomi konvoliuciniai sluoksniai, periodiškai mažinant erdvinius matmenis ir didinant funkcijų žemėlapių skaičių.

Nors klasikinės tinklo architektūros buvo sudarytos tiesiog iš sukrautų konvoliucinių sluoksnių, šiuolaikinės architektūros tyrinėja naujus ir novatoriškus būdus. [48]

1.5.1. U-Net

U-Net tai konvoliucinio neuroninio tinklo architektūra, kurio pagalba segmentuoti biomedicininiai vaizdai. Kadangi architektūra susideda iš dviejų dalių, ši architektūra atrodo kaip U raidė, kadangi ji pirmiausia sutraukia vaizdą, o po to jį išplečia. Dėl to kairioji dalis vadinama susitraukimo kelias (angl. *contracting path*), kuri užfiksuoja kontekstą, o dešinioji dalis – išplečiamasis kelias (angl. *expansive path*), ši dalis padeda nustatyti lokalizaciją. Po konvoliucijos pateikiamas pataisytas tiesinis vienetas ir du kartus apskaičiuojamas didžiausias sujungimas, siekiant sumažinti atranką. [49]

1.5.2. FastFCN —Fast Fully Convolutional Network

FCN paprastai susideda iš dviejų dalių: kodavimo ir dekoderio. Kodavimo etape ištraukia funkcijas, kurias vėliau naudos dekoderis. Įprasta naudoti kodavimo įrenginį, iš anksto paruoštą „ImageNet“. Pavyzdžiui, VGG ir ResNet populiariausi pasirinkimai. Kadangi tai iš esmės yra tas pats, kas mokymasis naudojant mokymosi perkėlimo būdus, kad paspartintume mūsų FCN mokymą. Norint konvertuoti CNN į FCN, pirmas dalykas, kurį reikia padaryti, konvertuoti visiškai prijungtą sluoksnį į 1x1 konvoliucinį sluoksnį. Tada kodavimo įrenginiui seka dekoderis, kuris naudoja kitą perkeltų konvoliucinių sluoksnių techniką, kad atrinktų vaizdą. Galiausiai pridamas praleidimo ryšys. Praleisti jungtis — sujungti vieno sluoksnio išvestį su ne gretimu sluoksniu. Tai darant, praleidimo ryšys leidžia tinklui naudoti informaciją iš kelių skiriamųjų gebų. Naudojant praleidžiamąsias jungtis, reikia būti atsargiems, kad nepridėtų per daug praleistų jungčių. Priešingu

atveju tai sukeltų per didelio modelio problemą. Kaip naudojant VGG-16 kaip kodavimo įrenginį, tik trečiasis ir ketvirtasis telkimo sluoksniai paprastai naudojami praleisti jungtis. Kai baigsime įtraukti visas šias tris technologijas, galėsime treniruoti modelį nuo galo iki galo, kaip tai darome su CNN. [50]

1.5.3. Deep – lab


DeepLab – moderniausias semantinio segmentavimo modelis, kurį 2016 m. sukūrė ir paskelbė „Google“. Nuo to laiko atlikta daugelis šio modelio patobulinimų ir egzistuoja skirtingos DeepLab versijos, viena naujausių iš jų DeepLab V3+. [50]

DeepLab modelį sudaro du pagrindiniai etapai:

- Kodavimo fazė. Išgaunama svarbiausia informacija, kai panaudojami jau iš anksto paruošti konvoliuciniai neuroniniai tinklai. Konvoliuciniai sluoksniai ieško skirtingų vaizdo ypatybių ir perduoda šią informaciją tolesniems sluoksniams, kadangi CNN puikiai atlieka klasifikaciją, segmentuojant vaizdą galima lengvai sužinoti esamus objektus.
- Dekodavimo fazė. Visa informacija, kurią pavyko išgauti kodavimo fazėje, panaudojama atkuriant reikiamų matmenų išvestį.

1.5.4. R-CNN

Regionu pagrįstu konvoliuciniu neuroniniu tinklu (angl. *region based convolutional neural network*) objektai esantys vaizduose klasifikuojami ir lokalizuojami. Šioms funkcijoms atlikti naudojamas ribojantis langelis ir semantinis segmentavimas. Semantinis segmentavimas – suskirsto kiekvieną vaizdo pikselį į kategorijų rinkinius, tokiu būdu kiekvienam iš dominančių regionų priskiriama segmentavimo kaukė. Galutiniame rezultate sukuriamos klasės etiketės ir linijos. R-CNN architektūra, tai Faster R-CNN plėtinys. Greitesnis R-CNN sudarytas iš gilaus konvoliucinio tinklo, kurį lengvą naudoti dėl siūlomų regionų, ir detektoriaus, kuris naudoja konvoliucinio tinklo siūlomus regionus. [49]



7 pav. R-CNN architektūra

1.6. Uždaviniai

1. Atlikti literatūrinę analizę eksperimentinių vaizdų, naudojamų giliesiems mokymosi metodams. Apžvelgti dirbtinių neuroninių tinklų architektūras ir metodus jų kūrimui bei pritaikymui.
2. Paruošti SEM eksperimentinius vaizdus naudojimui modelyje. Kiekvienam naudojamam vaizdui sukurti kaukes (angl. *masks*), dirbtinių neuroninių tinklų apmokymui.
3. Realizuoti U-Net architektūrą SEM eksperimentinių vaizdų segmentavimui. Sukurtą architektūrą panaudoti segmentuoti vaizduose dvi ir tris klases bei jas palyginti.
4. Realizuoti vandens baseinų metodą (angl. *watershed*) dviejų klasių segmentavimui.
5. Palyginti gautus segmentavimo rezultatus tarpusavyje ir pagrįsti globalios slenkstinės vertės metodo netinkamumą šių vaizdų segmentavimui.

2. Duomenys ir tyrimo metodai

2.1. Vaizdų apdirbimo metodai

Vaizdo apdorojimas ir kompiuterinė įranga atlieka gyvybiškai svarbų vaidmenį visose srityse, susijusiose su vaizdo gerinimu, manipuliavimu ir analize. Vaizdo apdorojimo metodai, kuriais atliekama skaitmeninių vaizdų analizė ir manipuliavimas, siekiama pagerinti vaizdo kokybę. Pritaikymas, pasikartojimas ir originalių duomenų išsaugojimo tikslumas pagrindiniai skaitmeninio vaizdo apdorojimo metodų pranašumai. [51]

2.1.1. Global threshold

Daugelyje su vaizdais susijusių programų naudinga atskirti vaizdų objektų sritis, kurios atitiktų foną ar kitą norimą atpažinti vaizdo sritį. [52] Slenkstinė vertė (angl. *threshold*) – paprastas būdas, kurį lengvą naudoti segmentavimui, atkreipiant dėmesį į skirtingus intensyvumus tarp fono ir objekto. Slenkstinė vertė dažniausiai taikoma pilkiems (angl. *grayscale*) arba spalvotiems (angl. *color* – RGB) vaizdams.

Vaizdas su visuotiniu slenksčiu (angl. *global threshold*) apibrėžiamas naudojant histogramą, kuri parodo pikselių intensyvumą visuose vaizduose. Jis turi prielaidą, jog visuose vaizduose galioja bimodalinis pasiskirstymas (angl. *Bimodal distribution*), kad vaizde bus dvi skirtingos grupės kurias galima atskirti. [53] Jei prielaida nepaneigiama, galima naudoti nesudėtingą operaciją, kad objektai atsiskirtų nuo fono. Naudojant pasirinktą operaciją, siekiama palyginti reikšmes esančias vaizde su norima slenksčio verte, kuri gali būti pasirenkama laisvai arba dažniausiai renkama T [32,132]. Vaizdo pikseliai suskirstomi į du dominuojančius režimus – vienas skirtas objekto, o kitas vaizdo atpažinimui. Pagal pasirinktą slenkstį T , norima atskirti šiuos du režimus. [54]

$$g(x, y) = \begin{cases} 1 & \text{if } (x, y) > T \\ 0 & \text{if } (x, y) < T \end{cases}$$

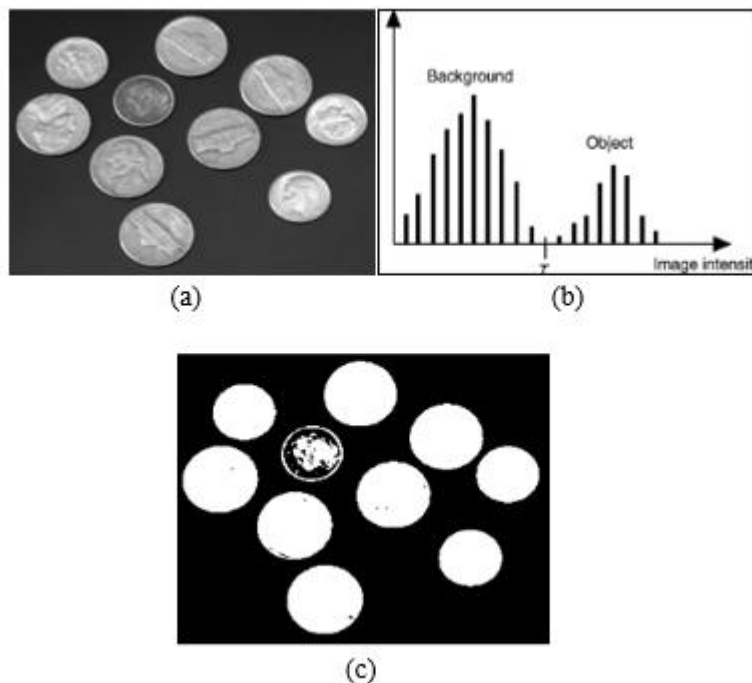
Patikrinama, kurie pikseliai patenka aukščiau slenksčio vertės, kad prisiskirtų vienam režimui, kurių intensyvumo reikšmė yra 1, tai jie atvaizduos objektą. Pikseliai, kurie žemiau slenksčio, prilyginami 0 ir atvaizduos foną.

Egzistuoja ir kitų būdų, kaip klasifikavimo modelis, norint parinkti visuotinį slenkstį. Juo sumažinama klaidos tikimybė. Jei turime bimodalinio pasiskirstymo histogramą vaizde, galima apskaičiuoti klaidų skaičių, kai fono pikseliai klaidingai klasifikuojami kaip objektas, ir objekto pikseliai, netinkamai klasifikuoti kaip fonas.

Pusiau automatizuota šios technikos versija buvo pritaikyta Johnson matuoti skilvelių tūrį iš 3D magnetinio rezonanso (MR) vaizdų. Operatorius pagal pasirinktą metodą identifikuoja du skirtingus pikselius, vienas iš objekto viduje, o kitas aplink esančio objekto fone. Srityse aplink pasirinktus pikselius palyginamas pikselių intensyvumo pasiskirstymas. Palyginamas pikselių intensyvumo pasiskirstymas. Tokiu būdu gautas rezultatas atvaizduojamas kaip kontūrinis žemėlapis, kuris vėliau sudedamas kartu su pagrindiniu vaizdu, taip gautas rezultatas yra aiškesnis. Esant būtinybei, naudojant operatorių, galima lengvai pakeisti bet kurią sienos dalį rankiniu būdu. Nustatyta, kad jis labai jautrus naudotojo vidinių ir išorinių taškų padėčiai. [55]

8 paveikslėlyje, visuotinės svartinės vertės pavyzdys:

- Pirminis vaizdas, kuriam taikoma visuotinė svartinė vertė
- Pateikiama vaizdo histograma, atvaizduojamas pikselių intensyvumas vaizde
- Rezultatas, kai $T = 127$



8 pav. Visuotinės svartinės vertės pavyzdys


Visuotinė slenkstinė vertė paprastai pritaikoma objektų vaizduose, kuriuos sudaro kontrastingas fonas su unikaliomis šviesumo reikšmėmis. Tačiau šį metodą sudėtinga naudoti, jei fonas turi daug triukšmo (angl. *noise*) arba pastebimas didelis kontrastingumas tarp objektų ir fono. [54]

2.2. Dirbtinis neuroninis tinklas

Dirbtiniuose neuroniniuose tinkluose apdorojimo vienetas vadinamas neuronu, kuris sujungiamas su kitais neuronais, esančiuose tame pačiame tinkle, svartinėmis jungtimis. Neuronai skirstomi į sluoksnius, kurie jungiasi tarpusavyje, tokiu būdu informacija pateikta į tinklą apdorojama nuosekliai. Vektorius, pirmasis įvesties šablonas

$$x = (x_1, \dots, x_M)$$

pateikiamas kaip įvesties sluoksnis, kad įvesties sluoksnio neuronui i suteiktų aktyvacija, kuri lygi x_i . Taip aktyvacijos funkcija plinta į kitus paslėptus sluoksnius, kurie sudaryti iš neuronų atitinkančių išvesties vektoriaus koordinatas. 9 paveiksle atvaizduotas dirbtinis neuroninis tinklas sudarytas iš įvesties sluoksnio (angl. *input layer*), vieno paslėpto sluoksnio (angl. *hidden layer*) ir išvesties sluoksnio (angl. *output layer*). [56]

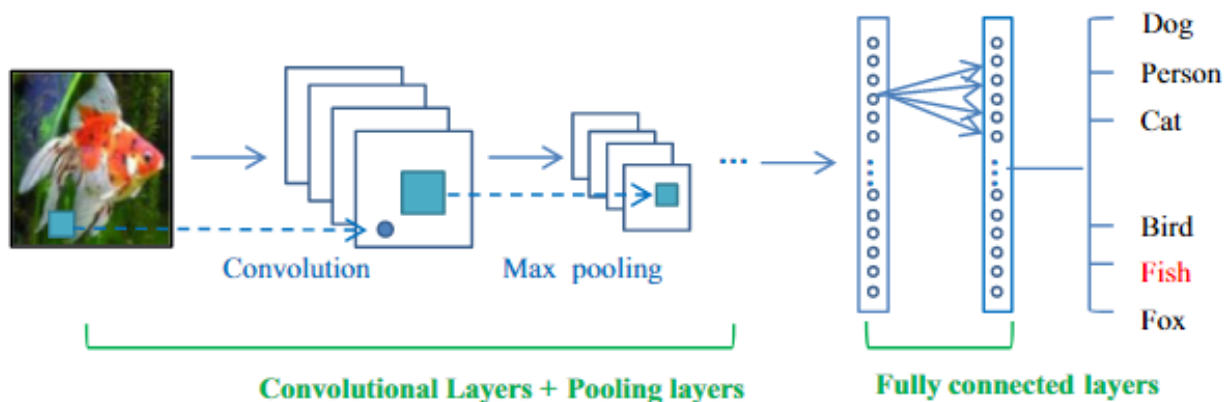


9 pav. Dirbtinio neuroninio tinklo struktūra

1. Įvesties sluoksnis. Jame esantys neuronai inicializuoti, jog turėtų aktyvacija x_i taip perduodant ją į kitus sluoksnius.
2. Paslėptasis sluoksnis. Jame jau esamiems neuronams suteikiama aktyvacija $a_j^{(1)} = \tilde{x}^T w_j^{(1)}$. Tai pat apskaičiuojami svoriai perduodami į kitą paslėptąjį ar išvesties sluoksnį. Jei dirbtiniame neuroniniame tinkle yra daugiau nei vienas paslėptasis sluoksnis, tada perduodame į kitą paslėptąjį sluoksnį prieš perleisdami į išvesties sluoksnį.
3. Išvesties sluoksnis. Neuronams priskiriama $a_k^{(2)} = (\tilde{z}^{(1)})^T w_k^{(2)}$, kurie atkeliavo iš paslėptojo sluoksnio. Šie neuronai laikomi išvestimi, kuri atvaizduojama vartotojo norimu formatu.

2.3. Konvoliuciniai neuroniniai tinklai

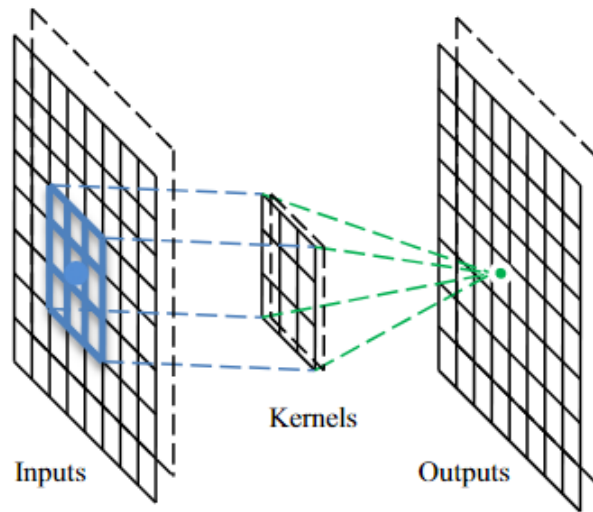
Vienas žinomiausių giliojo mokymosi metodų - konvoliuciniai neuroniniai tinklai. Tai tinklai, kai keli sluoksniai apmokomi atpažinti norimus objektus pateiktuose vaizduose. Dažniausiai šiuose neuroniniuose tinkluose įvestis susideda iš vaizdų. Neuronai, sudarantys konvoliucinį neuroninį sluoksnį, suskirstyti į tris matmenis: aukštį, plotį ir gylį. Gylis tai aktyvavimo tūris dimensijoje. [57]



10 pav. Konvoliucinio neuroninio tinklo struktūra

Konvoliucinio neuroninio tinklo sluoksniai [59]:


1. Įvestis. Pateikiamos vaizdo reikšmės pikseliais, vienos spalvos kanalu arba trimis (RGB)
2. Konvoliucinis sluoksnis. Įvesties reikšmei perėjus į šį sluoksnį, pritaikomas filtras, kuris pereina per visą įvestį ir apskaičiuoja kiekvienai reikšmei skaliarinę išvestį.



11 pav. Konvoliucinio tinklo operacija

Konvoliucinis sluoksnis optimizuojant išvestį sumažina modelio sudėtingumą. Optimizavimas atliekamas priskiriant tris parametrus: nulinių užpildymą (angl. *zero padding*), gylį ir žingsnį. Nulinis užpildymas, tai paprastas įvesties krašto užpildymo procesas, kuriuo lengva manipuluoti išvesties matmenimis. Gylis nustatomas pagal neuronų skaičių sluoksnyje, turinčių tą pačią įvesties sritį. Šį parametą mažinant bendras neuronų skaičius tinkle bus žymiai mažesnis, tačiau tai gali lemti prastesnį modelį.


3. Jungiamieji sluoksniai – juose sumažinami vaizdo matmenys ir parametų skaičius.



12 pav. Maksimali operacija konvoliuciniame tinkle

Jungiamasis sluoksnis paveikia kiekvieną aktyvaus žemėlapių įvestį ir jų dydį, panaudojus maksimalumo funkciją (angl. *max-pooling*).

4. Visiškai sujungtas sluoksnis. Šis sluoksnis turi visas įmanomas jungtis su ankstesniais esančiais tinkle sluoksniais.



13 pav. Visiškai sujungtas sluoksnis

Visiškai sujungtas sluoksnis – paskutinis sluoksnis esantis tinkle, kuris išeina iš jungiamojo sluoksnio. Šis sluoksnis paverčia dviejų dimensijų objektų žemėlapius į vienmačių dimensijų vektorius. Visiškai sujungtas sluoksnis, konvoliuciniame neuroniniame tinkle sudaro apie 90 procentų parametrų ir jo veikimo principas panašus į paprastą neuroninį tinklą. [58]


2.3.1. „U-Net“ architektūra

U-Net architektūra, pirmą kartą paskelbta 2015 m., kuri tapo revoliucija gilios mokymosi srityje. Per nedidelį laiko tarpą galima apskaičiuoti 512 x 512 dydžių vaizdų segmentaciją, naudojant U-Net architektūrą

Dėl fenomenalios sėkmės laikui bėgant atsirado daug šios architektūros variantų ir modifikacijų. U-Net nesudėtinga, bet plačiai naudojama architektūra, kuri išsprendžia daugumą kylančių problemų segmentuojant vaizdus. Šiam metodui naudojama visiškai konvoliucinių tinklų (angl. *fully convolutional network*) idėja. Šios architektūros pagalba užfiksuojamos tiek vaizdo ypatybės, tiek lokalizacija. Pagrindinė diegimo idėja panaudoti nuoseklius susitraukiančius sluoksnius, po kurių iš karto naudojami atrankos operatoriai, kad įvesties vaizduose pasiektų didesnę raišką. [60]

14 paveikslėlyje parodyta U-Net architektūra. Galima lengvai pastebėti, kad šioje architektūroje nenaudojama jokių kitų sluoksnių. Iš visų elementų esančių kūrimo procese, sudaromas visiškai konvoliucinis tinklas.

U-Net architektūroje matoma, kad įvesties vaizdas, kuris pradžioje paduodamas į tinklą, perduodamas per modelį, o po to seka konvoliuciniai sluoksniai su ReLU aktyvinimo funkcija (galima naudoti ir kitas esamas aktyvinimo funkcijas). Panaudojami nepaminkštinti posūkiai posūkiai (angl. *unpadded convolutions*), todėl pastebima, kad pirminis vaizdo dydis 572x572 sumažėja iki 570x570 ir galiausiai iki 568x568, dėl ko sumažėja bendras matmuo. Be konvoliucijos blokų, taip pat galima pastebėti, kad kairėje pusėje yra kodavimo blokas, o dešinėje - dekodavimo blokas.



14 pav. U-Net architektūra

Kodavimo blokas turi nuolatinį vaizdo dydžio mažinimą naudojant 2 maksimalaus sujungimo sluoksnius. Taip pat architektūroje naudojami pasikartojantys konvoliuciniai sluoksniai, kuriuose filtrų skaičius didėja. Kai pasiekiamo dekoderio fazę, pastebima, kad filtrų skaičius konvoliuciniuose sluoksniuose pradeda mažėti, o kituose sluoksniuose palaipsniui didinama atranka iki pat viršaus. Po jų seka praleisti ryšiai (angl. *skip connections*). Šie ryšiai sujungia ankstesnius išėjimo ryšius su dekoderio blokų sluoksniais. Ši praleidžiamoji jungtis svarbi koncepcija, norint išsaugoti ankstesnių sluoksnių pradžią (angl. *loss*), kad ši jungtis dar geriau atspindėtų bendras vertybes, taip duodami geresnius rezultatus. Galutiniame konvoliucijos bloke turima keletą konvoliucinių sluoksnių, po kurių seka galutinis konvoliucijos sluoksnis. Šį sluoksnį sudaro 2 filtrai, kurie turi priskirtas funkcijas, taip rodo gauta produkcija. Pagal reikalingą įvesties formatą, galutinį konvoliucinį sluoksnį galima keisti, jog rezultatai būtų toliau pateikiami apmokymui. [61]

2.3.1.1. Loss – Nuostolių funkcija

U-Net naudoja gana paprastą nuostolių (angl. *loss*) schemą kiekvienam pikseliui, kad segmentuotų objektų kraštuose būtų didesnis nuostolis. Ši nuostolių schema padėjo U-Net modelio ląsteles segmentuoti biomediciniuose vaizduose nepertraukiamai, todėl atskiras ląsteles galima lengvai identifikuoti dvejetainiame segmentavimo žemėlapyje. [62]

Visų pirma gautam vaizdui taikoma kryžminės entropijos (angl. *binary cross-entropy - BCE*) praradimo funkcija. Tokiu principu kiekvienas pikselis klasifikuojamas į vieną egzistuojančių klasių.

Kryžminė entropija naudojama kaip panašumo metrika, norint nustatyti, kiek vienas atsitiktinių įvykių pasiskirstymas arti kito, todėl kryžminės entropijos (BCE) nuostolis bando išmatuoti informacijos turinio skirtumus tarp faktinių ir numatomų vaizdo kaukių. Bernoulli paskirstymu pagrįstas ir geriausiai veikiantis, kai tarp klasių turimas vienodas duomenų pasiskirstymas. Kitaip

tariant, vaizdo kaukės su labai dideliu klasių disbalansu (pavyzdžiui, kai rentgeno nuotraukose nustatomi labai maži, reti navikai) gali būti netinkamai įvertintos BCE. Taip nutinka dėl to, kad kryžminė entropija vienodai traktuoja tiek neigiamus (0) tiek teigiamus (1) vaizdo kaukių mėginius. Kadangi gali būti nevienodas pikselių, vaizduojančių tam tikrą objektą ir likusio vaizdo pasiskirstymas [63]

$$L(y, \hat{y}) = -y * \log(\hat{y}) - (1 - y) * \log(1 - \hat{y})$$

y - tikslinė reikšmė pateikiama į modelį

\hat{y} – prognozuojama reikšmė pagal modelį

Nuostolių funkcija matuoja skirtumą tarp to, kas buvo pateikta (y) ir to, ką modelis davė (\hat{y}).

2.3.1.2. Mean IoU

Norint suprasti šį matavimo metriką, pirmiausia reikia apskaičiuoti susikirtimą padalintą iš sąjungos (angl. *Intersection over Union* – *IoU*). Šis matavimas padeda apskaičiuoti norimos reikšmės ir gautos išvesties pateiktos pagal modelį sutapimą. IoU metrika matuojamas bendras taškų skaičius tarp tikslinės ir numatytų reikšmių, padalinta iš bendro vaizdo elementų skaičiaus. [66]

$$IoU = \frac{target \cap prediction}{target \cup prediction}$$

Mean IoU - bendra sematinio vaizdo segmentavimo vertinimo metrika. Šia metrika apskaičiuojamas kiekvienos vaizde esančios kaukės IoU ir randamas visų klasių vidurkis. [67]

2.3.1.3. Adam optimizatorius

Adaptyvus momento įvertinimas (angl. *Adaptive Moment Estimation*), kitaip vadinamas Adam optimizatorius. Tai toks metodas, kuri padeda apskaičiuoti kiekvieno adaptyvaus parametro mokymosi greitį. Šis optimizatorius paspartina mokymąsi pagal vaizduose ar duomenyse esančius matmenis, kuriuose gradientas nukreipiamas ta pačia kryptimi. [68] Jis išlaiko eksponentiškai mažėjantį praeities vidurkį (m_t), taip pat saugo ir eksponentiškai mažėjantį ankstesnių kvadratinų gradientų vidurkį (v_t). Atitinkamai apskaičiuojami praeities kvadratinų gradientų m_t ir v_t mažėjančius vidurkius pagal šias formules:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) * g_t$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) * g_t^2$$

m_t ir v_t inicijuojami kaip nuliniai vektoriai, todėl šiam optimizatoriui lengva pastebėti, kai šios reikšmės yra nukrypusios nuo nulio. Neutralizuodami paklaidas, apskaičiuojami pirmojo ir antrojo momento įvertinimai:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

Tada panaudojus šiuos įvertinimus atnaujinti parametrus, taip suteikdami Adam atnaujinimo taisyklę:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t$$

Šis algoritmas lengvai praktiškai pritaikomas ir palyginamas su kitais adaptyviojo mokymosi metodo algoritmais. [69]

2.3.1.4. Kategorinė kryžminė entropija

Kategorinė kryžminė entropija (angl. *categorical loss function*) praradimo funkcija, ji plačiai pritaikoma treniruojant ir įvertinant giluminius modelius. [70] Apskaičiuoti pateiktų pavyzdžių nuostolius, pritaikoma ši funkcija:

$$Loss = - \sum_{i=1}^{output\ size} y_i * \log \hat{y}_i$$

šioje formulėje \hat{y}_i , tai modelio išvestinė, o y_i atitinka tikslinę vertę. Tai skaičiavimo matas, kuriuo lengvai atskiriami tikimybių skirstiniai vieną nuo kito. Formulėje minuso prirašomas dėl to, nes jis padeda užtikrinti, jog nuostoliai treniruojant modelį, kai skirstiniai vis priartėja vienas prie kito, mažėja. [71]

2.4. Vandens baseinas

Vandens baseinas (angl. *watershed*) vaizdą vizualizuoja trimis matmenimis – dviem erdvinėmis koordinatėmis ir vienu intensyvumu. [72] Šiame baseine yra trijų rūšių taškai:

- Pirmos rūšies taškai, tai tie kurie priklauso regioniniam minimui;
- Antros rūšies taškai, kuriuose vanduo nukristų mažiausiai vietiniu minimu;
- Trečios rūšies taškai, kuriuose vienodai tikėtina, kad vanduo nukris iki daugiau nei vieno tokio minimumo.

Minimumo baseinu vadinamas taškų rinkinys, kuris atitinka b sąlygą. O skiriamosiomis linijomis - taškai, atitinkantys c sąlygą.

Pagrindinė idėja baseiniais pagrįstų segmentavimo algoritmų – rasti baseino linijas (angl. *watershed lines*) vaizduose. Tarkime, kad kiekviename regioniniame minimume išmušta skylė ir visa topografija užtvindoma iš apačios, leidžiant vandeniui pro skylės vienodu greičiu kilti. Kylant vandeniui skirtinguose baseinuose, jie galiausiai turėtų susijungti, todėl pastatoma užtvanka, kad sustabdyti susiliejimą. Kylantis vanduo laikui bėgant pasieks tokį etapą, kad virš vandens linijos bus pastebimos tik pastatytos užtvankų viršūnės. Užtvankos ribos arba kitaip užtvankos viršūnės, kuriomis apstatomi baseinai atitiks vandens baseinų skiriamąsias linijas. Tokiu būtu kiekvienas iš baseinų yra atskirtas ir neturi galimybės susilieti. Šis metodas efektyvus norint atskirti panašios klasės objektus. [69]



15 pav. Pradinis vaizdas, Topografinis paviršius ir Galutiniai vandens baseinų vaizdas

2.5. Duomenų paskirstymas

Įvairių duomenų rinkinio pavyzdžių ir padalijimo sukūrimas padeda mums įvertinti tikrąjį modelio veikimą. Duomenų rinkinio padalijimo santykis priklauso nuo duomenų rinkinyje esančių pavyzdžių skaičiaus ir modelio. Duomenų rinkinys paruošiamas padalinant jį į tris dalis [70]:

1. Apmokymo rinkinys (angl. *training set*) – naudojamas išmokyti modelį duomenų ypatybių. Jis turi įvairų įvesties rinkinį, kad modelis apsimokytų visus įmanomus scenarijus ir pritaikytų bet kokiam duomenų pavyzdžiui.
2. Validavimo rinkinys (angl. *validation set*) – rinkinys naudojamas apmokymo metu įvertinti modelio veikimą. Suteikia informacijos, kuri padeda atitinkamai suderinti modelio hiperparametrus ir konfigūracijas.
3. Testavimo rinkinys (angl. *test set*) – šis duomenų rinkinys naudojamas išbandyti modelį. Jis pateikia nešališkas galutines metrikas, kaip tikslumas ir efektyvumas.

2.6. Programinė įranga

Darbe naudojama Python 3.8 programavimo kalba su Anaconda – Spyder aplinka. Darbo metu kuriant modelį ir segmentuojant vaizdus naudojamos Pandas, Matplotlib, Numpy, Keras ir Scikit-image bibliotekos.


Pandas – Python lankstus paketas, kuris suteikia lengvai pritaikomas duomenų struktūras, kurios naudotojui palengvina darbą su duomenimis. Tai viena stipriausių ir galingiausių bibliotekų naudojamų Python kalboje.

Keras – atvira Python biblioteka, kuri naudojama neuroniniams tinklas. Palengvina giliojo ir mašininio mokymosi modelių sukūrimą, nenaudojant vidinės architektūros informacijos, kas padaro kodą trumpesnį ir lengviau suprantamą.

Tensorflow – tai biblioteka, kuri padeda lengvai sukurti duomenų srautų grafikus ar struktūras. Jie padeda apibrėžti kaip duomenys juda apdorojimo mazgų serijoje. Kiekvienas grafike esantis mazgas atspindi tam tikrą matematinę operaciją. Tarp mazgų esanti jungtis tai daugiamatis masyvas (kitaip vadinamas tenzoriumi).

2.7. Duomenų paruošimas


Darbo tikslas – Nanodalelių segmentavimas SEM eksperimentiniuose vaizduose taikant giliojo mokymosi metodus, todėl norima pateikti į kuriamą modelį atitinkamus vaizdus. Vaizdai naudojami baigiamajame darbe gauti iš laboratorijos su skaitmeniniu elektroniniu mikroskopu užfiksuotų nanodalelių. 256×256 formato nuotraukose atvaizduojamos nanodalėlės, kurios išsidėsčiusios netvarkingai ir kai kurios tarpusavyje liečiasi. Taip pat nuotraukose galima pastebėti, jog fonas turi didelį triukšmą, kurio ir stengiamasi išvengti tyrimu. (žr. **16 pav.**)



16 pav. Duomenys pateikiami į modelį

Norint apmokyti ir pateikti turimus vaizdus į sukurtą modelį, turime sužymėti kiekvienai nuotraukai kaukes (angl. *mask*), kad galima būtų segmentuoti norimus vaizdus. Kiekviena nanodalelė sužymima atskirai, kad būtų lengviau atpažinti modeliui.

Šis procesas atliekamas rankiniu būdu, kad galėtume pagerinti tinklo apsimokymą ir pagerinti modelio rezultatus. Visos nuotraukų esančių nanodalelių kaukės išsaugojamos toje pačioje nuotraukoje (žr. 17 pav).



17 pav. 1. Originali nuotrauka 2. Išsaugotos nuotraukos

3. Tyrimų rezultatai ir jų aptarimas

3.1. Pradiniai kintamieji konvoliuciniame neuroniniame tinkle

Magistriniame darbe naudotas konvoliucinis neuroninis tinklas, kuriame pagal pasirinktus parametrus bandoma įvertinti modelio našumą. Keičiami parametrai norint išgauti geriausią modelį. Keičiamas rinkinio dydis (angl. *batch size*), validacijos žingsniai (angl. *validation steps*) bei žingsnių kiekis per epochą (angl. *steps per epoch*).

Rinkinio dydis, tai parametras naudojamas nustatyti mėginių skaičių ir atnaujinti modelio vidinius parametrus. Pasirinktas dydis perleidžiamas per praėjimus - pirmyn (angl. *forward*) ir atgal (angl. *backward*). Esant didesniai šiam parametrai, reikalinga didesnė kompiuterio atmintis. Norint įvertinti kaip šis parametras veikia turimą neuroninio tinklo modelį, naudojami keli skirtingi dydžiai – 10, 20, 30.

Validacijos žingsniai – tai rinkinio dydžio skaičius patvirtinimo duomenų rinkinyje.

Žingsniai per epochą – tai rinkinio dydžio skaičius apmokymo duomenų rinkinyje. Jį naudinga naudoti, jei turimas didelis duomenų kiekis ar naudojamos duomenų augmentacijos.

Įvestys į konvoliucinį neuroninį tinklą pateikiamos 256 x 256 formato nuotraukos. Jos modelyje pakeičiamos į trimatį formatą 256 x 256 x 1.

Taip pat, panaudojamas augmentacija (angl. *augmentation*), tai padeda mokymui išvengti persimokymo.

Modeliui apsimokant apskaičiuojama rodiklis *mean IoU*, kuris parodo nanodalelių segmentavimo tikslumą duomenų rinkinyje. Kadangi mūsų pirmoje tiriamoje dalyje atliekama nanodalelių segmentacija, tai tikriname kiek gerai nuotraukose atpažįstamos dalelės. Antru tyrimu atliekamas kelių klasių segmentavimas - nanodalelės ir dalelės krašto, todėl tokiu atveju šis rodiklis parodys kiek tiksliai atpažįstamas nanodalelės kraštas. Kuo arčiau vieneto *mean IoU*, tuo tikslesnis mūsų modelis.

Pirmoje tyrimo dalyje, konvoliuciniui neuroniniam tinklui taikoma dvinarė kryžminė entropija, o kelių klasių segmentacijai taikoma kategorinė kryžminė entropija. Abejuose modeliuose naudojamas Adam optimizatorius.

3.2. U-Net architektūra

U-Net architektūra sudaryta iš dviejų kelių : enkoderio (angl. *encoder*) ir dekoderio (angl. *decoder*).

Enkoderio kelias užfiksuoja vaizde esantį kontekstą į požymių žemėlapius, kad įvesties vaizdus būtų galima segmentuoti. Enkoderio dalis susideda iš konvoliucijos ir maksimalaus telkimo sluoksnių. Abiejuose tyrimų modeliuose naudojama ta pati U-Net struktūra, tik skiriasi galutinio sluoksnio išvestis.

Enkoderio sudaro keturi blokai:

1. Visuose konvoliuciniuose sluoksniuose naudojama ReLu aktyvavimo funkcija. Kiekviename bloke naudojama du konvoliuciniai sluoksniai su 3 x 3 matricos dimensija. Su kiekvienu sluoksniu filtrų skaičius didėja dvigubai, todėl pirmame sluoksnyje turime 32 filtrus, o paskutiniame enkoderio sluoksnyje yra 256 filtrai.

2. Taip pat naudojamas maksimalaus telkimo sluoksnis su 2 x 2 matrica.

Pereinant į dekoderio etapą U-Net architektūra turi tarpinį sluoksnį, kuris savyje talpina du konvoliucinius sluoksnius, tokio paties formato kaip ir enkoderio etape. Šiame sluoksnyje turime 521 skirtingus filtrus.

Dekoderio struktūra sudaroma tuo pačiu principu kaip enkoderis, tačiau priešinga tvarka:

1. Kiekviename iš blokų panaudojamas atvirkštinis 2 x 2 konvoliucinis sluoksnis.
2. Du konvoliuciniai sluoksniai kaip ir enkoderio dalyje.

Vienintelis skirtumas tarp dviejų modelių – galutinis sluoksnis. Šis sluoksnis keičia gautą vaizdo dydį taip, jog atitiktų mūsų norimus modelio nurodymus. Kai vykdoma kelių klasių segmentacija naudojama softmax funkcija ir 3 skirtingi filtrai, kai segmentuojamos tik nanodalelės – naudojama sigmoidinė funkcija ir vienas filtras.

Tyrimuose keičiamas rinkinio dydis ir epochų skaičius, o validacijos žingsniai lieka tokie patys:

1. Rinkinio dydis – [10, 20];
2. Validacijos žingsniai – 125;
3. Epochos – [15, 20, 25].

3.3. Segmentavimas pritaikius U-Net architektūrą

Kiekvienam rinkinio dydžiui išbandyti trys skirtingi modelio apmokymai, keičiant epochų ir žingsnių per epochą skaičių. Modelio apmokymo tikslumas kiekvieną kartą gali skirtis, kadangi apmokama ant asmeninio kompiuterio ir dėl pašalinių naudojimų, kai kuriais atvejais modelis užtrukdavo apsimokyti žymiai ilgiau. Tačiau neatsižvelgus į asmeninio kompiuterio galimybes, modelio pateikiami rezultatai pasiekiami per 20 minučių.


1 lentelė. Segmentavimo modelių rezultatai

Žingsniai per epochą	Epochos	Rinkinio dydis	Tikslumas	Laikas
125	15	10	0.86	591s
125	15	20	0.889	575s
125	20	10	0.903	678s
125	20	20	0.915	865s
125	25	10	0.901	1105s
125	25	20	0.921	1297s

Atsižvelgus į gautus rezultatus, panašus tikslumas gaunamas naudojant abu rinkinio dydžius. Tačiau tolimesniam naudojimui naudosime 20-ties rinkinio dydį ir 25 epochas. Taip pat su šiais parametrais, gaunamas 95% tikslumas patikrinimo duomenų rinkinyje, todėl galime laikyti, jog šis modelis tinkamas tolimesniems tyrimams.

Pateikiamas grafikas, kaip kito nuostolių funkciją pasirinkus: 125 žingsnių per epochą, 25 epochas ir 20 rinkinio dydį.

2 lentelė. Funkcijų vertės, kai naudojamos 25 epochos




Nuostolių funkcijos vertės grafike pastebime, kad testavimo ir apmokymo rinkinyje ši vertė tolygiai sumažėja. Testavimo rinkinyje galima pastebėti šiokių tokių svyravimų, tačiau pasiekama mažiausia nuostolių funkcijų vertė 0.0635.

Modelio tikslumo grafike, matoma, kad tikslumas šiek tiek svyruoja testavimo rinkinyje, tačiau jis visada tarp 96-98 procentų. Apmokymo rinkinyje pastebimas minimalus pokytis, tačiau galiausiai pasiekiamas 92 procentų tikslumas.

Šie galutinio naudojamo modelio rezultatai parodo, jog modelis sugeba gerai segmentuoti nanodaleles esančias vaizduose.

18 paveiksle pavaizduotos originalios nuotraukos, kuriose matome nanodaleles. Šie vaizdai pateikiami testavimui, pažiūrėti kaip segmentavimo modeliai aptinka daleles. Vaizduose galima matyti, jog nanodaleles, kai kuriose vietose susiliečia riba, taip pat matoma, kad vyrauja didelis triukšmas fone.



18 pav. Nuotraukos pateikiamos į modelį


3.3.1. Globalios slenkstinės vertės pritaikymas

Norint įrodyti, kodėl reikalingas konvoliucinių tinklų pritaikymas šiose nuotraukose, 19 paveiksle pateikiami pavyzdžiai, kaip panaudojus paprastą metodą, globalią slenkstinę vertę, nanodalelių atpažinimas nėra tikslus.


Pirmoje eilutėje 19 paveiksle matoma, kai globali slenkstinė vertė lygi 125, šis metodas atpažįsta daug triukšmo, kuris yra vaizduose. Tai iškraipo nanodalelių atpažinimą ir jų kraštai pasidaro netolygūs, taip pat jos susilieja tarpusavyje dėl didelio triukšmo vaizduose. Galima pastebėti b paveiksle, kai pritaikoma mažesnė globali slenkstinė vertė.

Antroje eilutėje pritaikoma didesnė globali slenkstinė vertė, kuri lygi 141. Šiose nuotraukose taip pat pastebimi netolygūs nanodalelių kraštai, tačiau atpažįstama šiek tiek mažiau triukšmo. Pritaikius didesnę globalią slenkstinę vertę, pastebima kita problema, jog vaizduose išlieka ne visos nanodalelės, kurias matėme originaliuose vaizduose. Tai ypač pastebima c paveikslėlyje, kai pritaikius šį metodą, vaizde dingsta daugelis nanodalelių arba jų dydis gerokai sumažėja lyginant su paduotu vaizdu.

Taip parodoma problema, kurios stengiamasi išvengti tolimesniuose etapuose pritaikius konvoliucinius neuroninius tinklus.



Viršuje pateikiamos nuotraukos, kai globali slenkstinė vertė = 125



19 pav. Globali slenkstinė vertė pritaikyta originaliems vaizdams


3.4. Vaizdų segmentavimas U-Net architektūra

Apmokytą konvoliucinio neuroninio tinklo, segmentavimo tikslumas siekia daugiau nei 94%, nepriklausomai nuo nanodalelių dydžio bei jų pozicijos vaizduose. Galima matyti 20 paveiksle, jog dalelės esančios vaizduose segmentuojamos tiksliai ir triukšmas, kurį matėme originaliose į modelį pateikiamose nuotraukose nebelieka.

Lyginant su globalia slenkstine verte, galima pastebėti, jog neprarandama jokia naudinga informacija, kurią stengiamasi išgauti iš norimų vaizdų. Taip pat palyginus su prieš tai naudotu metodu, dabartiniuose vaizduose nanodalelių kraštai tolygūs ir neiškraipyti.

Visgi galima pastebėti, kad dalelėms esant šalia viena kitos, jos šiek tiek susilieja arba atpažįstamos kaip viena nanodalelė. Dalelės geriausiai atpažįstamos kai yra kiek toliau viena nuo kitos arba neturi susikertančių sienų su kitomis vaizde esančiomis nanodalelėmis.


Norint pagerinti konvoliucinio neuroninio tinklo su U-Net architektūra segmentavimą pritaikomas vandens baseinų metodas, kuris padeda atskirai identifikuoti nanodalelių tikslią vietą ir jos ribas vaizduose.



20 pav. Konvoliucinio neuroninio tinklo su U-Net architektūra segmentavimas

3.5. Vandens baseino pritaikymas segmentuotiems vaizdams

Vandens baseinų metodas pritaikomas segmentuotiems vaizdams, kurie gauti iš konvoliucinio neuroninio tinklo apmokymo. Šiame procese pritaikomos skirtingos funkcijos ir procedūros, kurios palengvina dar tikslesnį nanodalelių atskyrimą.




21 pav. Vandens baseinų pritaikymas segmentuotiems vaizdams

Vandens baseino metodui pritaikius vaizdams, galima matyti, kaip nanodalelės atskiriamos viena nuo kitos lyginant su pradiniu konvoliucinio neuroninio tinklo segmentavimu. Nanodalelės kurios viena su kita liečiasi kraštais atpažįstamos kaip atskiros. Tačiau pastebima, kad kai kurios nanodalelės dingsta, kurios buvo segmentuotos prieš tai. Šios vietos pažymėtos juodais kvadratais 21 paveiksle. Nors besiliečiančios dalelės atskiriamos tinkamai, tačiau prarandama šiek tiek informacijos kai turima labai mažas daleles.

3.6. Segmentavimas pritaikius U-Net (segmentuojamos 3 klasės)

Apmokyto konvoliucinio neuronio tinklo, kuris naudojamas segmentuoti tris klases, tikslumas pasiekiamas daugiau nei 93%. Šiame modelyje trys klasės laikomos šiomis:

1. Pirmoji klasė – fonas;
2. Antroji klasė – nanodalelės kraštas;
3. Trečioji klasė – nanodalelė.



22 pav. Konvoliucinių neuroninių tinklų su U-Net architektūra 3 klasių segmentavimas

Naudojant šį metodą galima pastebėti, jog nėra prarandama nanodalelės, kaip naudojant vandens baseinų metodą. Šis metodas gerai klasifikuoja kiekvieną turimą klasę. Matoma, kad lyginant su dviejų klasių segmentavimu, šis metodas geriau atpažįsta, kuriose vietose nanodalelės nesusiliečia, taip atskirdamas daleles vieną nuo kitos.

Įsitikinti, kad kiekviena klasė gerai apskaičiuojama mean IoU rodiklis kiekvienai iš jų:

- pirmajai klasei: 0.9585389
- antrajai klasei: 0.74513828
- trečiajai klasei: 0.92976866

Antrosios klasės rodiklis lyginant su kitomis klasėmis yra mažesnis, kadangi ši klasė priskiriama nanodalelės kraštui ir jo pikselių pasiskirstymas vaizde mažesnis nei kitų dviejų klasių. Modeliui sunkiau jį atpažinti, tačiau nepaisant to, ribos atpažįstamos gana tiksliai.

Išvados

1. Baigiamajame darbe atlikta literatūros apžvalga, kurioje apžvelgta skenuojančio elektroninio mikroskopo svarba užfiksuojant įvairiausių paviršius, kadangi tai vienas iš prietaisų galinčių užfiksuoti net mažiausias daleles. Aprašyti neuroninių tinklų metodai, kurie dažniausiai naudojami SEM užfiksuotiems vaizdams analizuoti. Didelį pajėgumą ir gerus rezultatus parodė dirbtiniai neuroniniai tinklai, nes jie pritaikyti vaizdų segmentavimui. Skirtingų architektūrų neuroniniai tinklai suteikia plačias galimybes ir lengvą pritaikymą įvairių uždavinių sprendimui.
2. Baigiamajame darbe panaudotos nuotraukos, kurios užfiksuotos Kauno technologijos universiteto tyrime „Nanostruktūrų susidarymas ant atkaitintų TiO₂ plonų plėvelių paviršių“. Šiose nuotraukose užfiksuotos nanodalelės reikalingos tyrimo rezultatams pasiekti.
3. Vaizdams, kuriuose užfiksuotos nanodalelės ant paviršių, sukurtos kaukės kiekvienai dalelei, jog konvoliucinis neuroninis tinklas galėtų būti apmokamas. Naudojamas jau egzistuojanti konvoliucinis neuroninis tinklas, kurio architektūros parametrai pritaikomi turimiems vaizdams ir atliekama analizė.
4. Sukurtas modelis, kuris paremtas konvoliuciniais neuroniniais tinklais. Jame naudojama U-Net architektūra, kurios pagalba segmentuojamos nanodalelės esančios vaizduose. U-Net architektūra modifikuojama pagal uždavinį: pirmu atveju segmentuojamos dvi klasės, antru atveju trys klasės.
5. Pritaikytas globalios slenkstinės vertės metodas nanodalelių užfiksuotiems vaizdams, nėra tinkamas turimiems vaizdams analizuoti, kadangi pasirinkus mažesnę globalią slenkstinę vertę informacija iškraipoma dėl netolygių nanodalelių kraštų ir per didelio triukšmo. Pasirinkus didesnę globalią slenkstinę vertę, rezultatai iškraipomi, kadangi ne visos dalelės atvaizduojamos.
6. Konvoliucinio neuroninio tinklo paremta U-Net architektūra, pritaikymas SEM eksperimentinių vaizdų analizei, leido pasiekti dviejų klasių vidutinį 94% įvesties vaizdų segmentavimo tikslumą, o trijų klasių – 92% tikslumu.
7. Segmentuojant konvoliuciniu neuroniniu tinklu, kai norima aptikti tik nanodaleles, pastebėta, kad kai kuriuose vaizduose nanodalelės liečiasi viena su kita kraštu ir atpažįstama kaip viena. Norint išvengti to, pritaikomas vandens baseinas leido modeliui nustatyti, kurios nanodalelės atskiros, o kurios turėtų būti kartu.
8. Palyginus gautus rezultatus, kai pritaikomas vandens baseinas ir segmentuojamos trys klasės vaizduose, pastebėta, kad vandens baseino metodas ne visada užfiksuoja mažas nanodaleles, todėl jos pranyksta galutiniame rezultate. Tuo tarpu trijų klasių segmentavimas atpažįsta mažesnes daleles ir gerai segmentuoja dalelių kraštus, kai šios originaliose nuotraukose nesilietė.
9. Visi atlikti tyrimai parodė, jog konvoliuciniai neuroniniai tinklai pritaikomi lengvai ir efektyviai, norint gauti tikslus rezultatus analizuojant skaitmeniniu elektroniniu mikroskopu užfiksuotiems vaizdams. Šie tinklai pritaikomi ir kitų vaizdų rinkinių analizei bei interpretacijoms.

Literatūros sąrašas

- [1] S. Mondal, „Evolution Of Microscopes, A Brief History“, *Swarajyamag*. <https://swarajyamag.com/science/evolution-of-microscopes-a-brief-history> (žiūrėta 2022 m. balandžio 26 d.).
- [2] S. Bradbury, *The Evolution of the Microscope*. Elsevier, 2014.
- [3] R. F. Egerton, *Physical principles of electron microscopy: an introduction to TEM, SEM, and AEM*. New York, NY: Springer, 2005.
- [4] C. W. Oatley, „The early history of the scanning electron microscope“, *J. Appl. Phys.*, t. 53, nr. 2, p. R1–R13, vas. 1982.
- [5] J. Hogg, *The Microscope: Its History, Construction, and Applications ... Illustrated London Libr.*, 1854.
- [6] B. M. Collett, „Scanning Electron Microscopy: A Review and Report of Research in Wood Science“, *Wood Fiber Sci.*, p. 113–133, 1970.
- [7] V. K. ZWORYKIN, „The Scanning Electron Microscope“, *Sci. Am.*, t. 167, nr. 3, p. 111–113, 1942.
- [8] R. F. Egerton, „The Scanning Electron Microscope“, *Physical Principles of Electron Microscopy*, Boston, MA: Springer US, 2005, p. 125–153.
- [9] O. C. Wells ir D. C. Joy, „The early history and future of the SEM“, *Surf. Interface Anal.*, t. 38, nr. 12–13, p. 1738–1742, gruodž. 2006.
- [10] Q. Wu, F. Merchant, ir K. Castleman, *Microscope Image Processing*. Elsevier, 2010.
- [11] V. Alunni-Perret ir kt., „Scanning Electron Microscopy Analysis of Experimental Bone Hacking Trauma of the Mandible“, *Am. J. Forensic Med. Pathol.*, t. 31, nr. 4, p. 326–329, gruodž. 2010.
- [12] G. Zou, J. She, S. Peng, Q. Yin, H. Liu, ir Y. Che, „Two-dimensional SEM image-based analysis of coal porosity and its pore structure“, *Int. J. Coal Sci. Technol.*, t. 7, nr. 2, p. 350–361, birž. 2020.
- [13] B. Shivajirao Shinde, „The Origins of Digital Image Processing & Application areas in Digital Image Processing Medical Images“, *IOSR J. Eng.*, t. 1, nr. 1, p. 66–71, lapkr. 2011.
- [14] G. J. Awcock ir R. Thomas, *Applied Image Processing*. Macmillan International Higher Education, 1995.
- [15] E. A. B. da Silva ir G. V. Mendonça, „4 - Digital Image Processing“, *The Electrical Engineering Handbook*, W.-K. Chen, Sud. Burlington: Academic Press, 2005, p. 891–910.
- [16] B. Chitradevi, P. Srimathi, A. Professor, ir A. Professor, „An Overview on Image Processing Techniques“.
- [17] I.-I. J. of S. T. and Engineering, „Mathematical Analysis and Overview on Shape Matching Technique“, Žiūrėta: 2022 m. balandžio 28 d. [Interaktyvus]. Adresas: https://www.academia.edu/37647450/Mathematical_Analysis_and_Overview_on_Shape_Matching_Technique
- [18] G. Kumar ir P. K. Bhatia, „A Detailed Review of Feature Extraction in Image Processing Systems“, *2014 Fourth International Conference on Advanced Computing Communication Technologies*, vas. 2014, p. 5–12.
- [19] R. M. Haralick ir L. G. Shapiro, „Image segmentation techniques“, *Comput. Vis. Graph. Image Process.*, t. 29, nr. 1, p. 100–132, saus. 1985.
- [20] E. L. Hall, „Computer image processing and recognition“, *1980 Los ...*, saus. 1979, Žiūrėta: 2022 m. balandžio 28 d. [Interaktyvus]. Adresas: https://www.academia.edu/3273323/Computer_image_processing_and_recognition
- [21] „9780818623622: Digital Image Processing (IEEE COMPUTER SOCIETY PRESS TUTORIAL) - AbeBooks - Chellappa, Rama: 0818623624“.

<https://www.abebooks.com/9780818623622/Digital-Image-Processing-IEEE-COMPUTER-0818623624/plp> (žiūrėta 2022 m. balandžio 28 d.).

[22] „INTRODUCTION TO IMAGE PROCESSING - drkmm.com / introduction-to-image-processing-drkmm-com.pdf / PDF4PRO“, *PDF4PRO*, 2018 m. gruodžio 10 d. <https://pdf4pro.com/view/introduction-to-image-processing-drkmm-com-53c14d.html> (žiūrėta 2022 m. balandžio 28 d.).

[23] M. M. A, M. A. R. A, ir J. A. R. B. B, „Effects and Performance of Speckle Noise Reduction Filters on Active Radar and Sar Images“.

[24] K. S. Fu ir J. K. Mui, „A survey on image segmentation“, *Pattern Recognit.*, t. 13, nr. 1, p. 3–16, saus. 1981.

[25] A. M. Khan ir R. S, „Image Segmentation Methods: A Comparative Study“.

[26] „Theory of edge detection | Proceedings of the Royal Society of London. Series B. Biological Sciences“. <https://royalsocietypublishing.org/doi/10.1098/rspb.1980.0020> (žiūrėta 2022 m. balandžio 27 d.).

[27] Z. Wu ir R. Leahy, „An optimal graph theoretic approach to data clustering: theory and its application to image segmentation“, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 15, nr. 11, p. 1101–1113, lapkr. 1993.

[28] L. S. Davis, A. Rosenfeld, ir J. S. Weszka, „Region Extraction by Averaging and Thresholding“, *IEEE Trans. Syst. Man Cybern.*, t. SMC-5, nr. 3, p. 383–388, geg. 1975.

[29] R. Kohler, „A segmentation system based on thresholding“, *Comput. Graph. Image Process.*, t. 15, nr. 4, p. 319–338, bal. 1981.

[30] L. S. Davis, „A survey of edge detection techniques“, *Comput. Graph. Image Process.*, t. 4, nr. 3, p. 248–270, rugs. 1975.

[31] M. Kundu ir S. Pal, „Thresholding for edge detection using human psychovisual phenomena“, *Pattern Recognit Lett*, 1986.

[32] S. Sulaiman ir N. A. Mat Isa, „Adaptive Fuzzy-K-means Clustering Algorithm for Image Segmentation“, *Consum. Electron. IEEE Trans. On*, t. 56, p. 2661–2668, gruodž. 2010.

[33] M. E. Celebi, „A comparative study of efficient initialization methods for the k-means clustering algorithm“, *Expert Syst. Appl.*, p. 11, 2013.

[34] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, ir H. Arshad, „State-of-the-art in artificial neural network applications: A survey“, *Heliyon*, t. 4, nr. 11, p. e00938, lapkr. 2018.

[35] M. A. Arbib, Sud., *The Handbook of Brain Theory and Neural Networks*. Cambridge, MA, USA: A Bradford Book, 1995.

[36] F. Cao, T. Xie, ir Z. Xu, „The estimate for approximation error of neural networks: A constructive approach“, *Neurocomputing*, t. 71, nr. 4–6, p. 626–630, sausio 2008.

[37] R. Setiono ir W. K. Leow, „FERNN: An Algorithm for Fast Extraction of Rules from Neural Networks“, *Appl. Intell.*, t. 12, nr. 1, p. 15–25, saus. 2000.

[38] N. Kasabov *ir kt.*, „Evolving spatio-temporal data machines based on the NeuCube neuromorphic framework: Design methodology and selected applications“, *Neural Netw. Off. J. Int. Neural Netw. Soc.*, t. 78, p. 1–14, birž. 2016.

[39] C. D. Schuman *ir kt.*, „A Survey of Neuromorphic Computing and Neural Networks in Hardware“, *ArXiv170506963 Cs*, geg. 2017, Žiūrėta: 2022 m. balandžio 30 d. [Interaktyvus]. Adresas: <http://arxiv.org/abs/1705.06963>

[40] Y. Wu ir J. Feng, „Development and Application of Artificial Neural Network“, *Wirel. Pers. Commun.*, t. 102, nr. 2, p. 1645–1656, rugs. 2018.

- [41] „Development and Application of Artificial Neural Network | Wireless Personal Communications: An International Journal“. <https://dl.acm.org/doi/10.1007/s11277-017-5224-x> (žiūrėta 2022 m. balandžio 30 d.).
- [42] C. Parra, K. Iftekharuddin, ir R. Kozma, „Automated brain data segmentation and pattern recognition using ANN“, saus. 2003.
- [43] Q. Zhang, „Convolutional Neural Networks“, p. 6, 2018.
- [44] „Elsevier Enhanced Reader“. <https://reader.elsevier.com/reader/sd/pii/S0950705120303464?token=F212ED968D29219771E644051A190E44445C4FBF350CD4BCC2B8A0A33D285190BC2DF23DFF145EDC7113953AD94F199B&originRegion=eu-west-1&originCreation=20220427142457> (žiūrėta 2022 m. balandžio 30 d.).
- [45] R. Kaushik ir S. Kumar, „Image Segmentation Using Convolutional Neural Network“, t. 8, nr. 11, p. 9, 2019.
- [46] „Performance analysis of deep learning CNN models for disease detection in plants using image segmentation | Elsevier Enhanced Reader“. <https://reader.elsevier.com/reader/sd/pii/S2214317319301957?token=45EE6B5295A67F216131E48435EEFEA50C4A63121BACA1C239BAFECC8A3EF22920839453931DD0537223F579B339202C&originRegion=eu-west-1&originCreation=20220429100510> (žiūrėta 2022 m. balandžio 30 d.).
- [47] M. Zhang, X. Li, M. Xu, ir Q. Li, „Image Segmentation and Classification for Sickle Cell Disease using Deformable U-Net“, *ArXiv171008149 Cs Q-Bio*, spal. 2017, Žiūrėta: 2022 m. balandžio 30 d. [Interaktyvus]. Adresas: <http://arxiv.org/abs/1710.08149>
- [48] J. H. Murphy, „An Overview of Convolutional Neural Network Architectures for Deep Learning“, *undefined*, 2016, Žiūrėta: 2022 m. balandžio 30 d. [Interaktyvus]. Adresas: <https://www.semanticscholar.org/paper/An-Overview-of-Convolutional-Neural-Network-for-Murphy/64db333bb1b830f937b47d786921af4a6c2b3233>
- [49] „Image Segmentation in 2022: Architectures, Losses, Datasets, and Frameworks | Neptune Blog“, *neptune.ai*, 2020 m. kovo 9 d. <https://neptune.ai/blog/image-segmentation> (žiūrėta 2022 m. balandžio 30 d.).
- [50] „Quick intro to semantic segmentation: FCN, U-Net and DeepLab“. <https://kharshit.github.io/blog/2019/08/09/quick-intro-to-semantic-segmentation> (žiūrėta 2022 m. balandžio 30 d.).
- [51] S. Joseph, „IMAGE PROCESSING TECHNIQUES AND ITS APPLICATIONS: AN OVERVIEW“, t. 4, nr. 3, p. 7, 2018.
- [52] „What Is Global Thresholding In Image Processing?“, *icsid.org*, 2022 m. kovo 6 d. <https://www.icsid.org/uncategorized/what-is-global-thresholding-in-image-processing/> (žiūrėta 2022 m. gegužės 8 d.).
- [53] Stephanie, „Bimodal Distribution: What is it?“, *Statistics How To*, 2013 m. liepos 29 d. <https://www.statisticshowto.com/what-is-a-bimodal-distribution/> (žiūrėta 2022 m. gegužės 8 d.).
- [54] „Overview and Fundamentals of Medical Image Segmentation - ScienceDirect“. <https://www.sciencedirect.com/science/article/pii/B9780123739049500131> (žiūrėta 2022 m. gegužės 8 d.).
- [55] „(1) (PDF) OVERVIEW OF DIFFERENT THRESHOLDING METHODS IN IMAGE PROCESSING“. https://www.researchgate.net/publication/342038946_OVERVIEW_OF_DIFFERENT_THRESHOLDING_METHODS_IN_IMAGE_PROCESSING?enrichId=rgreq-a131a93f538795fb7aebf70f016468ad-XXX&enrichSource=Y292ZXJQYWdlOzM0MjAzODk0NjBUzo5MDA0MjU5MDE0MDgyNTdAMTU5MTY4OTY3MjQ3Mw%3D%3D&el=1_x_3&_esc=publicationCoverPdf (žiūrėta 2022 m. gegužės 8 d.).

- [56] „Machine learning for medical diagnosis: history, state of the art and perspective - ScienceDirect“. <https://www.sciencedirect.com/science/article/pii/S093336570100077X> (žiūrėta 2022 m. gegužės 8 d.).
- [57] K. O’Shea ir R. Nash, „An Introduction to Convolutional Neural Networks“, *ArXiv151108458 Cs*, gruodž. 2015, Žiūrėta: 2020 m. gegužės 19 d. [Interaktyvus]. Adresas: <http://arxiv.org/abs/1511.08458>
- [58] X. Jia, „Image recognition method based on deep learning“, *2017 29th Chinese Control And Decision Conference (CCDC)*, geg. 2017, p. 4730–4735.
- [59] „CS231n Convolutional Neural Networks for Visual Recognition“. <https://cs231n.github.io/convolutional-networks/> (žiūrėta 2020 m. gegužės 19 d.).
- [60] Z. Zhou, M. M. Rahman Siddiquee, N. Tajbakhsh, ir J. Liang, „UNet++: A Nested U-Net Architecture for Medical Image Segmentation“, *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, Cham, 2018, p. 3–11.
- [61] „U-Net Architecture For Image Segmentation“, *Paperspace Blog*, 2021 m. liepos 5 d. <https://blog.paperspace.com/unet-architecture-image-segmentation/> (žiūrėta 2022 m. gegužės 8 d.).
- [62] H. Sankesara, „U-Net“, *Medium*, 2019 m. sausio 23 d. <https://towardsdatascience.com/u-net-b229b32b4a71> (žiūrėta 2022 m. gegužės 8 d.).
- [63] „3 Common Loss Functions for Image Segmentation“, *DEV Community*. https://dev.to/_aadidev/3-common-loss-functions-for-image-segmentation-545o (žiūrėta 2022 m. gegužės 8 d.).
- [64] „tf.keras.metrics.MeanIoU TensorFlow Core v2.2.0“, *TensorFlow*. https://www.tensorflow.org/api_docs/python/tf/keras/metrics/MeanIoU (žiūrėta 2020 m. gegužės 19 d.).
- [65] „Evaluating image segmentation models.“, *Jeremy Jordan*, 2018 m. gegužės 30 d. <https://www.jeremyjordan.me/evaluating-image-segmentation-models/> (žiūrėta 2020 m. gegužės 19 d.).
- [66] E. Tiu, „Metrics to Evaluate your Semantic Segmentation Model“, *Medium*, 2020 m. spalio 3 d. <https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2> (žiūrėta 2022 m. gegužės 8 d.).
- [67] K. Team, „Keras documentation: Image segmentation metrics“. https://keras.io/api/metrics/segmentation_metrics/ (žiūrėta 2022 m. gegužės 8 d.).
- [68] „An overview of gradient descent optimization algorithms“, *Sebastian Ruder*, 2016 m. sausio 19 d. <https://ruder.io/optimizing-gradient-descent/> (žiūrėta 2022 m. gegužės 18 d.).
- [69] A. Tato ir R. Nkambou, „IMPROVING ADAM OPTIMIZER“, p. 4, 2018.
- [70] „Categorical crossentropy loss function | Peltarion Platform“, *Peltarion*. <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/categorical-crossentropy> (žiūrėta 2022 m. gegužės 20 d.).
- [71] A. H. Mostafa, H. Abdel-Galil, ir M. Belal, „Ensemble Model-based Weighted Categorical Cross-entropy Loss for Facial Expression Recognition“, *2021 Tenth International Conference on Intelligent Computing and Information Systems (ICICIS)*, gruodž. 2021, p. 165–171.
- [72] „U-Net convolutional neural network models for detecting and quantifying placer mining disturbances at watershed scales | Elsevier Enhanced Reader“. <https://reader.elsevier.com/reader/sd/pii/S0303243421002178?token=1A02ABBD80BEA7C6EAB A9F19681DB2141ADC3C07A892865D76CF19367A876A254F9A032A24228FDCFCCC1F2CE1238CA5&originRegion=eu-west-1&originCreation=20220508140531> (žiūrėta 2022 m. gegužės 8 d.).
- [73] A. Seal, A. Das, ir P. Sen, „Watershed: An Image Segmentation Approach“, t. 6, p. 3, 2015.

[74] „Train, Validation, and Test Set: How to Split Your Machine Learning Data“. <https://www.v7labs.com/blog/train-validation-test-set>, <https://www.v7labs.com/blog/train-validation-test-set> (žiūrēta 2022 m. gegužės 4 d.).

[75] „TensorFlow“. <https://www.tensorflow.org/> (žiūrēta 2020 m. balandžio 21 d.).