



Kauno technologijos universitetas

Informatikos fakultetas

Odos darinių klasifikavimas iš daugiaspektrinių vaizdų naudojant kompiuterinius regos metodus

Baigiamasis magistro projektas

Nojus Dimša

Projekto autorius

Prof. dr. Agnė Paulauskaitė-Tarasevičienė

Vadovė

Kaunas, 2024



Kauno technologijos universitetas

Informatikos fakultetas

Odos darinių klasifikavimas iš daugiaspektrinių vaizdų naudojant kompiuterinius regos metodus

Baigiamasis magistro projektas

Dirbtinio intelekto informatika (6211BX007)

Nojus Dimša

Projekto autorius

**Prof. dr. Agnė Paulauskaitė
Tarasevičienė**

Vadovė

Doc. dr. Andrius Kriščiūnas

Recenzentas

Kaunas, 2024



Kauno technologijos universitetas

Informatikos fakultetas

Nojus Dimša

Odos darinių klasifikavimas iš daugiaspektrinių vaizdų naudojant kompiuterinius regos 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 nustatytą 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.

Nojus Dimša

Patvirtinta elektroniniu būdu



Kauno technologijos universitetas

Informatikos fakultetas

Baigiamojo magistro projekto užduotis

Projekto tema Odos darinių klasifikavimas iš daugiaspektrinių vaizdų naudojant kompiuterinius regos metodus

Reikalavimai ir sąlygos

Funkciniai reikalavimai:

Sistema turėtų gebėti apdoroti duomenis ir paruošti juos dirbtinio intelekto (kompiuterinės regos) algoritmams sukurdamą CSV failą su išgautais bruožais;

Sistema turi atlikti vaizdų klasifikavimo funkciją juos skirstant į penkias klases:

Nefunkciniai reikalavimai:

Programos *accuracy* įvertis turėtų būti iš anksto numatyta slenkstinė vertė, ne mažesnė nei 80%;

Sistema turėtų tenkinti iš anksto apibrėžtas greیتaveikos slenkstines vertes: vieno spektro vaizdo apdorojimo trukmė neturėtų viršyti vienos minutės.

Vadovė

(vadovo pareigos, vardas, pavardė, parašas)

(data)

Dimša Nojus. Odos darinių klasifikavimas iš daugiaspektrinių vaizdų naudojant kompiuterinius regos metodus. Magistro baigiamasis projektas / vadovė prof. dr. Agnė Paulauskaitė Tarasevičienė; Kauno technologijos universitetas, informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatikos mokslai, Informatika (B01).

Reikšminiai žodžiai: neuroniniai tinklai, konvoliuciniai neuroniniai tinklai, mokymasis su mokytoju, skaitmeniniai vaizdai, vaizdų apdorojimas, daugiaspektriniai vaizdai, bruožų išgavimas.

Kaunas, 2024. 93 p.

Santrauka

Šiame tyrime sprendžiamas odos darinių klasifikavimo uždavinys. Darbe yra apžvelgiami egzistuojantys sprendimai odos vėžiui segmentuoti ir klasifikuoti, bei pasiūlytas patobulintas sprendimas - melanomos aptikimui iš superpikselių grafikų erdvinės ir spektrinės analizės sistemos. Patobulinimas išryškkinamas sistemos pritaikymui analizuoti daugiaspektrinius vaizdus ir atlikti išgautų bruožų genėjimą. Kadangi skirtingi požymiai atlieka svarbų vaidmenį atsitiktinio miško modelio apmokymui, buvo įtrauktos slenkstinės vertės grįstos MDI ir SHAP reikšmėmis. Eksperimentiniams tyrimams buvo naudotas 472 vaizdų duomenų rinkinys gautas iš Lietuvos sveikatos mokslų universiteto, kurį sudaro odos darinių vaizdai išgauti su SIAscope aparatu. Duomenų rinkinį sudaro 5 klasės, ir kiekvieną pavyzdį sudaro 5 vaizdai: RGB melanino vaizdas, pilkų atspalvių melanino vaizdas, hemoglobino, kolageno ir derma melanino vaizdas. Odos darinių kategorizavimas iš skaitmeninių vaizdų yra kompleksinė užduotis, tačiau ji yra labai svarbi medicinos srityje, norint paspartinti odos darinių nustatymą ir suteikti galimybę atlikti jų vertinimą nuotoliniu būdu. Aukščiausias tikslumas binarinio klasifikavimo atveju siekė 96,87%, tuo tarpu penkių klasių atveju 84.37%. Projekto sprendimas detalizuojamas projektavimo skyriuje, o eksperimentų skyriuje pristatomi suvestiniai rezultatai ir išvados.

Dimša Nojus. Classification of skin lesions from multispectral images using computer vision techniques. Master's Final Degree Project / supervisor prof. Agnė Paulauskaitė-Tarasevičienė; Faculty of informatics, Kaunas University of Technology.

Study field and area (study field group): Computer science, Informatics (B01).

Keywords: neural networks, convolutional neural networks, supervised learning, digital images, image processing, hyperspectral images, feature extraction.

Kaunas, 2024. 93.

Summary

This study addresses the problem of classifying skin lesions. It reviews existing solutions for skin cancer segmentation and classification and proposes an improved solution for melanoma detection from a spatial and spectral analysis of superpixel graphs. The improvement is highlighted by the application of the system to analyze multispectral images and to perform pruning of the extracted features. Since different features play an important role in training a random forest model, thresholds based on MDI and SHAP values were included. For the experiments, a dataset of 472 images obtained from the Lithuanian University of Health Sciences was used, consisting of images of skin lesions extracted with SIAscope. The dataset consists of 5 classes and each sample consists of 5 images: an RGB melanin image, a greyscale melanin image, a hemoglobin image, a collagen image, and a derma melanin image. The classification of skin lesions from digital images is a complex task, but it is of great importance in the medical field in order to speed up the identification of skin lesions and to allow their remote assessment. The highest accuracy achieved was 96.87% for binary classification, compared to 84.37% for five classes. The project solution is detailed through the design section. The Experiments section presents the results and conclusions.

Turinys

Lentelių sąrašas.....	9
Paveikslų sąrašas	10
Santrumpų ir terminų sąrašas.....	12
1. Įvadas.....	14
2. Esamų sprendimų odos vėžiui klasifikuoti literatūros analizė	16
2.1. Daugiaspektris vaizdas.....	16
2.2. Skaitmeninis vaizdas.....	16
2.3. Skaitmeninių vaizdų apdorojimo principas	16
2.4. Esami sprendimai odos vėžio klasifikavime.....	17
2.4.1. Atraminių vektoriųjų klasifikatorius su SMOTE.....	17
2.4.2. Diskriminantinė analizė ir atraminių vektoriųjų klasifikatorius.....	17
2.4.3. Rezervu paremtas KDE	18
2.4.4. Hiperspektrinis dermatologinis segmentacijos karkasas	18
2.4.5. Perkeltas mokymasis su <i>GoogLeNet</i>	19
2.4.6. <i>YOLO</i> giliųjų neurono tinklų šeima paremti sprendimai.....	19
2.4.7. Odos pažeidimų segmentavimas ir kelių klasių klasifikavimas naudojant gilaus mokymosi požymius ir patobulintą drugelio ugnies optimizavimo algoritmą	20
2.4.8. <i>MSRNet</i> : Daugiaklasis odos ligų atpažinimas naudojant papildomus rezidentinius blokus, patobulintus giluminio mokymosi modelius, informacijos suliejimą ir geriausio požymio pasirinkimą.....	20
2.4.9. Superpikselių grafikų erdvinė ir spektrinė analizė melanomos aptikimui	21
2.5. Algoritmai naudoti odos vėžio klasifikavimo sprendimuose	21
2.5.1. Diskriminantinė analizė	21
2.5.2. Atraminių vektoriųjų mašinos	22
2.5.3. Pasirinkimų medis ir atsitiktiniai miškai	23
2.5.4. K artimiausių kaimynų.....	23
2.5.5. Dirbtiniai neuronų tinklai	24
2.5.6. Giliojo mokymosi neuronų tinklų architektūros	26
3. Sistemos odos vėžiui klasifikuoti projektavimas	30
3.1. Funkciniai reikalavimai.....	30
3.2. Nefunkciniai reikalavimai.....	30
3.3. Vertinimo metrikos	30
3.4. Metodai ir įrankiai	32
3.4.1. Programavimo kalbos	32
3.4.2. Integruota kūrimo aplinka	32
3.4.3. Sistemos realizacija.....	33
3.4.4. Duomenys.....	38
3.4.5. Duomenų paruošimas	40

4. Eksperimentai atlikti odos vėžio aptikimo sistemai sukurti	53
4.1. Eksperimentai atlikti su <i>YOLOv7</i>	53
4.2. Eksperimentai atlikti su <i>YOLOv8</i>	65
4.3. Eksperimentai atlikti su superpikselių grafų sistema ir atsitiktiniais miškais	77
4.3.1. Eksperimentai su grafais be svorių dvejetainio modelio atveju	77
4.3.2. Eksperimentai su grafais be svorių daugiaklasio modelio atveju	81
4.3.3. Eksperimentų su grafais be svorių apibendrinimas.....	84
4.3.4. Eksperimentai su grafais kurie turi svorius	84
4.4. Eksperimentų apibendrinimas	86
Išvados	88
Literatūros sąrašas	89

Lentelių sąrašas

2.1 lentelė. <i>YOLOv1-YOLOv3</i> rezultatai.....	19
2.2 lentelė. Duomenų pasiskirstymas ISIC2018 duomenų rinkinyje.....	20
2.3 lentelė. Duomenų pasiskirstymas ISIC2019 duomenų rinkinyje.....	21
3.1 lentelė. Panaudos atvejais.....	34
3.2 lentelė. Grafų bruožai išgauti kiekvienai viršūnei.	42
3.3 lentelė. Grafų bruožai išgauti visam grafui.	43
3.4 lentelė. Dažnių srities bruožai.	44
3.5 lentelė. Geometrijos srities bruožai.....	45
3.6 lentelė. Standartiniai spalvų bruožai.....	46
3.7 lentelė. Standartiniai spalvų bruožai spalvų kanalams.	47
3.8 lentelė. Bruožai išgauti iš GLCM.	48
3.9 lentelė. Bruožai išgauti iš Har‘o bangų.	50
3.10 lentelė. Grafų svorių verčių sudarymo būdai.	52
4.1 lentelė. <i>YOLOv7</i> vidutinio tikslumo rezultatų palyginimas	53
4.2 lentelė. <i>YOLOv8</i> vidutinio tikslumo rezultatų palyginimas	65
4.3 lentelė. Dviejų klasių ir grafo, kuris neturi svorių rezultatai.....	78
4.4 lentelė. Penkių klasių ir grafo, kuris neturi svorių rezultatai.	81
4.5 lentelė. Rezultatų apibendrinimams grafams be svorių.....	84
4.6 lentelė. Geriausias rezultatas pasiektas dvejetainiame klasifikavime.....	85
4.7 lentelė. Antras geriausias rezultatas pasiektas dvejetainiame klasifikavime.	85
4.8 lentelė. Geriausias rezultatas pasiektas penkių klasių klasifikavime.....	86
4.9 lentelė. Antras geriausias rezultatas pasiektas penkių klasių klasifikavime	86
4.10 lentelė. Tikslumo metrikos klasifikacijai palyginimas <i>YOLO</i> modeliams	87
4.11 lentelė. Tikslumo metrikos klasifikacijai palyginimas grafų sistemai.	87

Paveikslų sąrašas

2.1 pav. Odos darinys RŽM (a) ir pilkos skalės (b) spalvų paletėse.....	16
2.2 pav. Skaitmeninio vaizdo apdorojimo eiga	17
2.3 pav. Dirbtinio neuronų tinklo pavyzdys	24
2.4 pav. Padidrinimo operacijos pavyzdys.....	25
2.5 pav. Konvoliucijos operacijos pavyzdys	25
2.6 pav. Maksimalaus grupavimo pavyzdys.....	26
2.7 pav. Išplėtimo operacijos pavyzdys	26
2.8 pav. <i>U-Net</i> architektūra.....	27
2.9 pav. Suglausta <i>YOLOv1</i> architektūra. Mėlyni langeliai vaizduoja konvoliucijos operaciją, o geltoni grupavimo.....	28
2.10 pav. Supaprastinta <i>YOLOv8</i> architektūra.	29
3.1 pav. Panaudos atvejų diagrama odos vėžio klasifikavimo sistemai iš grafų.....	34
3.2 pav. Sistemos paleidimo veiklos diagrama odos vėžio klasifikavimo sistemai iš grafų.	36
3.3 pav. Sistemos paleidimo sekų diagrama odos vėžio klasifikavimo sistemai iš grafų.	37
3.4 pav. Klasės #1 apgamo duomenų pavyzdys a – melanino apgamo vaizdas, b – pilkojo melanino apgamo vaizdas, c – odos melanino apgamo vaizdas, d – hemoglobino apgamo vaizdas, e – kolageno apgamo vaizdas.....	38
3.5 pav. Klasės #2 seborėjinės keratozės duomenų pavyzdys a – melanino seborėjinės keratozės vaizdas, b- pilkojo melanino seborėjinės keratozės vaizdas, c – odos melanino seborėjinės keratozės vaizdas, d – hemoglobino seborėjinės keratozės vaizdas, e – kolageno seborėjinės keratozės vaizdas	38
3.6 pav. Klasės #5 melanomos duomenų pavyzdys a –melanino melanomos vaizdas, b- pilkojo melanino melanomos vaizdas, c – odos melanino melanomos vaizdas, d hemoglobino melanomos vaizdas, e – kolageno melanomos vaizdas.....	39
3.7 pav. Klasės #7 dermatofibromos duomenų pavyzdys a – melanino dermatofibromos vaizdas, b- pilkojo melanino dermatofibromos vaizdas, c – odos melanino dermatofibromos vaizdas, d – hemoglobino dermatofibromos vaizdas, e – kolageno dermatofibromos vaizdas.....	39
3.8 pav. Klasės #8 piktybinio šlako duomenų pavyzdys a – melanino piktybinio šlako vaizdas, b - pilkojo melanino piktybinio šlako vaizdas, c – odos melanino piktybinio šlako vaizdas, d – hemoglobino piktybinio šlako vaizdas, e – kolageno piktybinio šlako vaizdas	40
3.9 pav. Suvidurkintų duomenų pavyzdys kiekvienai klasei: a – apgamui, b - seborėjinei keratozei, c – melanomai, d – defibriomai, e – piktybiniui šlakui.....	40
3.10 pav. Dvejetainės kaukės šalia odos darinių klasių.....	41
3.11 pav. Superpikselių grafų sistema bruožams išgauti.....	51
4.1 pav. <i>YOLOv7</i> metrikų statistika melanino vaizdams.....	54
4.2 pav. <i>YOLOv7</i> melanino susimaišymo matrica	55
4.3 pav. <i>YOLOv7</i> metrikų statistika pilko melanino vaizdams	56
4.4 pav. <i>YOLOv7</i> pilko melanino susimaišymo matrica.....	57

4.5 pav. <i>YOLOv7</i> metrikų statistika hemoglobino vaizdams.....	58
4.6 pav. <i>YOLOv7</i> hemoglobino susimaišymo matrica.....	59
4.7 pav. <i>YOLOv7</i> metrikų statistika kolageno vaizdams	60
4.8 pav. <i>YOLOv7</i> kolageno susimaišymo matrica.....	61
4.9 pav. <i>YOLOv7</i> metrikų statistika odos melanino vaizdams	62
4.10 pav. <i>YOLOv7</i> odos melanino susimaišymo matrica	63
4.11 pav. <i>YOLOv7</i> metrikų statistika suvidurkintiems vaizdams.....	64
4.12 pav. <i>YOLOv7</i> suvidurkintų vaizdų susimaišymo matrica.....	65
4.13 pav. <i>YOLOv8</i> statistika melanino vaizdams	66
4.14 pav. <i>YOLOv8</i> melanino susimaišymo matrica	67
4.15 pav. <i>YOLOv8</i> statistika pilko melanino vaizdams	68
4.16 pav. <i>YOLOv8</i> pilko melanino susimaišymo matrica.....	69
4.17 pav. <i>YOLOv8</i> statistika hemoglobino vaizdams	70
4.18 pav. <i>YOLOv8</i> hemoglobinas susimaišymo matrica	71
4.19 pav. <i>YOLOv8</i> statistika kolageno vaizdams	72
4.20 pav. <i>YOLOv8</i> kolageno susimaišymo matrica	73
4.21 pav. <i>YOLOv8</i> statistika odos melanino vaizdams	74
4.22 pav. <i>YOLOv8</i> odos melanino susimaišymo matrica	75
4.23 pav. <i>YOLOv8</i> statistika suvidurkintiems vaizdams.....	76
4.24 pav. <i>YOLOv8</i> susimaišymo matrica suvidurkintiems vaizdams	77
4.25 pav. Grafai pavaizduoti ant odos darinių.....	78
4.26 pav. Dvejetainio klasifikavimo naudojant įvairias SHAP vertes supainiojimo matricos: (a) SHAP vertės ≥ 0.6690 ; (b) SHAP vertės ≥ 1.0028 ; (c) SHAP vertės ≥ 1.5259 ; (d) SHAP vertės ≥ 3.128	79
4.27 pav. Dvejetainio klasifikavimo naudojant įvairias MDI vertes supainiojimo matricos: (a) MDI vertės ≥ 0.003 ; (b) MDI vertės ≥ 0.004 ; (c) MDI vertės ≥ 0.005 ; (d) MDI vertės ≥ 0.01	80
4.28 pav. F1 svorinės vertės dvinariai klasifikacijai naudojant MDI vertes kairėje, o SHAP vertes dešinėje.....	80
4.29 pav. Penkių klasių klasifikavimo naudojant įvairias SHAP vertes supainiojimo matricos ..	82
4.30 pav. Penkių klasių klasifikavimo naudojant įvairias MDI vertes supainiojimo matricos.	83
4.31 pav. F1 svorinės vertės penkių klasių klasifikacijai naudojant MDI vertes kairėje, o SHAP vertes dešinėje.....	84

Santrumpų ir terminų sąrašas

Santrumpos:

RBF (angl. *Radial Basis Function*) – radialinė bazinė funkcija.

SVM (angl. *Support Vector Machine*) – atraminių vektorinių klasifikatorius.

SMOTE (angl. *Synthetic Minority Oversampling TEchnique*) – dirbtinė pavyzdžių sukūrimo technika.

LCTF (angl. *Liquid Crystal Tunable Filters*) - suderinami skystųjų kristalų filtrai.

DA – Diskriminantinė analizė.

SNV (angl. *Standard Normal Variate*) - Standartinė normalioji variacija.

SVD (angl. *Sequential Singular Value Decomposition*) - Nuosekios vienetinės vertės dekompozicija.

KDE (angl. *Kernel Density Estimation*) – branduolio tankio įvertinimas.

SAM (angl. *Spectral Angle Mapper*) – spektrinio kampo žymėjimas.

GA (angl. *Genetic Algorithm*) – genetinis algoritmas.

ILSVRC (angl. *ImageNet Large Scale Visual Recognition Challenge*) - *ImageNet* didžiojo mato vaizdinio atpažinimo iššūkis.

YOLO (angl. *You Only Look Once*) – pažiūri tik vieną kartą.

mAP (angl. *Mean Average Precision*) – suvidurkintas aptikimo tikslumas.

CNN (angl. *Convolutional Neural Networks*) – konvoliuciniai neuronų tinklai.

KELM (angl. *Kernel Extreme Learning Machine*) – branduolio ekstremalaus mokymosi mašina.

GFT – grafo Furjė transformacija.

ISIC (angl. *The International Skin Imaging Collaboration*) – Tarptautinė odos vaizdų kūrimo grupė.

LDA (angl. *Linear Discriminant Analysis*) – tiesinė diskriminantinė analizė.

QDA (angl. *Quadratic Discriminant Analysis*) – kvadratinė diskriminantinė analizė.

KNN (angl. *K Nearest Neighbors*) – k artimiausių kaimynų.

Terminai:

Radiometrinė kalibracija - kalibravimo metodų rinkinys, skirtas elektromagnetinės spinduliuotės ir atominių dalelių spinduliuotei pamatuoti.

Genetinis algoritmas - paieškos algoritmas, naudojamas rasti optimizavimo ir paieškos problemų sprendimus. Jis veikia imituodamas natūralios evoliucijos procesą, naudojant tokius metodus kaip mutacija ir kryžminimas naujiems sprendimams generuoti.

Superpikselis – grupė pikselių, kurie yra panašūs pagal tam tikrus kriterijus, tokius kaip spalva ar tekstūra ir yra sujungti į vieną bloką.

Grafas – struktūra aprašanti objektų rinkinį, kuriame šie objektai yra susieti ryšiais.

1. Įvadas

Didžiausias kūno (kartu ir jutimo) organas - oda užimanti maždaug 1,5 – 2,0 m² plotą ir atlieka svarbų vaidmenį įvairiose organizmo funkcijose ir tarnauja kaip apsauginis barjeras nuo patogenų, padeda detoksikacijai ir reguliuoja mūsų šilumos balansą. Odą sudaro trys sluoksniai: epidermis (išorinė oda), derma (tikroji oda) ir hipoderma (poodis). Didžiausią riziką susirgti odos vėžiu kelia dažnas buvimas saulėje, nes saulės spindulių poveikis odai išlieka ir ilgainiui gali sukelti piktybinius pakitimus. Galima išskirti keturis pagrindinius odos vėžio tipus: bazalinių ląstelių karcinoma, plokščialąstelinė karcinoma, merkelio ląstelių karcinoma ir melanoma. Bazalinių ląstelių karcinoma sudaro apie 80% odos vėžių atvejų. Paprastai pasireiškia ant galvos ir kaklo, bet gali atsirasti bet kur ant odos dėl saulės spindulių poveikio. Lėtai auga ir retai metastazuoja. Plokščialąstelinė karcinoma sudaro apie 20% odos vėžių atvejų. Gali pasireikšti įvairiose odos vietose. Dažniausiai kyla dėl saulės poveikio. Nuo 2% iki 5% atvejų gali metastazuotis. Merkelio ląstelių karcinoma yra retas ir agresyvus vėžys, prasidedantis hormonų gamybos ląstelėse po oda ir plaukų folikuluose. Dažniausiai pasitaiko galvos ir kaklo srityje [1].

Melanoma - tai agresyvusis odos vėžio tipas, prasidedantis melanocituose - ląstelėse, gaminančiose pigmentą melaniną, kurios suteikia odai, plaukams ir akims spalvą. Melanoma yra sunkiausia odos vėžio rūšis, kuri gali išplisti į kitas kūno dalis, jei nėra anksti pastebėta ir gydoma. Viena iš priežasčių, kodėl melanomą sunku aptikti, yra ta, kad ji gali būti labai įvairios išvaizdos. Kai kurios melanomos gali būti tamsios ir aiškiai apibrėžtos, o kitos - netaisyklingos formos ir spalvos, todėl jas sunkiau atpažinti. Kita priežastis, kodėl melanomą sunku nustatyti, yra ta, kad ją galima supainioti su kitomis odos ligomis, pavyzdžiui, kitos rūšies odos vėžiu, senatvinėmis dėmėmis ar strazdanomis [1]. Dėl to gali vėluoti diagnozė ir gydymas, o tai įtakoja sėkmingo gydymo rezultato tikimybę. Pagal *AIM at Melanoma foundation* fondą 2023 metais buvo aptikti 97610 melanomos atvejai ir dėl melanomos numirė 7650 žmonės [3].

Dirbtinio intelekto ir kompiuterinės regos metodai atlieka labai svarbų vaidmenį tiek nustatant, tiek prisidedant prie efektyvaus ankstyvojo melanomos gydymo, nes padidina pačios diagnozės tikslumą ir veiksmingumą. Melanomos nustatymas dažnai priklauso nuo dermatologų atliekamos vizualinės apžiūros, o odos pažeidimų interpretacija gali būti subjektyvi, nes pati melanoma gali būti įvairios išvaizdos, todėl ankstyvas jos nustatymas yra labai svarbus sėkmingam gydymui. Kompiuterine rege pagrįstas sprendimas yra tikslingas, nes gali padėti greičiau nustatyti odos vėžio tipą analizuodamas duomenis ir nustatydamas dėšningumus, vaizdinius požymius kurie gali būti ne iš karto akivaizdūs gydytojui (ekspertui). Kompiuterinės regos algoritmus galima išmokyti atpažinti odos vėžių požymius [4, 5, 6, 7], o tai gali padėti padidinti diagnozės tikslumą ir sumažinti klaidingų teigiamų ir neigiamų rezultatų skaičių. Kompiuterinės regos algoritmai taip pat gali padėti automatizuoti odos vėžių nustatymo procesą, o tai gali sumažinti dermatologų ir kitų sveikatos priežiūros specialistų darbo krūvį [8]. Tai gali padėti padidinti sveikatos priežiūros sistemos veiksmingumą ir efektyvumą.

Apibendrinant, melanoma yra odos vėžio rūšis, kurią gali būti sunku aptikti dėl jos įvairios išvaizdos ir galimybės supainioti su kitų rūšių odos ligomis. Fundamentinė tyrimo dalis

fokusuojasi į skirtingus algoritmus, giliojo mokymosi architektūras, daugiaspektrinių vaizdų analizavimo ir jų apjungimo technikas, kartu nustatant vaizdinių duomenų parametrų koreliacijas, išskiriant kertinius parametrus odos vėžio nuotraukose, būtinus siekiant padidinti diagnozės tikslumą ir sveikatos priežiūros sistemos efektyvumą neinvaziniu būdu.

Pagrindinis šio darbo tikslas yra sukurti kompleksinį sprendimą odos darinių daugiaklasiam klasifikavimui iš daugiaspektrinių vaizdų pasitelkiant kompiuterinės regos metodus.

Pagrindiniai uždaviniai reikalingi darbo tikslui pasiekti:

1. Atlikti esamų odos darinių vaizdų klasifikavimo sprendimų literatūros analizę.
2. Apdoroti turimus odos darinių vaizdų duomenų rinkinius ir juos papildyti.
3. Sukurti odos darinių apdorojimo sistemą, įtraukiant aptikimo, segmentavimo ir klasifikavimo procesus.
4. Atlikti eksperimentinius scenarijus ir paskaičiuoti skirtingas tikslumo metrikas.
5. Atlikti palyginamąją rezultatų analizę ir pateikti išvadas.

Šį tiriamąjį darbą sudaro 4 skyriai su poskyriais. Pirmame yra aprašoma atlikta literatūros analizė, kuriame apžvelgiami skaitmeninių ir daugiaspektrinių vaizdų apdorojimo būdai, aprašomi egzistuojantys sprendimai ir juose integruoti metodai bei algoritmai. Antrame skyriuje yra aprašomi funkciniai ir nefunkciniai reikalavimai, atliekama įgyvendinimo priemonių analizė. Trečiame skyriuje yra pateikiamas siūlomos sistemos aprašas skirtos odos darinių klasifikavimui, taip pat darinių aptikimo bei segmentavimo architektūros. Papildomai šiame skyriuje aprašomas duomenų paruošimo procesas, pateikiami modelių apmokymo ir testavimo rezultatai. Paskutiniame skyriuje yra pateikiamos išvados.

2. Esamų sprendimų odos vėžiui klasifikuoti literatūros analizė


Literatūros analizė prasideda nuo daugiaspektrio ir skaitmeninio vaizdo apibrėžimo bei jų apdorojimo principų. Vėliau yra apžvelgiami šiuo metu egzistuojantys sprendimai tiksle įvardintai problemai spręsti. Po to, apžvelgiami skirtingi kompiuterinės regos metodai, didžiausią dėmesį sutelkiant į giliojo mokymosi architektūras.

2.1. Daugiaspektris vaizdas

Daugiaspektris vaizdas, tai skaitmeninis vaizdas, gautas naudojant kelių bangos ilgių elektromagnetinę spinduliuotę, pavyzdžiui, regimąją šviesą arba infraraudonąją spinduliuotę [9]. Įvairių bangų ilgių šviesa, naudojama daugiaspektriui vaizdui sukurti, gali suteikti informacijos apie skirtingas vaizduojamų audinių ar medžiagų savybes. Pavyzdžiui, į daugiasektorinį odos vaizdą gali būti įtrauktos skirtingų bangos ilgių šviesos bangos, kurias sugeria skirtingi odos sluoksniai arba kurias sugeria skirtingi odos pigmentai ar kitos medžiagos. Šią informaciją galima panaudoti nustatant odos anomalijas ar pokyčius, kurie gali rodyti tam tikrą būklę ar ligą [10].

2.2. Skaitmeninis vaizdas

Skaitmeninis vaizdas yra duomenų rinkinys, sudarytas iš pikselių. Kiekviename pikselyje saugoma informacija apie vaizdą, išreikšta skaitmenine verte. Pikselių reikšmių diapazonas priklauso nuo bitų gylio. Pavyzdžiui, 8 bitų skaitmeninio vaizdo diapazonas yra nuo 0 iki 255. Kuo didesnis bitų gylis, tuo daugiau vietos skaitmeninis vaizdas užima. PNG, JPG formatai informacijos saugojimui naudoja 8 bitus viename kanale ir turi tik teigiamas reikšmes 2.1 pav. pavaizduota odos tekstūra RGB ir pilkos skalės spalvų paletėse.

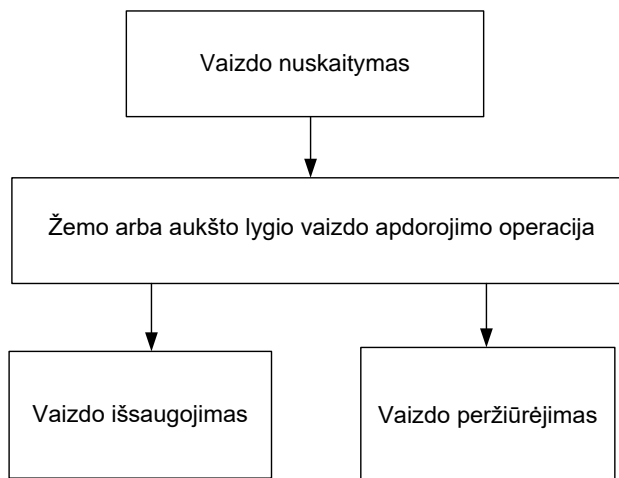


2.1 pav. Odos darinys RŽM (a) ir pilkos skalės (b) spalvų paletėse

2.3. Skaitmeninių vaizdų apdorojimo principas

Skaitmeninio vaizdo apdorojimas prasideda nuo jo nuskaitymo. Nuskaityto skaitmeninio vaizdo duomenys paprastai saugomi matricoje. Matricos dydis atitinka skaitmeninio vaizdo matmenų dydį, t. y. jei skaitmeninis vaizdas yra 128 x 128 x 3, jis bus saugomas tokio pat dydžio matricoje.

Tada skaitmeninis vaizdas apdorojamas naudojant žemo arba aukšto lygio vaizdo apdorojimo operacijas. Žemo lygio operacijos – tai operacijos, susijusios su atskirais pikseliais, pavyzdžiui, filtravimas, slenksčio pritaikymas (angl. *thresholding*). Aukšto lygio operacijos yra vaizdo bruožų supratimas, šablonų atpažinimas bei kitos. Pabaigoje apdorotas skaitmeninis vaizdas yra įrašomas į diską arba atvaizduojamas ekrane. Skaitmeninių vaizdų apdorojimas pateiktas 2.2 pav. [11, p 37].



2.2 pav. Skaitmeninio vaizdo apdorojimo eiga

2.4. Esami sprendimai odos vėžio klasifikavime

2.4.1. Atraminių vektorių klasifikatorius su SMOTE

2012 metais pasiūlytas sprendimas - atraminių vektorių klasifikatorius su RBF branduoliu bei SMOTE. Nuotraukų duomenų rinkiniui sudaryti buvo panaudotos dvi sistemos sudarytos iš dviejų skirtingų kamerų ir LCTF. Buvo padarytos 26 nuotraukos, 6 iš jų buvo vėžinės, o 20 ne. Šiam netolygiam pasiskirstymui išspręsti buvo panaudotas SMOTE technika, kuri padidina mažesnės klasės pavyzdžių pasirodymą mokymo imtyje (angl. *oversampling*). Šis algoritmas sukuria sintetinius mažesnės klasės pavyzdžius, o ne iš naujo panaudoja esančius. Tai daroma pasirenkant pavyzdį ir surandant jo k artimiausių kaimynų požymius erdvėje. Tada atsitiktinai parenkant vieną iš k artimiausių kaimynų ir sujungiant jį su pradiniu pavyzdžiu yra sukuriamos naujos sintetinės duomenų imtys. Šis procesas kartojamas tol, kol klasės yra subalansuojamos. Klasifikavimui buvo panaudotas atraminių vektorių klasifikatorius naudojantis RBF branduolį. Šio sprendimo gerumas buvo matuojamas ploto po kreive įverčiu (angl. *AUC*). Gautas įvertis buvo 0.925 [12].

2.4.2. Diskriminantinė analizė ir atraminių vektorių klasifikatorius

2016 metais pasiūlytas paprastas sprendimas panaudoti diskriminantinę analizę ir atraminių vektorių klasifikatorių. Naudodami *Hospital Clinic i Provincial de Barcelona* pateikta įranga buvo padarytos 165 nuotraukos iš kurių 125 nevėžinės, 25 vėžinės. Šis sprendimas nenaudojo pačių nuotraukų klasifikavimui, vietoj to, naudojo bruožus išgautus iš nuotraukų per įrangą. Duomenų

apdorojimas nebuvo daromas. Klasifikavimui buvo panaudotas atraminių vektorių klasifikatorius ir diskriminantinė analizė. Sprendimų gerumas buvo vertinamas pagal susimaišymo matricos klaidos įvertį. SVM gaunamas klaidos įvertis buvo režiuose nuo 0.1333 ir 0.1867, DA – 0.06 ir 0.28 [13].

2.4.3. Rezervu parentas KDE

2018 metais pasiūlytas sprendimas. Duomenis paimti iš *The Melanoma HSI dataset*. Jis turi *Matlab* matricos formatu išsaugotą odos vaizdą ir pilkuose atspalviuose išsaugotą odos vaizdą. Tokie duomenys yra pateikti 330 vaizdų iš jų 80 yra Melanomos, 160 yra displastinių apgamų ir 70 kitų odos vėžių [14]. Duomenų apdorojimui buvo naudoti keli algoritmai. Standartinė normalioji variacija buvo panaudota standartizuoti duomenims. Nuoseklios vienetinės vertės dekompozicija (angl. *Sequential Singular Value Decomposition*) ir pikselio poaibio atsitiktinis parinkimas (angl. *random sampling*) buvo panaudoti duomenų dimensijoms sumažinti. Klasifikavimui panaudota kombinacija branduolio tankio įvertinimo (angl. *Kernel Density Estimation*), maksimalaus paskesnio (angl. *Maximum posteriori*) klasifikatorius ir maksimalios tikimybės (angl. *Maximum likelihood*) klasifikatorius. Sprendimo gerumas buvo matuojamas jautrumo, specifiškumo, tikslumo metrikomis. Gauti rezultatai buvo 96.8%, 95.7% ir 96.0% [15].

2.4.4. Hiperspektrinis dermatologinis segmentacijos karkasas

2020 metais buvo sukurtas Hiperspektrinis dermatologinis segmentacijos karkasas (angl. *HS Dermatologic Segmentation Framework*). Nuotraukų duomenų rinkiniui sudaryti buvo panaudota Hiperspektrinė dermatologinė išgavimo sistema (angl. *HS Dermatologic Acquisition System*). Iš padarytų 116 nuotraukų 55 buvo neįtraukta į duomenų rinkinį dėl klaidų padarytų darant nuotrauką. Todėl finale duomenų rinkinį sudarė 66 nuotraukos iš kurių 44 teko apmokymo duomenų imčiai, 9 validavimo duomenų imčiai ir 10 testavimo duomenų imčiai. Mokymo imtyje buvo 18 nevėžinių nuotraukų ir 26 vėžines, validavimo 4 ir 5, o testavimo 5 ir 5. Duomenų rinkinys buvo sužymėtas su dermatologo ir SAM algoritmo pagalba. Duomenų apdorojimo stadijoje buvo atlikta radiometrinė kalibracija (angl. *Radiometric Calibration*), sumažintas šviesų diapazonas iki 116 ir atlikta duomenų normalizacija. Nuotraukos pikseliams klasifikuoti į priklausančius vėžiniam, nevėžiniam odos dariniui buvo panaudota k-vidurkių (angl. *K-Means*) segmentacija kur $k = 2$ ir SAM klasifikacija. Buvo naudojamas genetinis algoritmas optimaliems klasifikatorių hiperparametrams rasti. Klasifikavimo algoritmai pasirinkti darbe buvo atraminių vektorių mašinos, atsitiktiniai miškai ir dirbtinis neuronų tinklas. Sprendimo gerumas buvo matuojamas ploto po kreive įverčiu bei jautrumo ir specifiškumo matais. Geriausias rezultatas buvo pasiektas naudojant tiesinę atraminių vektorių mašiną kaip klasifikatorių. AUC 0.89, jautrumas 87.5 specifiškumas 100 [16].

2.4.5. Perkeltas mokymasis su *GoogLeNet*

2020 metais buvo panaudotas perkeltas mokymasis (angl. *Transferred learning*) su *GoogLeNet* giliojo mokymosi architektūra. Duomenų rinkinys naudotas šiame tyrime buvo sudarytas iš 619 nuotraukų iš kurių 283 buvo vėžiniai ir 336 ne vėžiniai. Nuotraukos buvo gauto iš keturių skirtingų universitetų. *GoogLeNet* naudojo išmoktą informaciją iš ILSVRC kuri turi 140,000 įvairių nuotraukų ir 1000 klasių, Turimas 619 duomenų rinkinys buvo padidintas apverčiant nuotraukas tiek vertikaliai, tiek horizontaliai.

Tyrime buvo naudotas metodas, kai iš hiperspektrinių duomenų atrenkami trys vieno bangos ilgio vaizdai (angl. *Single wavelength*) ir į gilaus mokymosi tinklus jie įvedami kaip trijų kanalų vaizdai. Hiperspektrinių duomenys buvo konvertuojami į kelis vieno bangos ilgio vaizdus ir paimama jų vidurkis. Tada iš šio vaizdo buvo atrinkti trys bangos ilgiai ir priskirti trims kanalams bangų ilgių tvarka nuo trumpiausio iki ilgiausio. Galiausiai vaizdas buvo pakeistas į 164 pikselių pločio ir 224 pikselių aukščio vaizdą, o kairėje ir dešinėje vaizdo pusėje buvo pridėta atsitiktinio triukšmo, kad būtų gauti kvadratiniai vaizdai tinkami *GoogLeNet* modeliui. Sprendimo gerumas buvo matuojamas jautrumo, specifiškumo, tikslumo metrikomis. Gauti rezultatai 72.3%, 81.2%, 77.2% [17].

2.4.6. *YOLO* giliųjų neurono tinklų šeima paremti sprendimai

2019 pasirodė straipsnis naudojantis *YOLOv1*, *YOLOv2* ir *YOLOv3* giliuosius neuronų tinklus odos darinių klasifikavimui į vėžinius ir nevėžinius. Iš ISIC archyvo buvo paimti 100 vėžinių ir 100 nevėžinių vaizdų. Straipsnyje pateikiamos *YOLOv1*, *YOLOv2* ir *YOLOv3* suvidurkintas aptikimo tikslumas (angl. *Mean Average Precision*).

2.1 lentelė. *YOLOv1*-*YOLOv3* rezultatai

Modelis	Nevėžinių darinių mAP	Vėžinių darinių mAP	Bendras mAP
<i>YOLOv1</i>	41%	33%	37%
<i>YOLOv2</i>	85%	82%	83%
<i>YOLOv3</i>	79%	75%	77%

Rezultatai esantys 2.1 lent. rodo, kad *YOLOv2* pasiekė didžiausią Melanomos aptikimo tikslumą testuotame duomenų rinkinyje [18].

2023 pasirodė straipsnis naudojantis *YOLOv3* ir *YOLOv4*. Iš ISIC archyvo buvo paimti 1460 vaizdai reprezentuojantys 9 skirtingas odos vėžio rūšis. Šiame straipsnyje *YOLOv3* ir *YOLOv4* mAP įverčiai buvo 88.03% ir 86.52% [19].

YOLO neuroninio tinklo modelis buvo pritaikytas, kad veiktų ant išmaniųjų telefonų. Jis buvo apmokytas su visais duomenimis iš ISIC archyvo (58457 vaizdų), kad gebėtų skirti melanomas,

apgamus ir seborėjines keratozes. Ši YOLO modifikacija parodė aukštą jautrumą ir specifiškumą melanomoms (88% ir 87%) ir apgamams (77% ir 91%), lyginant su kvalifikuotais dermatologais [19].

2.4.7. Odos pažeidimų segmentavimas ir kelių klasių klasifikavimas naudojant gilias mokymosi požymius ir patobulintą drugelio ugnies optimizavimo algoritmą

Siūlomas sprendimas apima visiškai automatizuotą odos pažeidimų segmentavimo ir kelių klasių klasifikavimo sistemą, naudojančią optimalius gilias mokymosi požymius. Sistema sudaryta iš etapų: kontrasto ištempimas, giliuoju salsvumu pagrįsti metodai, požymių išskyrimas naudojant iš anksto apmokytus CNN modelius (*ResNet101* ir *DenseNet201*), požymių optimizavimas naudojant patobulintą drugelio liepsnos optimizavimo algoritmą, optimizuotų požymių suliejimas naudojant koreliacijos analizę ir klasifikavimas naudojant branduolio ekstremalaus mokymosi mašiną. Šiuo metodu siekta padidinti pažeidimų segmentavimo ir klasifikavimo tikslumą, kartu sprendžiant nereikšmingi požymių skaičiavimus ir skaičiavimo laiko apribojimus. Tyrimo duomenų imtį sudarė 10015 vaizdų. Jie buvo suskirstyti į 7 klases (žr. 2.2 lent.): Aktininė keratozė (AKIEC), bazalinių ląstelių karcinoma (BCC), seborėjinė keratozė (BKL), dermatofibroma (DF), apgamas (NV), melanoma (MEL), kraujagysliniai dariniai (VA).

2.2 lentelė. Duomenų pasiskirstymas ISIC2018 duomenų rinkinyje

Klasės	AKIEC	BCC	BKL	DF	NV	MEL	VA
Vaizdų skaičius	327	541	1099	155	6705	1113	142

Blogiausio eksperimento rezultatai turėjo 81.31% tikslumo įvertį ir 81.24% jautrumo įvertį. Geriausi eksperimento rezultatai turėjo 90.67% ir 90.2% atitinkamus įverčius [21].

2.4.8. MSRNet: Daugiaklasis odos ligų atpažinimas naudojant papildomus rezidentinius blokus, patobulintus giluminio mokymosi modelius, informacijos suliejimą ir geriausio požymio pasirinkimą

MSRNet - neinvazinė, kompiuterizuota dermoskopijos technika, skirtą pagerinti odos ligų klasifikacijos tikslumą. *MSRNet* pasinaudoja kontrasto pagerinimo technika, paremta šviesumo (angl. *luminance*) kanalu ir *Retinex* modeliu. Taip yra pagerinama užkrėstų ir sveikų odos sričių kontrasto kokybė. Šio pagerinimo etapo tikslas - palengvinti tikslesnį požymių išskyrimą tolesniuose etapuose. *MSRNet* pasinaudoja dviem patobulintais ir iš anksto apmokytais giluminio mokymosi modeliais (*DarkNet-53* ir *DenseNet-201*). Patobulinimai pasireiškia papildomai įtraukiant rezidentinius blokus prie kiekvieno modelio pabaigos ir taip pagerinant modelių mokymosi gebėjimus.

Požymiai yra išgaunami iš abiejų apmokytų modelių bendrojo vidurkio grupavimo sluoksnio. Toliau naudojama suliejimo technika, derinanti požymius iš abiejų CNN modelių. Serijinis-

harmoninis vidurkio suliejimo metodas (angl. *serial-harmonic mean*) išnaudoja kiekvieno modelio stipriuosius bruožus ir pagerina bendrą klasifikacijos tikslumą. Galiausiai sulietas požymių vektorius yra optimizuotas naudojant patobulintą jūrinių plėšrūnų algoritimą (angl. *marine predator optimization*), kurį kontroliuoja Rényi entropija. Tyrimas pasinaudojo dvejais laisvai prieinamais duomenų rinkiniais: ISIC2018 ir ISIC2019. ISIC2018 sudaro 10015 vaizdų suskirstytų į 7 klases. Jis matomas 2.2 lentelė. Duomenų pasiskirstymas ISIC2018 duomenų rinkinyje ISIC2019 sudaro 33569 vaizdų suskirstytų į 8 klases. Naujoji klasė yra suragėjusių ląstelių karcinoma (SCC). Vaizdų pasiskirstymas tarp klasių matomas 2.3 lent.

2.3 lentelė. Duomenų pasiskirstymas ISIC2019 duomenų rinkinyje

Klasės	MEL	NV	BCC	AK	BKL	DF	VA	SCC
Vaizdų skaičius	4522	12875	3323	867	2624	239	253	628

Su pirmuoju duomenų rinkiniu blogiausias pasiektas tikslumo įvertis buvo 55.3%, o geriausias 86.2%. Su antruoju duomenų rinkiniu blogiausias pasiektas tikslumo įvertis buvo 56.2%, o geriausias 99.1% [22].

2.4.9. Superpikselių grafikų erdvinė ir spektrinė analizė melanomos aptikimui

2021 metais pasirodė metodas naudojantis superpikselių grafus melanomos aptikimui. Autoriai pasiūlė naudoti superpikslius išgautus iš odos pažeidimų vaizdų, o iš jų sudaryti grafus. Grafo briauna jungia du gretimus superpikslius, o jos svoris yra apibrėžtas kaip atstumas tarp šių superpikselių požymių deskriptorių funkcijos. Grafo signalas apibrėžtas kiekvienam grafo mazgui tam tikra vienareikšme funkcija, susijusia su superpikseline deskriptoriumi.

Išgaunami požymiai iš svertinių arba nesvertinių grafų modelių, vietiniu ir globaliu bruožu, o spektrinėje srityje - naudojant grafo Furjė transformaciją. Taip pat išgaunami požymiai, grindžiami spalva, geometrija ir tekstūra iš odos pažeidimų vaizdų.

Naudojant du dermoskopinių vaizdų duomenų rinkinius iš ISIC archyvo, buvo apmokyti ir išbandyti keli klasifikatoriai pagal skirtingus šių požymių derinius. Siūlomoms sistemoms AUC buvo 99.91%, tikslumas 97.40 %, specifiškumas 95.16 %, o jautrumas 100 % [23].

2.5. Algoritmai naudoti odos vėžio klasifikavimo sprendimuose

2.5.1. Diskriminantinė analizė

Diskriminantinė analizė - tai metodas, naudojamas duomenų rinkiniui klasifikuoti į skirtingas grupes arba klases. Jis veikia ieškant geriausiai klases atskiriančių požymių derinio ir naudojant šią informaciją sukuriamas modelis, pagal kurį galima nuspėti naujų stebėjimų klasę. Yra du

pagrindiniai DA tipai: tiesinė diskriminantinė analizė (LDA) ir kvadratinė diskriminantinė analizė (QDA).

LDA remiasi prielaida, kad klasės turi tą pačią kovariacijos matricą, ir randa tiesinį požymių derinį, kuris maksimizuoja tarpklasines dispersijas ir vidinės klasės dispersijos santykį. Taip nustatoma tiesinė sprendimo riba, skirianti klases. LDA yra paprastesnis metodas ir gerai veikia, kai klasės yra gerai atskirtos ir turi panašias kovariacijos struktūras.

QDA nedaroma prielaida, kad klasės turi tą pačią kovariacijos matricą, o vietoj to kiekvienai klasei įvertinama atskira kovariacijos matrica. Taip gaunama kvadratinė sprendimo riba, kuri atskiria klases. QDA yra lankstesnis metodas ir gerai veikia, kai klasės turi skirtingas kovariacijos struktūras.

Abu metodai naudoja informaciją apie klasių vidurkius ir kovariacijas, kad rastų sprendimo ribą, tačiau LDA naudoja tiesinę ribą, o QDA kvadratinę, todėl QDA gali būti lankstesnis ir atspindėti sudėtingesnius duomenų modelius [24].

2.5.2. Atraminų vektorių mašinos

Atraminų vektorių mašinos (SVM) - tai prižiūrimo mokymosi algoritmas, kuris gali būti naudojamas klasifikavimo arba regresijos užduotims atlikti. Pagrindinė SVM idėja - rasti geriausią ribą arba hiperplokštumą, kuri atskirtų skirtingas duomenų klases. Ši riba parenkama taip, kad ji maksimizuotų skirtumą, t. y. atstumą tarp ribos ir artimiausių kiekvienos klasės duomenų taškų. Šie artimiausi duomenų taškai vadinami atraminiais vektoriais, o riba parenkama taip, kad būtų vienodai nutolusi nuo kiekvienos klasės atraminų vektorių. Nustačius ribą, naujus duomenų taškus galima klasifikuoti nustatant, į kurią ribos pusę jie patenka. Netiesiškai atskiriamais duomenims SVM gali naudoti branduolio triuką (angl. *kernel trick*) duomenims transformuoti į didesnės dimensijos erdvę, kurioje klasėms atskirti galima naudoti tiesinę ribą. Dažniausiai naudojamos branduolio funkcijos yra radialinė bazinė funkcija (RBF) ir polinominis branduolys. SVM gali būti jautrus branduolio ir parametrų parinkimui, taip pat gali būti linkę per daug prisitaikyti.

Tiesinis SVM algoritmas ypač naudingas, kai duomenys yra tiesiškai atskiriami, t. y. juos galima atskirti tiesia linija arba plokštuma. Jis veikia surandant liniją arba plokštumą, kuri atskiria klases su didžiausia atsarga, t. y. atstumu tarp sprendimo ribos ir artimiausių kiekvienos klasės duomenų taškų. Dėl to jis yra atsparesnis triukšmui ir nukrypimams.

Tiesinį SVM algoritmą paprasta ir greitai apmokėti, todėl jis tinka dideliems duomenų rinkiniams ir didelės dimensijos duomenims, tačiau jis gali būti netinkamas, kai duomenys nėra tiesiškai atskiriami ir norint gauti geresnių rezultatų reikia naudoti netiesines branduolio funkcijas.

RBF branduolys yra funkcija, kuri matuoja dviejų duomenų taškų panašumą. Jis veikia transformuodamas duomenis į didesnės dimensijos erdvę, kurioje duomenų taškus skiria ne tiesinė,

o išlenkta riba. Taip siekiama, kad didelio matmens erdvėje lengviau rasti ribą, kuri atskirtų duomenis į skirtingas klases [25].

2.5.3. Pasirinkimų medis ir atsitiktiniai miškai

Sprendimų medis yra mašininio mokymosi algoritmas, naudojamas klasifikavimo ir regresijos uždavimams atlikti. Tai į schemą panaši struktūra, kurios vidinis mazgas yra požymis (arba atributas), šaka - sprendimo taisyklė, o kiekvienas lapų mazgas - rezultatas. Sprendimų medžio algoritmas pradedamas nuo šakninio mazgo, kuris atspindi visą duomenų rinkinį. Tada jis iteratyviai suskirsto duomenis į poaibius pagal įvesties požymių reikšmes. Pasirenkamas tas padalijimas, kurį atlikus gaunami homogeniškesni poaibiai. Šis procesas kartojamas ankstesniame etape sukurtiems poaibiams ir tęsiamas tol, kol medis pasiekia sustabdymo kriterijų (pvz., didžiausią medžio gylį arba mažiausią pavyzdžių skaičių lapiniame mazge). Kiekvienas vidinis medžio mazgas reiškia požymį arba atributą, o kiekviena atšaka - sprendimo taisyklę. Medis sudaromas iš viršaus į apačią, pasirenkant geriausią požymį, kuris suskirsto duomenis į homogeniškesnius poaibius. Medžio pabaigoje lapų mazgai vaizduoja prognozuojamą įvesties duomenų klasę arba reikšmę. Sprendimų medžius paprasta suprasti ir interpretuoti, tačiau jie gali tapti sudėtingi ir lemti perteklinį pritaikymą, kai medis yra gilus, su daugybe šakų ir lapų mazgų.

Atsitiktiniai miškai yra mašininio mokymosi algoritmas, naudojamas klasifikavimo ir regresijos uždavimams atlikti. Jis sujungia kelis sprendimų medžius, kad būtų sukurtas tikslesnis modelis. Pagrindinė atsitiktinių miškų idėja - apmokyti daug sprendimų medžių pagal skirtingas duomenų imtis ir tada sujungti jų prognozes. Kiekvienas miško medis apmokytas pagal skirtingą atsitiktinį duomenų poaibį, o galutinė prognozė sudaroma išvedant visų medžių prognozių vidurkį [26].

2.5.4. K artimiausių kaimynų

K artimiausių kaimynų algoritmas yra mašininio mokymosi algoritmas, kuris gali būti naudojamas klasifikavimo ir regresijos uždaviniams spręsti. KNN algoritmas pagrįstas idėja, kad panašūs atvejai arba duomenų taškai greičiausiai turės tą pačią klasės etiketę.

K-NN algoritmas veikia taip:


1. Algoritmo įvestis yra naujas duomenų taškas, dar vadinamas testo tašku.
2. Tada apskaičiuojamas atstumas (arba panašumas) tarp bandomojo taško ir visų mokymo duomenų rinkinio taškų.
3. Išrenkami k mokymo taškų, kurie yra artimiausi (arba labiausiai panašūs) į bandomąjį tašką.
4. Tada testuojamam taškui priskiriama klasės etiketė, atsižvelgiant į daugumą klasių tarp k artimiausių kaimynų.

KNN algoritme k yra hiperparametras, t. y. vertė, kuri nustatoma prieš paleidžiant algoritmą ir kuria kontroliuojamas artimiausių kaimynų, naudojamų prognozei atlikti, skaičius. Paprastai k reikšmė būna maža, pavyzdžiui, $k=3$ arba $k=5$, bet gali būti bet koks teigiamas sveikasis skaičius.

KNN algoritmą paprasta įgyvendinti, jam nereikia jokių išankstinių prielaidų apie duomenų pasiskirstymą ir jis yra atsparus triukšmui bei nukrypimams. Tačiau jis gali būti skaičiavimo požiūriu brangus, nes algoritmas turi apskaičiuoti atstumą tarp tiriamojo taško ir visų mokymo duomenų rinkinio taškų. Be to, jis gali būti neveiksmingas, kai duomenų aibė yra labai didelė. Dėl šios priežasties šis algoritmas nebuvo naudotas hiperspektrinių vežinių vaizdų klasifikavimui, tik paprastų [27, 28].

2.5.5. Dirbtiniai neuronų tinklai


Dirbtinis neuronų tinklas - tai mašininio mokymosi algoritmas, įkvėptas žmogaus smegenų struktūros ir funkcijų. Tai prižiūrimento tipo mokymo algoritmas, o tai reiškia, kad jam mokytis reikia pažymėtų mokymo duomenų rinkinio (angl. *labeled dataset*). Mokymo duomenis sudaro įvesties pavyzdžiai ir išvestys su tikruoju rezultatu (angl. *ground truth*), o neuroninis tinklas mokosi gauti teisingą išvestį pagal įvestį, mokymo proceso metu koreguodamas savo vidinių parametrų vertes. Paprasto dirbtinio neuronų tinklo pavyzdys matomas 2.3 pav. Dirbtinį neuronų tinklą sudaro tarpusavyje sujungtų „neuronų“ tinklas, sukurtas pagal žmogaus smegenų ląsteles, atsakingas už informacijos apdorojimą ir perdavimą. Šie neuronai yra suskirstyti į sluoksnius: įvesties sluoksnis priima įvesties duomenis, vienas ar daugiau paslėptų sluoksnių apdoroja duomenis, o išvesties sluoksnis sukuria galutinį neuronų tinklo išvesties rezultatą. Kiekvienas tinklo neuronas gauna įvestį iš kitų ankstesnio sluoksnio neuronų ir sukuria išvestį, kuri perduodama kito sluoksnio neuronams. Mokymo proceso metu neuroninis tinklas koreguoja savo vidinių parametrų vertes, kad būtų sumažinta paklaida tarp jo prognozuojamos išvesties ir tikruoju rezultatu. Šis procesas paprastai atliekamas taikant optimizavimo algoritmą, pavyzdžiui, gradientinio nusileidimo algoritmą, kuris koreguoja parametrus taip, kad laikui bėgant mažėtų paklaida [29, p 60-61].



2.3 pav. Dirbtinio neuronų tinklo pavyzdys


2.5.5.1. Konvoliucinių dirbtinių neuronų tinklų operacijos

Padidinimas (angl. *padding*) - tai operacija, naudojama duomenų matricos dydžiui padidinti, prie matricos kraštų pridendant nurodytą skaičių eilučių ir stulpelių, užpildytų nuliais [30]. Operacija matoma 2.4 pav. Šis procesas, dar vadinamas nuliniu užpildymu, dažnai naudojamas siekiant išsaugoti erdvinius duomenų matmenis ir išvengti informacijos praradimo matricos kraštuose. Pavyzdžiui, konvoliuciniuose neuroniniuose tinkluose užpildymas dažnai naudojamas siekiant užtikrinti, kad konvoliucinio sluoksnio išvesties duomenys būtų tokių pačių erdvinių matmenų kaip ir to sluoksnio įvesties duomenys.



2.4 pav. Padidinimo operacijos pavyzdys


Konvoliucija - tai matematinė operacija, kuria duomenų matrica yra sujungiama su filtro matrica, elementais dauginant (angl. *element-wise multiplication*) ir sumuojant abiejų matricų reikšmes. Operacija matoma 2.5 pav. Konvoliucija yra naudojama požymiams išgauti iš įvesties duomenų matricos, taikant duomenims filtro matricą (dar vadinamą branduoliu arba svorio matrica). Gautoje matricoje yra požymiai išgauti iš išvesties duomenų ir filtrų matricos [30]. Konvoliucinės operacijos yra pagrindinė konvoliucinio neuronų tinklo sudedamoji dalis, naudojama hierarchiškai išgauti ir apdoroti požymius iš įvesties duomenų. Po jų paprastai seka netiesinės aktyvavimo funkcijos.




2.5 pav. Konvoliucijos operacijos pavyzdys

Maksimalus grupavimas (angl. *max pooling*) - tai operacija, naudojama duomenų matricai sumažinti, taikant matricai fiksuoto dydžio grupavimo langą ir kiekvienoje pozicijoje pasirenkant didžiausią reikšmę patekusią į langą [31]. Operacija matoma 2.6 pav. Šis procesas sumažina duomenų dydį ir gali būti naudojamas svarbiems požymiams iš duomenų išgauti, atmetant mažiau

svarbią informaciją. Didžiausių matmenų sujungimas dažnai naudojamas konvoliuciniuose neuroniniuose tinkluose, siekiant sumažinti konvoliucinio sluoksnio išvesties erdvinis matmenis ir pagerinti CNN našumą bei efektyvumą.



2.6 pav. Maksimalaus grupavimo pavyzdys



2.7 pav. Išplėtimo operacijos pavyzdys

Išplėtimas (angl. *upsampling*) - tai operacija, naudojama duomenų matricos padidinti, išplečiant kiekvieną matricos elementą per tam tikro dydžio išplėtimo langą. Visos matricoje esančios reikšmės bus nukopijuotos per išplėtimo lango dydį. [32]. Operacija matoma 2.7 pav.

Išmetimas (angl. *dropout*) – yra reguliarizavimo operacija, skirtas sumažinti persimokymą (angl. *overfitting*) neuroniniuose tinkluose. Ji veikia mokymo metu atsitiktinai nustatant, kad dalies neuronų reikšmės būtų lygios nuliui ir taip veiksmingai išjungiant šiuos neuronus iš tinklo. Tai sumažina modelio sudėtingumą ir neleidžia neuronams per daug prisitaikyti prie mokymo duomenų. Išmetimo dažnis (angl. *dropout rate*) yra hiperparametras, nustatantis, kokia neuronų dalis mokymo metu bus atmetama. Pavyzdžiui, 0,5 išmetimo dažnio reiškia, kad vidutiniškai pusė tinklo neuronų bus atmetama kiekviename mokymo etape [33].

Paketo normalizacija (angl. *batch normalization*) - normalizuoja matricą išlaikydamas rezultatų vidurkį arti 0, o standartinį nuokrypį arti 1. Tinklo mokymo metu yra naudojamas duomenų paketo vidurkis ir standartinis nuokrypis normalizacijai. Paketo normalizacijos (1) formulė

$$BN(x) = \frac{\gamma(x - \hat{x})}{\sqrt{\sigma^2 + \epsilon + \beta}}, \quad (1)$$

čia x yra duomenų paketas, \hat{x} duomenų paketo vidurkis, σ^2 duomenų paketo variacija, γ ir β išmokstami parametrai inicijuojami kaip 1 ir 0, $\epsilon = 0.001$ [34].

2.5.5.2. Aktyvacijos funkcijos

Aktyvacijos funkcijos yra reikalingos, kad visas tinklas nesupaprastėtų į tiesinę regresiją ir gebėtų mokytis. Jos nusprendžia ar dirbtinis neuronas turėtų būti aktyvus (turėti ne 0 reikšmę). Tokios aktyvacijos funkcijos kaip *ReLU* yra naudojamos paslėptuose sluoksniuose, o tokios kaip *sigmoid* ar *softmax* klasifikavime dirbtinio neuronų tinklo pabaigoje. [35,36].

2.5.6. Giliojo mokymosi neuronų tinklų architektūros

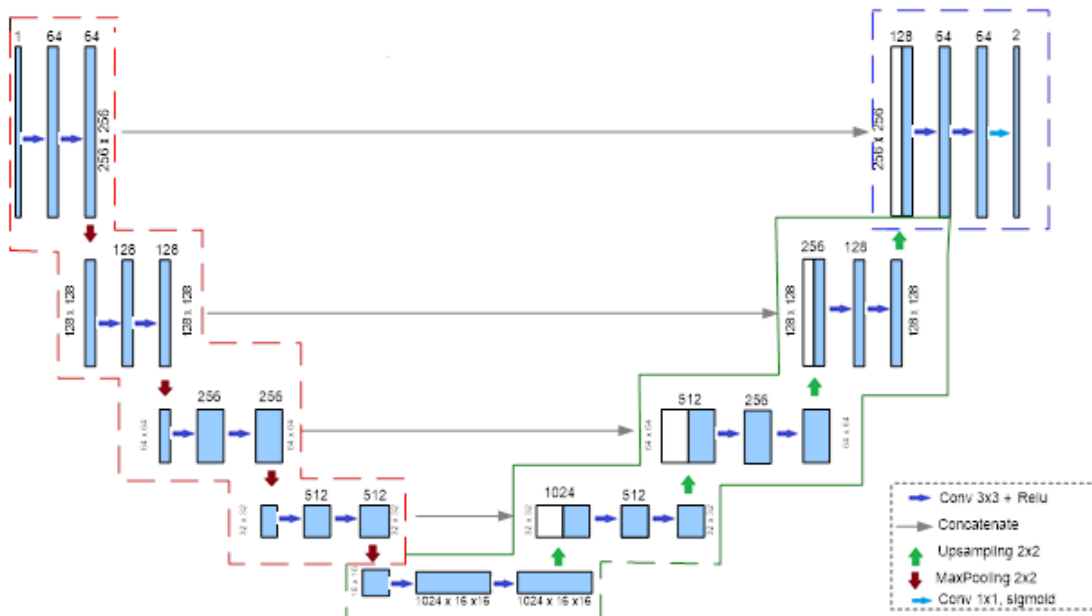
Šiame skyrelyje bus apžvelgiamos konvoliucinių neuronų tinklų architektūros naudotos anksčiau aprašytuose straipsniuose. Todėl čia bus apžvelgtos *YOLO* ir *U-Net* architektūros.

2.5.6.1. U-Net

U-Net 2015 metais sukurtas konvoliucinis neuronų tinklas skirtas biomedicinių vaizdų segmentavimui. Konvoliuciniai neuronų tinklai paprastai yra naudojami klasifikacijos užduotims, kurių išvestis būna etiketė (angl. *label*) visam įvesties vaizdui. Tačiau apdorojant biomedicinius vaizdus pageidautina kiekvienam vaizdo pikseliui priskirti klasės etiketę.

U-Net konvoliucinio neuroninio tinklo architektūrą sudaro dvi dalys: mažėjanti dalis, pažymėta raudona spalva, ir didėjanti dalis, pažymėta žalia spalva. Mažėjančią dalį sudaro keturi blokai. Kiekvieną bloką sudaro dvi 3×3 konvoliucijos, po kiekvienos konvoliucijos seka *ReLU* aktyvavimo funkcija. Šio blokėlio pabaigoje yra atliekama 2×2 maksimalaus grupavimo operacija kurios žingsnis (angl. *stride*) yra 2. Po kiekvieno tokio bloko požymių kanalų (angl. *feature channels*) skaičius padvigubėja.


Didėjančioje dalyje kiekvieną bloką sudaro išplėtimo operacija, po kurios seka 2×2 konvoliucija, dėl kurios sumažėja požymių kanalų skaičius. Šis rezultatas sujungiamas (angl. *concatenate*) su mažėjančios dalies požymių žemėlapiu (angl. *feature map*). Tada atliekamos 3×3 konvoliucijos ir *ReLU* aktyvacijos, kaip ir mažinimo dalyje. Išvesties bloko, kuris pažymėtas mėlynai, pabaigoje atliekama 1×1 konvoliucija. Kiekvienam pikseliui priskirti klasės etiketę naudojama *Sigmoido* aktyvavimo funkcija [37]. Architektūros schema matoma 2.8 pav.



2.8 pav. *U-Net* architektūra

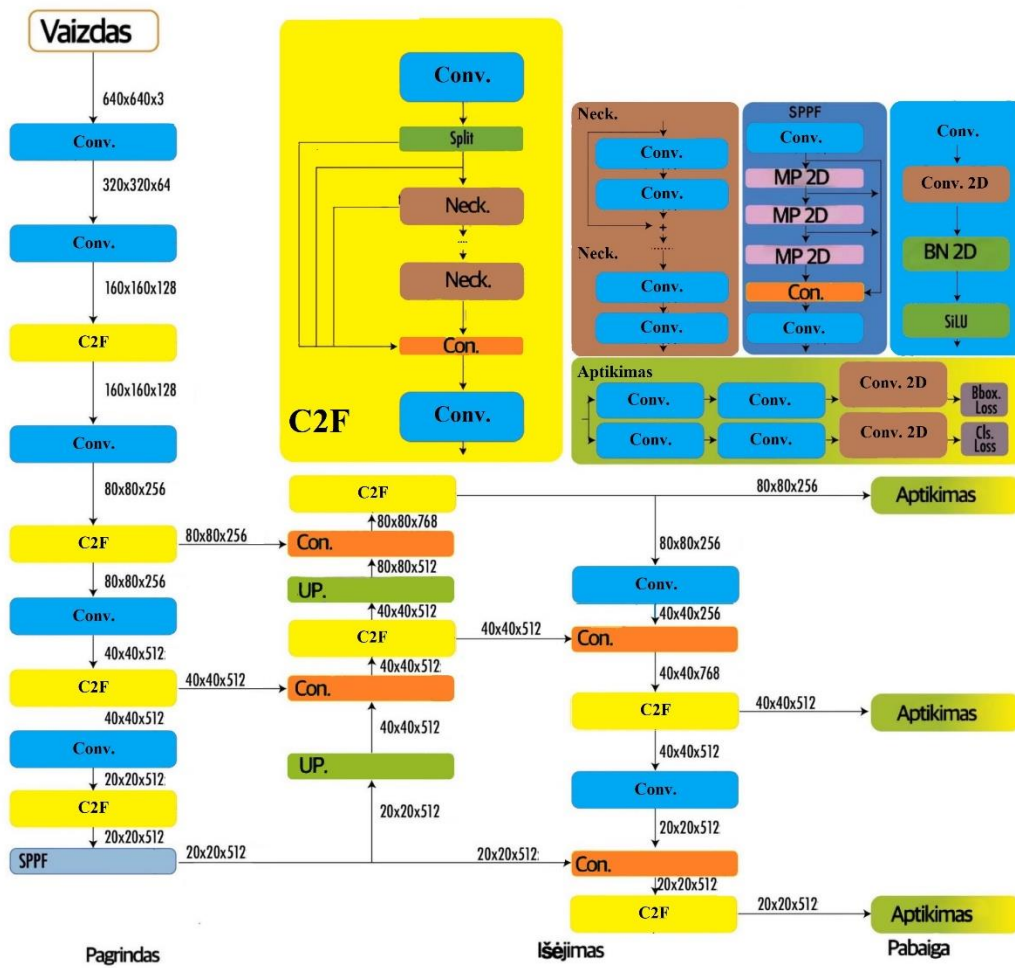
2.5.6.2. YOLO architektūros

YOLO objektų aptikimą pertvarko į paprastą regresijos problemą. *YOLO* algoritmas veikia tiesiogiai su neapdorotomis įvesties vaizdo pikselių vertėmis. Jis ima visą vaizdą kaip įvestį, t. y. *YOLO* mato visą vaizdo kontekstą, kitaip nei algoritmai, kurie naudoja slankiojančio lango ar panašius algoritmus. Neuroninis tinklas naudoja viso vaizdo požymius nuspėti ribinius langus. *YOLO* padalina vaizdą į mažesnius ir bando išsiaiškinti, ar yra objektas tame kvadratelyje. Jei taip, jis nubrėžia aplink jį langelį. Kiekvienam langeliui *YOLO* padaro kelias prognozes apie objekto vietą ir prognozės patikimumą bei kokios klasės objektas ten yra. *YOLO* visa tai atlieka kiekviename tinklo langelyje, atsižvelgdamas į visus paveikslėlyje esančius objektus. Tai padeda suprasti visą paveikslėlį ir efektyviau surasti objektus. Pradiniai tinklo konvoliuciniai sluoksniai iš vaizdo išgauna požymius, o visiškai sujungti sluoksniai prognozuoja išėjimo tikimybes ir koordinates (žr. 2.9 pav.). *YOLO* yra gana paprastas ir įkvėptas *GoogLeNet*. Jį sudaro 24 konvoliuciniai sluoksniai. Galutinė tinklo išvestis yra $7 \times 7 \times 30$ prognozių tenzorius [38].



2.9 pav. Suglausta *YOLOv1* architektūra. Mėlyni langeliai vaizduoja konvoliucijos operaciją, o geltoni grupavimo.

Su kiekviena nauja *YOLO* versija tinklo architektūra vis tobulėja. *YOLOv8* yra naudojamas požymių piramidės tinklas (FPN), kelio agregavimo tinklas (PAN), naujas ženklinimo įrankis *RoboFlow Annotate*, Pagalbinių langelių algoritmas buvo pakeistas kitu, kuris tiesiogiai numato objekto centrą. Požymių piramidė tinklas (FPN) sumažina vaizdą ir į jį prideda daugiau informacijos. Kelio agregavimo tinklas sujungia požymius iš skirtingų tinklo dalių naudodamas specialias jungtis. Tai leidžia tinklui aptikti skirtingo dydžio ir raiškos požymius. *YOLOv8* naudoja pažangesnius vėlesnio apdorojimo metodus. *Soft-NMS* persidengiantiems ribiniams langams pritaiko lankstų slenkstį, užuot juos išmetus 2.10 pav. pavaizduotas, kad *YOLO* algoritmas gali būti ir daug sudėtingesnis kaip tarkime aštuntoje *YOLO* versijoje. Prie paprastų konvoliucijos operacijų atsiranda sudėtingesnės *C2f*. *SPPF* blokas pagreitina *YOLO* greitį sugrupuodamas savybes į tam tikrą nustatytą dydį. Kiekviena konvoliucija turi paketo normalizacijos operaciją ir SiLU aktyvacijos funkciją. Pabaigos dalis yra padalinta į keletą dalių, kad nepriklausomai galėtų atlikti objekto aptikimo, klasifikacijos ir regresijos užduotis. Visi atnaujinimai pridėti siekiant algoritmui geresnės greitaiveikos ir tikslumo [39].



2.10 pav. Supaprastinta YOLOv8 architektūra.

3. Sistemos odos vėžiui klasifikuoti projektavimas

3.1. Funkciniai reikalavimai

Iškelti funkciniai reikalavimai:

- Sistema turėtų gebėti apdoroti duomenis ir paruošti juos dirbtinio intelekto (kompiuterinės regos) algoritmams sukurdama CSV failą su išgautais bruožais;
- Sistema turi atlikti vaizdų klasifikavimo funkciją juos skirstant į penkias klases;

3.2. Nefunkciniai reikalavimai

Iškelti nefunkciniai reikalavimai:

- Programos tikslumas turi pasiekti iš anksto numatytas slenkstines vertes: jautrumas ir specifiškumas turėtų būti ne mažesnis kaip 80 %;
- Programa turėtų tenkinti iš anksto apibrėžtas greitaveikos slenkstines vertes: vieno vaizdo apdorojimo trukmė turėtų ≤ 60 sekundžių.

3.3. Vertinimo metrikos

Programos rezultatų vertinimui gali būti pasirinkti vertinimo kriterijai pateikti žemiau:

Tikslumas (angl. - *Accuracy*) - tai matas, kuris apskaičiuoja modelio teisingai klasifikuotų įrašų santykį su visais įrašais. Tikslumas yra dažnai naudojama metrika, nes ji suteikia bendrą supratimą apie modelio veikimą. Skaičiavimas atliekamas pagal (2) formulę:

$$\text{Tikslumas} = \frac{TP + TN}{TI} \quad (2)$$

čia TP – teisingas teigiamas prognozių skaičius; TN – teisingas neigiamas prognozių skaičius; TI – visų prognozių skaičius. Skaičiavimas atliekamas pagal (3) formulę:

Jautrumas (angl. – *Sensitivity or Recall*) – matuoja modelio gebėjimą atpažinti tikrąsias vėžines odos darinių klases;

$$\text{Jautrumas} = \frac{TP}{TP + FN} \quad (3)$$

čia teisingas teigiamas prognozių skaičius; FN – neteisingas neigiamas prognozių skaičius.

Specifiškumas (angl. - *Specificity*) – matuoja modelio gebėjimą atpažinti tikrąsias nevėžines odos darinių klases; Skaičiavimas atliekamas pagal (4) formulę:

$$\text{Specifiškumas} = \frac{TN}{TN + FP} \quad (4)$$

čia TN – teisingas neigiamas prognozių skaičius; neteisingas teigiamas prognozių skaičius.

Precision įvertis – matuoja proporcingą teisingai klasifikuotų teigiamų rezultatų skaičių tarp visų teigiamų rezultatų; Skaičiavimas atliekamas pagal (5) formulę:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

čia TP teisingas teigiamas prognozių skaičius; FP neteisingas teigiamas prognozių skaičius.

F1 įvertis (angl. - *F1 Score*) – tai santykis tarp modelio pataikymo (angl. - *precision*) ir jautrumo. Ši metrika suteikia vieną balansuotą įvertinimą, kai reikalingas gerai suderintas rezultatas tarp tikslumo ir jautrumo. Skaičiavimas atliekamas pagal (6) formulę:

$$F1 = 2 \times \frac{Precision \times Jautrumas}{Precision + Jautrumas} \quad (6)$$

Vidutinis tikslumas - metrika, apibendrinanti *precision* ir jautrumo kreivę kaip vieną reikšmę. Skaičiavimas atliekamas pagal (7) formulę:

$$AP = \sum_n (R_n - R_{n-1})P_n \quad (7)$$

čia P_n yra tikslumas esant tam tikrai ribai n (t. y. teisingų teigiamų rezultatų skaičius, padalytas iš bendro iki n -tosios pozicijos rastų elementų skaičiaus); R_n yra jautrumas ties n (t. y. teisingų teigiamų rezultatų skaičius, padalytas iš bendro atitinkamų dokumentų skaičiaus iki n -tosios pozicijos).

Vidutinė tikslumo reikšmė apskaičiuota ant 0,50 aibių sankirtos ir sąjungos santykio vertės (angl. – *Mean Average Precision at an Intersection over Union (IoU) threshold of 0.50*. trumpinama kaip *mAP50*) - matas dirbtinio intelekto modelio tikslumo, atsižvelgiant tik į „lengvus“ aptikimus. Skaičiavimas atliekamas pagal (8) formulę:

$$mAP_{0.50} = \frac{1}{C} \sum_i i = 1^c AP_{i,0.50} \quad (8)$$

čia c yra klasių skaičius, AP – vidutinis tikslumas.

Vidutinė tikslumo reikšmė apskaičiuota skirtingose aibių sankirtos ir sąjungos santykio vertėse nuo 0,50 iki 0,95 (angl. – *Mean Average Precision calculated across IoU thresholds from 0.50 to 0.95*. trumpinama kaip *mAP50-95*) - matas dirbtinio intelekto modelio tikslumo, kuris suteikia išsamų modelio veikimo vaizdą skirtingais aptikimo sunkumo lygiais. Skaičiavimas atliekamas pagal (9) formulę:

$$mAP_{0.50:0.95} = \frac{1}{c} \sum i = 1^c \left(\frac{1}{10} \sum_{j=50}^{95} AP_{i,j/100} \right) \quad (9)$$

čia c yra klasių skaičius, AP – vidutinis tikslumas.

Plotas po ROC (angl. – *Receiver Operating Characteristic (AUC-ROC)*) kreive. ROC kreivė vaizduoja modelio jautrumą ir 1 minus specifiškumą, keičiant klasifikavimo slenkstį. AUC-ROC metrika suteikia bendrą įvertinimą, kaip gerai modelis atskiria tarp vėžinių ir nevėžinių odos darinių, nepriklausomai nuo slenksties;

Susimaišymo matrica (angl. – *Confusion Matrix*) – suteikia išsamią informaciją apie modelio teisingai ir neteisingai klasifikuotus rezultatus kiekvienai klasei. Šis įrankis leidžia išsamiau analizuoti modelio veikimą ir identifikuoti galimas klaidas.

3.4. Metodai ir įrankiai

3.4.1. Programavimo kalbos

C++ ir *Python* yra dvi populiarios programavimo kalbos, kurios gali būti naudojamos dirbtinio intelekto (DI) uždaviniams.

Python dažnai naudojama DI ir mašininio mokymosi srityse dėl savo paprastumo, aiškumo ir didelio bibliotekų skaičiaus, pvz.: *TensorFlow*, *Keras*, *PyTorch* ir *scikit-learn*. *Python* turi paprastą sintaksę, kuri leidžia greitai kurti prototipus ir eksperimentuoti su DI modeliais. Taip pat yra daugybė DI bibliotekų, kurios palaiko *Python* ir teikia sprendimus, neuroninių tinklų architektūroms, optimizavimo algoritmams ir duomenų apdorojimo įrankiams.

C++ taip pat naudojama DI srityje, ypač kai reikalingas aukštas našumas ir efektyvumas. *C++* yra greita kalba, kuri leidžia tiesiogiai optimizuoti kodą ir pasiekti geresnį skaičiavimo efektyvumą. Tai yra svarbu, kai dirbama su didelėmis duomenų rinkiniais arba skaičiavimų intensyviais DI algoritmais.

Jei reikalingas greitas skaičiavimo efektyvumas ir didelių duomenų rinkinių apdorojimas, *C++* yra geresnis pasirinkimas, tačiau greitam prototipų kūrimui *Python* yra geresnis pasirinkimas. Todėl šiam darbui pasirinkta *Python* programavimo kalba.

3.4.2. Integruota kūrimo aplinka

Visual studio 2022 yra integruota kūrimo aplinka (IDE) veikianti su dauguma programavimo kalbų. *Visual studio* turi daugybę funkcijų, kurios palengvina kodo rašymą. Tai apima automatinį užbaigimą, kodo formatavimą, klaidų tikrinimą, spalvotą paryškinimą ir kt. Tai padeda efektyviai rašyti kodą ir padidinti jų produktyvumą. *Visual studio* turi priemonių valdyti projektų aplinkas ir

priklausomybes. Tai leidžia efektyviai valdyti ir diegti reikalingas bibliotekas, kai dirbama su DI bibliotekomis, tokiomis kaip *TensorFlow* ar *PyTorch*.

Jupyter Notebook yra interaktyvi programavimo aplinka, skirta vykdyti *Python* kodą ir kurti analizės dokumentus. *Jupyter Notebook* leidžia programuotojams vykdyti kodą etapais, eilutė po eilutės, kas labai patogu eksperimentuojant ir analizuojant rezultatus. *Jupyter Notebook* puikiai tinka duomenų vizualizacijai, nes vizualizacijos yra rodomos šalia kodo, o ne naujai atsidarančiuose languose.

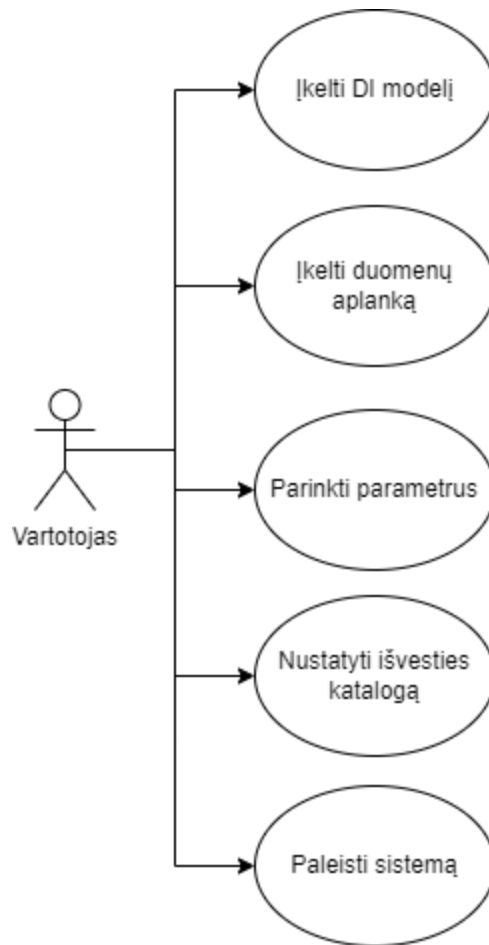
Pagrindė bus naudojama *Jupyter Notebook*, dėl patogios vizualizacijos ir galimybės kodą leisti dalimis. Ištikus sunkumams bus pereita prie *Visual studio*.

3.4.3. Sistemos realizacija

Sistemos realizacijos dalyje pavaizduota sistema odos vėžiui klasifikuoti naudojant grafus, pasitelkiant panaudotos atvejų ir veiklos diagramas. Aprašytas duomenų apdorojimas ir papildymas.

3.4.3.1. Panaudos atvejų diagrama

Sistemos naudotojas gali atlikti porą veiksmų: įkelti DI modelį, įkelti duomenų aplanką, parinkti parametrus spektrams, nustatyti išvesties katalogą ir klasifikuoti odos darinį nuotraukoje nurojant duomenų rinkinio vietą, klasifikavimo modelių svorių failo vietą ir išvesties duomenų vietą 3.1 pav.



3.1 pav. Panaudos atvejų diagrama odos vėžio klasifikavimo sistemai iš grafų.

Nurodyti kelią iki aplanko su odos darinių duomenų rinkiniu galima tada, kai nenorima duomenų perkelti į numatytą. Nenurodžius kelio, bus naudojamas numatytasis odos darinių nuotraukų aplankas. Nurodyti kelią iki išvesties rezultatų galima, jeigu norima išvesties rezultatus saugoti kitame aplanke, nei numatytame. Pasirinkti kiek nuotraukų apdoroti galima, jeigu nenorima naudoti tik melanino nuotraukos. Nenurodžius nuotraukų bus apdorojamas tik melanino vaizdas. Sistemos paleidimo panaudos atvejis aprašytas 3.1 lentelė.

3.1 lentelė. Panaudos atvejis

PA	Sistemos paleidimas
Tikslas	Nurodyti kur yra duomenų rinkinys, apmokytas klasifikavimo modelis, kur išsaugoti rezultatus, pasirinkti papildomus spektrus klasifikacijai.
Aprašymas	
Prieš sąlyga	Naudotojas nenori paleisti sistemos su numatytomis reikšmėmis.
Aktorius	Naudotojas

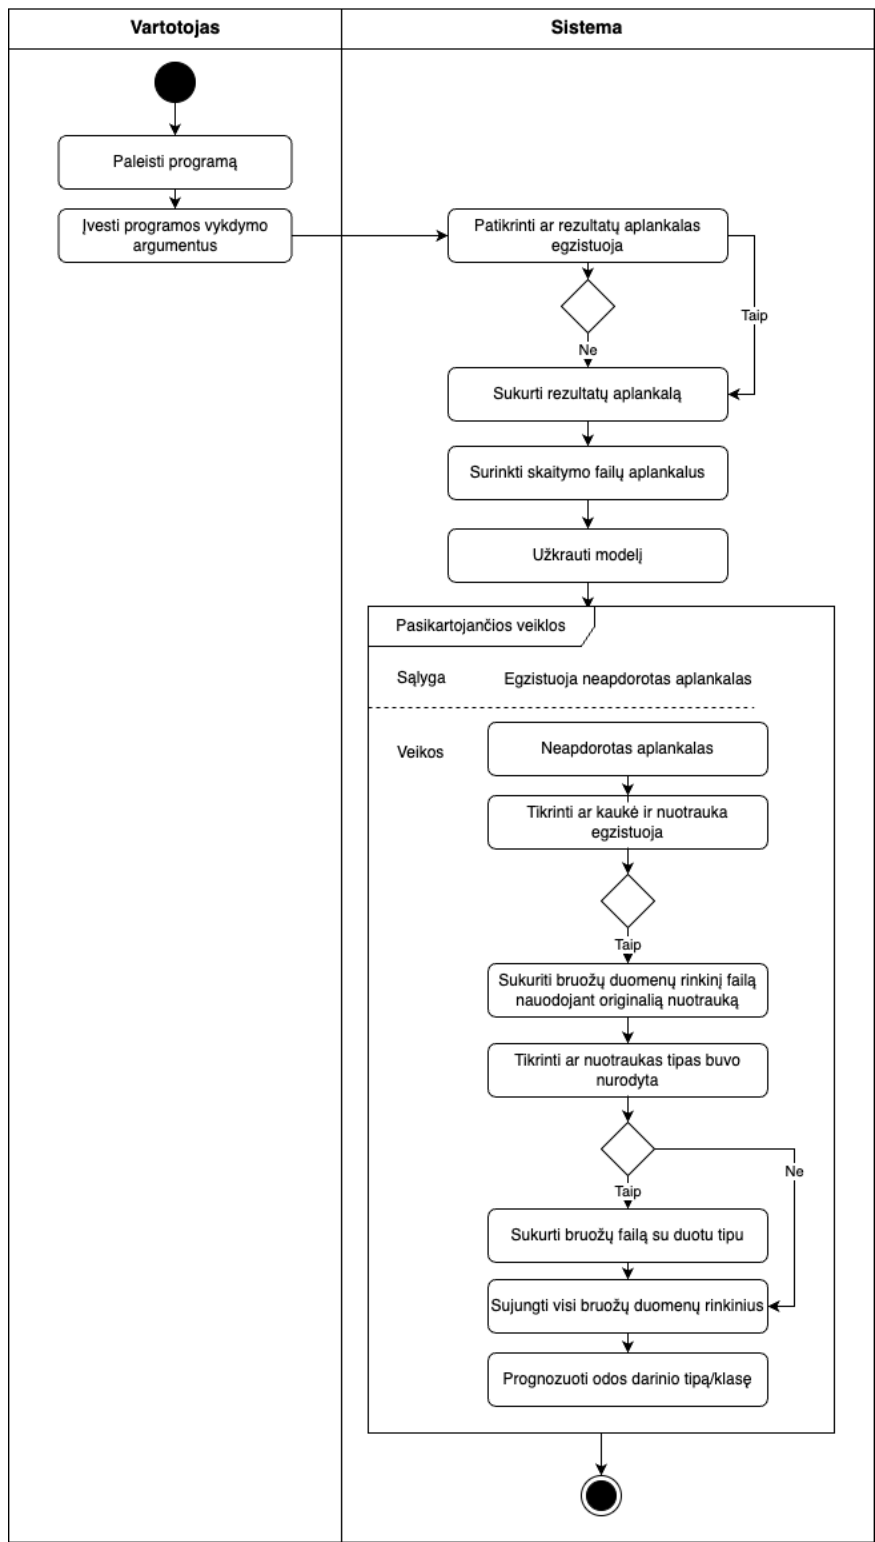
Sužadavimo sąlyga	Naudotojas nori nurodyti savo duomenų rinkinio aplanką, klasifikavimo modelio aplanką, išvesties duomenų aplanką ir pasirinkti papildomus spektrus klasifikacijai.
Pagrindinis įvykių srautas	Sistemos reakcija ir sprendimai
Sąlyga: Jei naudotojas nurodo kelią iki savo odos darinių duomenų imties aplanko	Sistema nuskaityto nuotraukas iš naudotojo nustatyto aplanko
Sąlyga: Jei naudotojas nenurodo kelio iki odos darinių duomenų imties aplanko	Sistema nuskaityto nuotraukas iš numatytojo duomenų aplanko
Sąlyga: Jei naudotojas nurodo kelią iki savo išvesties rezultatų aplanko	Sistema saugo rezultatus nurodytame aplanke
Sąlyga: Jei naudotojas nenurodo kelio iki savo išvesties rezultatų aplanko	Sistema saugo rezultatus numatytame aplanke
Sąlyga: Jei vartotojas nurodo papildomus spektrus klasifikavimui	Sistema naudoja nurodytus spektrus klasifikavimui
Sąlyga: Jei vartotojas nenurodo papildomų spektrų klasifikavimui .	Sistema naudoja tik melanino spektrą.
Baigiamas PA	
Po sąlyga	Parodoma kiek užtruko apdoroti vaizdą ir klasifikavimo rezultatas. Galima peržiūrėti CSV failą, kuriame buvo išsaugoti bruožai.

3.4.3.2. Veiklos atvejų diagrama

3.2 pav. pavaizduota sistemos paleidimo veikos diagrama. Vartotojas paleidžia programą iškviesdamas *showcase.py* failą su parametrais:

- w - kelias iki aplanko, iš kurio bus nuskaitytas klasifikavimo modelis.
- o - kelias iki aplanko, į kurį bus įrašyti CSV failai.
- i - kelias iki aplanko, iš kurio bus skaitomi duomenys.
- t - paduodami spektrai, kuriuos papildomai klasifikuoti.

Jei parametras -t nepaduotas – naudojama tik melanino vaizdas. Taip pat jei neduoti -i ar -o parametrai – naudojami numatytieji aplankalai. Iškviesta sistema išmeta klaidą jeigu skaitymo ar rašymo aplankalai neegzistuoja. Kitu atveju pradeda apdoroti odos darinių nuotraukas. Apdorojus nuotraukas išgautus bruožus surašo į CSV failą, bei pateikia sistemos naudotojui gautus rezultatus.

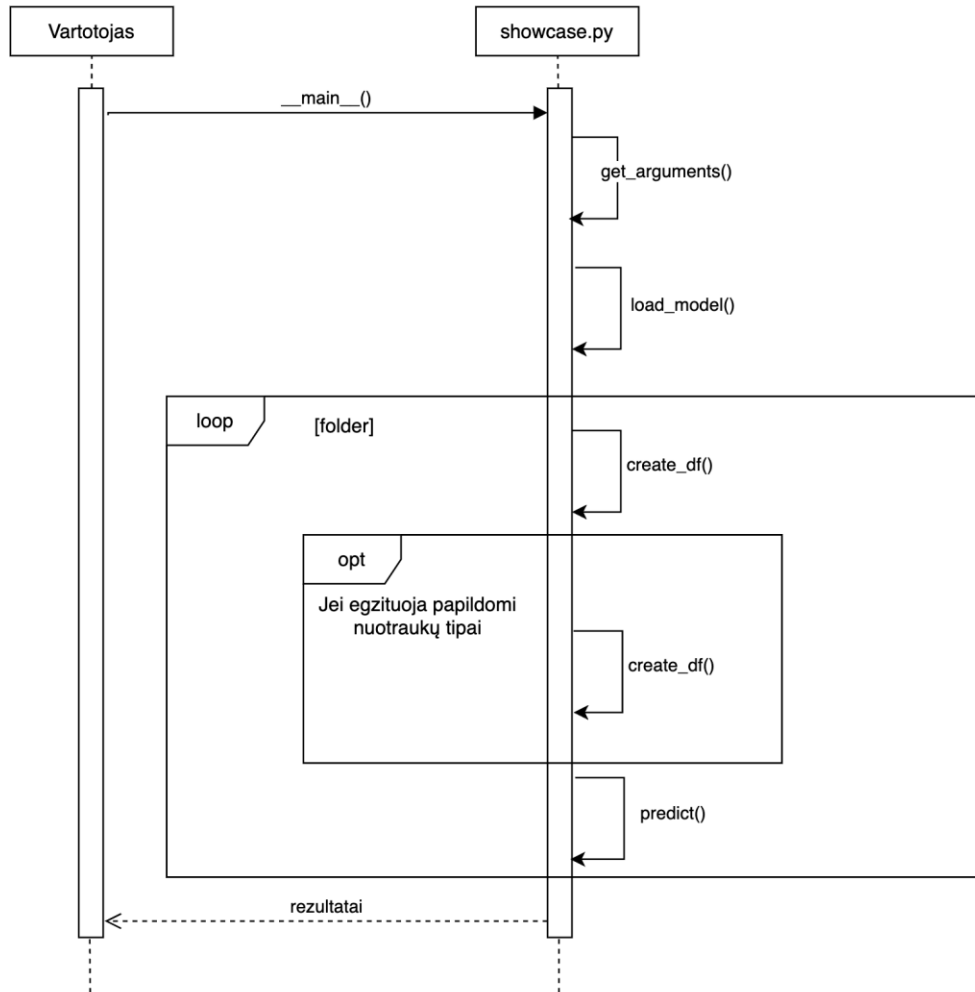


3.2 pav. Sistemos paleidimo veiklos diagrama odos vėžio klasifikavimo sistemai iš grafų.

Sistema patikrina ar egzistuoja DI modelio failas, aplankas su nuotraukomis. Jeigu jie yra sistema atlieką bruožų išgavimą iš nuotraukos ir grafų sudarymas. Tada vyksta klasifikacija ir yra sukuriamas CSV failas bei vartotojui parodomi rezultatai.

3.4.3.3. Duomenų sekų diagrama

Duomenų sekų diagrama parodo kokie metodai naudojami sistemoje ir kaip keičiasi duomenys.




3.3 pav. Sistemos paleidimo sekų diagrama odos vėžio klasifikavimo sistemai iš grafų.

3.3 pav. pavaizduota sistemos paleidimo sekų diagrama. Pirmiausia vartotojas iškviečia showcase.py failą su parametrais. Tada yra patikrinami ar egzistuoja duomenų ir rezultatų aplankai, ir jeigu neegzistuoja – yra parodomas klaidos pranešimas. Tada kiekvienam aplankui nurodytoje vietoje tikrinama, ar yra dvejetainės kaukės ir melanino vaizdai, bei vartotojui pasirinkus ir kitų spektrų vaizdai. Iš melanino vaizdo ir kaukės sukuriamas duomenų rinkinys, išgaunami bruožai iš melanino ir kitų vaizdų. Jie yra išsaugomi CSV faile bei naudojami prognozavimui. Užkraunamas apmokytas modelis ir vykdoma klasifikacija.


3.4.4. Duomenys

Šiame darbe bus naudojami duomenis išgauti su *SIAscope* aparatu. *SIAscope*, veikia skleisdamas į odą nekenksmingą spinduliuotę nuo 400 iki 950 nm bangos ilgio ir matuodamas atspindėtos šviesos kiekį pagal kiekvieną bangos ilgį. Tai įmanoma, nes atskiros odos sudedamosios dalys skiriasi savo optinėmis savybėmis. Jos skirtingai sugeria ir (arba) atspindi šviesą ir pirmenybę teikia tam tikrų bangos ilgių šviesai. Iš spektrinių matavimų *SIAscope* gauna informaciją apie melanino, kolageno ir hemoglobino (t. y. kraujagyslių) vietą, kiekį ir pasiskirstymą odos sluoksniuose [40]. Duomenų rinkinį sudaro: 43 pavyzdžiai priklausantys klasei 1, kuri yra apgamas (angl. *naevus*), 36 pavyzdžiai priklausantys klasei 2, kuri yra seborėjinė keratozė, 219 pavyzdžiai priklausantys klasei 5, kuri yra melanoma, 30 pavyzdžiai priklausantys klasei 7, kuri yra Dermatofibroma ir 144 pavyzdžiai priklausantys klasei 8, kuri yra piktybinis šlakas (lot. *Lentigo Maligna*). Iš viso 472 pavyzdžiai. Kiekvieną pavyzdį sudaro 5 vaizdai: $1544 \times 1544 \times 3$ RGB melanino vaizdas, $708 \times 708 \times 1$ pilkų atspalvių melanino vaizdas, $708 \times 708 \times 3$ hemoglobino, $708 \times 708 \times 3$ kolageno ir $708 \times 708 \times 3$ derma melanino vaizdas [41].



3.4 pav. Klasės #1 apgamo duomenų pavyzdys a – melanino apgamo vaizdas, b – pilkojo melanino apgamo vaizdas, c – odos melanino apgamo vaizdas, d – hemoglobino apgamo vaizdas, e – kolageno apgamo vaizdas


Apgamai gali būti įvairios spalvos, dydžio ir formos, plokšti arba iškilę. Jie gali būti su plaukais ir laikui bėgant gali keistis.



3.5 pav. Klasės #2 seborėjinės keratozės duomenų pavyzdys a – melanino seborėjinės keratozės vaizdas, b- pilkojo melanino seborėjinės keratozės vaizdas, c – odos melanino seborėjinės


keratozės vaizdas, d – hemoglobino seborėjinės keratozės vaizdas, e – kolageno seborėjinės keratozės vaizdas

Seborėjinė keratozė pasireiškia kaip vaškinis, žvynuotas ar šiurkštus pažeidimas. Jis gali būti įvairios spalvos, dažnai rudos arba rusvos ir paprastai būna apvalios arba ovalios formos.




3.6 pav. Klasės #5 melanomos duomenų pavyzdys a –melanino melanomos vaizdas, b- pilkojo melanino melanomos vaizdas, c – odos melanino melanomos vaizdas, d hemoglobino melanomos vaizdas, e – kolageno melanomos vaizdas

Melanomos odos dariniai pasižymi asimetrija, netaisyklingomis formomis, įvairiomis spalvomis ir didesniu nei pieštuko trintuko dydžio skersmenimis.




3.7 pav. Klasės #7 dermatofibromos duomenų pavyzdys a – melanino dermatofibromos vaizdas, b- pilkojo melanino dermatofibromos vaizdas, c – odos melanino dermatofibromos vaizdas, d – hemoglobino dermatofibromos vaizdas, e – kolageno dermatofibromos vaizdas

Dermatofibromos odos dariniai, paprastai rausvai rudos arba rusvos spalvos.



3.8 pav. Klasės #8 piktybinio šlako duomenų pavyzdys a – melanino piktybinio šlako vaizdas, b - pilkojo melanino piktybinio šlako vaizdas, c – odos melanino piktybinio šlako vaizdas, d – hemoglobino piktybinio šlako vaizdas, e – kolageno piktybinio šlako vaizdas

Piktybiniai šlakai dažnai būna dideli, netaisyklingos formos, plokšti, įvairiaspalviai odos dariniai.



3.9 pav. Suvidurkintų duomenų pavyzdys kiekvienai klasei: a – apgamui, b - seborėjinei keratozei, c – melanomai, d – defibriomai, e – piktybiniui šlakui.


Suvidurkintuose duomenyse matomos dominančios odos vietos klasei 1, 2 ir 5, bet ne 7 ir 8. Duomenys atrodo lyg turėtų daug bruožų iš kurių dirbtinio intelekto modeliai galėtų daryti prognozes.

3.4.5. Duomenų paruošimas

Duomenų paruošimas susidarė iš dviejų etapų: dvejetainių kaukių sudarymo su objektų langų koordinatėms paskaičiavimu ir bruožų išgavimo atsitiktinių miškų klasifikatoriui.

3.4.5.1. Duomenų paruošimas – dvejetainių kaukių sudarymas ir objektų langų koordinatės

Pradinis duomenų rinkinys neįtraukė dvejetainių kaukių ir objekto langų duomenų. Tam tikslui buvo sukurta programėlė, kuri rankiniu būdu leido pažymėti odos darinius ir sukurti binarinę kaukę bei objekto langus.



3.10 pav. Dvejetainės kaukės šalia odos darinių klasių.

Eksperimentiniais tiksliais buvo panaudotas iš anksto apmokytas *U-Net* modelis dvejetainių kaukių išgavimui, tačiau gauti rezultatai buvo prasti, nes gautos kaukės pateikia per daug arba per mažai odos darinio (žr. 3.10 pav.), o tas trukdė stabiliai sukurti grafus su 20 viršūnių.

3.4.5.2. Duomenų paruošimas ir bruožų išgavimas

Sukūrus dvejetainės kaukės buvo pereita prie superpikselių grafų sistema bruožams išgauti (žr. 3.11 pav.) kodavimo. Paduodamiems vaizdams buvo pašalinamas fonas ir sveikos odos dalys pasinaudojant dvejetaine kauke.

Vaizdai buvo sumažinami ir iš jų buvo išgaunami įvairūs bruožai. Grafo viršūnėms buvo paskaičiuoti 120 bruožai (žr. 3.2 lent.). Visam grafiui buvo paskaičiuoti 5 bruožai (žr. 3.3 lent.). Iš dažnių srities buvo paskaičiuoti 24 bruožai (žr. 3.4 lent.). Visų šių bruožų paskaičiavimo formulės buvo aprašytos melanomos aptikimo iš grafų straipsnio [23]. Iš geometrijos srities buvo paskaičiuoti 9 bruožai (žr. 3.5 lent.). Kiekvienas vaizdas buvo nuskaitytas RGB, CIELAB, CIELUV ir HSV spalvose ir iš jų paimta 12 bruožų (žr. 3.5 lent.) Kiekvienam spalvos kanalui iš kiekvienos spalvos buvo paskaičiuoti 84 bruožai (3.7 lent.) taip pat 156 GLCM bruožai (žr. 3.8 lent.) bei Har'o bangos dekompozicija (angl. *Haar wavelet decomposition*) pirmoms 10 bangų paskaičiuoti 240 bruožų (žr. 3.9 lent.). Iš grafų buvo išgauti 125 bruožai. Iš dažnių domeno 24. Iš geometrijos 9. Iš spalvų išgauti 492 bruožai iš kurių 12 priklauso spalvoms, 84 spalvų kanalams, 156 GLCM ir 240 Har'o bangų. Visų šių bruožų paskaičiavimo formulės buvo aprašytos odos

ligos diagnozavimo pasitelkiant vaizdo savybes straipsnio [42]. Iš viso kiekvienam vaizdui buvo išgauta 650 bruožai.

3.2 lentelė. Grafių bruožai išgauti kiekvienai viršūnei.

Bruožas	Bruožų skaičius
Lokalus efektyvumas (angl. <i>Local efficiency</i>)	20
Lokalus klasterizavimo koeficientas (angl. <i>Local clustering coefficient</i>)	20
Viršūnės stiprumas (angl. <i>Nodal strength</i>)	20
Viršūnės tarpiškumo centriškumas (angl. <i>Nodal betweenness centrality</i>)	20
Artumo centriškumas (angl. <i>Closeness centrality</i>)	20
Ekscentriškumas (angl. <i>Eccentricity</i>)	20

Lokalus efektyvumas – vidurkis abstrakčiai paskaičiuoto trumpiausio kelio ilgio iš kaimyninių viršūnių. Lokalaus klasterizavimo koeficientas - sąsajų tarp kaimyninių viršūnių santykis, padalintas iš galimų sąsajų tarp jų skaičiaus. Skaičiuojamas pagal (10) formulę:

$$C_{loc}(v_i) = \frac{2 \times |E_{v_i}|}{k_i \times (k_i - 1)}, \quad i = 1, \dots, N \quad (10)$$

čia v_i - grafo viršūnė k_i – viršūnės laipsnis, E_{v_i} - kraštinių skaičius tarp viršūnės kaimynų, N – viršūnių skaičius grafe.

Viršūnės stiprumas – grafe su svoriais, tai yra su ta viršūne sujungtų briaunų svorių suma, grafe be svorių tai yra jo jungčių skaičius. Grafiui su svoriais skaičiuojamas pagal (11) formulę:

$$N_s(v_i) = \sum_{e_{ij} \in E} l_{ij}, \quad (11)$$

čia v_i - grafo viršūnė, l_{ij} – svoriai tarp grafo viršūnių.

Viršūnės tarpiškumo centriškumas - trumpiausių kelių, einančių per šią viršūnę, skaičius. Skaičiuojamas pagal (12) formulę:

$$\mathcal{R}(v_i) = \sum_{m \neq n \neq i} \frac{\sigma_{mn}(v_i)}{\sigma_{mn}}, \quad (12)$$

čia v_i - grafo viršūnė, σ_{mn} – trumpiausių kelių skaičius nuo m iki n viršūnių, $\sigma_{mn}(v_i)$ – skaičius trumpiausių kelių pereinančių per viršūnę v_i .

Artumo centriškumas - trumpiausių kelių tarp viršūnės ir visų kitų grafo viršūnių ilgių abipusė suma. Skaičiuojamas pagal (13) formulę:

$$\mathcal{C}(v_i) = \frac{N}{\sum_{j=1}^N \epsilon_{ij}}, \quad i = 1, \dots, N. \quad (13)$$

čia v_i - grafo viršūnė, ϵ_{ij} – invertuotas trumpiausias kelias, N – viršūnių skaičius grafe.

Ekscentriškumas – maksimalus atstumas tarp viršūnės ir visų kitų viršūnių. Skaičiuojamas pagal (14) formulę:

$$O(v_i) = \max_{j \in G} \gamma_{ij} \quad (14)$$

čia v_i - grafo viršūnė, γ_{ij} – trumpiausias kelias.

3.3 lentelė. Grafių bruožai išgauti visam grafiui.

Bruožas	Bruožų skaičius
Savitasis kelio ilgis (angl. <i>Characteristic path length</i>)	1
Globalus efektyvumas (angl. <i>Global efficiency</i>)	1
Globalus klasterizavimo koeficientas (angl. <i>Global clustering coefficient</i>)	1
Tankumas (angl. <i>Density</i>)	1
Globalus asortatyvumas (angl. <i>Global assortativity</i>)	1

Savitasis kelio ilgis - trumpiausių kelių, jungiančių kiekvieną viršūnę su visomis kitomis viršūnėmis, ilgių vidurkių mediana. Skaičiuojamas pagal (15) formulę:

$$L(G) = \frac{1}{N(N-1)} \sum_{i \neq j} \gamma_{ij}, \quad (15)$$

čia G – grafas, N – viršūnių skaičius grafe, γ_{ij} – trumpiausias kelias.

Globalus efektyvumas - apskaičiuotų atstumų tarp visų viršūnių porų vidurkis. Skaičiuojamas pagal (16) formulę:

$$E_g = \frac{1}{N(N-1)} \sum_{i \neq j} \epsilon_{ij}, \quad (16)$$

čia N – viršūnių skaičius grafe, ϵ_{ij} – invertuotas trumpiausias kelias.

Globalus klasterizavimo koeficientas – lokalių klasterizavimo koeficientų vidurkis. Skaičiuojamas pagal (17) formulę:

$$C_g(G) = \frac{1}{N} \sum_{i=1}^N C_{loc}(v_i). \quad (17)$$

čia G – grafas, N – viršūnių skaičius grafe, v_i - grafo viršūnė.

Tankumas - grafe esančių briaunų ir didžiausio galimo briaunų skaičiaus santykis. Skaičiuojamas pagal (18) formulę:

$$D(G) = \frac{2|E|}{N(N-1)} \quad (18)$$

čia G – grafas, N – viršūnių skaičius grafe, E – kraštinių skaičius grafe.

Globalus asortatyvumas - skaičius nuo -1 iki 1 parodantis grafo tiesiškumo santyki. Skaičiuojamas pagal (19) formulę:

$$r = \frac{\sum_{i=1}^{|E|} \left[\frac{j_i k_i}{|E|}, - , \left(\sum_{i=1}^{|E|} \frac{j_i + k_i}{2|E|^{3/2}} \right)^2 \right]}{\sum_{i=1}^{|E|} \left[\frac{j_i + k_i}{2|E|}, - , \left(\sum_{i=1}^{|E|} \frac{j_i + k_i}{2|E|^{3/2}} \right)^2 \right]} \quad (19)$$

čia j_i ir k_i viršūnių laipsnius kraštinės i galuose skaičius, E – kraštinių skaičius grafe.

Visi bruožai matomi 3.3 lentelėje.

3.4 lentelė. Dažnių srities bruožai.

Bruožas	Bruožų skaičius
Grafo Furjė transformacijos vektorius	20
Energija	1
Jėga	1
Entropija	1
Amplitudė	1

Pasinaudojant grafo Furjė transformaciją, iš Laplaciano savųjų reikšmių dekompozicijos pagal (20) formulę, buvo paskaičiuotas transformacijos vektorius. Energija - grafo gretimybės matricos savųjų verčių absoliučiuųjų verčių suma. Jėga - kvadratinė absoliutinė GFT vertė. Entropija – entropijos vertė paskaičiuota GFT. Amplitudė – GFT spektrinis tankumas, parodantis kiek mato yra vienete. Visi bruožai matomi 3.4 lentelėje.

$$L = UAU^T \quad (20)$$

čia $L = D - A$, A yra grafo kaimynystės matrica, D yra laipsnių matricos įstrižainė, Λ yra savųjų reikšmių įstrižainės matrica, o U stulpeliai yra savosios vektorinės reikšmės.

3.5 lentelė. Geometrijos srities bruožai.

Bruožas	Bruožų skaičius
Plotas	1
Perimetras	1
Ekvivalentinis skersmuo	1
Kompaktiškumas	1
Apvalumas	1
Solidumas	1
Keturkampiškumas	1
Kraštinių santykis (angl. <i>aspect ratio</i>)	1
Ekscentriškumas	1

Ekvivalentinis skersmuo paskaičiuojamas pagal formulę (21):

$$ED = \sqrt{4A/\pi} \quad (21)$$

čia A - odos darinio plotas.

Kompaktiškumas apibrėžiamas kaip objekto ploto ir tokio paties perimetro apskritimo ploto santykis. Paskaičiuojamas pagal (22) formulę:

$$CO = \frac{ED}{MD} \quad (22)$$

čia MD - maksimalus odos darinio diametras, ED – ekvivalentinis skersmuo.

Apvalumas - tai dvimatė paklaida, pagal kurią kontroliuojama bendra apskritimo forma, kad jis nebūtų per daug pailgas, kvadratinis ar neapvalus. Paskaičiuojamas pagal (23) formulę:

$$CI = \frac{4A\pi}{P^2} \quad (23)$$

čia P – perimetras, A - odos darinio plotas.

Kietumas: parodo, kaip glaudžiai figūra užpildo erdvę. Paskaičiuojamas pagal (24) formulę:

$$CI = \frac{A}{CH} \quad (24)$$

čia CH yra apgaubtasis daugiakampis (angl. Convex Hull) odos dariniui, A - odos darinio plotas.

Keturkampiškumas: Tai yra odos darinio ploto ir odos darinio rėmelio ploto santykis Paskaičiuojamas pagal (25) formulę:

$$R = \frac{A}{BA} \quad (25)$$

čia BA odos darinio rėmelis (angl. *bounding box*), A - odos darinio plotas.

Aspekto santykis: Geometrinės figūros kraštinių santykis - tai jos dydžių santykis įvairiuose matmenyse. Paskaičiuojamas pagal (26) formules:

$$AR = \frac{A_1}{A_2}$$

$$A_1, A_2 = \sqrt{\{8\{\mu_{02} + \mu_{20} \pm \sqrt{(\mu_{02} - \mu_{20})^2 + 4\mu_{11}}\}\}}$$

$$\mu_{ij} = \sum_{x=1}^{rows} \sum_{y=1}^{cols} (x - C_x)^i \cdot (x - C_y)^j$$

$$\mu_{ij} = \sum_{x=1}^{rows} \sum_{y=1}^{cols} x^i \cdot y^j$$

$$C_x = \frac{m_{10}}{m_{00}}$$

$$C_y = \frac{m_{01}}{m_{00}} \quad (26)$$

Ekscentriškumas geometrijoje yra atstumas nuo bet kurio kūgio pjūvio taško iki židinio, padalytas iš statmeno atstumo nuo to taško iki artimiausios tiesės. Paskaičiuojamas pagal (27) formulę:

$$e = \frac{(\mu_{02} - \mu_{20})^2 + 4\mu_{11}}{(\mu_{02} + \mu_{20})^2} \quad (27)$$

3.6 lentelė. Standartiniai spalvų bruožai.

Bruožas	Bruožų skaičius
Vidurkis	4
Variantiškumas	4
Standartinis nuokrypis	4

Vaizdo pikselių vidurkis (skaičiuojamas pagal (30) formulę), variantiškumas (skaičiuojamas pagal (31) formulę) ir standartinis nuokrypis (skaičiuojamas pagal (32) formulę) sudaro standartinius spalvos bruožus (žr. 3.6 lent.).

$$\mu_c = \frac{1}{N} \sum_{p=1}^N (I_p) \quad (30)$$

$$s_c^2 = \frac{1}{N-1} \sum_{p=1}^N (I_p - \mu_c)^2 \quad (31)$$

$$S_c = \sqrt{s \frac{2}{c}} \quad (32)$$

čia N yra pikselių skaičius, I pikselio intensyvumo vertė.

3.7 lentelė. Standartiniai spalvų broožai spalvų kanalams.

Broožas	Broožų skaičius
Vidurkis	12
Variantiškumas	12
Standartinis nuokrypis	12
Minimali vertė	12
Maksimali vertė	12
Asimetriškumas	12
Hausdorfo dimensija	12

Vaizdo pikselių kanalo vidurkis, variantiškumas, standartinis nuokrypis, minimali vertė, maksimali vertė, asimetriškumas ir Hausdorfo dimensija sudaro standartinius spalvos broožus. Asimetriškumas yra paskaičiuojamas pagal (33) formulę:

$$SK_c = \left[\frac{1}{N} \sum_{p=1}^N (I_p - \mu_c)^3 \right] / s_c^3 \quad (33)$$

čia N yra pikselių skaičius, I_p - pikselio intensyvumo vertė, μ_c - vidurkis, S_c - standartinis nuokrypis.

Hausdorfo dimensija yra šiurkštumo, tiksliau, fraktalinio matmens matas. Tai būdas apibrėžti aibės matmenį metrinėje erdvėje. Paskaičiuotas pagal (34) formulę:

$$D = \frac{\log P}{\log T^{-1}}$$

$$D_c^2 = \frac{1}{N} \left(\sum_{i=1}^{rows} \sum_{j=1}^{cols} D_{i,j} \right) + 1; c = 1, 2, \dots, n \quad (34)$$

čia P - panašių elementų skaičius iš vaizdo rekonstrukcijos, T kvadrantų skaičius.

3.8 lentelė. Bruožai išgauti iš GLCM.

Bruožas	Bruožų skaičius
Kontrastas	12
Nepanašumas (angl. <i>dissimilarity</i>)	12
Homogeniškumas	12
Energija	12
Koreliacija	12
Variantiškumas	12
Sumos entropija	12
Sumos vidurkis	12
Variantiškumo skirtumas	12
Maksimalus koreliacijos koeficientas	12
Informacinis koreliacijos matas 1	12
Entropijos skirtumas	12
Informacinis koreliacijos matas 2	12

Kontrastas - pikselio ir jo kaimyno intensyvumo skirtumas viso vaizdo kontekste. Apskaičiuojamas pagal (35) formulę:

$$C_c = \sum_{i=1}^N \sum_{j=1}^N [m_{i,j} (i - j)^2] \quad (35)$$

čia $m_{i,j}$ GLC matricos vertė, i ir j yra pikselių vertės.

Nepanašumas - pikselio ir jo kaimyno intensyvumo suvidurkintas skirtumas viso vaizdo kontekste. Apskaičiuojamas pagal (36) formulę:

$$C_d = \sum_{i=1}^N \sum_{j=1}^N [m_{i,j} |i - j|] \quad (36)$$

čia $m_{i,j}$ GLC matricos vertė, i ir j yra pikselių vertės.

Homogeniškumas - pikselio ir jo kaimyno panašumas viso vaizdo kontekste. Apskaičiuojamas pagal (37) formulę:

$$C_h = \sum_{i=1}^N \sum_{j=1}^N \left[\frac{m_{i,j}}{1 + (i - j)^2} \right] \quad (37)$$

čia $m_{i,j}$ GLC matricos vertė, i ir j yra pikselių vertės.

Energija - pikselio ir jo kaimyno pasikartojimo matas viso vaizdo kontekste. Apskaičiuojamas pagal (38) formulę:

$$C_e = \sqrt{\sum_{i=1}^N \sum_{j=1}^N [m_{i,j}^2]} \quad (38)$$

čia $m_{i,j}$ GLC matricos vertė.

Koreliacija yra apskaičiuojama pagal (39) formulę:

$$CRL_c = \frac{[\sum_{i=1}^N \sum_{j=1}^N (i \times j \times m_{i,j}) - \mu_x \mu_y]}{\sigma_x \sigma_y} \quad (39)$$

čia σ - standartiniai nuokrypiai, μ - vidurkiai, $m_{i,j}$ GLC matricos vertė, i ir j yra pikselių vertės.

Variantiškumas šiuo atveju matuoja pilkumo lygių reikšmių sklaidą GLCM matricoje. Apskaičiuojama pagal (40) formulę:

$$VAR_c = \sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 m_{i,j} \quad (40)$$

čia μ - vidurkis, $m_{i,j}$ GLC matricos vertė.

Sumos entropija – vaizdo sudėtingumo matas. Apskaičiuojamas pagal (41) formulę:

$$SH_c = - \sum_{i=2}^{2N} [(m_{x+y(i)} \log (m_{x+y(i)}))] \quad (41)$$

$$m_{x+y}(k) = \sum_{i=1}^N \sum_{j=1}^N (m_{i,j})$$

$$m_{x-y}(k) = \sum_{i=1}^N (m_{i,j}) \sum_{j=1}^N (m_{i,j})$$

Sumos vidurkis – pikselių sumų vidurkis vaizde. Apskaičiuojamas pagal (42) formulę:

$$SA_c = \sum_{i=2}^{2N} (i \times m_{x+y(i)}) \quad (42)$$

Variantiškumo skirtumas – variantiškumo skirtumas tarp pikselių intensyvumo. Apskaičiuojamas pagal (43) formulę:

$$DV_c = VAR(m_{x-y}) \quad (43)$$

Maksimalus koreliacijos koeficientas - vaizdo pikselių porų tiesinės priklausomybės laipsnis. Apskaičiuojamas pagal (44) formulę:

$$MCC_c = \sqrt{Q_{(2)}} \quad (44)$$

$$Q_{i,j} = \sum_K^N [(m_{i,k} m_{j,k}) / m_{x,(i)} m_{y,(k)}]$$

Entropijos skirtumas - vaizdo sudėtingumo matas pagal pikselių intensyvumo skirtumus. Apskaičiuojamas pagal (45) formulę:

$$DH_c = - \sum_{i=0}^{N-1} [m_{x-y(i)} \log(m_{x-y(i)})] \quad (45)$$

Informacinis koreliacijos matas 1 - bendras vaizdo pikselių porų tikimybinis pasiskirstymas. Apskaičiuojamas pagal (46) formulę:

$$DH_c = - \sum_{i=0}^{N-1} [m_{x-y(i)} \log(m_{x-y(i)})]$$

$$CRL1_c = (HXY - HXY1) / \max(HX, HY)$$

$$HXY = - \sum_{i=1}^N \sum_{j=1}^N [m_{i,j} \log(m_{i,j})] \quad (46)$$

$$HXY1 = - \sum_{i=1}^N \sum_{j=1}^N [m_{i,j} \log(m_{x(i)} m_{y(j)})]$$

$$SH_c = - \sum_{i=2}^{2N} [(m_{x+y(i)} \log(m_{x+y(i)}))]$$

$$HX = SH(m_{x(i)}); HY = SH(m_{y(j)});$$

3.9 lentelė. Bruožai išgauti iš Har'o bangų.

Bruožas	Bruožų skaičius
Energija	120
Entropija	120

Energija - bendros signalo galios matas, ji apskaičiuojama kaip bangos koeficientų kvadratų suma. Apskaičiuojamas pagal (47) formulę:

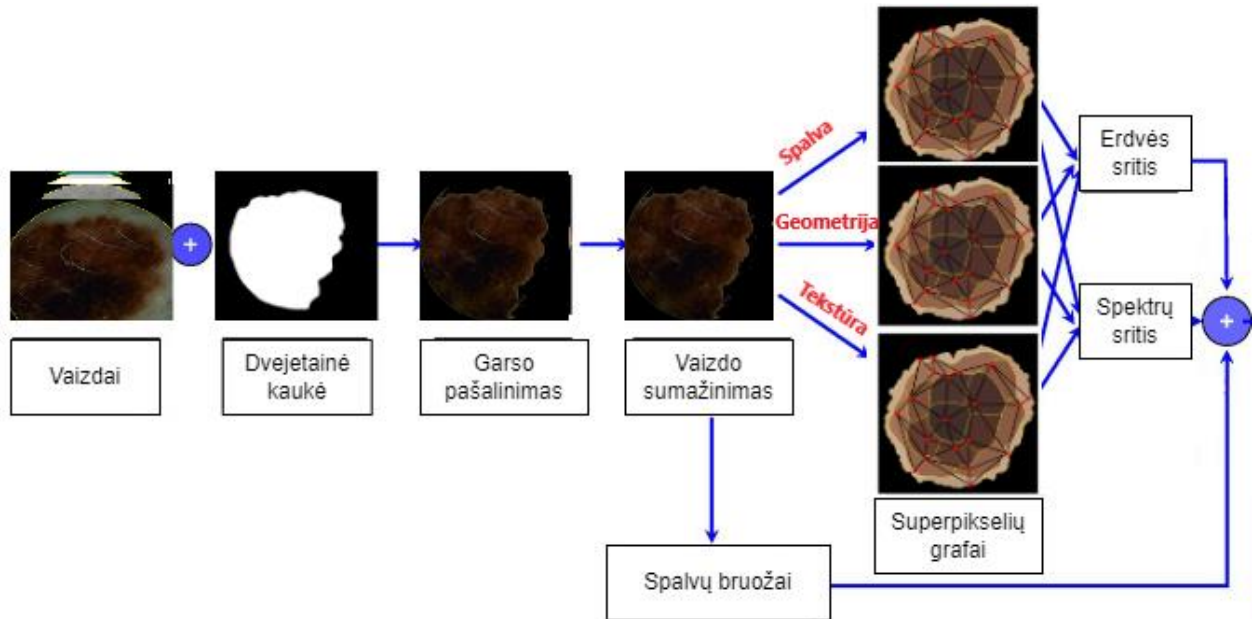
$$E(Sb)_c = \sqrt{\frac{1}{N} \sum_{i=1}^{rows} \sum_{j=1}^{cols} (Sb_{i,j}^2)} \quad (47)$$

čia Sb - subjostos koeficientą pikseliui i ir j , o N yra bendras pikselių skaičius subjostoje.

Entropija - signalo neapibrėžtumo arba atsitiktinumo matas. Apskaičiuojamas pagal (48) formulę:

$$E(Sb)_c = \frac{1}{N} \sum_{i=1}^{rows} \sum_{j=1}^{cols} [Sb_{i,j}^2 \times \log(Sb_{i,j}^2)] \quad (48)$$

čia S_b - subjostos koeficientą pikseliui i ir j , o N yra bendras pikselių skaičius subjustoje.



3.11 pav. Superpikselių grafų sistema bruožams išgauti

Grafai be svorių buvo sudaromi sujungiant paskaičiuotas viršūnes naudojant Delaunė trianguliacija (angl. *Delaunay triangulation*). Grafams su svoriais buvo sudaromi pagal (49) formulę kartu su dviem funkcijomis Gauso (50) ir eksponentine (51).

$$w_{ij} = \Omega^{-1} \exp[-(f(x))^2]$$

$$\Omega = \sum_{\{i,j\} \in E} \exp[-(f(x))^2] \quad (49)$$

čia $f(x)$ gali būti eksponentinė (50) arba Gauso (51) funkcija

$$f(x) = \frac{|x_i - x_j| - \mu_c}{\sigma_c} \quad (50)$$

čia σ_c – standartinis nuokrypis, μ_c – vidurkis, x vektorius su bruožais.

$$f(x) = \frac{1}{2} e^{-|x|}, x \in \mathbb{R}. \quad (51)$$

čia x vektorius su bruožais.

Grafų jungčių vertės buvo paaimamos iš spalvų bruožų skirtumo tarp superpikselių. Šiuo atveju bruožai buvo minimumas, maksimumas, vidurkis, mediana, standartinis nuokrypis, variantiškumas ir entropija. Jie buvo paimti iš vaizdo esančio CIELAB spalvų srityje. Kitu atveju grafų jungčių vertės buvo paimtos iš geometrijos bruožų skirtumų tarp superpikselių. Šiuo atveju bruožai buvo: Plotas, skersmuo, kompaktiškumas, apvalumas, solidumas, keturkampiškas, kraštinių santykis, ekscentriškumas, didžiosios ašies ilgis, mažosios ašies ilgis. Dar kitaip grafų

viršūnės buvo sudaromos iš GLCM bruožų skirtumų tarp superpikselių. Bruožai matomi 3.8 lent. Kitais atvejais grafų svoriai buvo sudaromi naudojant kombinacijas tarp šių bruožų. Visos svorių vertės gali būti matomos 3.10 lent.

3.10 lentelė. Grafų svorių verčių sudarymo būdai.

Vertės funkcijai	Funkcija svoriui paskaičiuoti
Įprastiniai vaizdo bruožai	Gauso
Geometriniai bruožai	Gauso
GLCM bruožai	Gauso
Įprastiniai vaizdo ir geometriniai bruožai	Gauso
Įprastiniai vaizdo ir GLCM bruožai	Gauso
Įprastiniai vaizdo, geometriniai ir GLCM bruožai	Gauso
Geometriniai ir GLCM bruožai	Gauso
Įprastiniai vaizdo bruožai	EkspONENTINĖ
Geometriniai bruožai	EkspONENTINĖ
GLCM bruožai	EkspONENTINĖ
Įprastiniai vaizdo ir geometriniai bruožai	EkspONENTINĖ
Įprastiniai vaizdo ir GLCM bruožai	EkspONENTINĖ
Įprastiniai vaizdo, geometriniai ir GLCM bruožai	EkspONENTINĖ
Geometriniai ir GLCM bruožai	EkspONENTINĖ

4. Eksperimentai atlikti odos vėžio aptikimo sistemai sukurti

Visi dirbtinių neuronų tinklų modeliai buvo mokyti 100 epochų su kiekvienu vaizdo tipu ir su suvidurkintu variantu. Superpikselių grafų sistema bruožams išgauti buvo modifikuota, kad palaikytų daugiaspektrinius duomenis. Tai buvo padaryta, praplečiant įvesties vaizdų skaičių nuo 1 iki 5. Kiekvienas vaizdas yra skirtingame bangų spektre.

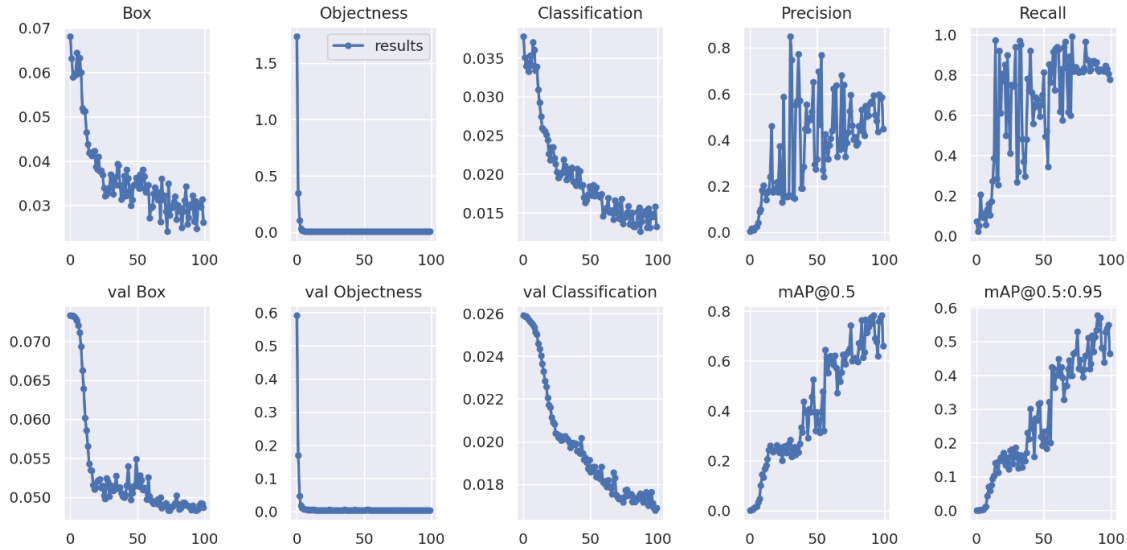
4.1. Eksperimentai atlikti su *YOLOv7*

Melanino, pilko melanino, hemoglobino, kolageno, odos melanino ir suvidurkinti vaizdai buvo naudojami apmokyti šešis *YOLOv7* modelius. Kiekvienas modelis buvo treniruotas 100 epochų. Sprendimas apmokyti skirtingus *YOLOv7* modelius buvo priimtas todėl, kad kiekvienas modelis gerai apsimokytų išgauti bruožus duotame spektre. Apmokyti *YOLOv7* modelį su dideliu įvesties dydžiu reikalauja galingos kompiuterinės įrangos, ši problema nepasireiškia išskaidant mokymą tarp skirtingų modelių. Galiausiai, modelis apsimokantis ant melanino spektro vaizdų gali pasinaudoti perkeliama mokymosi privalumais. Suvidurkinti vaizdai mokymui buvo naudojami dėl tokių priežasčių, kaip bruožų apjungimo, garso sumažinimo, spektrinio nuoseklumo palaikymas, efektyvesnis ir greitesnis mokymasis dėl sumažinto įvesties dydžio. Visoms pateiktoms matricoms duomenų pasiskirstymas vienodas ir yra: 2 apgamų vaizdai, 2 seborėjinei keratozei, 23 melanomoms, 5 dermafibriomoms, 16 piktybinėms šlakams.

4.1 lentelė. *YOLOv7* vidutinio tikslumo rezultatų palyginimas

Vaizdo tipas	mAP50	mAP50-95	Epocha
Melanino	0.7827	0.5777	99
Pilko melanino	0.6188	0.3804	97
Hemoglobino	0.4942	0.3280	91
Kolageno	0.3970	0.2218	73
Odos melanino	0.3354	0.2980	95
Suvidurkintas	0.6749	0.4617	92

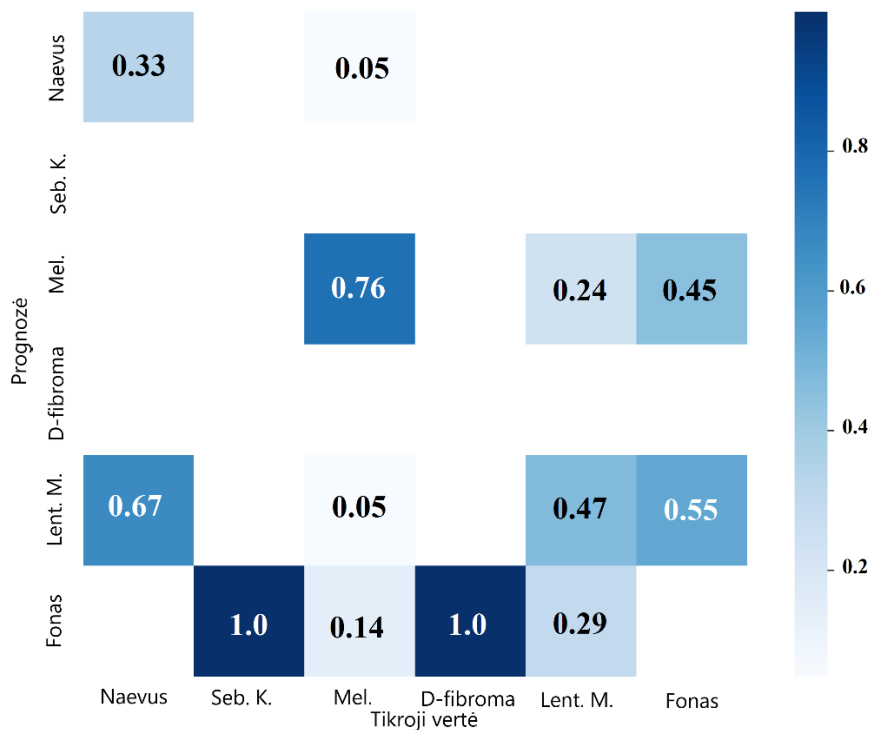
YOLOv7 atveju didžiausias mAP50 buvo pasiektas naudojant melanino vaizdus (78%), po to suvidurkintant vaizdus (67%). Tas pats buvo ir mAP50-95 metrikos atveju. Melanino vaizdai pasiekė 57%, o suvidurkinti – 46%. Pastebėtina, kad odos melanino vaizdai pasiekė mažiausias mAP50 ir mAP50-95 vertes iš visų vaizdų tipų, pasiekdami 33% ir 30%.



4.1 pav. *YOLOv7* metrikų statistika melanino vaizdams

Iš 4.1 pav. galime matyti, kad per 100 epochų rėmų (angl. *box*) įvertis pasikeitė nuo 0.07 iki 0.03. Objektškumo (angl. *objectness*) grafike matomas pokytis nuo vertės didesnės už 1.5 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.4. Jautrumo įvertyje matomas pokytis nuo 0 iki 0.8. Validavimo rėmų (angl. *val box*) įvertis pasikeitė nuo 0.075 iki 0.050. Validavimo objektiškumo (angl. *val objectness*) pirminis įvertis siekia 0.6, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.026, kito iki 0.018. *mAP @0.5* kito nuo 0 iki 0.6. *mAP@05:0.95* kito nuo 0 iki 0.5. Galime matyti, kad iki 25 epochos melanino *YOLOv7* modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti žymiai mažesnius svyravimus šiuose srityse, tačiau

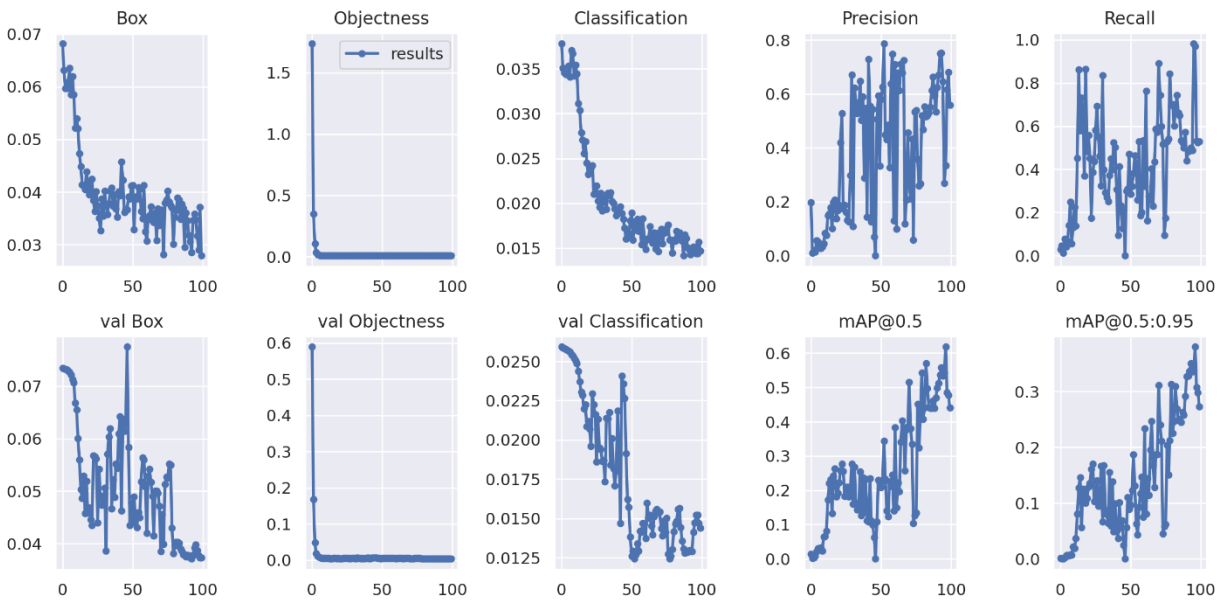
matosi, kad modelis tobulėja. Tikslumo, jautrumo ir *mAP* metrikos buvo labiausiai svyruojančios tarp epochų.



4.2 pav. YOLOv7 melanino susimaišymo matrica

Iš 4.2 pav. galime matyti, kad apgamas buvo supainiojama su piktybiniu šlaku santykiu 1:2, Seborėjinės keratozės visais atvejais buvo supainiojamos su fonu, melanoma buvo supainiojama su apgamu ir piktybiniu šlaku 5% atvejų, taip pat, supainiojama su fonu 14% atvejų. Dermatofibroma buvo supainiojama visais atvejais su fonu. Piktybinis šlakas buvo supainiojama melanoma 24% atvejų ir fonu 29% atvejų. Fonas buvo maišomas su piktybiniu šlaku ir melanoma.

Iš to, kad nesusiformavo įstrižainė matrica galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.



4.3 pav. *YOLOv7* metrikų statistika pilko melanino vaizdams

Iš 4.3 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 0.07 iki 0.03. Objektiškumo grafike matomas pokytis nuo vertės didesnės už 1.5 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0 iki artimo 1. Validavimo rėmų įvertis pasikeitė nuo 0.075 iki 0.04. Validavimo objektiškumo pirminis įvertis siekia 0.6, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.025, kito iki 0.0125. $mAP @0.5$ kito nuo 0 iki 0.6. $mAP@0.5:0.95$ kito nuo 0 iki 0.35.

Iki 25 epochos pilkojo melanino *YOLOv7* modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Tikslumo metrika tolygiai didėjo iki 40 epochos. Didžiausios metrikos vertės yra pasiekiamos 60-80 epochose. Artėjant link 100 epochos vertės

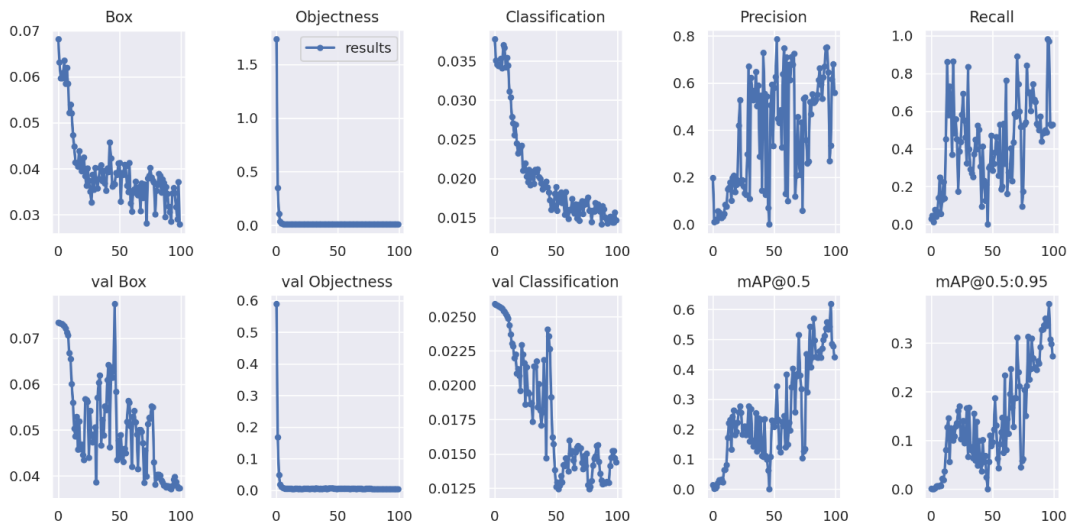
sumažėja. Jautrumo metrika tikslingai didėjo iki 10 epochos, nuo tada iki 60 epochos jautrumo metrikos labai svyruoja nuo virš 0.8 iki 0.01. Nuo 61 iki 100 epochos modelis įgauna stabilumą.



4.4 pav. YOLOv7 pilko melanino susimaišymo matrica

Iš 4.4 pav. galime matyti, kad apgamas ir seborėjinė keratozė visais atvejais buvo supainiojama su fonu. Melanoma buvo supainiojama su apgamu 4% atvejų, piktybinis šlakas 19% atvejų ir fonu – 23% atvejų. Dermafibrioma visais atvejais buvo supainiojama su fonu. Piktybinis šlakas buvo supainiojamas su melanoma 21% atvejų ir fonu 57% atvejų. Fonas buvo supainiojamas su melanoma ir piktybiniu šlaku. Iš to, kad nesusiformavo įstrižainė matrica ir mažo procento


teisingos melanomos atpažinimo, galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.



4.5 pav. *YOLOv7* metrikų statistika hemoglobino vaizdams

Iš 4.5 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 0.07 iki 0.03. Objektiškumo grafike matomas pokytis nuo vertės didesnės už 1.5 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0 iki artimo 1. Validavimo rėmų įvertis pasikeitė nuo 0.075 iki 0.04. Validavimo objektiškumo pirminis įvertis siekia 0.6, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.025, kito iki 0.0125. $mAP @0.5$ kito nuo 0 iki 0.6. $mAP@0.5:0.95$ kito nuo 0 iki 0.35. Galime matyti, kad iki 25 epochos hemoglobino *YOLOv7* modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Tikslumo

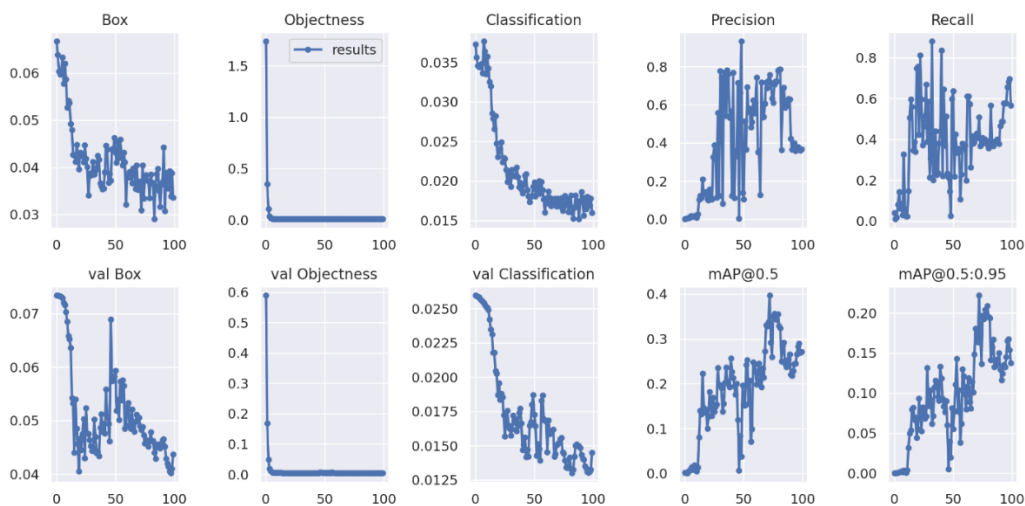
metrika svyruodama kyla iki 60 epochos tada pasiekia aukščiausią vertę tarp 60 ir 80 epochų. Jautrumo metrika seka panašia tendencija.



4.6 pav. YOLOv7 hemoglobino susimaišymo matrica

Apgamas 50% atvejų buvo supainiojamas su fonu. Seborėjinė keratozė visais atvejais buvo supainiojamas su fonu. Melanoma buvo supainiojama su piktybiniu šlaku 13% atvejų ir fonu 57% atvejų. Dermatofibroma visais atvejais buvo supainiojama su fonu. Piktybinis šlakas buvo supainiojama su melanoma 7% atvejų ir fonu – 93%. Fonas visais atvejais buvo supainiojamas su

Melanoma. Iš to, kad nesusiformavo įstrižainė matrica ir mažo procento teisingos melanomos atpažinimo, galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.




4.7 pav. *YOLOv7* metrikų statistika kolageno vaizdams

Iš 4.7 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 0.07 iki 0.03. Objektiškumo grafike matomas pokytis nuo vertės didesnės už 1.5 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0 iki artimo 0.8. Validavimo rėmų įvertis pasikeitė nuo 0.075 iki 0.04. Validavimo objektiškumo pirminis įvertis siekia 0.6, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.025, kito iki 0.0125. $mAP @ 0.5$ kito nuo 0 iki 0.4. $mAP @ 0.5:0.95$ kito nuo 0 iki 0.2.

Galime matyti, kad iki 25 epochos kolageno *YOLOv7* modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Tikslumo metrikos vertės iki 70 epochos išlieka gana pastovios, tik retkarčiais šiek tiek svyruoja. Šių epochų metu modelis pasiekė savo

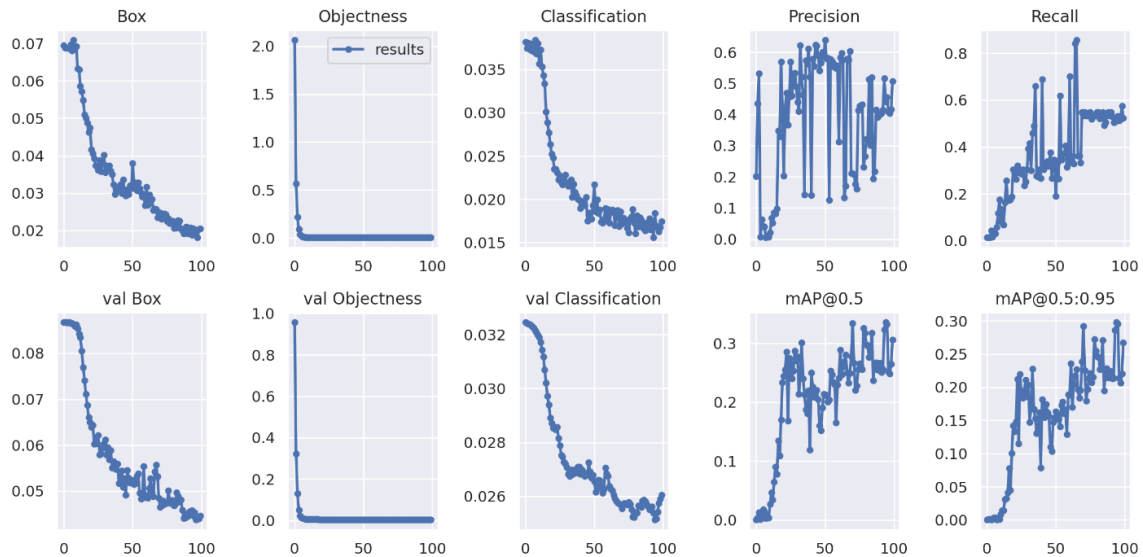
žemiausią (0.001) ir aukščiausią vertę (0.9) . Tikslumas pastebimai padidėja maždaug 70-80 epochose ir mažėja artėjant link 100 epochos. Jautrumo metrika seka panašia tendencija.



4.8 pav. YOLOv7 kolageno susimaišymo matrica

Iš 4.8 pav. galime matyti, kad apgamas ir seborėjinės keratozės visais atvejais buvo supainiojamas su fonu. Melanoma buvo supainiojama su apgamu 4% atvejų, piktybinis šlakas 12% atvejų ir fonu 50% atvejų. Dermatofibroma visais atvejais buvo supainiojama su Fonu. Piktybinis šlakas buvo supainiojama su melanoma 7% atvejų ir fonu 93% atvejų. Fonas visais atvejais buvo supainiojamas su melanoma. Iš to, kad nesusiformavo įstrižainė matrica ir mažo procento teisingos

melanomos atpažinimo, galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.



4.9 pav. YOLOv7 metrikų statistika odos melanino vaizdams

Iš 4.9 pav. matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 0.07 iki 0.02. Objektiškumo grafike matomas pokytis nuo vertės didesnės už 2 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.6. Jautrumo įvertyje matomas pokytis nuo 0 iki artimo 0.8. Validavimo rėmų įvertis pasikeitė nuo 0.085 iki 0.04. Validavimo objektiškumo pirminis įvertis siekia 0.9, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.032, kito iki 0.026. $mAP @0.5$ kito nuo 0 iki 0.3. $mAP@0.5:0.95$ kito nuo 0 iki 0.3. Galime matyti, kad iki 25 epochos odos melanino YOLOv7 modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti žymiai mažesnius svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja. Iš Tikslumo metrikos, galime

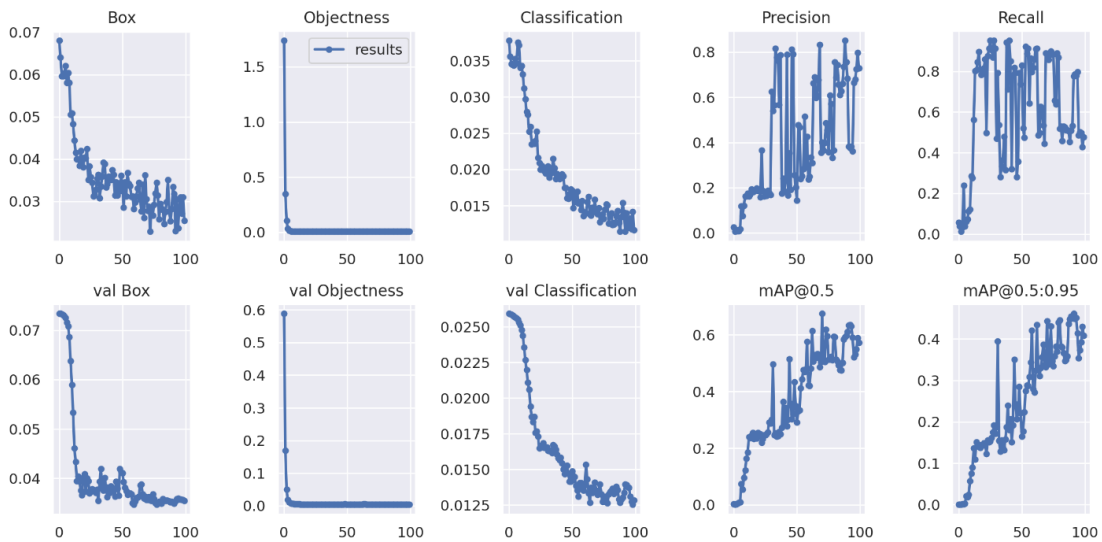
matyti, kad visose epochose nėra aiškios didėjimo ar mažėjimo tendencijos, o tai rodo, kad modelio našumas svyruoja. Jautrumo metrika seka panašia tendencija.



4.10 pav. YOLOv7 odos melanino susimaišymo matrica

Iš 2.10 pav. galime matyti, kad apgamas buvo supainiojamas su melanoma, dermatofibroma 12% atvejų. Taip pat buvo supainiojama su piktybiniu šlaku 62% atvejų. Seborėjinės keratozės visais atvejais buvo supainiojamos su fonu. Melanoma buvo supainiojama su apgamu 9% atvejų, taip pat piktybinis šlakas 18% ir fonu 45% atvejų. Dermatofibroma visais atvejais buvo supainiojama su fonu. Piktybinis šlakas buvo supainiojama su apgamu 8% atvejų, melanoma 46% atvejų ir fonu 38% atvejų. Fonas buvo supainiojamas su apgamu 20% atvejų, melanoma 40% atvejų ir piktybiniu šlaku 40% atvejų. Iš to, kad nesusiformavo įstrižainė matrica ir mažo procento teisingos

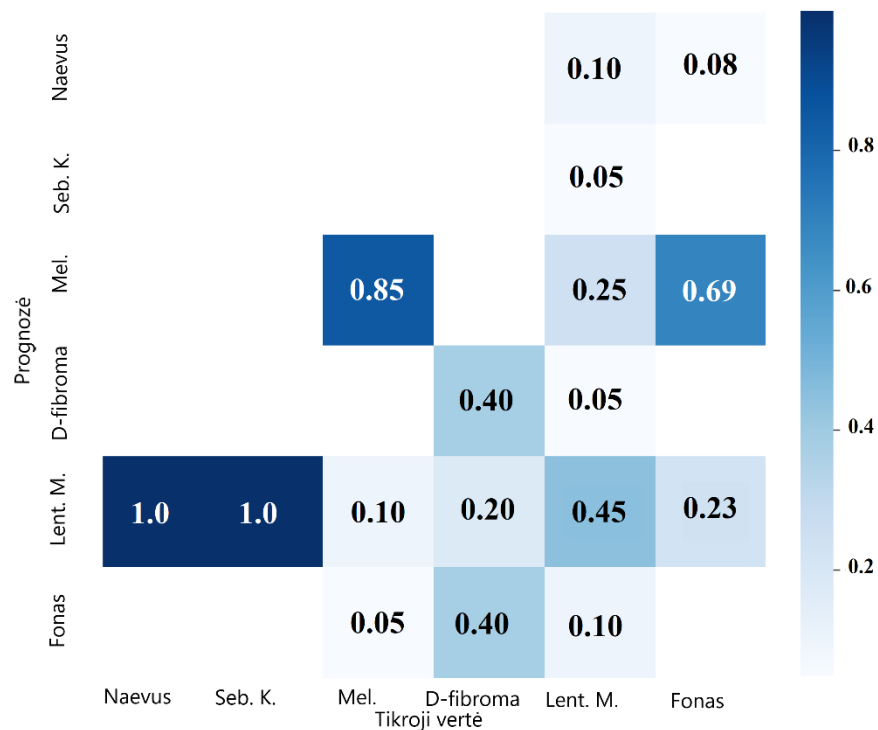
melanomos atpažinimo, galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.



4.11 pav. *YOLOv7* metrikų statistika suvidurkintiems vaizdams

Iš 4.11 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 0.07 iki 0.03. Objektiškumo grafike matomas pokytis nuo vertės didesnės už 1.5 iki vertės artimos 0. Klasifikavimo įvertis kito nuo 0.035 iki 0.015. Tikslumo įvertis keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0 iki artimo 0.8. Validavimo rėmų įvertis pasikeitė nuo 0.07 iki 0.04. Validavimo objektiškumo pirminis įvertis siekia 0.6, pasikeitė į artimą 0. Validavimo klasifikavimo pradinis įvertis 0.250, kito iki 0.125. $mAP @0.5$ kito nuo 0 iki 0.6. $mAP@05:0.95$ kito nuo 0 iki 0.4. Galime matyti, kad iki 25 epochos suvidurkintų vaizdų *YOLOv7* modelis stabiliai tobulėjo, o po jos prasidėjo svyravimai odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti žymiai mažesnius svyravimus šiuose srityse, tačiau matosi, kad

modelis tobulėja. Tikslumo vertės išlaiko santykinai pastovų intervalą viso mokymo metu, jautrumo metrika seka panašia tendencija.



4.12 pav. YOLOv7 suvidurkintų vaizdų susimaišymo matrica

Iš 4.12 pav. galime matyti, kad apgamas ir seborėjinės keratozės visais atvejais buvo supainiojamas su piktybiniu šlaku. Melanoma buvo supainiojama su piktybiniu šlaku 10% atvejų ir fonu 5% atvejų. Dermatofibroma buvo supainiojama su piktybiniu šlaku 20% atvejų ir fonu 40% atvejų. Piktybinis šlakas buvo supainiojama su apgamu 10% atvejų, seborėjinės keratozės 5% atvejų, melanoma 25% atvejų, dermatofibroma 5% atvejų ir fonu 10% atvejų. Fonas buvo supainiojamas su apgamu 8% atvejų, melanoma 69% atvejų ir piktybiniu šlaku 23% atvejų. Iš to, kad nesusiformavo įstrižainė matrica ir mažo procento teisingos melanomos atpažinimo, galime teigti, kad modelis nėra tinkamas odos darinių klasifikavimui ir aptikimui.

4.2. Eksperimentai atlikti su YOLOv8

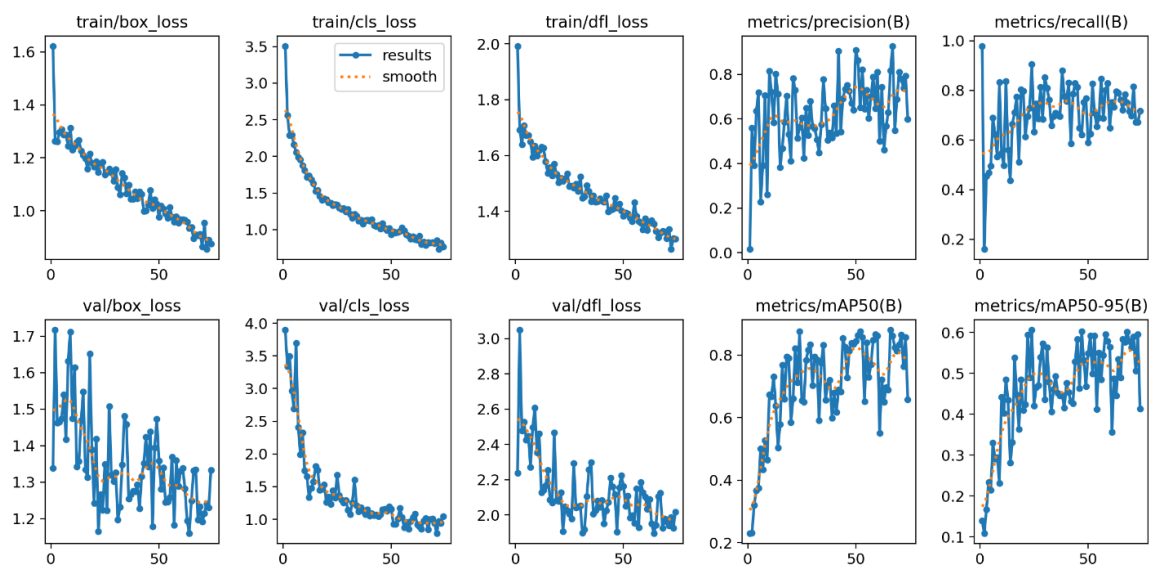
Melanino, pilko melanino, hemoglobino, kolageno, odos melanino ir suvidurkinti vaizdai buvo naudojami apmokyti šešis YOLOv8 modelius. Kiekvienas modelis buvo treniruotas 100 epochų.

4.2 lentelė. YOLOv8 vidutinio tikslumo rezultatų palyginimas

Modelis	<i>mAP50</i>	<i>mAP50-95</i>	Epocha
Melanino	0.8812	0.6032	3
Pilko melanino	0.7742	0.5211	2

Hemoglobino	0.8229	0.5039	3
Kolageno	0.7109	0.4235	3
Odos melanino	0.4745	0.4011	13
Suvidurkintas	0.8019	0.5865	6

YOLOv8 pasižymėjo geresniais rezultatais visose vaizdų tipuose. Didžiausią *mAP50* pasiekė melanino vaizdai (88%), paskui suvidurkinti vaizdai (80%). Tas pats buvo tiesa ir *mAP50-95* melanino vaizdai pasiekė 60%, o suvidurkinti - 58%. *YOLOv8* pasirodė geriau už *YOLOv7* su visais vaizdo tipais.



4.13 pav. *YOLOv8* statistika melanino vaizdams

Iš 4.13 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.6 iki 1.0. Klasifikavimo grafike matomas pokytis nuo 3.5 iki artėjančio link 0. Pasiskirstymo židinio nuostolių įvertis DFL (angl. *Distribution Focal Loss*) kito nuo 2.0 iki 1.3. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvartyje matomas pokytis nuo 1.0 iki 0.8. Validavimo rėžių įvertis pasikeitė nuo 1.7 iki 1.2. Validavimo tikslumo įvertis kito nuo 4.0 iki 1.0. Validavimo DFL įvertis keitėsi nuo 3.0 iki 2.0. *mAP50* kito nuo 0.2 iki 0.8. *mAP50:0.95* kito nuo 0.1 iki 0.6. Mokymo metu galime matyti stabilų *YOLOv8* modelio tobulėjimą odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja. Tikslumo metrikos

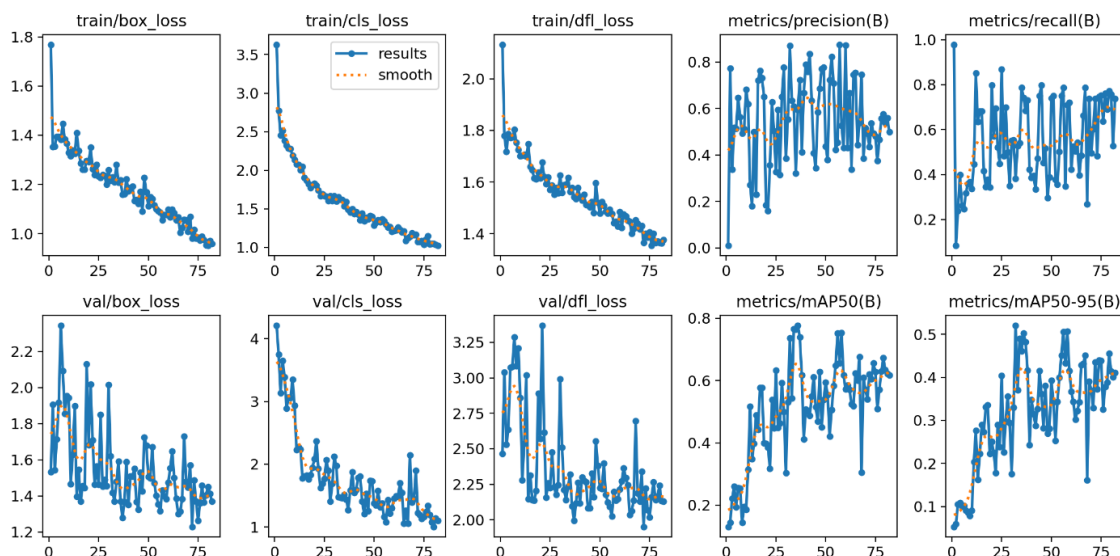
vertės svyravo mokymosi metu, bet pagrindinė tendencija buvo didėjimo, modelis aukščiausią vertę pasiekė tarp 50-55 epochų.



4.14 pav. YOLOv8 melanino susimaišymo matrica

Apgamas buvo supainiojamas su piktybiniu šlaku 50% atvejų. Seborėjinės keratozės visais atvejais buvo supainiojamos su fonu. Melanoma buvo supainiojama su apgamu 4% atvejų ir fonu 9% atvejų. Dermatofibroma buvo supainiojama su fonu 60% atvejų. Piktybinis šlakas buvo

supainiojama su apgamu ir melanoma 12% atvejų bei fonu 6% atvejų. Fonas buvo supainiojamas su apgamas 22% atvejų, melanoma 67% atvejų ir piktybiniu šlaku 11% atvejų.



4.15 pav. YOLOv8 statistika pilko melanino vaizdams

Iš 4.15 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.8 iki 1.0. Klasifikavimo grafike matomas pokytis nuo 3.5 iki artėjančio link 1. DFL įvertis kito nuo virš 2.0 iki 1.4. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 1.0 iki 0.4. Validavimo rėžių įvertis pasikeitė nuo 2.2 iki 1.2. Validavimo tikslumo įvertis kito nuo 4.0 iki 1.0. Validavimo DFL įvertis keitėsi nuo 3.25 iki 2.0. $mAP50$ kito nuo 0.2 iki 0.8. $mAP50:0.95$ kito nuo 0.1 iki 0.5. Mokymo metu galime matyti stabilų YOLOv8 modelio tobulėjimą odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti svyravimus šiuose srityse, tačiau

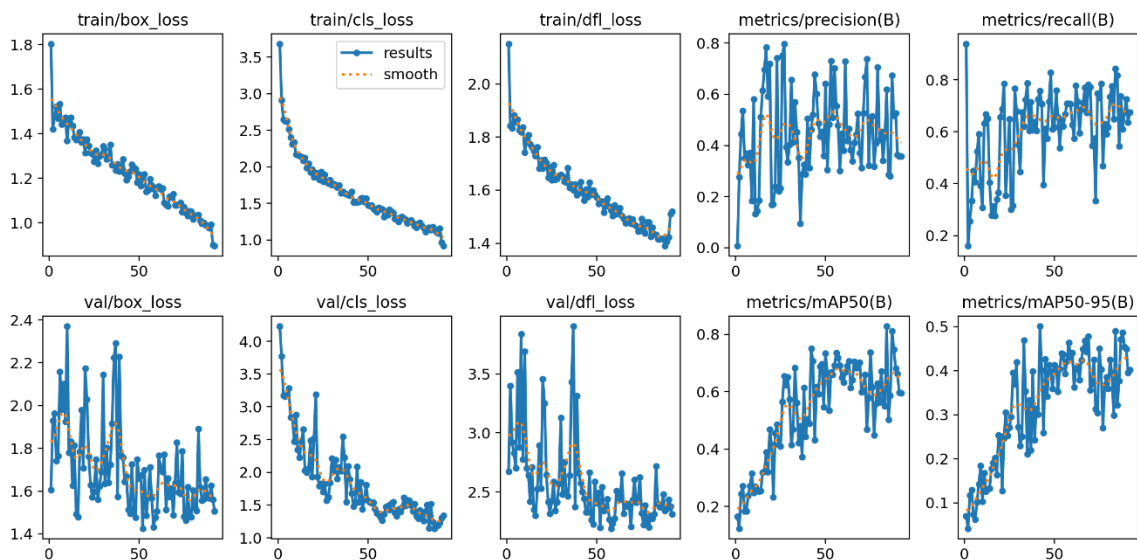
matosi, kad modelis tobulėja. Tikslumo metrikos atžvilgiu modelis stabiliai tobulėja iki 50 epochos, nuo 51 iki 70 pasiekia aukščiausias vertes.



4.16 pav. YOLOv8 pilko melanino susimaišymo matrica

Iš 4.16 pav. galime matyti, kad apgamas buvo supainiojamas su piktybiniu šlaku 50% atvejų. Seborėjinės keratozės buvo supainiojamos su piktybiniu šlaku visais atvejais. Melanoma buvo supainiojama su piktybiniu šlaku 26% atvejų ir fonu 4% atvejų. Dermatofibroma buvo supainiota su piktybiniu šlaku 60% atvejų ir fonu 40% atvejų. Piktybinis šlakas buvo supainiojamas su melanoma 19 % atvejų ir fonu 12% atvejų. Fonas buvo supainiojamas su melanoma 55% atvejų


ir piktybiniu šlaku 45% atvejų.



4.17 pav. *YOLOv8* statistika hemoglobino vaizdams

Iš 4.17 pav. *YOLOv8* statistika hemoglobino vaizdams galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.8 iki 1.0. Klasifikavimo grafike matomas pokytis nuo 3.5 iki artėjančio link 1. DFL įvertis kito nuo virš 2.0 iki 1.4. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0.9 iki 0.2. Validavimo rėžių įvertis pasikeitė nuo 2.4 iki 1.4. Validavimo tikslumo įvertis kito nuo 4.0 iki 1.0. Validavimo DFL įvertis keitėsi nuo 3.5 iki 2.25. *mAP50* kito nuo 0.2 iki 0.8. *mAP50:0.95* kito nuo 0.1 iki 0.5. Mokymo metu galime matyti stabilų *YOLOv8* modelio tobulėjimą odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti

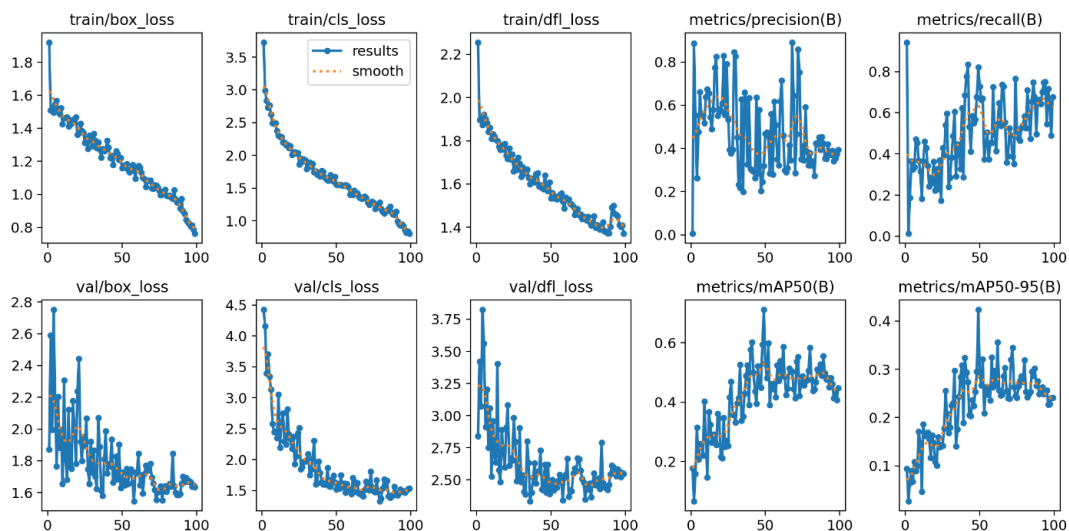
svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja. Tikslumo metrika svyruoja viso mokymosi metu o aukščiausią vertę pasiekia 16 epochoje.



4.18 pav. YOLOv8 hemoglobinas susimaišymo matrica

Pagal 4.18 pav. apgamas supainiojamas su Melanoma 50% atvejų. Seborėjinės keratozės visad buvo supainiojamos su apgamu. Melanoma buvo supainiojama su piktybiniu šlaku 19% atvejų ir fonu 14% atvejų. Dermatofibroma buvo supainiojama su piktybiniu šlaku. Piktybinis šlakas buvo

supainiojama su melanoma 6% atvejų ir fonu 6% atvejų. Fonas buvo supainiojamas su apgamu ir melanoma 15% atvejų ir piktybiniu šlaku 69% atvejų.



4.19 pav. *YOLOv8* statistika kolageno vaizdams

Iš 4.19 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.85 iki 0.8. Klasifikavimo grafike matomas pokytis nuo 3.5 iki artėjančio link 0.5. DFL įvertis kito nuo virš 2.2 iki 1.4. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0.9 iki 0.0. Validavimo rėžių įvertis pasikeitė nuo 2.8 iki 1.6. Validavimo tikslumo įvertis kito nuo 4.5 iki 1.5. Validavimo DFL įvertis keitėsi nuo 3.75 iki 2.5. *mAP50* kito nuo 0.0 iki 0.6. *mAP50:0.95* kito nuo 0.1 iki 0.4. Mokymo metu galime matyti stabilų *YOLOv8* modelio tobulėjimą odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja. Tikslumo metrikos atžvilgiu galime matyti, kad nepaisant tam tikrų

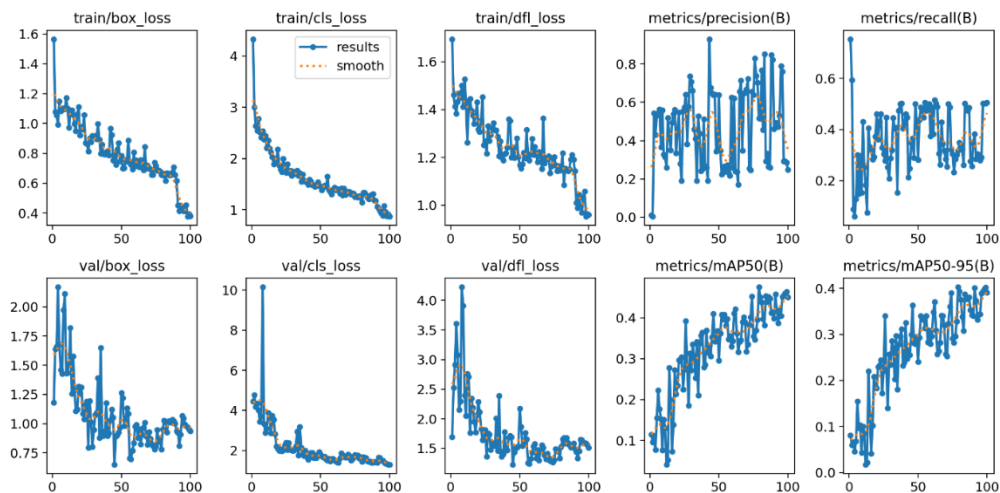
svyravimų, neatrodo, kad visose epochose būtų aiški tikslumo didėjimo ar mažėjimo tendencija. 100 epochų pabaigoje tikslumo reikšmės yra palyginti mažos, o jų vertė viršija 0.4.



4.20 pav. YOLOv8 kolageno susimaišymo matrica

Iš 4.20 pav. galime, matyti, kad apgamas buvo supainiojamas su melanoma 50% atvejų. Seborėjinės keratozės visad buvo supainiojamos su fonu. Melanoma buvo supainiojama su apgamu 10% atvejų, piktybinis šlakas 5% atvejų ir fonu 24% atvejų. Dermatofibroma supainiota su piktybiniu šlaku 20% atvejų ir fonu 40% atvejų. Piktybinis šlakas buvo supainiotas su apgamu

12% atvejų ir melanoma 6% atvejų bei fonu 19% atvejų. Fonas buvo supainiojamas su apgamu 33% atvejų ir piktybiniu šlaku 67% atvejų.



4.21 pav. YOLOv8 statistika odos melanino vaizdams

Iš 4.21 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.6 iki 0.4. Klasifikavimo grafike matomas pokytis nuo 4 iki artėjančio link 1. DFL įvertis kito nuo virš 1.6 iki 1.0. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 0.7 iki 0.2. Validavimo rėžių įvertis pasikeitė nuo 2.0 iki 0.75. Validavimo tikslumo įvertis kito nuo 10.0 iki 2.0. Validavimo DFL įvertis keitėsi nuo 4 iki 1.5. $mAP50$ kito nuo 0.1 iki 0.4. $mAP50:0.95$ kito nuo 0.1 iki 0.4. Mokymo metu galime matyti stabilų YOLOv8 modelio tobulėjimą odos darinių

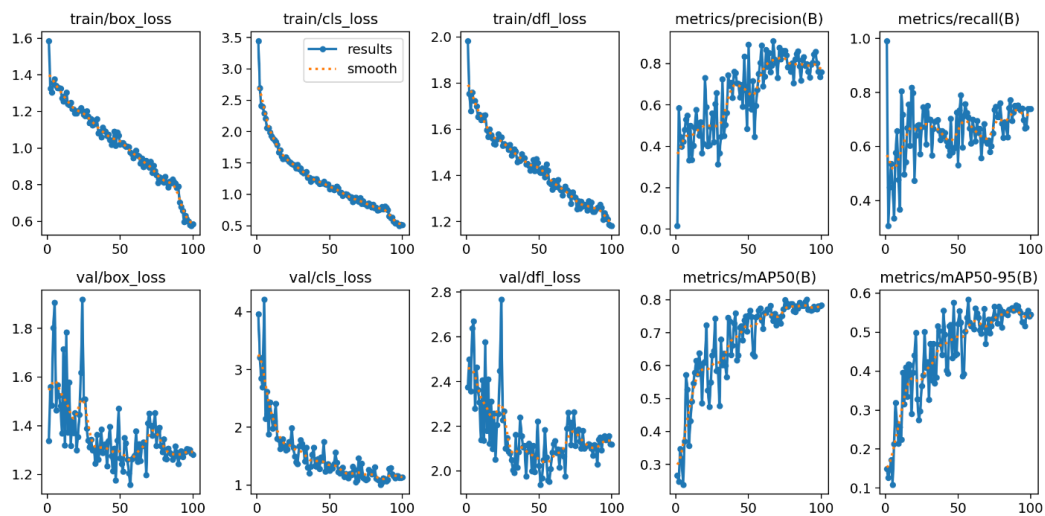
vietos aptikime ir klasifikavime. Validavimo metu galime matyti svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja.



4.22 pav. YOLOv8 odos melanino susimaišymo matrica

Iš 4.22 pav. galime matyti, kad apgamas buvo supainiotas su seborėjine keratoze ir piktybiniu šlaku 33% atvejų. Seborėjinės keratozės visad buvo supainiojama su piktybiniu šlaku. Melanoma buvo supainiota su apgamu 7% atvejų, piktybinis šlakas 33% atvejų ir fonu 27% atvejų. Dermatofibroma buvo supainiota su seborėjinės keratozėmis ir piktybiniu šlaku 50% atvejų.


Piktybinis šlakas buvo supainiojamas su melanoma 62% atvejų ir fonu 15% atvejų. Fonas buvo supainiojamas su apgamu 21% atvejų, melanoma 43% atvejų ir piktybiniu šlaku 36% atvejų.



4.23 pav. YOLOv8 statistika suvidurkintiems vaizdams

Iš 4.23 pav. galime matyti, kad per 100 epochų rėmų įvertis pasikeitė nuo 1.6 iki 0.6. Klasifikavimo grafike matomas pokytis nuo 3.5 iki 0.5. DFL įvertis kito nuo 2.0 iki 1.2. Tikslumo vertė keitėsi nuo 0 iki 0.8. Jautrumo įvertyje matomas pokytis nuo 1.0 iki 0.4. Validavimo režijų įvertis pasikeitė nuo 1.8 iki 1.2. Validavimo tikslumo įvertis kito nuo 4.0 iki 1.0. Validavimo DFL įvertis keitėsi nuo 2.6 iki 2.0. $mAP50$ kito nuo 0.3 iki 0.8. $mAP50:0.95$ kito nuo 0.1 iki 0.6. Mokymo metu galime

matyti stabilų *YOLOv8* modelio tobulėjimą odos darinių vietos aptikime ir klasifikavime. Validavimo metu galime matyti svyravimus šiuose srityse, tačiau matosi, kad modelis tobulėja.



4.24 pav. *YOLOv8* susimaišymo matrica suvidurkintiems vaizdams

Iš 4.24 pav. galime matyti, kad apgamas buvo supainiojamas su melanoma 50% atvejų. Seborėjinės keratozės nebuvo supainiotos su niekuo. Melanoma supainiojama su piktybiniu šlaku 13% atvejų ir fonu 4% atvejų. Dermatofibroma buvo supainiota su melanoma 20% atvejų ir piktybiniu šlaku 40% atvejų. Piktybinis šlakas supainiotas su melanoma 12% atvejų ir fonu 6% atvejų. Fonas buvo supainiotas su seborėjinės keratozėmis ir dermatofibroma 10% atvejų, melanoma ir piktybiniu šlaku 40% atvejų.

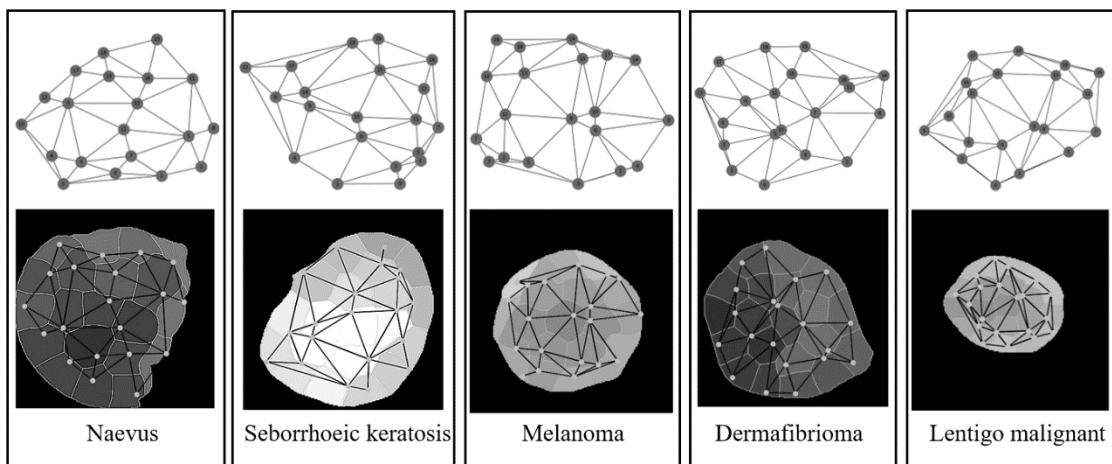
4.3. Eksperimentai atlikti su superpikselių grafų sistema ir atsitiktiniais miškais

Pirminė superpikselių grafų sistema paliko neapibrėžtumą grafų su svoriais sudaryme ir bruožų filtravime. Todėl eksperimentai atlikti su grafais, kurie neturi svorių, susitelkė ties bruožų filtravimu. Eksperimentai atlikti su grafais, kurie turi svorius, susitelkė, ties geriausių svorių radimu.

4.3.1. Eksperimentai su grafais be svorių dvejetainio modelio atveju

Pradinė grafų sistema turėjo paliktos vietos interpretacijai, kaip pvz.: bruožų genėjimui buvo skirtas tik sakiny, neapibrėžta kokios vertės ir funkcija buvo naudojama grafo briaunų svoriams paskaičiuoti. Todėl eksperimentai atlikti su be svoriais grafai susitelkė dėmesį į bruožų genėjimą.

Tam atlikti buvo pasitelkta SHAP (angl. *SHapley Additive exPlanations*) verčių paskaičiavimas ir filtravimas pagal priemaišos vidutinį sumažėjimo MDI (angl. *Mean Decrease Impurity*) vertę.

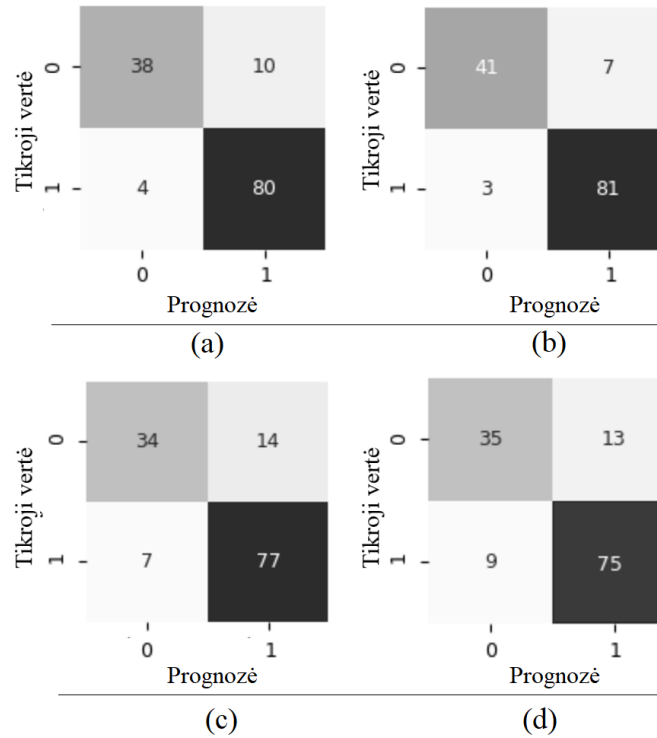


4.25 pav. Grafai pavaizduoti ant odos darinių

4.3 lentelė. Dviejų klasių ir grafo, kuris neturi svorių rezultatai

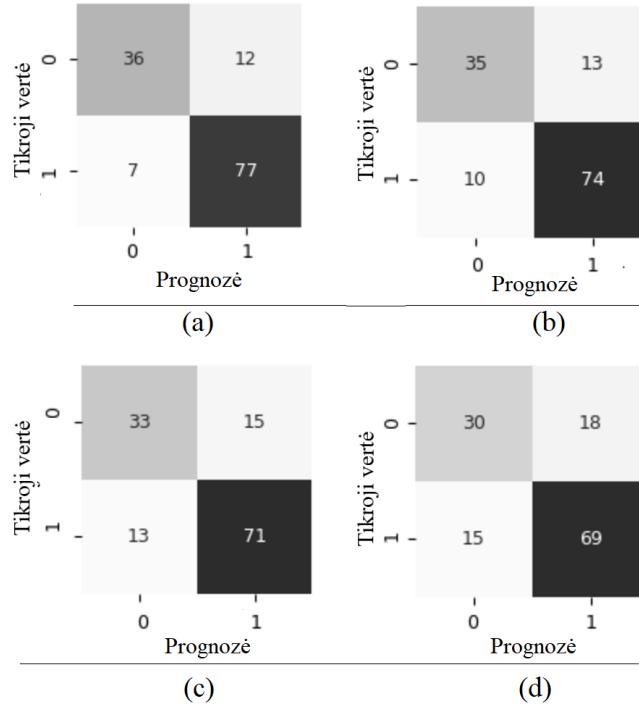
Metrika	Visi bruožai	Filtruoti su MDI	Filtruoti su SHAP
F1	0.9225	0.9478	0.9667
Tikslumas	0.8312	0.8530	0.9248

Galima daryti išvadą, kad didžiausias tikslumas ir geriausias F1 balas buvo gautas atrenkant požymius pagal SHAP sumos reikšmėms taikomą ribą. Priešingai, našumo rodikliai sumažėjo tais atvejais, kai buvo naudojami visi požymiai arba požymiai buvo atrenkami pagal ribą, nustatytą MDI reikšmėms (žr. 4.3 lent.)




4.26 pav. Dvejetainio klasifikavimo naudojant įvairias SHAP vertes supainiojimo matricos: (a) SHAP vertės ≥ 0.6690 ; (b) SHAP vertės ≥ 1.0028 ; (c) SHAP vertės ≥ 1.5259 ; (d) SHAP vertės ≥ 3.128 .

4.26 pav. parodo dvejetainio klasifikavimo modelio veikimą esant skirtingoms SHAP sumos vertėms. Modelis yra labiau linkęs daryti klaidas prognozuodamas ~1 klasę, tačiau bendras tikslumas yra palyginti didelis. Pastebėtina, kad geriausias našumas pasiektas naudojant SHAP sumos slenksčius, artimus 1, o tai yra geriau nei nustačius mažesnę SHAP reikšmių ribos reikšmę.



4.27 pav. Dvejetainio klasifikavimo naudojant įvairias MDI vertes supainiojimo matricos: (a) MDI vertės ≥ 0.003 ; (b) MDI vertės ≥ 0.004 ; (c) MDI vertės ≥ 0.005 ; (d) MDI vertės ≥ 0.01 .

Palyginimui, 4.27 pav. rodo, kad MDI reikšmių naudojimas požymių atrankai su didesnėmis ribomis neigiamai veikia prognozavimo rezultatus, nes pablogėja dviejų klasių diskriminacija. Kita vertus, nustačius palyginti mažą MDI ribą, mokymo modelyje galima panaudoti daugiau informacijos, tačiau jos vis tiek nepakanka, palyginti su rezultatais, pastebėtais, kai požymiams atrinkti buvo nustatytos formos suma pagrįstos ribos.



4.28 pav. F1 svorinės vertės dvinariai klasifikacijai naudojant MDI vertes kairėje, o SHAP vertes dešinėje

Galima pastebėti (žr. 4.28 pav.), kad svartinis F1 balas šiek tiek skiriasi esant skirtingoms SHAP vertėms, o tai laikome privalumu. Priešingai, svartinis F1 rodiklis yra labai jautrus MDI grindžiamų slenksčių koregavimui, o tai gali turėti įtakos modelio veikimo stabilumui.

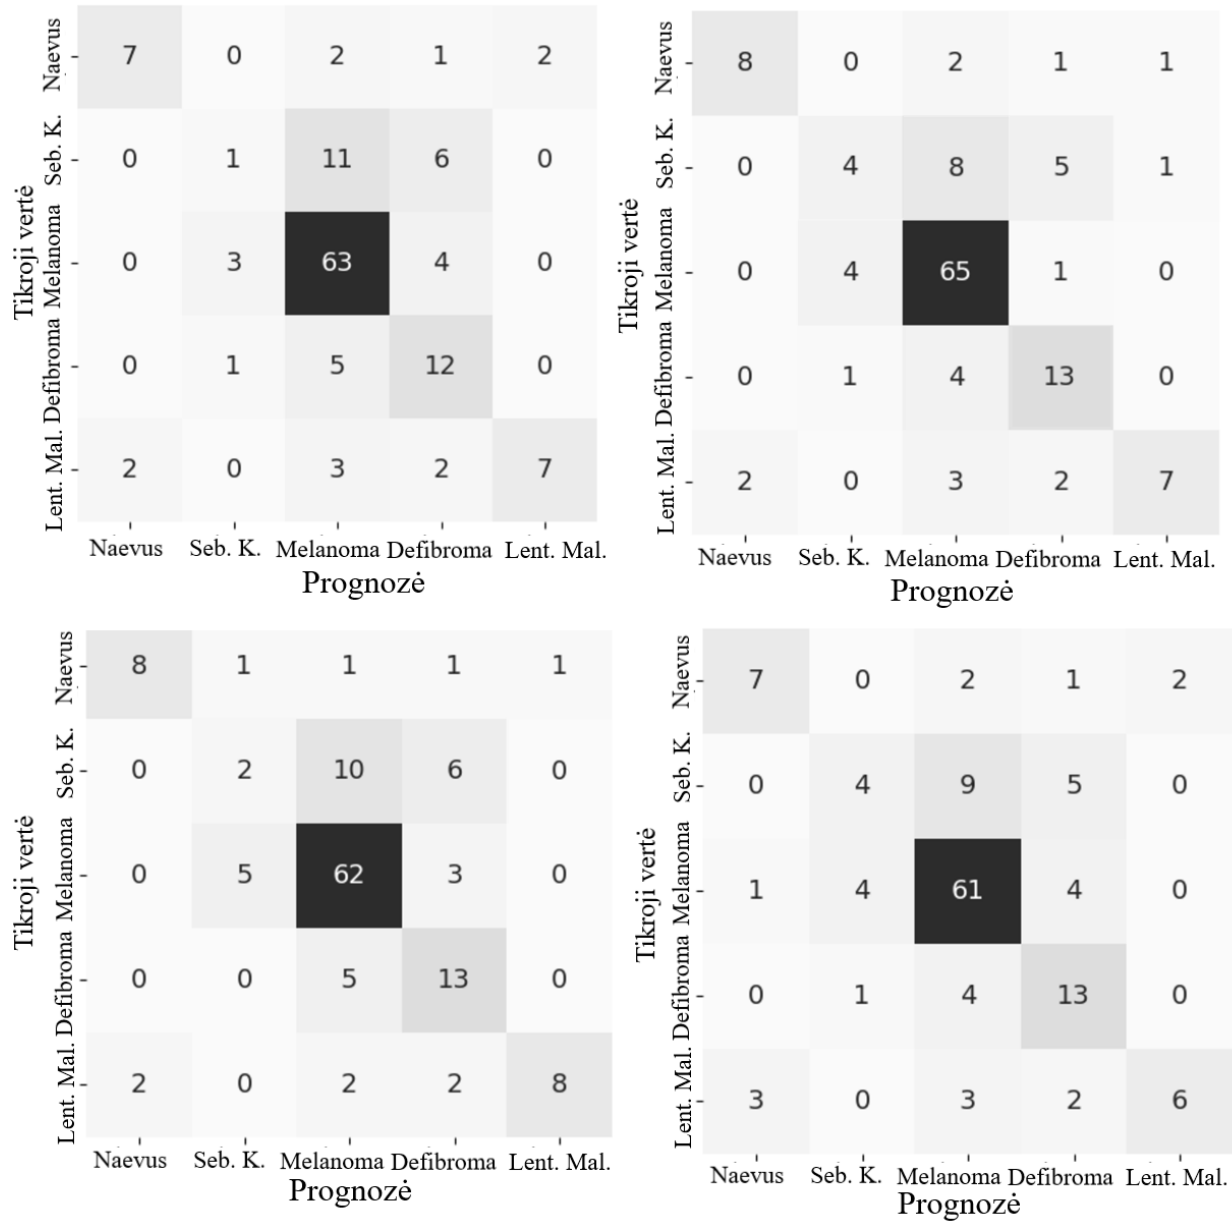
4.3.2. Eksperimentai su grafais be svorių daugiaklasio modelio atveju

Lyginant su dvejetainiu odos pažeidimų klasifikavimu, našumo rodikliai prastėja, o tai nestebina, nes didėjant klasių skaičiui didėja prognozavimo sunkumai.

4.4 lentelė. Penkių klasių ir grafo, kuris neturi svorių rezultatai.

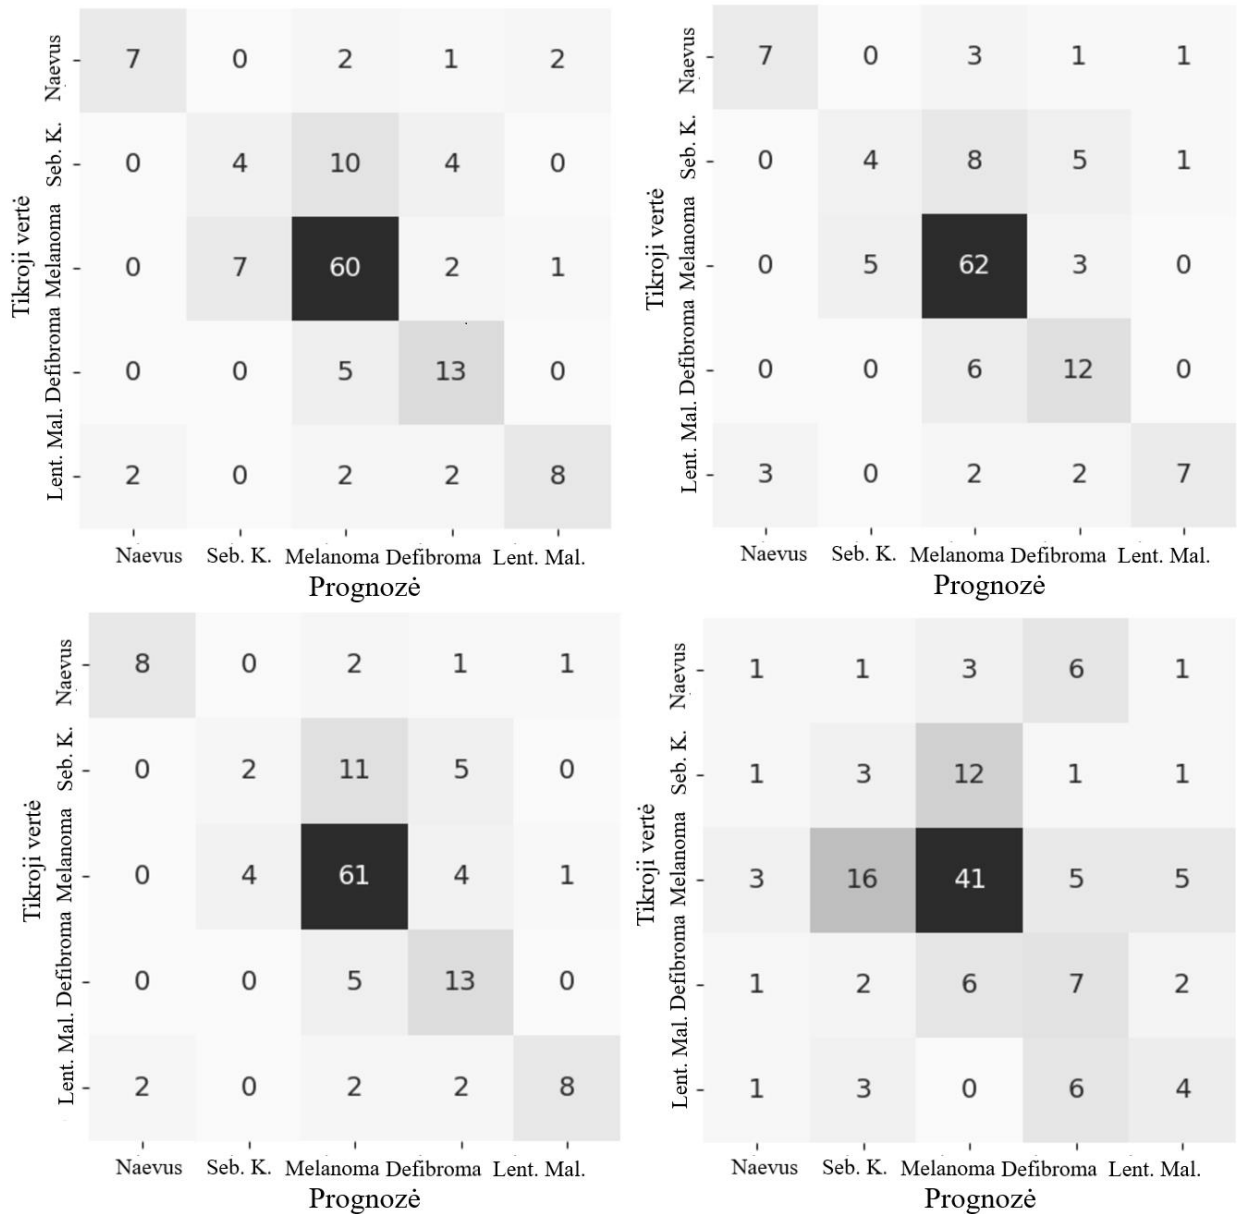
Metrika	Visi bruožai	Filtruoti su MDI	Filtruoti su SHAP
F1	0.6818	0.6970	0.7213
Tikslumas	0.6366	0.6818	0.7121

Akivaizdu, kad didžiausias tikslumas ir didžiausias F1 balas buvo pasiektas parenkant požymius per SHAP reikšmes. Ypač verta paminėti, kad gerokai pagerėjo F1 balas, kai požymiai buvo parinkti naudojant SHAP reikšmes, palyginti su scenarijumi, kai buvo naudojami visi požymiai. Galima numanyti, kad dėl perteklinių požymių arba pernelyg plataus požymių sąrašo prognozavimo rezultatai pablogėjo.



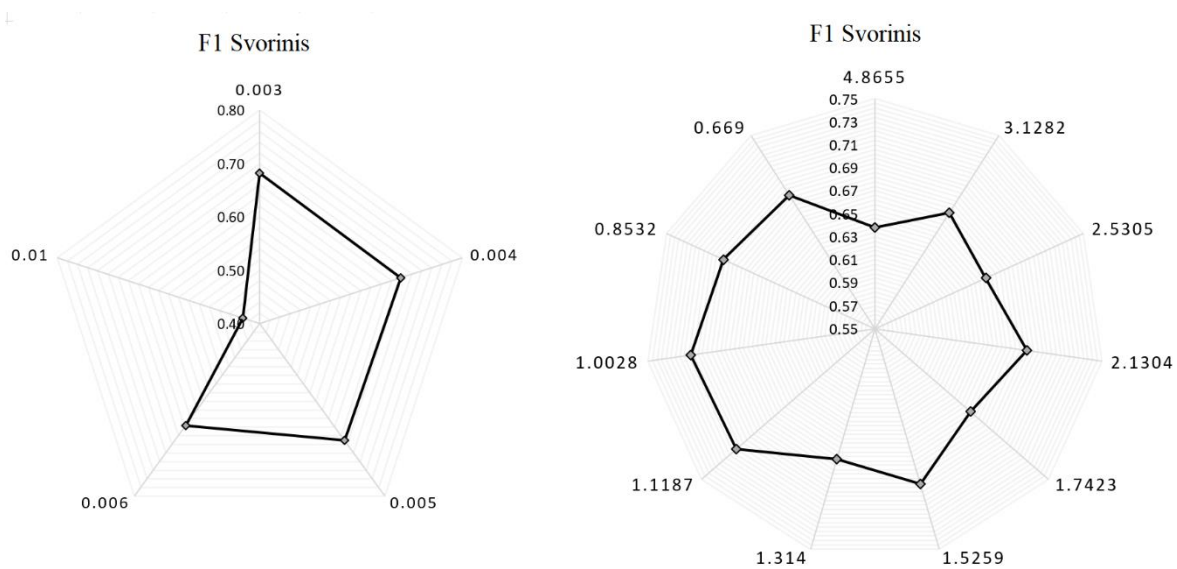
4.29 pav. Penkių klasių klasifikavimo naudojant įvairias SHAP vertes supainiojimo matricos

4.29 pav. įstrižainės elementai rodo, kad sukurtas modelis labai gerai prognozuoja odos pažeidimo tipą. Pažymėtina, kad modelis geriausiai veikia prognozuojant melanomą. Tačiau modelis susiduria su sunkumais prognozuodamas seborėjinę keratozę, kuri dažniausiai painiojama su melanoma ir rečiau su dermatofibroma. SHAP reikšmių viršutinės ribos koregavimas rodo, kad pernelyg aukštos ribos nustatymas gali būti ne optimalus. Tiksliau, kai riba yra per aukšta, tik nedidelis skaičius požymių atitinka kriterijus, o to nepakanka odos pažeidimo tipui nuspėti.



4.30 pav. Penkių klasių klasifikavimo naudojant įvairias MDI vertes supainiojimo matricos.

Iš 4.30 pav. paveikslo matyti, kad tuo atveju, kai požymiai buvo atrenkami taikant ribą pagal MDI vertę, diagnozės klaidingas klasifikavimas turėjo tendenciją didėti, palyginti su 4.31 pav. pateiktais rezultatais. Per didelės MDI ribos nustatymas lemia, kad prognozės tampa mažiau tikslios, o tam įtakos gali turėti per mažas požymių skaičius, reikalingas geram modelio veikimui.



4.31 pav. F1 svorinės vertės penkių klasių klasifikacijai naudojant MDI vertes kairėje, o SHAP vertes dešinėje

Ta pati tendencija pastebima ir šiuo atveju, t. y. svertinis F1 rodiklis pasižymi didesniu jautrumu MDI reikšmės pokyčiui nei scenarijaus, kai buvo naudojamos SHAP reikšmės, atveju.

4.3.3. Eksperimentų su grafais be svorių apibendrinimas

4.5 lentelė. Rezultatų apibendrinimams grafams be svorių.

Metrika	Dviejų klasių rezultatai		Penkių klasių rezultatai	
	Įprast. br.	Įprast. + graf. br.	Įprast. br.	Įprast. + graf. br.
Tikslumas	0.8439	0.9375	0.6390	0.7213
F1 Svorinis	0.8405	0.9248	0.6133	0.7121

4.5 lentelėje pateikimas superpikselių grafo požymių, naudotų mokant dvejetainį prognozavimo modelį ir 5 klasių prognozavimo modelį, poveikis. Savybių svarba buvo nustatoma tik pagal formos pagrindu nustatytus slenksčius. Kaip parodyta lentelėje, modelio veikimas gerokai pagerėjo dėl grafų pagrindu sukurtų požymių naudojimo, nes tikslumas padidėjo 1,11 (dvejetainis) ir 1,13 (kelių klasių), o svertinis F1 balas atitinkamai pakito 1,10 ir 1,16.

4.3.4. Eksperimentai su grafais kurie turi svorius

Su svoriniais grafais buvo žiūrima kaip svorių vertės įtakoja klasifikavimo kokybę. Dvejetainėje klasifikacijoje geriausias tikslumas buvo pasiektas tada kai klasifikavimu buvo naudota tik melanino vaizdo grafai kur svoriai sudaryti geometrinių savybių ir panaudota eksponentinė funkcija. Papildomi bruožai klasifikavimui buvo tik 25 dažnių domeno savybės, o mokymo ir patikrinimo duomenų imčių santykis buvo 75/25.

4.6 lentelė. Geriausias rezultatas pasiektas dvejetainiame klasifikavime.

Eksperimentas	Tikslumas	F1 dvejetainis	F1 mikro	F1 makro	F1 svorinis
Mel.	0.9167	0.9431	0.9167	0.8938	0.9137
Pilk. mel. ir mel.	0.9048	0.9344	0.9048	0.8803	0.9022
Kol. ir mel.	0.8929	0.9268	0.8929	0.8634	0.8891
Kol, pilk mel, hemo, mel.	0.8929	0.9256	0.8929	0.8671	0.8908
Mel ir odos mel.	0.8810	0.9180	0.8810	0.8503	0.8777
Visų spektrų.	0.8690	0.9091	0.8690	0.8375	0.8665
Pilk mel, hemo, mel.	0.8690	0.9091	0.8690	0.8375	0.8665
Hemo ir mel.	0.8690	0.9091	0.8690	0.8375	0.8665

4.6 lentelėje matome, kad papildomų spektrų pridėjimas pablogindavo prognozavimą ir metrikas. Pilko melanino spektro pridėjimas situaciją pablogino tik per 0.129, o visų spektrų panaudojimas per 0.477.

Antri geriausias tikslumas buvo pasiektas tada kai klasifikavimui buvo naudoti visi vaizdai išskyrus odos melanino. Grafų svoriai buvo sudaromi iš tekstūros savybių ir panaudota eksponentinė funkcija. Papildomi bruožai klasifikavimui buvo tik 25 dažnių domeno savybės, o mokymo ir patikrinimo duomenų imčių santykis buvo 90/10.

4.7 lentelė. Antras geriausias rezultatas pasiektas dvejetainiame klasifikavime.

Eksperimentas	Tikslumas	F1 dvejetainis	F1 mikro	F1 makro	F1 svorinis
Kol, pilk mel, hemo, mel.	0.9118	0.9412	0.9118	0.8824	0.9100
Kol. ir mel.	0.9118	0.9412	0.9118	0.8824	0.9100
Visų spektrų.	0.8824	0.9231	0.8824	0.8365	0.8773
Mel ir odos mel.	0.8529	0.9057	0.8529	0.7862	0.8424
Mel.	0.8529	0.9057	0.8529	0.7862	0.8424
Pilk mel, hemo, mel.	0.8529	0.9057	0.8529	0.7862	0.8424
Pilk. mel. ir mel.	0.8690	0.9091	0.8690	0.8375	0.8665
Hemo ir mel.	0.8690	0.9091	0.8690	0.8375	0.8665

4.7 lentelėje matome, kad nepanaudojamas odos melanino bruožų arba naudojimas tik kolageno ir melanino duoda rezultatus prastesnius tik per 0.049. Visų spektrų panaudojimas arba kitų ir melanino spektrų naudojimas rezultatams neleidžia perkopti 0.89.

Penkių klasių klasifikacijoje geriausias tikslumas buvo pasiektas tada kai klasifikavimu buvo naudota tik Melanino ir Kolageno spektrų vaizdų grafikų svoriai sudaryti iš geometrinių savybių ir panaudota eksponentinė funkcija. Papildomi bruožai klasifikavimui buvo tik 25 dažnių domeno savybės, o mokymo ir patikrinimo duomenų imčių santykis buvo 70/30.

4.8 lentelė. Geriausias rezultatas pasiektas penkių klasių klasifikavime

Eksperimentas	Tikslumas	F1 mikro	F1 makro	F1 svorinis
Kol. ir mel.	0.8081	0.8081	0.7278	0.7821
Visų spektrų.	0.7677	0.7677	0.6571	0.7307
Kol, pilk mel, hemo, mel.	0.7475	0.7475	0.6339	0.7085
Mel ir odos mel.	0.7374	0.7374	0.6508	0.7169
Pilk. mel. ir mel.	0.7374	0.7374	0.6594	0.7167
Mel.	0.7172	0.7172	0.6119	0.6827
Hemo ir mel.	0.7172	0.7172	0.6567	0.6934
Pilk mel, hemo, mel.	0.7071	0.7071	0.6321	0.6884

4.8 lent. matome, kad papildomų bruožų kurie nėra iš kolageno spektro pridėjimas pablogina prognozavimą ir metrikas, nuo 0.04 iki 0.11.

Antras geriausias tikslumas skiriantis tik per 0.006 buvo pasiektas tada kai klasifikavimu buvo naudota tik kolageno ir melanino vaizdų grafikų svoriai sudaryti iš geometrinių savybių ir panaudota eksponentinė funkcija, o mokymo ir patikrinimo duomenų imčių santykis buvo 75/25. Klasifikavimui buvo panaudoti visos 650 savybių iš abiejų spektrų.

4.9 lentelė. Antras geriausias rezultatas pasiektas penkių klasių klasifikavime

Eksperimentas	Tikslumas	F1 mikro	F1 makro	F1 svorinis
Kol. ir mel.	0.8017	0.8017	0.7453	0.7864
Kol, pilk mel, hemo, mel.	0.75	0.75	0.6204	0.7208
Mel ir odos mel.	0.7414	0.7414	0.6671	0.7257
Hemo ir mel.	0.7241	0.7241	0.5944	0.6944
Mel.	0.7155	0.7155	0.6144	0.6862
Pilk. mel. ir mel.	0.7069	0.7069	0.5665	0.6703
Pilk mel, hemo, mel.	0.7069	0.7069	0.5641	0.6705
Hemo ir mel.	0.6897	0.6897	0.5838	0.6783

4.9 lent. matome, kad papildomų bruožų kurie nėra iš kolageno spektro pridėjimas pablogina prognozavimą ir metrikas, nuo 0.05 iki 0.11.

4.4. Eksperimentų apibendrinimas

Palyginus rezultatus iš 4.1 lent. ir 4.2 lent. matome, kad *YOLOv8* pasižymėjo geresniais rezultatais nei *YOLOv7* visose vaizdų tipuose. Melanino vaizdai nuosekliai rodė didesnę *mAP50* ir *mAP50-95* rezultatą lyginant su kitais vaizdų tipais tiek *YOLOv7*, tiek *YOLOv8* atveju. Tai parodo spalvų informacijos svarbą objektų aptikimo uždavinyje. *YOLOv7* atveju odos melanino vaizdų aptikime pasirodė mažiausiai efektyvus *mAP* tik 33% iš visų vaizdų tipų, tai rodo, kad modelis gali susidurti su iššūkiais atpažindamas objektus šiame konkrečiame vaizdo tipe. *YOLOv8* sugebėdavo žymiai

greičiau pasiekti aukščiausius *mAP* įverčius, tam reikėdavo nuo 2 iki 13 epochų, o *YOLOv7* dažniausiai reikėdavo pereiti virš 90 epochų.

4.10 lentelė. Tikslumo metrikos klasifikacijai palyginimas *YOLO* modeliams

Modelis	<i>YOLOv7</i>	<i>YOLOv8</i>
Pilko Melanino	0.46	0.30
Suvidurkinto	0.54	0.62
Melanino	0.52	0.60
Odos melanino	0.40	0.15
Kolageno	0.36	0.49
Hemoglobino	0.19	0.21
Visi modeliai balsuoja	0.44	0.55

4.10 lent. matome, kad didžiausią tikslumo metriką pasiekė *YOLOv8*, klasifikuojant suvidurkintus vaizdus, o prasčiausią *YOLOv7* klasifikuojant hemoglobino vaizdus. Iš susimaišymo matricų pamatėme, kad *YOLOv8* dažniau maišosi tarp melanomos ir piktybinių šlakų klasių negu *YOLOv7*.

4.11 lentelė. Tikslumo metrikos klasifikacijai palyginimas grafų sistemai.

Grafai be svorių visi melanino bruožai	0.7714
Grafai be svorių genėta su MDI verte 0.003	0.8000
Grafai be svorių genėta su SHAP 300 verčių	0.8000
Grafai su svoriais visi melanino bruožai	0.8125
Grafai su svoriais melanino ir odos melanino	0.8437
Grafai su svoriais visi melanino bruožai 2 kl.	0.9687

4.11 lent. matome, kad grafų sistema pralenkė *YOLO* modelius klasifikavime. Superpikselių be svorių grafų sistema su atsitiktiniais miškais pasiekė geresnius rezultatus klasifikavime nei *YOLO* modeliai ir turėjo tikslumo vertę 0.7714, su bruožų genėjimų vertę pavyko padidinti iki 0.800, ty. per 0.0286. Grafų sistema su grafais kuriems sudaryti buvo naudojami svoriai pasižymėjo dar geresniais rezultatais nei be jų ir tikslumą padidino per 0.125. Papildomų spektrų įtraukimas dar labiau padidino tikslumą iki 0.8437. Klasifikavimo tik į gerybinius ir blogus odos darinius atveju buvo pasiektas 0.9687 tikslumas pasitelkiant tik svorinius grafus ir melanino spektro bruožus.

Išvados

1. Atlikus literatūros analizę metu buvo pastabėta, kad odos darinių klasifikavimo uždavinys yra gana plačiai sprendžiamas panaudojant skirtingus kompiuterinės regos algoritmus, tačiau dažnai naudojami skirtingi duomenų rinkiniai ir skirtingos vertinimo metrikos.
2. Tyrimo metu paruoštas 472 vaizdų duomenų rinkinys, kur kiekvienam paveikslėliui buvo sukurta dvejetainė kaukė, iš pradžių pasitelkiant *U-Net*, ir vėliau rankiniu būdu. Dalį kaukių reikėjo perdaryti, dėl prastos kokybės, kuri neleido formuoti grafų su 20 viršūnių.
3. Sukurtas suvidurkintas vaizdas, bei paskaičiuoti objektų rėmeliai siekiant išgauti geresnius rezultatus su *YOLO* architektūrų modeliais.
4. Darbe kiekvienam spektro vaizdui sukonstruoti grafai leido išgauti informatyvias vaizdo savybes reikalingas tikslesniam vaizdų klasifikavimo rezultatui išgauti.
5. Sukurta kompleksinė odos darinių apdorojimo sistema, kuri leidžia pasirinkti iš kelių spektrų imti duomenis bei atlikti klasifikavimą (binarinį arba daugia-klasinį) pasitelkiant sprendimų medžius.
6. Eksperimentų rezultatai parodė, kad didžiausio vidutinio tikslumo objekto vietos aptikimo metrikomis pasižymėjo melanino vaizdai, kur *YOLOv7* pasiekė 78% tikslumą, o *YOLOv8* 88% tikslumą.
7. Atlikti klasifikavimo eksperimentiniai rezultatai, penkių klasių atveju, parodė, kad *YOLOv8* pasiekė 62% tikslumą, tuo tarpu *YOLOv7* modelis pateikė 6% mažesnę tikslumą. Grafų sistema su atsitiktiniu miškų klasifikatoriumi pasižymėjo geresniais rezultatais nei giliojo mokymosi modeliai. Naudojant tik RGB vaizdus, ir grafų išgautas savybes buvo pasiektas 77% tikslumas. Atliktas savybių genėjimas leido pagerinti tikslumą 3% pasiekiant 80% tikslumą. Svorinių grafų realizavimas leido pagerinti tikslumą 4% ir pasitelkus papildomų spektrų savybių tikslumas toliau buvo pagerintas iki 84%.
8. Darbe odos darinių sistemos sukūrimui panaudotos giliojo mokymosi neuronų tinklų modeliai ir grafų sistema su atsitiktinių miškų klasifikatoriumi parodė, kad vaizdo apdorojimo technologijas galima sėkmingai taikyti odos darinių atpažinimui ir tokiu būdu palengvinti dermatologų darbą.

Literatūros sąrašas

1. Skin Cancer (Non-Melanoma): Introduction [interaktyvus] [žr. 2023-11-15] Prieiga per internetą: <https://www.cancer.net/cancer-types/skin-cancer-non-melanoma/introduction>
2. Davis, Lauren E et al. Current state of melanoma diagnosis and treatment. *Cancer biology & therapy* [interaktyvus]. PMC, August 2019, vol. **(20)**11 1366-1379 [žiūrėta 2014-10-28]. DOI: [10.1080/15384047.2019.1640032](https://doi.org/10.1080/15384047.2019.1640032)
3. 2024 Melanoma Facts & Statistics. [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per : <https://www.aimatmelanoma.org/facts-statistics/>
4. BHATT, Harsh, Vrunda SHAH, Krish SHAH, Ruju SHAH Manan SHAH. State-of-the-art machine learning techniques for melanoma skin cancer detection and classification: a comprehensive review. *Intelligent Medicine*. 2022, ISSN 2667-1026.
5. KHAN, ZUBER, TANAY SHUBHAM, and RAVI KUMAR ARYA. "Skin Cancer Detection Using Computer Vision." In *International Conference on Computational Techniques and Applications*, Singapore: Springer Nature Singapore, 2021. pp. 3- (https://link.springer.com/chapter/10.1007/978-981-19-0745-6_1.)
6. HERMOSILLA, PAMELA, RICARDO SOTO, EMANUEL VEGA, CRISTIAN SUAZO and JEFTÉ PONCE. Skin Cancer Detection and Classification Using Neural Network Algorithms: A Systematic Review. *Diagnostics* [interaktyvus]. February, 2024, vol. **14**(4), 454 [žiūrėta 2021-02-25]. <https://doi.org/10.3390/diagnostics14040454>
7. LI, ZHOUXIAO et al. Artificial Intelligence in Dermatology Image Analysis: Current Developments and Future Trends. *Journal of clinical medicine* [interaktyvus]. November 2022, vol. **11**(22) 6826. [žiūrėta 2024-05-04]. doi:10.3390/jcm11226826 <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9693628/>
8. LIUTKUS JOKUBAS, ARTURAS KRIUKAS, DOMINYKA STRAGYTE, ERIKAS MAZEIKA, VIDAS RAUDONIS, WOLFGANG GALETZKA, ANDREAS STANG ir SKAIDRA VALIUKEVICIENE. Accuracy of a Smartphone-Based Artificial Intelligence Application for Classification of Melanomas, Melanocytic Nevi, and Seborrheic Keratoses. *Diagnostics* [interaktyvus]. MDPI, June 2023, vol. 13(13) 2139 [žiūrėta 2024-05-04]. <https://doi.org/10.3390/diagnostics13132139>
9. Multispectral Image. [interaktyvus] [žiūrėta 2023-01-07]. Prieiga per internetą: <https://www.sciencedirect.com/topics/earth-and-planetary-sciences/multispectral-image>

10. AGGARWAL, Pushkar, A. PAPAY, Francis. Applications of multispectral and hyperspectral imaging in dermatology. *Experimental dermatology*. [interaktyvus] [žiūrėta 2023-01-07] Prieiga per: <https://onlinelibrary.wiley.com/doi/pdfdirect/10.1111/exd.14624>
11. CHITYALA, Ravishankar, Sridevi PUDIPEDDI. Image Processing and Acquisition using Python. Second Edition. Chapman and Hall/CRC: 2020. ISBN: 0367198088
12. QUINZÁN, Ianisse & CARMONA, Pedro & GARCÍA-SEVILLA, Pedro & BOLDO, Enrique & Pla, Filiberto & GARCÍA, Vicente & LOZOYA, Rafael & LUCÍA, Guillermo. (2012). Non-invasive Melanoma Diagnosis using Multispectral Imaging. *ICPRAM 2012 - Proceedings of the 1st International Conference on Pattern Recognition Applications and Methods*. 1. 386-393. Prieiga per: https://www.researchgate.net/profile/Vicente-Garcia-16/publication/230582591_Non-invasive_Melanoma_Diagnosis_using_Multispectral_Imaging/links/00b7d515d33989a5e6000000/Non-invasive-Melanoma-Diagnosis-using-Multispectral-Imaging.pdf
13. LIANG, Chenxue. *Multispectral Imaging Methods for the Diagnosis of Skin Cancer Lesions* [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per : https://upcommons.upc.edu/bitstream/handle/2117/103158/MScThesis_ChenxueLiang.pdf?sequence=1&isAllowed=y
14. GU, YANYANG, YI-PING PARTRIDGE, and JUN ZHOU. "A hyperspectral dermoscopy dataset for melanoma detection." In *OR 2.0 Context-Aware Operating Theaters, Computer Assisted Robotic Endoscopy, Clinical Image-Based Procedures, and Skin Image Analysis: First International Workshop, OR 2.0 2018, 5th International Workshop, CARE 2018, 7th International Workshop, CLIP 2018, Third International Workshop, ISIC 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16 and 20, 2018, Proceedings 5*, Springer International Publishing, 2018, pp. 268-276.
15. ARTURO, pardo, et al. On the spectral signature of melanoma: a non-parametric classification framework for cancer detection in hyperspectral imaging of melanocytic lesions. *Biomedical Optics Express*. [interaktyvus]. Optica, November 2018, vol. **9**(12), 6283–6301 [žiūrėta 2023-01-20]. doi: [10.1364/BOE.9.006283](https://doi.org/10.1364/BOE.9.006283)
16. LEON, Raquel, et al. Non-Invasive Skin Cancer Diagnosis Using Hyperspectral Imaging for In-Situ Clinical Support. *Journal of Clinical Medicine*. [interaktyvus]. June 2020, vol. **9**(6), 1662 [žiūrėta 2023-01-18]. doi: [10.3390/jcm9061662](https://doi.org/10.3390/jcm9061662)
17. KATO, Kana, et al. Performance Improvement of Automated Melanoma Diagnosis System by Data Augmentation. *Advanced Biomedical Engineering*. 2020, 9(1), 62-70. ISSN 2187-5219.
18. NIE, Y., P. SOMMELLA, M. O'NILS, C. LIGUORI AND J. LUNDGREN. Automatic Detection of Melanoma with Yolo Deep Convolutional Neural Networks. 2019 E-Health and

Bioengineering Conference (EHB), Iasi, Romania, 2019, pp. 1-4, https://www.researchgate.net/publication/337498273_Automatic_Detection_of_Melanoma_with_Yolo_Deep_Convolutional_Neural_Networks

19. AISHWARYA, N. et al. Skin Cancer diagnosis with Yolo Deep Neural Network. *Procedia Computer Science*. 2023, 220, 651-658. ISSN 1877.
20. ARBAYOMI-ALLI, Olusola OLUWAKEMI, Robertas DAMASEVICIUS, Sanjay MISRA, Rytis MASKELIUNAS and Adebayo ABAYOMI-ALLI. Malignant skin melanoma detection using image augmentation by oversampling in nonlinear lower-dimensional embedding manifold. *Turkish Journal of Electrical Engineering and Computer Sciences* [interaktyvus]. Menesis, 2021 vol. 29(8), 2600-2614 [žiūrėta 2024-05-04]. ISSN: 1300-063. Prieiga per: Tubitak. <https://doi.org/10.3906/elk-2101-133>
21. KHAN, M.A., SHARIF, M., AKRAM, T., DAMAŠEVIČIUS R. and MASKELIŪNAS, R. Skin Lesion Segmentation and Multiclass Classification Using Deep Learning Features and Improved Moth Flame Optimization. *Diagnostics*. [interaktyvus]. MDPI, April 2021, vol. 11(5), 811 [žiūrėta 2024-05-04]. <https://doi.org/10.3390/diagnostics11050811>
22. BIBI, SOBIA, MUHAMMAD ATTIQUE KHAN, JAMAL HUSSAIN SHAH, ROBERTAS DAMAŠEVIČIUS, AREEJ ALASIRY, MEHREZ MARZOUGUI, MAJED ALHAISONI, and ANUM MASOOD. MSRNet: Multiclass Skin Lesion Recognition Using Additional Residual Block Based Fine-Tuned Deep Models Information Fusion and Best Feature Selection. *Diagnostics*. [interaktyvus]. MDPI, September 2023, vol. 13(19), 3063 [žiūrėta 2024-05-04]. <https://doi.org/10.3390/diagnostics13193063>
23. ANNABY, M., H., et al. Melanoma Detection Using Spatial and Spectral Analysis on Superpixel Graphs. *J Digit Imaging*. [interaktyvus]. February 2021, vol. 34(1), 162-181 [žiūrėta 2021-02-25]. <https://doi.org/10.1007/s10278-020-00401-6>
24. Linear, Quadratic and Regularized Discriminant Analysis [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per: [https://www.datascienceblog.net/post/machine-learning/linear-discriminant-analysis/#:~:text=Linear%20discriminant%20analysis%20\(LDA\)%20is,non%2Dlinear%20separation%20of%20data](https://www.datascienceblog.net/post/machine-learning/linear-discriminant-analysis/#:~:text=Linear%20discriminant%20analysis%20(LDA)%20is,non%2Dlinear%20separation%20of%20data)
25. Support Vector Machine — Simply Explained [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per: <https://towardsdatascience.com/support-vector-machine-simply-explained-fee28eba5496>
26. HOWARD, J. and GUGGER, S. Deep Learning for Coders with Fastai and Pytorch: AI Applications Without a PhD, ISBN: 9781492045526. Prieiga per: https://github.com/fastai/fastbook/blob/master/09_tabular.ipynb

27. ADEGUN, A., VIRIRI, S. Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art. *Artif Intell Rev* [interaktyvus]. Springer Link, June, 2021, vol. **54**, 811–841[žiūrėta 2023-01-18]. <https://doi.org/10.1007/s10462-020-09865-y>
28. ALOUPOGIANNI, Eleni, et al. Hyperspectral and multispectral image processing for gross-level tumor detection in skin lesions: a systematic review. *Journal of Biomedical Optics* [interaktyvus]. June, 2022, 27(6) [žiūrėta 2023-01-18]. <http://doi.org/10.1117/1.JBO.27.6.060901>
29. ANDREW W.TRASK. Grokking deep learning. Manning Publications: 2019. ISBN: 1617293709
30. CHANG, JING & JIN, SHA. (2017). An efficient implementation of 2D convolution in CNN. *IEICE Electronics Express*. 14. 20161134-20161134. Prieiga per: https://www.researchgate.net/publication/312438814_An_efficient_implementation_of_2D_convolution_in_CNN
31. HOSSEIN GHOLAMALINEZHAD and HOSSEIN KHOSRAVI. Pooling Methods in Deep Neural Networks, a Review. [interaktyvus] [žiūrėta 2021-02-23] . Prieiga per: <https://arxiv.org/ftp/arxiv/papers/2009/2009.07485.pdf>
32. Transposed Convolution Demystified [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per: [intelligence.com/transposed-convolution-demystified-84ca81b4baba](https://www.intelligence.com/transposed-convolution-demystified-84ca81b4baba) ???
33. SRIVASTAVA, N. ir kt. Dropout: a simple way to prevent neural networks from overfitting. In *Journal of Machine Learning Research* [interaktyvus]. 2014. Vol. 15, no. 1, p. 1929–1958. Prieiga per: <https://www.cs.toronto.edu/~rsalakhu/papers/srivastava14a.pdf>
34. IOFFE, SERGEY and SZEGEDY, CHRISTIAN, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. Prieiga per: <https://arxiv.org/abs/1502.03167>
35. Why do you need non linear activation functions. 2020. [interaktyvus] [žiūrėta 2021-05-16]. Prieiga per: <https://www.coursera.org/learn/neural-networks-deep-learning/lecture/OASKH/why-do-you-need-non-linear-activation-functions>
36. Layer activation functions. 2020. [interaktyvus] [žiūrėta 2021-05-16]. Prieiga per internetą: <https://keras.io/api/layers/activations/>
37. RONNEBERGER, O., FISCHER, P., and BROX, T. 2015 U-net: Convolutional networks for biomedical image segmentation. [interaktyvus] [žiūrėta 2021-02-23]. Prieiga per: <https://arxiv.org/pdf/1505.04597>

38. REDMON, JOSEPH, SANTOSH DIVVALA, ROSS GIRSHICK, and ALI FARHADI. "You only look once: Unified, real-time object detection." In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, pp. 779-788.
39. TERVEN, Juan, Diana-Margarita CÓRDOVA-ESPARZA, and Julio-Alejandro ROMERO-GONZÁLEZ. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. [interaktyvus]. MDPI, November 2023, vol. 5(4), 1680-1716. [žiūrėta 2021-02-23] <https://doi.org/10.3390/make5040083>
40. MICHALSKA M., CHODOROWSKA G. and KRASOWSKA D. SIAscopy--a new non-invasive technique of melanoma diagnosis. *Ann Univ Mariae Curie Skłodowska Med*. 2004, vol. 59(2):421-31. PMID: 16146122
41. EMERY, J.D., Hunter, J., HALL, P.N. *et al*. Accuracy of SIAscopy for pigmented skin lesions encountered in primary care: development and validation of a new diagnostic algorithm. [interaktyvus] *BMC Dermatol*, September, 2010, vol. 10(9) [žiūrėta 2014-10-28]. <https://doi.org/10.1186/1471-5945-10-9>
42. OLIVEIRA, R.B., PEREIRA, A.S. & TAVARES, J.M.R.S. Computational diagnosis of skin lesions from dermoscopic images using combined features. *Neural Comput & Applic*. [interaktyvus] Springer link, March, 2019, vol. 31, 6091–6111 [žiūrėta 2014-10-28]. <https://doi.org/10.1007/s00521-018-3439-8>