



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Kompiuterinės regos metodų, skirtų lokalių odos reakcijų stebėsenai atlikti, tyrimas

Baigiamasis magistro projektas

Vaiva Paškevičiūtė

Projekto autorė

Prof. Dr. Vidas Raudonis

Vadovas

Kaunas, 2026



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Kompiuterinės regos metodų, skirtų lokalių odos reakcijų stebėsenai atlikti, tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Vaiva Paškevičiūtė

Projekto autorė

Prof. Dr. Vidas Raudonis

Vadovas

Asist. Dr. Julius Gelšvartas

Recenzentas

Kaunas, 2026



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Vaiva Paškevičiūtė

Kompiuterinės regos metodų, skirtų lokalių odos reakcijų stebėsenai atlikti, tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Vaiva Paškevičiūtė

Patvirtinta elektroniniu būdu

Paškevičiūtė, Vaiva. Kompiuterinės regos metodų, skirtų lokalių odos reakcijų stebėsenai atlikti, tyrimas. Magistro baigiamasis projektas / vadovas prof. Vidas Raudonis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypties grupė): Elektronikos inžinerija. Inžinerijos mokslai.

Reikšminiai žodžiai: YOLOv12, giluminis mokymasis, dermatologinių vaizdų analizė, odos ligų segmentavimas, odos alergijos, dirbtinis intelektas medicinoje .

Kaunas, 2026. 70p.

Santrauka

Šiame darbe nagrinėjamas dirbtinio intelekto metodo taikymas dermatologinių vaizdų analizėje, orientuojantis į algoritmo tyrimą skirtą odos reakcijų lokalizavimui ir vertinimui. Tyrimo tikslas – įvertinti giliojo mokymosi modelių gebėjimą identifikuoti odos reakcijos požymius ir palyginti skirtingų modelių struktūrų veiksmingumą.

Algoritmų kokybei įvertinti buvo taikytos IoU (Intersection over Union) ir Dice score metrikos, leidžiančios kiekybiškai įvertinti prognozuojamų segmentų ir anotacijų persidengimą. Atlikta eksperimentinių rezultatų analizė suteikė galimybę palyginti skirtingų struktūrų modelių tikslumą ir jų tinkamumą praktiniam pritaikymui. Tyrime analizuojama, kaip skirtingi duomenų rinkiniai veikia modelių gebėjimą atpažinti patologinius odos pokyčius.

Baigiamąjį darbą sudaro šios pagrindinės dalys: literatūros analizė, duomenų paruošimas ir apdorojimas, modelių mokymas bei eksperimentinis tyrimas. Literatūros analizės dalyje nagrinėjami giliojo mokymosi metodai ir jų taikymas dermatologijoje. Eksperimentinio tyrimo dalyje pateikiami atlikti skaičiavimai, modelių palyginimai ir gautų rezultatų analizė. Darbo pabaigoje pateikiamos išvados ir apibendrinami tyrimo rezultatai.

Paškevičiūtė, Vaiva. Research of computer vision methods for monitoring local skin reactions. Master's Final Degree Project / supervisor prof. Vidas Raudonis, Faculty of Electrical and Electronics Engineering Kaunas University of Technology.

Study field and area (study field group): Electronics engineering. Engineering science.

Keywords: YOLOv12, deep learning, dermatological image analysis, skin lesion segmentation, skin allergies, artificial intelligence in medicine.

Kaunas, 2026. 70 pages.

Summary

This thesis investigates the application of artificial intelligence methods in the analysis of dermatological images, with a particular focus on the development and evaluation of an algorithm designed for the localization and assessment of skin reactions. The aim of the study is to evaluate the ability of deep learning models to identify features of skin reactions and to compare the effectiveness of different model architectures.

To assess the performance of the algorithms, the Intersection over Union (IoU) and Dice score metrics were employed, enabling a quantitative evaluation of the overlap between predicted segments and ground truth annotations. The analysis of experimental results provided insights into the accuracy of different model architectures and their suitability for practical applications. The study also examines how different datasets influence the models' ability to detect pathological skin changes.

The thesis consists of the following main parts: literature review, data preparation and processing, model training, and experimental analysis. The literature review discusses deep learning methods and their applications in dermatology. The experimental section presents the performed computations, model comparisons, and analysis of the obtained results. The thesis concludes with a summary of the findings and final conclusions.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	9
Ivadas	10
1. Literatūros apžvalga	12
1.1. Kontaktinė odos reakcija (KOR) – epidemiologija ir patofiziologija	12
2. Tradiciniai odos lopo testų metodai ir diagnostiniai iššūkiai	14
2.1. Odos lopo testų metodika ir taikymas	14
3. Kompiuterinė rega medicinoje	19
3.1. Vaizdo analizės, DI, ir jutiklių taikymas medicinoje	19
3.2. Giluminio mokymosi tyrimai ir taikymas odos ligų diagnostikoje	20
3.3. Išvados	22
4. Dirbtinio intelekto metodo metodologijos ir architektūros analizė	24
4.1. YOLO architektūros modeliai	24
4.2. Pasirinkto modelio architektūra	24
4.2.1. Stuburo tinklas (Backbone)	25
4.2.2. Kaklo architektūra (Neck)	26
4.2.3. Galvos architektūra (Head)	27
4.3. Naudotos metrikos ir matematinės lygtys	27
4.3.1. Segmentavimo modelio vertinimo metrikos ir jų matematinis pagrindas	27
4.3.2. Odos spalvinių pokyčių matematinis vertinimas naudojant ΔE pagrindu gautą koeficientą ir jo matematinis pagrindimas	30
5. Eksperimentinis tyrimas	35
5.1. Tyrimo etapai ir eiga	35
5.2. Duomenų apdorojimas ir paruošimas	37
5.3. Kontūrų radimas	40
5.4. Modelių mokymas	40
5.5. Alergijos pažeistos odos vaizdų paruošimas	41
5.6. Alergijos paveiktos odos aptikimas, aerginės reakcijos radimas ir klasifikavimas	42
6. Rezultatai	51
6.1. Sveikos odos segmentavimo rezultatai	51
6.1.1. YOLOv12s-seg (small) modelio rezultatų analizė	51
6.1.2. YOLOv12m-seg (medium) modelio rezultatų analizė	52
6.1.3. YOLOv12l-seg (large) modelio rezultatų analizė	52
6.1.4. Bendras modelių palyginimas ir rezultatų interpretacija	53
6.2. Alergijos paveiktos odos segmentavimo ir detekcijos rezultatai	54
6.2.1. 1 paciento (ID: 2022091) rezultatų analizė	55
6.2.2. 2 paciento (ID: 2022092) rezultatų analizė	56
6.2.3. 3 paciento (ID: 2022093) rezultatų analizė	57
6.2.4. 4 paciento (ID: 2022094) rezultatų analizė	58
6.2.5. 5 paciento (ID: 2022095) rezultatų analizė	58
6.2.6. Naudoto metodo ir žmogaus tikslumo palyginimas	59
6.2.7. Rezultatų apibendrinimas	61
Išvados	65
Literatūros sąrašas	67

Lentelių sąrašas

1 lentelė. Pacientų sveikos odos koeficiento reikšmės.....	45
2 lentelė. Gautų rezultatų metrikų palyginimas.	51
3 lentelė. Gauti rezultatai ir jų palyginimas.	60

Paveikslų sąrašas

1 pav. Alerginis kontaktinis dermatitas [8].	12
2 pav. Alergenų lopo testas [22].	14
3 pav. Suregavusios odos pavyzdys [24].	15
4 pav. ALT pavyzdžiai, (A, C, E) bendras odos vaizdas ir iškirptos suregavusios odos nuotraukos (B, D, F).	17
5 pav. Odos reakcijos vertinimas	18
6 pav. YOLOv12 architektūra [55].	26
7 pav. Matematiškai gautų reikšmių ir odos reakcijų palyginimas.	32
8 pav. Didelės, vidutinės ir mažos alerginių reakcijų pavyzdžiai nustatyti žmogaus.	33
9 pav. Pirminio sveikos odos segmentavimo tyrimo etapų atvaizdavimas schema.	35
10 pav. Schema kurioje yra atvaizduoti tolimesni tyrimo etapai.	36
11 pav. Sveikos odos nuotraukų naudotų mokyme pavyzdys.	37
12 pav. Pixel anotation programine įranga žymimi tinkamos odos kontūrai.	38
13 pav. Sukurtos kaukės.	39
14 pav. Odos reakcijų pavyzdžiai.	39
15 pav. Paciento nuotraukos kuriose matoma alerginė reakcija praėjus laiko intervalams.	42
16 pav. Aptikti juodi medicinos darbuotojo sužymėti taškai.	43
17 pav. Sveikos odos aptikimas.	43
18 pav. Aptiktos sveikos odos iškirpimas ir panaudojimas.	44
19 pav. Sveikos odos iškirptų nuotraukų naudojamų koeficiento nustatymui pavyzdys.	45
20 pav. Automatiškai iškripti alergijos paveiktos odos vaizdiniai mėginiai.	46
21 pav. Automatiškai iškripti antro pleistro alergijos paveiktos odos vaizdiniai mėginiai.	47
22 pav. Automatiškai iškripti trečio pleistro alergijos paveiktos odos vaizdiniai mėginiai.	47
23 pav. Alerginės reakcijos paveiktos odos lopų iškirpimo iš nuotraukų algoritmo veikimo paaiškinimo schema.	48
24 pav. Alergijos paveiktos odos iškarpių pavyzdys.	50
25 pav. Paciento: 2022091 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.	55
26 pav. Paciento: 2022092 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.	56
27 pav. Paciento: 2022093 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.	57
28 pav. Paciento: 2022094 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.	58
29 pav. Paciento: 2022095 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.	59
30 pav. Dirbtinio intelekto priskirta odos reakcijos sudėtingumo kategorija.	60
31 pav. Žmogaus priskirta odos reakcijos sudėtingumo kategorija.	61
32 pav. Visų tirtų pacientų pavyzdinės nuotraukos ir jų sveikos odos koeficientai.	63

Santrumpų ir terminų sąrašas

Santrumpos:

AI. – dirbtinis intelektas

DNN. – dirbtiniai neuroniniai tinklai

ALT. – alerginių lopo testų (Allergic Patch Testing) metodika

SSD. – Single Shot Detector (vieno etapo objektų aptikimo modelis)

CNN. – Convolutional Neural Network (konvoliucinis neuroninis tinklas)

RetinaNet. – vieno etapo objektų aptikimo neuroninis tinklas, naudojantis Focal Loss

SVM. – Support Vector Machine (atrankinių vektorių metodas klasifikacijai ir regresijai)

YOLOv12. – You Only Look Once version 12 (vieno praėjimo objektų aptikimo modelis)

IoU. – Intersection over Union (persidengimo koeficientas)

mAP. – mean Average Precision (vidutinė tikslumo metrika objektų aptikimui)

CIELAB. – Lab spalvų erdvė (percepcinis spalvų modelis)

ΔE . – Delta E (spalvų skirtumo metrika)

ΔC . – Delta chroma (chromatiškumo skirtumas)

Dice score. – Dice Similarity Coefficient (segmentacijos panašumo koeficientas)

GPU. – Graphics Processing Unit (grafinis procesorius skaičiavimams spartinti)

KOR. – Kontaktinė odos reakcija

Įvadas

Kontaktinė odos reakcija (KOR) yra dažna odos liga, išsivystanti po kontakto su įvairiais aplinkos alergenais, kurių identifikavimas yra esminis veiksmingam gydymui ir ligos prevencijai [1]. KOR sukėlėjams nustatyti yra naudojami odos lopo testai. Tačiau jų rezultatų vertinimas dažnai pasižymi subjektyvumu ir skirtingomis interpretacijomis tarp specialistų [2]. Klinikinėje praktikoje tai gali lemti diagnostinius netikslumus, todėl aktualu ieškoti objektyvesnių, standartizuotų ir patikimesnių vertinimo metodų.

Pastaraisiais metais medicinoje sparčiai vystomos kompiuterinės regos ir dirbtinio intelekto technologijos leidžia automatizuoti vaizdų analizę ir sumažinti žmogiškojo faktoriaus įtaką diagnostiniams sprendimams [3]. Vis dėlto, nepaisant pažangių technologijų teikiamų galimybių, jų taikymas KOR diagnostikoje vis dar išlieka pradinėje stadijoje. Siekiant įvertinti šių metodų patikimumą, pritaikomumą, bei klinikinę naudą, būtini papildomi moksliniai tyrimai. Be to, svarbu atsižvelgti į etinius ir teisinius aspektus, susijusius su automatizuotų sistemų naudojimu medicinoje, ypač užtikrinant pacientų duomenų apsaugą ir saugumą [4].

Šiame kontekste itin svarbus tampa tikslus odos reakcijos lokalizavimas, leidžiantis identifikuoti konkretų alergeną ir parinkti individualizuotą gydymą. Atliekant alergenų lopo testą ant paciento odos klijuojami specialūs pleistrai su skirtingais alergenais ir laikomi nustatytą laiką. Odos reakcija gali pasireikšti ne iš karto – ji gali išryškėti po 24 valandų ar net po kelių dienų, o kartais ir po savaitės, kas apsunkina tikslų reakcijos vietos nustatymą ir vertinimą [5]. Tradiciškai odos reakcijos stiprumas vertinamas vizualiai, gydytojui apžiūrint odos pokyčius nustatytais laiko intervalais, tačiau šis metodas išlieka ribotas dėl subjektyvumo ir galimos interpretacijos variacijos tarp specialistų. Be to, alerginių odos reakcijų vertinimas reikalauja pakartotinių paciento vizitų – dažniausiai po 48 val., 72 val. ir po 7 parų nuo alergenų lopo testo aplikavimo. Tai reiškia, kad tiek pacientas, tiek gydytojas turi skirti papildomą laiką keliems apsilankymams, o tai didina organizacinę ir laiko naštą sveikatos priežiūros sistemai. Gydytojams dermatovenerologams, kurie kasdien konsultuoja didelį pacientų srautą, pakartotiniai vizitai apsunkina darbo planavimą ir mažina galimybes skirti pakankamai laiko sudėtingesniems klinikiniais atvejais. Esant ribotiems žmogiškiesiems ištekliams ir augančiam pacientų poreikiui, toks diagnostikos modelis tampa ne tik laikui imlus, bet ir mažiau efektyvus sveikatos priežiūros paslaugų organizavimo požiūriu.

Automatiniai kompiuterinės regos metodai sudaro galimybę greičiau, objektyviau ir tiksliau identifikuoti reakcijos vietą, analizuojant odos vaizdus dinamiškai ir vertinant spalvinius, tekstūrinius bei kitus vizualinius parametrus [6]. Tokios sistemos gali padėti standartizuoti vertinimo procesą, jį gerokai pagreitinti ir supaprastinti, sumažinti diagnostinių klaidų tikimybę bei padidinti KOR diagnostikos tikslumą. Atsižvelgiant į tai, šiame darbe siekiama iširti kompiuterinės regos metodų taikymą alergenų lopo pozicijos nustatymui, kuriant objektyvesnę ir efektyvesnę KOR diagnostikos procesą.

Šio darbo tikslas:

Ištirti kompiuterinės regos metodų taikymą lokalių odos reakcijų aptikimui, segmentavimui ir sukurti metodiką objektyviai alerginių reakcijų vertinimui, taikant spalvinę analizę dermatologinių lopo testų vaizduose.

Darbo uždaviniai:

1. Atlikti mokslinės literatūros analizę, nagrinėjant objektų aptikimo ir segmentavimo metodų taikymą medicininių vaizdų analizėje.
2. Suformuoti ir paruošti sveikos odos vaizdų duomenų rinkinį, atliekant rankinį anotavimą bei segmentavimo kaukių sudarymą.
3. Sukurti automatizuotą algoritmą segmentavimo kaukių konvertavimui į YOLO formatą.
4. Apmokyti skirtingų architektūrinių dydžių YOLOv12 segmentavimo modelius, įvertinti jų veikimą taikant segmentavimo kokybės metrikas bei palyginti YOLOv12s-seg, YOLOv12m-seg ir YOLOv12l-seg modelių tikslumo bei skaičiavimo efektyvumo charakteristikas.
5. Sukurti algoritmus, leidžiančius apdoroti ir paruošti dermatologinius vaizdus sveikos odos koeficiento nustatymui, gydytojo specialisto pažymėtų taisyklių radimui bei odos pokyčių vaizdinių mėginių formavimui.
6. Pritaikyti CIELAB spalvų erdvės metodus alerginių odos reakcijų spalvinių pokyčių analizei.
7. Sukurti individualizuoto sveikos odos etalono metodiką ir įvertinti jos įtaką alerginių reakcijų vertinimo tikslumui.
8. Sukurti alerginių reakcijų klasifikavimo metodą pagal spalvinio nuokrypio intensyvumą.
9. Įvertinti sukurtos dviejų lygių sistemos tinkamumą automatizuotai alerginių odos reakcijų analizei bei jos pritaikymo galimybes klinikinėje praktikoje.

1. Literatūros apžvalga

1.1. Kontaktinė odos reakcija (KOR) – epidemiologija ir patofiziologija

Odos reakcijos gali pasireikšti kaip lėtinė IV tipo padidėjusio jautrumo imuninė reakcija, kuri išsivysto, kai specifiniai alergenai sąveikauja su odos imunine sistema (žr. 1 pav.). Šios reakcijos metu mažos molekulinės masės medžiagos, patekusios į odą, jungiasi su odos baltymais ir tampa imunogeniškos, taip aktyvindamos T limfocitų sukeltą ląstelinį imuninį atsaką. Pirminės sensibilizacijos fazėje klinikinių simptomų gali nebūti, tačiau pakartotinio kontakto metu išsivysto uždegiminė reakcija, pasireiškianti eritema, infiltracija, pūslelėmis, pleiskanėjimu bei intensyviu niežėjimu. Dėl uždelsto reakcijos pobūdžio klinikiniai požymiai dažniausiai išryškėja praėjus 24–72 valandoms po kontakto su alergenu, o kai kuriais atvejais – dar vėliau, kas apsunkina priežastinio ryšio nustatymą.



1 pav. Alerginis kontaktinis dermatitas [8].

KOR yra viena dažniausių profesinių odos ligų, ypač paplitusi tarp asmenų, dirbančių sveikatos priežiūroje, grožio, statybos ar chemijos pramonės srityse, kur nuolatinis kontaktas su dirginančiomis ar alergizuojančiomis medžiagomis yra neišvengiamas [7]. Liga turi reikšmingą poveikį paciento gyvenimo kokybei – sukelia fizinį diskomfortą, miego sutrikimus, darbingumo sumažėjimą bei psichologinę įtampą. Be to, KOR sukelia papildomą našą sveikatos priežiūros sistemai dėl pakartotinių konsultacijų, diagnostinių procedūrų ir ilgalaikio gydymo poreikio. Dėl sudėtingo diagnostikos proceso, reakcijų įvairovės ir vertinimo subjektyvumo ši patologija išlieka aktuali tiek klinikiniu, tiek organizaciniu požiūriu [8].

KOR yra plačiai paplitusi visame pasaulyje, tačiau jos paplitimas priklauso nuo įvairių veiksnių, įskaitant aplinkos poveikį, profesinę ekspoziciją ir genetinį polinkį. Tyrimai rodo, kad KOR sergamumas tarp bendrosios populiacijos siekia nuo 15 % iki 20 %, tačiau tam tikrose profesinėse grupėse šis rodiklis gali būti dar didesnis [9]. Pavyzdžiui, sveikatos priežiūros darbuotojai, kirpėjai, statybininkai, mechanikai bei asmenys, dirbantys su chemikalais, metalais ar dirginančiais tirpikliais, dažnai patiria nuolatinį ir ilgalaikį kontaktą su odą dirginančiomis medžiagomis, todėl yra padidintos KOR rizikos grupėje [10]. Epidemiologiniai tyrimai rodo, kad moterys serga KOR dažniau nei vyrai, o tai gali būti susiję tiek su kosmetikos, papuošalų bei asmens priežiūros produktų vartojimo įpročių

skirtumais, tiek su profesine veikla, kurioje dažniau pasitaiko odos kontaktas su alergizuojančiomis medžiagomis [11]. Šie skirtumai pabrėžia, kad lytis, profesija ir individualios sąlygos vaidina svarbų vaidmenį alerginio kontaktinio dermatito epidemiologijoje ir prevencijos strategijų kūrime.

KOR išsivysto kaip ląsteliniu imunitetu pagrįsta uždelsto tipo padidėjusio jautrumo reakcija, vykstanti dviejose pagrindinėse fazėse: jautrinimo ir išraiškos fazėse [12]. Jautrinimo fazėje pirmą kartą patenkantis į odą alergeną sąveikauja su Langerhanso ląstelėmis bei T limfocitais, sukeldamas imunologinę atmintį. Pakartotinio kontakto metu išraiškos fazėje aktyvuojamas T limfocitų atsakas, kuris sukelia uždegiminę reakciją odos vietoje. Klinikiniai požymiai gali pasireikšti tik po kelių dienų nuo kontakto su alergenu ir apima eritemą, papules, pūsleles, odos infiltraciją, niežėjimą bei pleiskanojimą. Dėl tokio uždelsto pobūdžio alerginės reakcijos lokalizavimas, stiprumo vertinimas ir diagnostikos procesas yra sudėtingas, o subjektyvus vertinimas gali lemti klaidingą ar nevienareikšmę diagnozę [13].

Jautrumo etapo metu mažos masės cheminių medžiagų sudėties molekulės, dar vadinamos haptenuis, prasiskverbia per epidermį ir jungiasi su endogeniniais baltymais, formuodamos imunogeniškus kompleksus. Šiuos kompleksus atpažįsta odos antigeną pateikiančios ląstelės, ypač Langerhanso ląstelės bei dermos dendritinės ląstelės, kurios atlieka pagrindinį vaidmenį imuninio atsako inicijavime. Toliau šios antigeną pateikiančios ląstelės migruoja per limfagysles į regioninius limfmazgius, kur aktyvuoja naivius CD4⁺ ir CD8⁺ T limfocitus, kurie tampa specifiniai konkrečiam alergenui. Šio proceso metu susidaro atminties T ląstelės, kurios cirkuliuoja organizme ir yra pasirengusios greitai sureaguoti pakartotinai susidūrus su tuo pačiu antigenu [14]. Taip organizmas „prisimena“ alergeną ir gali inicijuoti spartesnę bei stipresnę imuninę atsaką.

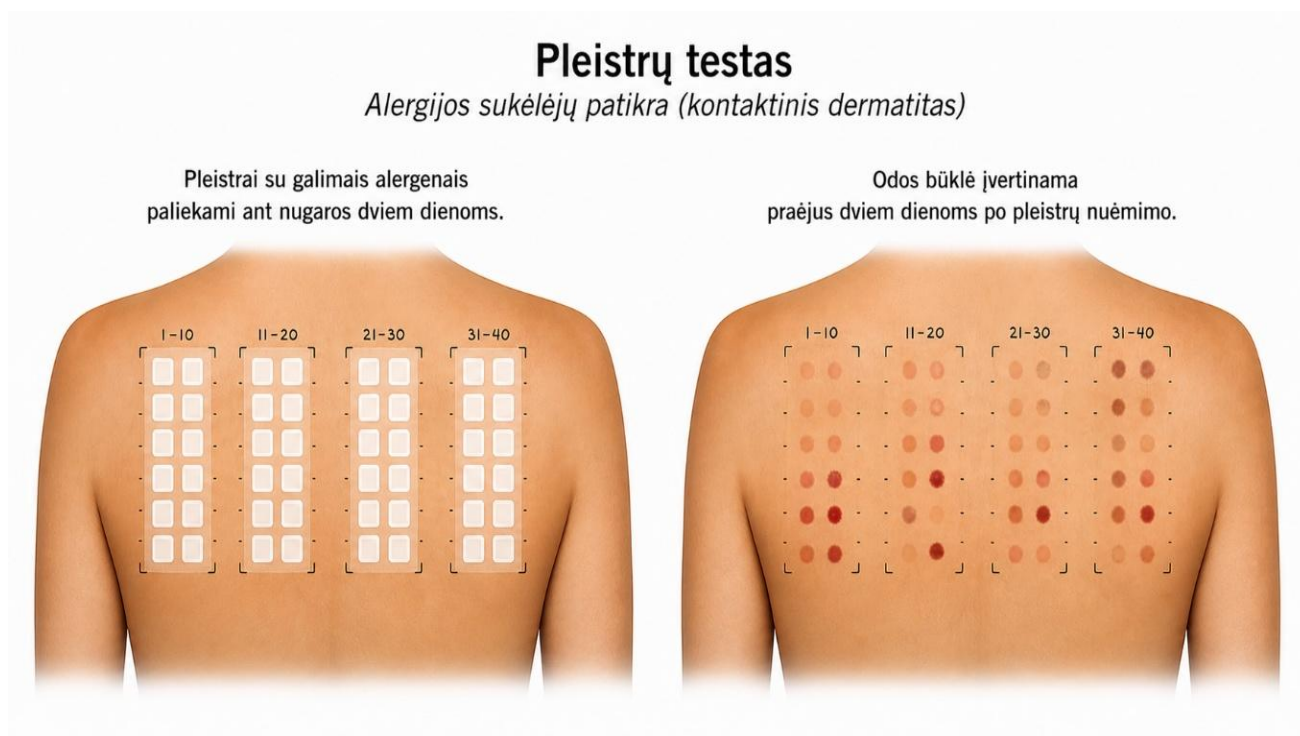
Šis jautrinimo procesas yra būtinas tolimesnei išraiškos fazei, kurioje pasireiškia klinikiniai odos reakcijų simptomai [15]. Pakartotinai patekus alergenui, aktyvios T ląstelės migruoja į odą ir išskiria uždegimą skatinančius citokinus, kurie sukelia paraudimą, edemą, niežėjimą ir kitus būdingus odos pokyčius. Ši ląstelėmis pagrįsta reakcija sudaro pagrindą automatizuotų diagnostikos metodų poreikiui, nes tikslus reakcijos vietos nustatymas leidžia identifikuoti konkretų alergeną ir optimizuoti individualizuotą gydymą [16]. Kai žmogus, jau yra anksčiau jautriai sureagavęs į tą patį alergeną, vėl susiduria su juo, organizme prasideda aktyvi uždegiminė reakcija. Haptenui vėl prasiskverbia per odą ir yra atpažįstami antigeną pateikiančių ląstelių, kurios suaktyvina jau susiformavusias atminties T ląsteles. Šios ląstelės leidžia organizmui reaguoti greičiau ir stipriau nei pirmą kartą susidūrus su alergenu [17].

KOR patofiziologija apima tiek įgimtą, tiek įgytą imunitetą, o klinikinėje praktikoje odos lopo testai išlieka pagrindiniu diagnostikos metodu. Jų vertinimas gali būti sudėtingas dėl uždegiminės reakcijos atsiradimo laiko intervalo, subjektyvumo ir sudėtingo reakcijos lokalizavimo [18]. Tikslus reakcijos vietos ir stiprumo nustatymas yra būtinas – tai leidžia identifikuoti konkretų reakcijos sukėlėją. Šių aspektų supratimas yra ypač svarbus automatizuotų diagnostikos sistemų kūrimo kontekste: kompiuterinės regos metodai leidžia tiksliai stebėti odos pokyčius laiko eigoje, vertinti reakcijos intensyvumą ir lokalizaciją, didinti diagnostikos objektyvumą bei mažinti klaidų tikimybę, o tai ypač aktualu sveikatos priežiūros specialistams, kurie dažnai neturi galimybės kelis kartus per dieną stebėti kiekvieno paciento odos lopo testo reakcijos [19].

2. Tradiciniai odos lopo testų metodai ir diagnostiniai iššūkiai


2.1. Odos lopo testų metodika ir taikymas

Kontaktinės odos reakcijos (KOR) diagnostika yra sudėtingas procesas, kuriam reikalingas tikslus alergenų identifikavimas ir paciento imuninio atsako įvertinimas. Vienas iš pagrindinių diagnostikos metodų yra odos lopo testai (patch testing), kurie plačiai naudojami klinikinėje praktikoje (žr. 2 pav.). Tačiau, nepaisant jų efektyvumo, šis metodas turi ir tam tikrų trūkumų, įskaitant subjektyvumą, ilgą rezultatų vertinimo laikotarpį bei specialistų interpretacijų skirtumus [20].



2 pav. Alergenų lopo testas [22].

Odos lopo testai yra standartizuotas ir patvirtintas metodas, naudojamas KOR diagnozavimui [21]. Testavimo principas grindžiamas kontaktiniu alergenu ekspozicijos modeliu – ant paciento nugaros ar kitos odos vietos klijuojamos specialios pleistrų juostelės, kuriose yra įvairių potencialių alergenų. Šios medžiagos palaikomos kontaktiniame sąlytyje su oda nuo 48 iki 72 valandų, o vėliau atliekami odos reakcijos įvertinimai [22] (žr. 3 pav.).



3 pav. Suregavusios odos pavyzdys [24].

Testavimo procedūra vykdoma keliais etapais:

1. Lopo testų užklėjimas – alergeno turintys pleistrai klijuojami ant paciento odos, dažniausiai nugaros srityje, kur yra mažiau judesių sukeltų trinties efektų [23].
2. Ekspozicijos laikotarpis – pacientas turi išlaikyti pleistrus nepažeistus 48–72 valandas, vengti drėgmės ir mechaninio dirginimo, kad užtikrintų patikimus rezultatus [24].
3. Pirminis įvertinimas – po pleistrų pašalinimo pradiniai odos pokyčiai vertinami po 24 valandų. Tai leidžia nustatyti greitesnes imunines reakcijas [25].

Antrinis vertinimas – galutinė odos reakcija stebima po 7 dienų, kad būtų galima identifikuoti uždelstas imunines reakcijas, kurios dažnai pasireiškia vėliau [26]. Lopo testai yra plačiai taikomas kontaktinės alergijos diagnostikos metodas, leidžiantis identifikuoti įvairius alergenų ir pritaikyti individualizuotą gydymą. Jie ypač naudingi nustatant profesinius ir kasdienės aplinkos dirgiklius, sukeliančius alerginį kontaktinį dermatitą [27].

Pagrindiniai šio metodo privalumai: standartizuota ir ilgametė klinikinė praktika, platus tiriamų alergenų spektras (pvz., metalai, konservantai, kvapikliai), maža invazyvumo rizika bei pakankamai aukštas diagnostinis jautrumas. Tai daro lopo testus svarbiu pirmo pasirinkimo įrankiu KOR diagnostikoje [28].

Vis dėlto metodas turi reikšmingų ribotumų. Rezultatų vertinimas yra subjektyvus ir priklauso nuo specialisto patirties, todėl galimi interpretavimo skirtumai. Taip pat gali pasitaikyti klaidingai

teigiamų ar neigiamų rezultatų dėl nespecifinių odos reakcijų, paciento odos savybių ar vartojamų vaistų. Diagnostiką apsunkina ir uždelstas imuninis atsakas – reakcijos dažniausiai pasireiškia po 3 – 7 dienu, todėl būtini pakartotiniai vizitai.

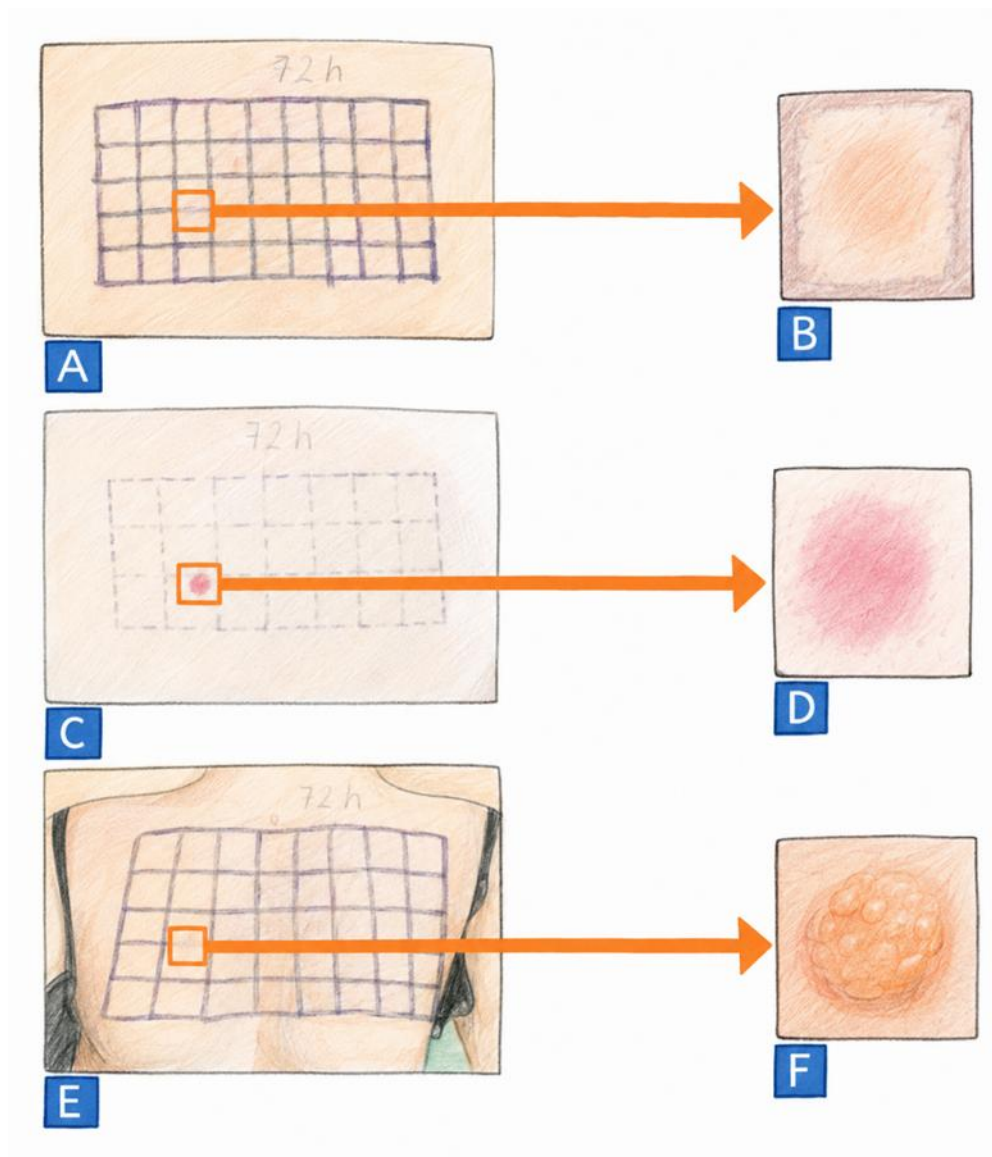
Dėl šių priežasčių didėja poreikis objektyvesniems diagnostikos sprendimams. Perspektyvi kryptis – kompiuterinės regos ir dirbtinio intelekto taikymas, leidžiantis automatizuotai vertinti odos reakcijas. Tokios sistemos gali analizuoti spalvos, tekstūros ir pokyčių dinamiką laike, sumažinti subjektyvumą bei pagerinti diagnostikos tikslumą.

Apibendrinant, nors lopo testai išlieka pagrindinis KOR diagnostikos metodas, jų ribotumai skatina inovatyvių, automatizuotų sprendimų diegimą, siekiant tikslesnės, greitesnės ir standartizuotos diagnostikos.

Odos reakcijų vertinimą atliko gydytojas dermatovenerologas, vadovaudamasis standartizuota alerginių lopo testų (ALT) interpretavimo metodika [29]. Vertinimas buvo grindžiamas pagrindinių klinikinių požymių analize: eritemos intensyvumu, odos infiltracija, papulių bei pūslelių susidarymu. Atsižvelgiant į uždegiminės reakcijos stiprumą ir morfologinius požymius, odos reakcijos buvo suskirstytos į tris pagrindines kategorijas:

1. 1 tipo reakcija – lengva reakcija, pasireiškianti eritema, odos infiltracija (sukietėjimu) arba pavienėmis papulėmis (+) (1 pav. B);
2. 2 tipo reakcija – vidutinio intensyvumo reakcija, kai stebima eritema, infiltracija, papulės bei pavienės pūslelės (++) (1 pav. D);
3. 3 tipo reakcija – stipri reakcija, apibūdinama ryškia eritema, infiltracija bei susiliejančiomis pūslelėmis (+++) (1 pav. F).

Toks reakcijų klasifikavimas leido nuosekliai ir sistemiškai įvertinti uždegiminio atsako intensyvumą bei užtikrinti skirtingų atvejų tarpusavio palyginamumą (žr. 4 pav.). Be to, aiškiai apibrėžti vertinimo kriterijai sudarė prielaidas sumažinti interpretavimo skirtumus ir užtikrinti didesnę diagnostinių duomenų patikimumą.



4 pav. ALT pavyzdžiai, (A, C, E) bendras odos vaizdas ir iškirptos sureagavusios odos nuotraukos (B, D, F).

Tolimesnei analizei buvo naudojami skaitmeniniai ALT odos reakcijų vaizdai ($n = 822$), kurie buvo eksportuoti ir apdoroti. Vaizdų paruošimo etape buvo atliekama reakcijos srities identifikacija bei iškirpimas, siekiant atskirti diagnostiniu požiūriu reikšmingas odos zonas nuo aplinkinių audinių ir foninių elementų (1 pav. B, D, F). Tokiu būdu buvo suformuota standartizuota ir analizei tinkama vaizdų duomenų bazė.

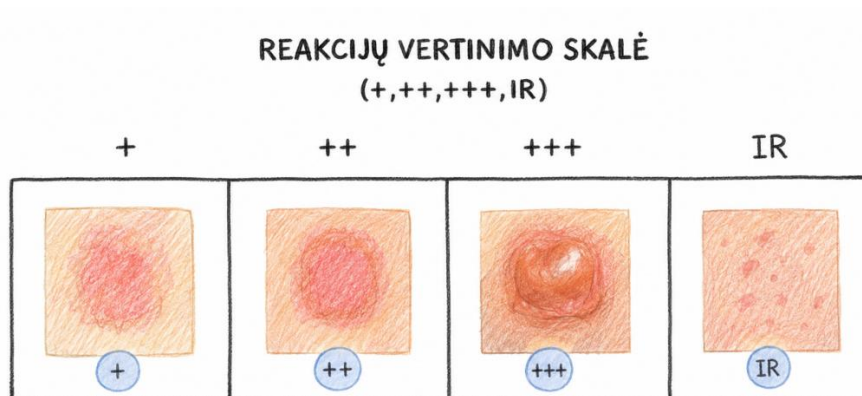
Vaizdų standartizavimas buvo svarbus etapas, leidęs sumažinti išorinių veiksnių įtaką, tokių kaip nevienodas apšvietimas, odos fono skirtumai ar nereikšmingi vaizdo artefaktai. Šis procesas sudarė sąlygas objektyvesnei skaitmeninei odos reakcijų analizei bei pagerino tolimesnių kompiuterinės regos metodų pritaikymo galimybes. Be to, vienodai paruošti vaizdai užtikrino didesnę duomenų nuoseklumą ir analizės tikslumą.

Sukaupti, apdoroti ir struktūrizuoti duomenys sudarė pagrindą reprezentatyvios skaitmeninių odos reakcijų vaizdų duomenų bazės formavimui, kuri buvo naudojama tolimesniems tyrimams bei automatizuotos analizės metodų kūrimui (žr. 5 pav.).

Tolimesnei analizei buvo naudojami skaitmeniniai ALT odos reakcijų vaizdai (n = 822), kurie buvo eksportuoti ir apdoroti. Vaizdų paruošimo etape buvo atliekama reakcijos srities identifikacija bei iškirpimas, siekiant atskirti diagnostiniu požiūriu reikšmingas odos zonas nuo aplinkinių audinių ir foninių elementų (1 pav. B, D, F). Tokiu būdu buvo suformuota standartizuota ir analizei tinkama vaizdų duomenų bazė.

Vaizdų standartizavimas buvo svarbus etapas, leidęs sumažinti išorinių veiksnių įtaką, tokių kaip nevienodas apšvietimas, odos fono skirtumai ar nereikšmingi vaizdo artefaktai. Šis procesas sudarė sąlygas objektyvesnei skaitmeninei odos reakcijų analizei bei pagerino tolimesnių kompiuterinės regos metodų pritaikymo galimybes. Be to, vienodai paruošti vaizdai užtikrino didesnę duomenų nuoseklumą ir analizės tikslumą.

Sukaupti, apdoroti ir struktūrizuoti duomenys sudarė pagrindą reprezentatyvios skaitmeninių odos reakcijų vaizdų duomenų bazės formavimui, kuri buvo naudojama tolimesniems tyrimams bei automatizuotos analizės metodų kūrimui (žr. 5 pav.).



5 pav. Odos reakcijos vertinimas

3. Kompiuterinė rega medicinoje

3.1. Vaizdo analizės, DI, ir jutiklių taikymas medicinoje

Pastaraisiais dešimtmečiais medicinos srityje įvyko reikšmingas technologinis proveržis, leidžiantis automatizuoti diagnostikos procesus ir padidinti jų tikslumą [30]. Viena iš pažangiausių sričių, kurioje vis dažniau taikomos dirbtinio intelekto (DI) technologijos, yra kompiuterinė rega. Ši technologija leidžia analizuoti medicininius vaizdus ir atpažinti įvairius patologinius pokyčius su dideliu tikslumu [31]. Dermatologijoje kompiuterinė rega yra itin svarbi, nes odos ligų diagnostika dažnai grindžiama vizualiais požymiais, kuriuos galima automatizuotai aptikti naudojant giluminį mokymąsi (deep learning) [32]. Giluminio mokymosi metodai, ypač konvoliuciniai neuroniniai tinklai (Convolutional Neural Networks, CNN), yra ypač veiksmingi analizuojant dermatologinius vaizdus ir gali būti naudojami įvairių odos ligų, įskaitant melanomą, psoriazę, egzemą ir kitas patologijas, nustatymui [33].

Nors gilieji neuroniniai tinklai šiuo metu dominuoja automatizuotoje skaitmeninių odos vaizdų analizėje, jų taikymas nėra vienintelis įmanomas metodas, o pažangios diagnostinės sistemos gali būti paremtos daugiakomponenčiais algoritmais ir sensoriais [34]. Tradiciniai mašininio mokymosi metodai, tokie kaip atraminių vektorių mašinos (SVM), atsitiktiniai klasifikatoriai (Random Forest) ar gradientinio stiprinimo algoritmai (XGBoost), išlieka aktualūs, ypač kai vaizdinių duomenų imtis yra santykinai maža arba kai siekiama geresnės interpretacijos. Šie modeliai leidžia klasifikuoti iš anksto išgautus atvaizdo požymių vektorius, pavyzdžiui, spalvų histogramas, tekstūros statistiką, kontūrų erdvinius parametrus ar reakcijos zonų dydžius, be didelių skaičiavimo resursų, būdingų giliesiems tinklams.

Be vaizdų, diagnostikoje vis plačiau eksperimentuojama su daugialypiais mediciniais signalais, kurie suteikia papildomos informacijos apie odos audinių fiziologiją [35]. Pavyzdžiui, termografiniai jutikliai (infraraudonųjų spindulių kameros) gali fiksuoti vietinius temperatūros skirtumus, susijusius su uždegiminiu procesu, kurie ne visada akivaizdūs matomoje spektro srityje. Odos natūralios drėgmės praradimo sensoriai leidžia objektyviai įvertinti odos barjero pažeidimą ir drėgmės pokyčius, o odos elektrinio laidumo tyrimai matavimo platformoms suteikia informaciją apie elektrofiziologinius odos pokyčius, kurie taip pat koreliuoja su uždegimu ir imuninėmis reakcijomis. Tokie papildomi signalai gali būti integruojami su kompiuterinės regos rezultatais į bendrą klasifikavimo modelį, kuris kartu analizuoja vizualinę, termodinaminę ir elektrofizinę informaciją [36].

Diagnostikos sistemose naudojama įranga taip pat gali būti labai įvairi, nuo profesionalių spalvų kalibruotų skaitmeninių fotoaparatus (pavyzdžiui, Canon EOS ar Nikon D-srityje su aukštos raiškos sensoriais) iki specializuotų medicininių dermatoskopų, gebančių fiksuoti vaizdus su dideliu kontrastu ir žemu triukšmo lygiu [36]. Mėgėjiškos klasės įrenginiai, tokie kaip Apple iPhone ar Samsung Galaxy serijos telefonų kameros, taip pat aktyviai naudojami tyrimuose dėl jų plačiai paplitusio naudojimo, tačiau jų plataus kampo lęšiai ir automatiniai fokusavimo algoritmai gali įvesti geometrinių iškraipymų, todėl dažnai papildomi aparatūriniais arba programiniais korekcijos žingsniais. Termografinės kameros, pavyzdžiui, FLIR arba Seek Thermal, suteikia papildomą infraraudonųjų spindulių duomenų sluoksnį, kuris kartu su vaizdo klasifikacija gali padidinti diagnostinį pasitikėjimą [37].

Tokios daugialypės technologijos derinys, gilieji neuroniniai tinklai dideliems duomenų kiekiams, klasikiniai algoritmai mažesnėms imtims ir papildomi jutikliai, sudaro pagrindą patikimesnėms automatizuotoms diagnostikos sistemoms [38]. Integruotas požiūris gali ne tik pagerinti klasifikavimo tikslumą, bet ir sumažinti netikslumą, kuriuos sukelia vien tik vaizdų analizė, skaičių. Be to, toks metodų mišinys suteikia galimybę kurti adaptyvius modelius, kurie geba prisitaikyti prie skirtingų įrenginių charakteristikų bei realių klinikinių sąlygų, taip kurdami patikimesnę ir universalesnę KOR diagnostikos įrankių architektūrą [39].

3.2. Giluminio mokymosi tyrimai ir taikymas odos ligų diagnostikoje

Giluminio mokymosi algoritmai geba atpažinti sudėtingus vaizdų modelius ir priimti sprendimus remdamiesi didelėmis duomenų bazėmis. Dermatologijoje dažniausiai naudojami CNN modeliai, kurie yra pritaikyti vaizdo atpažinimui ir gali išmokyti atpažinti specifinius odos pažeidimų požymius. Tokios sistemos yra apmokomos naudojant didžiules dermatologinių vaizdų duomenų bazines, kuriose yra tūkstančiai pacientų odos nuotraukų su tiksliai nustatytomis diagnozėmis. CNN tinklai, gavę pakankamai duomenų, geba identifikuoti patologinius odos pokyčius, klasifikuoti juos pagal ligos tipą ir įvertinti ligos progresavimo tikimybę.

Vienas iš reikšmingiausių šios technologijos pranašumų – diagnostikos tikslumas. Kai kurie tyrimai rodo, kad giluminio mokymosi modeliai gali veikti tokiu pačiu ar net geresniu tikslumu nei patyrę dermatologai. Pavyzdžiui, Esteva ir bendraautorių (2017) atliktas tyrimas parodė, kad neuroniniai tinklai gali pasiekti 91% tikslumą nustatant melanomą, o tai yra panašu į ekspertų dermatologų rezultatus [40]. Šis atradimas rodo, kad giluminis mokymasis gali tapti ne tik pagalbine priemone gydytojams, bet ir potencialiai pakeisti tam tikrus tradicinius diagnostikos metodus, sumažindamas subjektyvumo įtaką.

Be to, tokios sistemos gali būti integruotos į mobiliąsias aplikacijas ar telemedicinos platformas, leidžiančias pacientams patiems atlikti pirminę odos būklės analizę. Tai ypač aktualu regionuose, kur dermatologų konsultacijos yra ribotos arba sunkiai prieinamos.

Pastarųjų metų tyrimai rodo, kad giluminio mokymosi taikymas dermatologijoje yra ne tik perspektyvus, bet ir praktiškai įgyvendinamas. Han ir bendraautorių metaanalizė parodė, kad giluminio mokymosi modeliai gali pranokti dermatologus nustatant tam tikrus odos vėžio tipus, ypač kai naudojami dideli ir kokybiški duomenų rinkiniai. Pavyzdžiui, modeliai, apmokyti naudojant HAM10000 duomenų rinkinį, sugebėjo identifikuoti septynis dažniausiai pasitaikančius odos pažeidimus su vidutiniu tikslumu, siekiančiu 87–95%, priklausomai nuo patologijos [41].

Svarbu pažymėti, kad šių modelių veiksmingumas priklauso nuo įvairių veiksnių, įskaitant duomenų kiekį, jų kokybę ir algoritmų optimizavimo metodus. Pavyzdžiui, naudojant duomenų išplėtimo (*data augmentation*) technikas, galima padidinti modelių gebėjimą atpažinti retus ar mažiau reprezentuotus odos ligų tipus. Taip pat taikant ansamblių metodus, kai keli giluminio mokymosi modeliai dirba kartu, galima padidinti bendrą diagnostikos tikslumą ir sumažinti klaidingų diagnozių skaičių.

Nepaisant didelių pasiekimų, giluminio mokymosi taikymas dermatologijoje susiduria su keliais iššūkiais. Vienas pagrindinių – duomenų trūkumas ir jų kokybė. Norint pasiekti patikimus diagnostikos rezultatus, modeliai turi būti apmokyti naudojant įvairių odos tipų, skirtingų

apšvietimo sąlygų ir skirtingų demografinių grupių pacientų duomenis. Jei treniravimo duomenų bazė yra nepakankamai įvairi, modelis gali būti šališkas ir prastai veikti tam tikrose pacientų grupėse [42].

Kitas svarbus aspektas yra etiški ir teisiniai šių technologijų naudojimo aspektai. Kadangi odos ligų diagnostika yra jautri sritis, būtina užtikrinti duomenų apsaugą ir laikytis griežtų privatumo reikalavimų. Be to, svarbu nustatyti aiškias atsakomybės ribas ar diagnostikos klaidos atveju atsakomybę prisiima DI modelio kūrėjas, sveikatos priežiūros įstaiga ar pats gydytojas.

Nepaisant šių iššūkių, giluminio mokymosi modelių integracija į dermatologiją turi didžiulį potencialą. Ateityje galima tikėtis dar tikslesnių ir patikimesnių sistemų, kurios leis ne tik diagnozuoti odos ligas, bet ir prognozuoti jų eigą, optimizuoti gydymo strategijas ir net personalizuoti terapiją pagal individualius paciento duomenis [43]. Šios technologijos gali tapti neatsiejama dermatologinės praktikos dalimi, padedančia sumažinti diagnostikos laiką, pagerinti pacientų išgyvenamumą ir sumažinti sveikatos priežiūros sistemos kaštus.

Giluminio mokymosi technologijos, ypač CNN pagrįsti modeliai, rodo didelį potencialą dermatologijoje, leidžiantį tiksliai ir efektyviai diagnozuoti odos ligas. Tyrimai rodo, kad šie modeliai gali pasiekti aukštą tikslumą, kartais pranokstantį net patyrusių dermatologų diagnostinius gebėjimus. Tačiau norint užtikrinti šių sistemų patikimumą ir etišką naudojimą, būtina tobulinti duomenų bases, užtikrinti jų įvairovę bei spręsti su duomenų privatumu susijusius iššūkius [44]. Ateityje giluminis mokymasis gali tapti neatsiejama dermatologijos dalimi, padedančia užtikrinti ankstyvą odos ligų diagnostiką ir pagerinti pacientų gydymo rezultatus [45].

Objektų aptikimo uždavinyje giluminio mokymosi architektūros dažniausiai skirstomos į dviejų etapų (angl. two-stage) ir vieno etapo (angl. one-stage) modelius. Šis skirstymas grindžiamas tuo, kaip organizuojamas objektų lokalizavimo ir klasifikavimo procesas neuroniniame tinkle. Abu metodai pasižymi skirtingais privalumais ir trūkumais, kurie ypač svarbūs medicininių vaizdų analizės kontekste [46].

Dviejų etapų objektų aptikimo architektūros pirmiausia generuoja galimų objektų regionus, o vėliau šiuos regionus klasifikuoja. Vieni pirmųjų ir plačiai žinomų šio tipo modelių yra R-CNN, Fast R-CNN ir Faster R-CNN. R-CNN modelyje pirmame etape naudojami regionų pasiūlymo metodai, o antrame etape kiekvienas regionas apdorojamas konvoliuciniu neuroniniu tinklu klasifikacijai atlikti [46]. Vėlesnės šių modelių versijos, tokios kaip Fast R-CNN ir Faster R-CNN, optimizavo skaičiavimo procesą, sumažindamos perteklinius skaičiavimus ir pagerindamos veikimo spartą [47]. Nepaisant to, dviejų etapų architektūros išlieka skaičiavimo požiūriu sudėtingesnės, nes objektų pasiūlymų generavimas ir jų klasifikavimas atliekami atskiruose etapuose.

Vieno etapo architektūros, tokios kaip YOLO, SSD ir RetinaNet, buvo sukurtos siekiant sumažinti skaičiavimo sudėtingumą ir užtikrinti didesnę veikimo greitį [48]. Šiuose modeliuose objektų lokalizavimas ir klasifikavimas atliekami vienu neuroninio tinklo perėjimu, be atskiro regionų pasiūlymo etapo. Pavyzdžiui, YOLO architektūra traktuoja objektų aptikimą kaip regresijos uždavinį, kuriame vienu metu prognozuojamos objektų koordinatės ir jų klasės [49]. SSD modelis naudoja kelių mastelių požymių žemėlapius skirtingo dydžio objektams aptikti [50], o RetinaNet išsiskiria fokusuotos nuostolių funkcijos (focal loss) panaudojimu, siekiant spręsti klasių disbalanso problemą [51]. Pagrindinis skirtumas tarp šių dviejų architektūrų tipų yra skaičiavimo sudėtingumo ir tikslumo kompromisas.

Dviejų etapų modeliai dažniausiai pasiekia aukštesnį aptikimo tikslumą, ypač sudėtinguose scenarijuose ar aptinkant smulkius objektus, tačiau jų veikimo greitis yra mažesnis. Tuo tarpu vieno etapo architektūros pasižymi žymiai didesne sparta ir yra tinkamesnės realaus laiko užduotims, nors istoriškai jų tikslumas buvo kiek mažesnis. Vis dėlto, naujausios vieno etapo modelių versijos ženkliai sumažino šį skirtumą ir daugeliu atvejų pasiekia palyginamą tikslumą su dviejų etapų architektūromis [52].

Medicinos srityje, ypač analizuojant dermatologinius vaizdus, svarbus ne tik aukštas aptikimo tikslumas, bet ir modelio veikimo greitis bei skaičiavimo efektyvumas. Klinikinėse ar sprendimų palaikymo sistemose realaus laiko arba beveik realaus laiko analizė leidžia greičiau pateikti diagnostines išvagas ir sumažinti specialistų darbo krūvį. Dėl šios priežasties vieno etapo architektūros, tokios kaip YOLO, tampa patraukliu pasirinkimu medicininių vaizdų segmentavimo ir patologinių sričių aptikimo uždaviniuose, kai reikalingas pakankamas tikslumas kartu su dideliu veikimo greičiu [53].

Pastaraisiais metais YOLO architektūra vis plačiau taikoma medicininių vaizdų analizėje dėl gebėjimo efektyviai aptikti, lokalizuoti ir segmentuoti kliniškai reikšmingas struktūras. YOLO modeliai sėkmingai naudojami anatominių struktūrų aptikimui radiologiniuose, histopatologiniuose ir dermatologiniuose vaizduose.

Dermatologijoje YOLO architektūros ypač tinka odos pažeidimų analizei, nes leidžia vienu metu nustatyti pažeidimo buvimą ir tiksliai apibrėžti jo ribas. Skirtingai nuo vien tik klasifikavimo metodų, segmentavimo pagrindu veikiančios YOLO modeliai suteikia išsamesnę informaciją apie patologinių sričių plotą, formą ir pasiskirstymą, kas yra svarbu klinikinei diagnostikai ir ligos eigos stebėjimui [54].

Medicininėje praktikoje svarbus ne tik modelio tikslumas, bet ir veikimo sparta. YOLO architektūra, gebanti apdoroti vaizdus realiuoju laiku, yra tinkama naudoti klinikiniuose sprendimų palaikymo įrankiuose, telemedicinos sistemose ir mobiliuosiuose sprendimuose. Tai leidžia sumažinti diagnostikos laiką ir padėti specialistams greičiau priimti sprendimus, ypač esant dideliame pacientų

3.3. Išvados

Atlikus mokslinės literatūros analizę nustatyta, kad kontaktinė odos reakcija (KOR) reikšminga dermatologinė bei visuomenės sveikatos problema. Didelis ligos paplitimas, sudėtingas imunologinis mechanizmas ir ilgalaikis poveikis pacientų gyvenimo kokybei lemia nuolatinį poreikį tobulinti diagnostikos metodus. Literatūros šaltiniai parodė, kad šiuo metu pagrindinis KOR diagnostikos metodas yra odos lopo testai, tačiau jų taikymas klinikinėje praktikoje vis dar susijęs su tam tikrais ribotumais, kurie gali mažinti diagnostikos tikslumą ir efektyvumą. Taip pat nustatyta, kad sparčiai vystomos dirbtinio intelekto bei kompiuterinės regos technologijos sudaro prielaidas kurti objektyvesnius, greitesnius ir standartizuotus diagnostikos sprendimus dermatologijoje.

Remiantis atlikta literatūros analize galima išskirti šias pagrindines išvadas:

1. Tradiciniai odos lopo testai išlieka pagrindiniu ir plačiausiai taikomu KOR diagnostikos metodu, tačiau jų efektyvumą riboja rezultatų interpretavimo subjektyvumas, priklausomybė nuo gydytojo klinikinės patirties bei uždelstas alerginės reakcijos pasireiškimas. Literatūroje pabrėžiama, kad skirtingi specialistai tas pačias odos reakcijas gali interpretuoti nevienodai, ypač kai reakcijos yra

silpnos arba netipinės. Be to, būtinybė atlikti pakartotinius paciento vizitus didina laiko sąnaudas bei apkrovą sveikatos priežiūros sistemai.

2. Nustatyta, kad kompiuterinės regos ir dirbtinio intelekto metodai turi didelį potencialą automatizuotoje dermatologinių vaizdų analizėje. Giluminio mokymosi modeliai, ypač konvoliuciniai neuroniniai tinklai (CNN), geba tiksliai identifikuoti odos pažeidimus, analizuoti reakcijų lokalizaciją ir vertinti patologinius pokyčius. Moksliniai tyrimai rodo, kad tokios architektūros kaip YOLO gali būti efektyviai taikomos objektų aptikimo ir segmentavimo uždaviniuose, užtikrinant didelį veikimo greitį bei pakankamą diagnostinį tikslumą. Tai sudaro galimybes kurti realaus laiko sprendimų palaikymo sistemas dermatologijoje ir telemedicinoje.

3. Literatūros analizė parodė, kad perspektyviausios ateities diagnostikos sistemos turėtų būti grindžiamos integruotu požiūriu, apjungiančiu kompiuterinę regą, giluminį mokymąsi, tradicinius mašininio mokymosi metodus bei papildomus fiziologinius signalus, tokius kaip termografiniai ar odos laidumo duomenys. Daugialypių duomenų integracija gali padidinti diagnostikos tikslumą, sumažinti klaidingų rezultatų riziką ir pagerinti sistemų pritaikomumą realiomis klinikinėmis sąlygomis.

Apibendrinant galima teigti, kad dirbtinio intelekto ir kompiuterinės regos technologijų taikymas dermatologijoje yra perspektyvi kryptis, galinti reikšmingai pagerinti KOR diagnostikos procesą. Vis dėlto literatūroje taip pat akcentuojama, kad norint šias sistemas sėkmingai integruoti į klinikinę praktiką, būtina spręsti su duomenų kokybe, modelių interpretabilumu, etiniais aspektais ir pacientų duomenų apsauga susijusius iššūkius. Tolimesni tyrimai šioje srityje išlieka būtini siekiant sukurti patikimus, standartizuotus ir praktiškai pritaikomus automatizuotos diagnostikos sprendimus.

4. Dirbtinio intelekto metodo metodologijos ir architektūros analizė

4.1. YOLO architektūros modeliai

Ankstesnėse objektų atpažinimo sistemose dažniausiai buvo taikomos dviejų etapų architektūros, kuriose vaizdo analizės procesas yra suskaidomas į atskiras fazes. Pirmojo etapo metu iš įvesties vaizdų yra išgaunami vizualiniai požymiai, neturintys tiesioginės informacijos apie objektų klases. Antrajame etape šie požymiai yra perduodami klasifikavimo moduliui, kuris nustato objektų ar vaizdų kategorijas bei jų lokalizaciją. Nors tokia architektūrinė schema leidžia pasiekti aukštą atpažinimo tikslumą, ji pasižymi dideliais skaičiavimo kaštais ir ilgesniu apdorojimo laiku.

Siekdami sumažinti skaičiavimo sudėtingumą ir padidinti apdorojimo spartą, tyrėjai sukūrė vieno etapo objektų aptikimo architektūras, kuriose visas vaizdo analizės procesas atliekamas vienu neuroninio tinklo perėjimu. Viena žinomiausių tokio tipo architektūrų yra YOLO (You Only Look Once). Šis metodas objektų aptikimo uždavinį formuluoja kaip regresijos problemą, kurioje neuroninis tinklas vienu metu prognozuoja objektų klases, jų tikimybes ir lokalizacijos parametrus.

YOLO veikimo principas grindžiamas įvesties vaizdo padalijimu į reguliarią ląstelių gardelę. Kiekviena gardelės ląstelė yra atsakinga už objektų aptikimą tam tikroje vaizdo srityje, prognozuojant ribojančiųjų dėžių koordinatas ir atitinkamų klasių tikimybes. Skirtingai nuo dviejų etapų metodų, visi šie skaičiavimai atliekami vienu neuroninio tinklo perdavimu, todėl YOLO architektūra pasižymi itin dideliu veikimo greičiu. Dėl šios priežasties YOLO yra ypač tinkama realaus laiko vaizdų apdorojimo užduotims.

YOLO architektūra sudaryta iš trijų pagrindinių komponentų: stuburo (backbone), kaklo (neck) ir galvos (head). Stuburo dalis yra atsakinga už pagrindinių vizualinių požymių išgavimą iš įvesties vaizdo ir dažniausiai realizuojama naudojant gilius konvoliucinius neuroninius tinklus. Kaklo komponentas skirtas skirtingų mastelių požymių sujungimui ir informacijos perdavimui tarp sluoksnių, siekiant pagerinti objekto reprezentaciją. Galvos dalis atlieka galutinių prognozių generavimą – apskaičiuoja objektų klases, jų tikimybes bei lokalizacijos parametrus.

4.2. Pasirinkto modelio architektūra

YOLO (angl. You Only Look Once) architektūra objektų aptikimo uždavinį sprendžia kaip regresijos problemą, kurioje vienu neuroninio tinklo perėjimu tiesiogiai prognozuojamos objektų lokalizacijos ir jų klasės. Skirtingai nei dviejų etapų metodai, kuriuose objektų pasiūlymų generavimas ir klasifikavimas atliekami atskirai, YOLO modelis visas reikalingas prognozes pateikia viename etape, todėl ženkliai sumažinamas skaičiavimo sudėtingumas [54]. YOLO veikimo principas pagrįstas vaizdo padalijimu į fiksuoto dydžio gardelę (angl. grid), kurioje kiekviena gardelės ląstelė yra atsakinga už objektų, kurių centras patenka į jos sritį, aptikimą. Tokiu būdu erdvinė vaizdo informacija struktūrizuojama, o objektų paieška tampa lokalia, tačiau tuo pačiu apima visą įvesties vaizdą. Kiekviena gardelės ląstelė prognozuoja keletą ribinių dėžučių (angl. bounding boxes), kurios apibrėžia galimų objektų padėtį vaizde bei leidžia nustatyti jų lokalizaciją.

Kiekvienai prognozuojamai sričiai YOLO modelis apskaičiuoja tris pagrindinius komponentus: objekto buvimo tikimybę (confidence score), ribinės dėžutės koordinatas ir klasių tikimybes. Objekto buvimo tikimybė atspindi, kiek tikėtina, kad nurodytoje srityje yra aptinkamas objektas, o klasių tikimybės leidžia nustatyti, kuriai klasei objektas priklauso. Šios prognozės yra atliekamos vienu

metu, todėl objektų aptikimas tampa vientisu regresijos procesu, o ne kelių tarpinės analizės etapų seka.

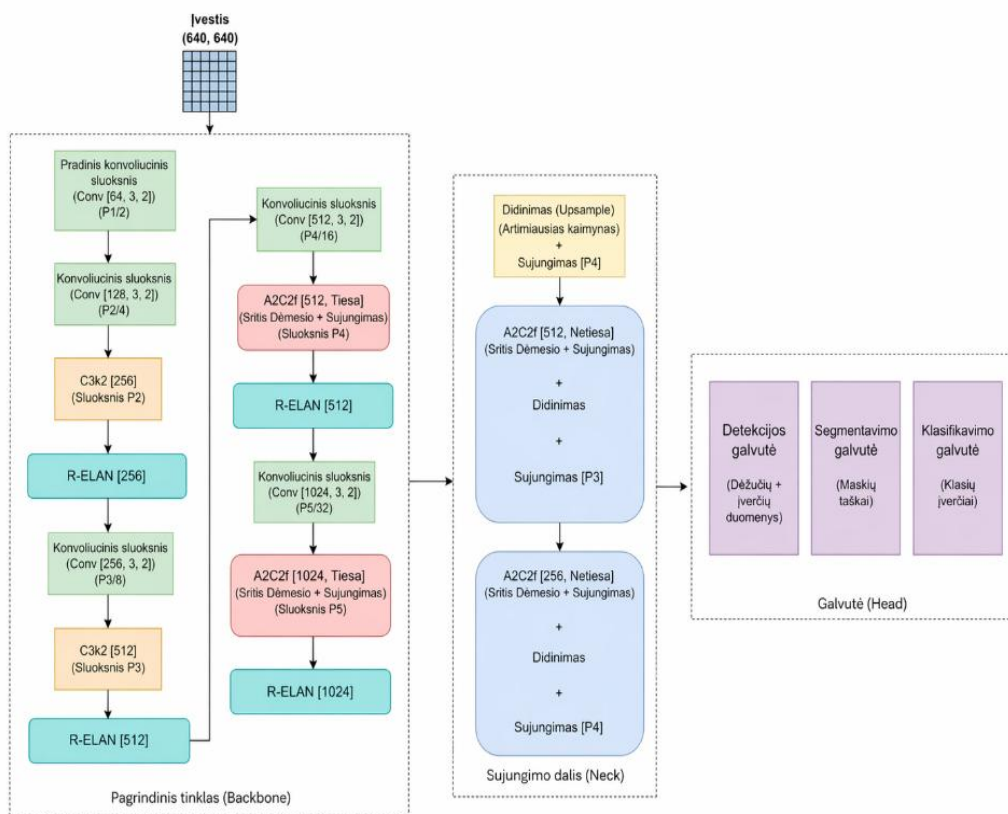
Matematiškai YOLO regresijos metodas gali būti suprantamas kaip tiesioginis ryšio tarp įvesties vaizdo pikselių ir išvesties prognozių mokymasis. Vietoje to, kad būtų ieškoma galimų objektų regionų ir vėliau jie būtų klasifikuojami, modelis iš karto mokosi prognozuoti optimalius ribinių dėžučių parametrus ir klasių tikimybes. Toks požiūris sumažina tarpinių žingsnių skaičių, o kartu ir galimų klaidų kaupimąsi, kuris būdingas sudėtingesnėms, kelių etapų architektūroms[54].

Dėl mažesnio tarpinių operacijų skaičiaus ir supaprastinto sprendimo proceso YOLO architektūra pasižymi ne tik dideliu greičiu, bet ir stabiliu veikimu sudėtingose taikymo srityse. Medicininių vaizdų analizėje tai ypač svarbu, nes leidžia efektyviai apdoroti didelius vaizdų kiekius ir pateikti patikimus rezultatus per trumpą laiką. Tokios savybės daro YOLO architektūrą tinkamu pasirinkimu realaus laiko dermatologinių vaizdų segmentavimo ir patologinių odos pažeidimų aptikimo uždaviniuose [55]

YOLO architektūra sudaryta iš trijų pagrindinių struktūrinių komponentų: stuburo tinklo (angl. backbone), kaklo architektūros (angl. neck) ir galvos dalies (angl. head). Kiekvienas iš šių komponentų atlieka skirtingą, tačiau tarpusavyje glaudžiai susijusią funkciją, užtikrinančią efektyvų objektų aptikimą ir segmentavimą. Toks modulinis architektūros suskirstymas leidžia optimizuoti tiek skaičiavimo efektyvumą, tiek modelio tikslumą, o tai ypač svarbu medicininių vaizdų analizėje [55].

4.2.1. Stuburo tinklas (Backbone)

Stuburo tinklas yra pagrindinė YOLO architektūros dalis, atsakinga už požymių išskyrimą iš įvesties vaizdo. Šiame etape naudojami konvoliuciniai neuroniniai tinklai (CNN), kurie apdoroja vaizdą hierarchiniu principu – nuo paprastų žemo lygio požymių, tokių kaip kraštai ar tekstūros – iki sudėtingesnių aukšto lygio struktūrų.



YOLOv12 architektūra

6 pav. YOLOv12 architektūra [55].

Ankstyvosiose YOLO versijose buvo naudojamas Darknet architektūros pagrindu sukurtas stuburo tinklas, pasižymintis geru greičio ir tikslumo balansu (žr. 6 pav.). Vėlesnėse versijose pradėtos taikyti pažangesnės struktūros, tokios kaip CSP (Cross Stage Partial) tinklai, kurie sumažina skaičiavimo sąnaudas ir pagerina gradientų sklaidą mokymo metu. CSP tipo architektūros leidžia efektyviau išnaudoti tinklo gylį, neauginant modelio sudėtingumo, todėl tampa ypač tinkamos didelės raiškos vaizdams apdoroti [55].

Medicininėje vaizdų analizėje stuburo tinklo reikšmė yra itin didelė, nes patologiniai požymiai dažnai pasižymi subtiliais vizualiniais skirtumais. Odos pažeidimai, alerginės reakcijos ar dermatologiniai pakitimai gali skirtis vos spalvos ar tekstūros niuansais, todėl kokybiškas požymių išskyrimas yra būtina sąlyga tiksliam tolimesniam aptikimui ir segmentavimui.

4.2.2. Kaklo architektūra (Neck)

Kaklo architektūra YOLO modelyje skirta skirtingų mastelių požymių sujungimui ir jų informatyvumo didinimui. Kadangi objektai vaizduose gali būti įvairaus dydžio, vien tik stuburo tinklo išvesties dažnai nepakanka efektyviam jų aptikimui. Kaklo dalyje naudojami požymių suliejimo (angl. feature fusion) metodai leidžia sujungti informaciją iš skirtingų tinklo lygių.

Plačiai taikomi sprendimai yra FPN (Feature Pyramid Network) ir PAN (Path Aggregation Network) architektūros. FPN leidžia perduoti semantinę informaciją iš gilesnių sluoksnių į seklesnius, o PAN papildomai stiprina informacijos srautą priešinga kryptimi, taip pagerindamas lokalizacijos tikslumą. Šis daugiaskalės informacijos apdorojimas yra ypač svarbus aptinkant smulkius objektus.

Dermatologiniuose vaizduose smulkūs odos pažeidimai, tokie kaip nedidelės alerginės reakcijos ar ankstyvos stadijos patologiniai pokyčiai, gali sudaryti labai mažą vaizdo dalį. Dėl šios priežasties kaklo architektūros gebėjimas efektyviai apdoroti skirtingų mastelių požymius yra esminis veiksnys siekiant aukšto segmentavimo ir aptikimo tikslumo.

4.2.3. Galvos architektūra (Head)

Galvos dalis yra paskutinis YOLO architektūros komponentas, atsakingas už galutinių prognozių generavimą. Šiame etape atliekama ribinių dėžučių regresija, objektų klasifikacija ir, priklausomai nuo modelio konfigūracijos, segmentavimo kaukių prognozavimas.

Ribinių dėžučių regresija leidžia nustatyti tikslią objektų padėtį vaizde, o klasifikacijos komponentas apskaičiuoja tikimybes, priskiriančias objektus atitinkamoms klasėms. Segmentavimo užduotyse galvos dalis papildomai generuoja pikselių lygmens išvestis, kurios leidžia tiksliai atskirti patologines sritis nuo sveikos odos.

Medicininėje praktikoje segmentavimo išėjimai yra itin vertingi, nes suteikia ne tik objekto buvimo informaciją, bet ir detalų jo ribų apibrėžimą. Tai leidžia geriau įvertinti pažeidimų plotą, formą ir išsidėstymą, kas yra svarbu tiek diagnostikai, tiek ligos progresavimo stebėsenai. Dėl šios priežasties YOLO architektūros galvos dalies pritaikymas segmentavimo užduotims tampa ypač aktualus dermatologinių vaizdų analizėje.

4.3. Naudotos metrikos ir matematinės lygtys

4.3.1. Segmentavimo modelio vertinimo metrikos ir jų matematinis pagrindas

Segmentavimo modelio efektyvumo vertinimas šiame tyrime grindžiamas standartizuotomis kompiuterinės regos metrikomis, kurios plačiai taikomos objektų aptikimo ir semantinio segmentavimo uždaviniuose. Modelio mokymui ir validacijai buvo naudojama Ultralytics YOLO biblioteka, realizuojanti pažangias vertinimo procedūras, paremtas tikslumo, atkūrimo (precision–recall) analize. Kadangi nagrinėjamas uždavinys sprendžia segmentavimo problematiką, tai vertinimas atliekamas ne tik pagal objektų aptikimą, bet ir pagal jų erdvinį atitikimą su tikrosiomis (angl. *ground truth*) kaukėmis.

Sankirtos per sąjungą metrika (Intersection over Union)

Pagrindinė segmentavimo kokybės vertinimo metrika yra Intersection over Union, kuri kiekybiškai įvertina prognozuotos ir tikrosios srities persidengimą.

Ji apibrėžiama taip:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

kur: A žymi prognozuotą segmentacijos sritį, B – tikrąją, rankiniu būdu pažymėtą sritį, $|A \cap B|$ nusako abiem sritims bendrų pikselių skaičių, o $|A \cup B|$ – bendrą visų unikalių pikselių skaičių, priklausančių bent vienai iš lyginamų sričių. IoU reikšmė priklauso intervalui $[0, 1]$, kur: $IoU = 1$ reiškia idealią segmentaciją, $IoU = 0$ reiškia visišką neatitikimą.

Ši metrika yra kritinė, nes ji vertina ne tik objekto aptikimą, bet ir jo formos tikslumą. Remiantis IoU slenksčiu, prognozės klasifikuojamos į:

1. **True Positive (TP)** – teisingai aptikti objektai,
2. **False Positive (FP)** – klaidingai aptikti objektai,
3. **False Negative (FN)** – praleisti objektai.

Iš šių dydžių skaičiuojamos dvi pagrindinės metrikos:

Tikslumas (Precision):

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Atkūrimas (Recall):

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

Šios metrikos leidžia nustatyti ir rasti:

1. Precision parodo, kiek modelio aptikimų yra teisingi,
2. Recall parodo, kiek realių objektų modelis sugebėjo aptikti.

Šios metrikos dažnai yra matematiškai susijusios, didinant vieną, mažėja kita.

Vidutinio tikslumo metrika (Average Precision)

Norint įvertinti modelio veikimą per skirtingus sprendimo slenksčius, naudojama Average Precision (AP) metrika. AP apskaičiuojamas kaip tikslumo ir atkūrimo kreivės plotas:

$$AP = \int_0^1 Precision(Recall) d(Recall) \quad (4)$$

Praktikoje ši integralinė išraiška aproksimuojama diskretizuotais taškais.

Vidutinis vidutinis tikslumas (Mean Average Precision)

Kadangi modelis vertinamas per skirtingus IoU slenksčius, naudojama apibendrinta metrika:

$$mAP = \frac{1}{K} \sum_{k=1}^K AP_k \quad (5)$$

kur: K – IoU slenksčių skaičius, AP_k – vidutinis tikslumas esant konkrečiam IoU slenksčiui.

Taip pat šiame tyrime norint nustatyti modelių tikslumą ir jų veikimo teisingumą buvo naudotos ir kitos papildomos metrikos. Modelių vertinimui buvo naudojamos trys pagrindinės tikslumo nustatymo metrikos:

mAP50

$$mAP_{50} = AP \text{ esant } IoU = 0.5 \quad (6)$$

Tai reiškia, kad prognozė laikoma teisinga, jei:

$$IoU \geq 0.5 \quad (7)$$

Ši metrika yra „liberalesnė“ ir vertina, ar objektas apskritai buvo pakankamai tiksliai aptiktas.

mAP75

$$mAP_{75} = AP \text{ esant } IoU = 0.75 \quad (8)$$

Tai griežtesnė metrika, reikalaujanti didesnio segmentacijos tikslumo.

mAP50–95

$$mAP_{50-95} = \frac{1}{10} \sum_{i=0}^9 AP_{0.5+0.05i} \quad (9)$$

Ši metrika apskaičiuojama per IoU intervalą nuo 0.5 iki 0.95 kas 0.05:

$$IoU \in \{0.50, 0.55, 0.60, \dots, 0.95\} \quad (10)$$

Tai yra griežčiausia ir informatyviausia metrika, nes:

1. vertina modelių įvairiais tikslumo lygiais,
2. atspindi tiek aptikimo, tiek segmentacijos kokybę.

Modelio validacijos metu išvedami rodikliai:

1. mAP_{50-95} – bendras modelio našumas,
2. mAP_{50} – gebėjimas aptikti objektus,
3. mAP_{75} – gebėjimas tiksliai segmentuoti objektus.

Aukštas mAP_{50} , bet žemas mAP_{75} rodo, kad modelis aptinka objektus, tačiau netiksliai nustato jų ribas. Tuo tarpu aukštas mAP_{50-95} rodo stabilų modelio veikimą įvairiais tikslumo lygiais.

Šiame darbe segmentavimo metrikos yra kritinės, nes:

1. nuo segmentacijos kokybės tiesiogiai priklauso iškerpamų odos fragmentų tikslumas,

2. netikslūs segmentai lemia klaidingus spalvinius koeficientus,
3. tai tiesiogiai veikia alergijos klasifikavimo rezultatus.

Pasirinktos metrikos leidžia ne tik įvertinti modelio veikimą, bet ir pagrįsti visos tolimesnės analizės patikimumą.

4.3.2. Odos spalvinių pokyčių matematinis vertinimas naudojant ΔE pagrindu gautą koeficientą ir jo matematinis pagrindimas

Alerginių odos reakcijų kiekybiniam vertinimui šiame tyrime pasitelkiamas spalvinio skirtumo parametras ΔE (delta E), kuris nusako dviejų spalvų skirtumą CIELAB spalvų erdvėje. Šis rodiklis leidžia objektyviai įvertinti, kiek stipriai pakinta odos spalva reaguojant į alergena, lyginant sveikos ir pažeistos odos regionus. ΔE reikšmė šiuo atveju tampa svarbiu kiekybiniu indikatoriumi, leidžiančiu vizualinius odos pokyčius transformuoti į matematiškai apdorojamus duomenis, kurie gali būti naudojami reakcijos intensyvumo analizei ir palyginimui tarp skirtingų atvejų.

Norint rasti skirtumą tarp sveikos odos ir alergijos paveiktos odos buvo naudotas delta e skaičiavimas ir koeficientas. Šiame tyrime alerginių odos reakcijų identifikavimui ir intensyvumo vertinimui taikoma kompiuterinės regos ir spalvinės analizės metodų sintezė, leidžianti transformuoti vaizdinę informaciją į kiekybinius, palyginamus rodiklius. Esminė metodikos idėja grindžiama prielaida, kad alerginės reakcijos pasireiškia vizualiai stebimais odos spalvos pokyčiais, kurie gali būti objektyviai išreikšti matematinėmis funkcijomis.

Vaizdų analizėje svarbus žingsnis yra tinkamos spalvų erdvės parinkimas. Šiame darbe naudojama CIELAB color space spalvų erdvė, kuri pasižymi perceptiniu vienodumu, t. y. vienodi skaitiniai skirtumai atitinka panašius žmogaus regėjimo suvokiamus spalvinius pokyčius.

Transformacija iš RGB (BGR) į CIELAB erdvę apibrėžiama funkcija:

$$I_{LAB} = f(I_{RGB}) \quad (11)$$

Kiekvienam pikseliui p_i priskiriamas trijų dimensijų vektorius:

$$p_i = (L_i, a_i, b_i) \quad (12)$$

kur: $L_i \in [0,100]$ – šviesumo komponentė, a_i – žalios, raudonos spalvinės ašies reikšmė, b_i – mėlynos geltonos spalvinės ašies reikšmė.

Analizuojant odos fragmentą, sudarytą iš N pikselių, kiekvienam kanalui apskaičiuojamos vidutinės reikšmės:

$$\bar{L} = \frac{1}{N} \sum_{i=1}^N L_i, \bar{a} = \frac{1}{N} \sum_{i=1}^N a_i, \bar{b} = \frac{1}{N} \sum_{i=1}^N b_i \quad (13)$$

Šios reikšmės reprezentuoja agreguotą odos spalvinę būseną konkrečiame fragmente ir sumažina lokalių triukšmų bei tekstūrinių variacijų įtaką.

Klasikinėje spalvinėje analizėje skirtumas tarp dviejų spalvų apibrėžiamas naudojant Delta E metriką. Paprasčiausia jos forma (CIE76) yra:

$$\Delta E_{ab} = \sqrt{(L_1 - L_2)^2 + (a_1 - a_2)^2 + (b_1 - b_2)^2} \quad (14)$$

Ši formulė leidžia įvertinti bendrą spalvinių nuokrypių tarp dviejų taškų CIELAB erdvėje. Tačiau šiame tyrime taikomas modifikuotas, užduočiai adaptuotas modelis, orientuotas į specifinį alerginių reakcijų požymį, odos paraudimą. Eksperimentiniai stebėjimai parodė, kad alerginės reakcijos dažniausiai pasireiškia reikšmingu a^* kanalo (raudonumo) padidėjimu, tuo tarpu L^* komponentė leidžia kompensuoti apšvietimo variacijas.

Atsižvelgiant į tai, suformuluojamas normalizuotas spalvinis koeficientas:

$$C = \frac{\bar{a}}{\bar{L} + \epsilon} + 1 \quad (15)$$

kur: \bar{a} vidutinė paraudimo reikšmė, \bar{L} vidutinis šviesumas, $\epsilon = 1$ stabilizavimo konstanta, apsauganti nuo dalybos iš nulio ir mažų reikšmių.

Šis koeficientas interpretuojamas taip:

1. sveikai odai būdingos mažesnės a^* reikšmės $\rightarrow C \approx 1$,
2. alergizuotai odai būdingas padidėjęs $a^* \rightarrow C > 1$.

Kadangi odos spalva yra stipriai individuali savybė, šiame darbe taikomas personalizuotas požiūris. Kiekvienam pacientui apskaičiuojamas jo individualus sveikos odos etalonas.

Iš $M = 100$ sveikos odos fragmentų gaunami koeficientai C_i , o galutinis etalonas apibrėžiamas kaip:

$$C_{baseline} = \frac{1}{M} \sum_{i=1}^M C_i \quad (16)$$

Šis dydis atspindi paciento normalią odos būseną ir tampa referencine verte tolimesniems palyginimams.

Svarbu pažymėti, kad toks metodas:

1. eliminuoja tarpindividinius skirtumus,
2. sumažina apšvietimo ir vaizdo gavimo sąlygų įtaką,

Alergijos paveiktiems odos fragmentams apskaičiuojamas analogiškas koeficientas $C_{allergy}$. Tuomet nustatomas nuokrypis nuo individualaus etalono:

$$\Delta C = C_{allergy} - C_{baseline} \quad (17)$$

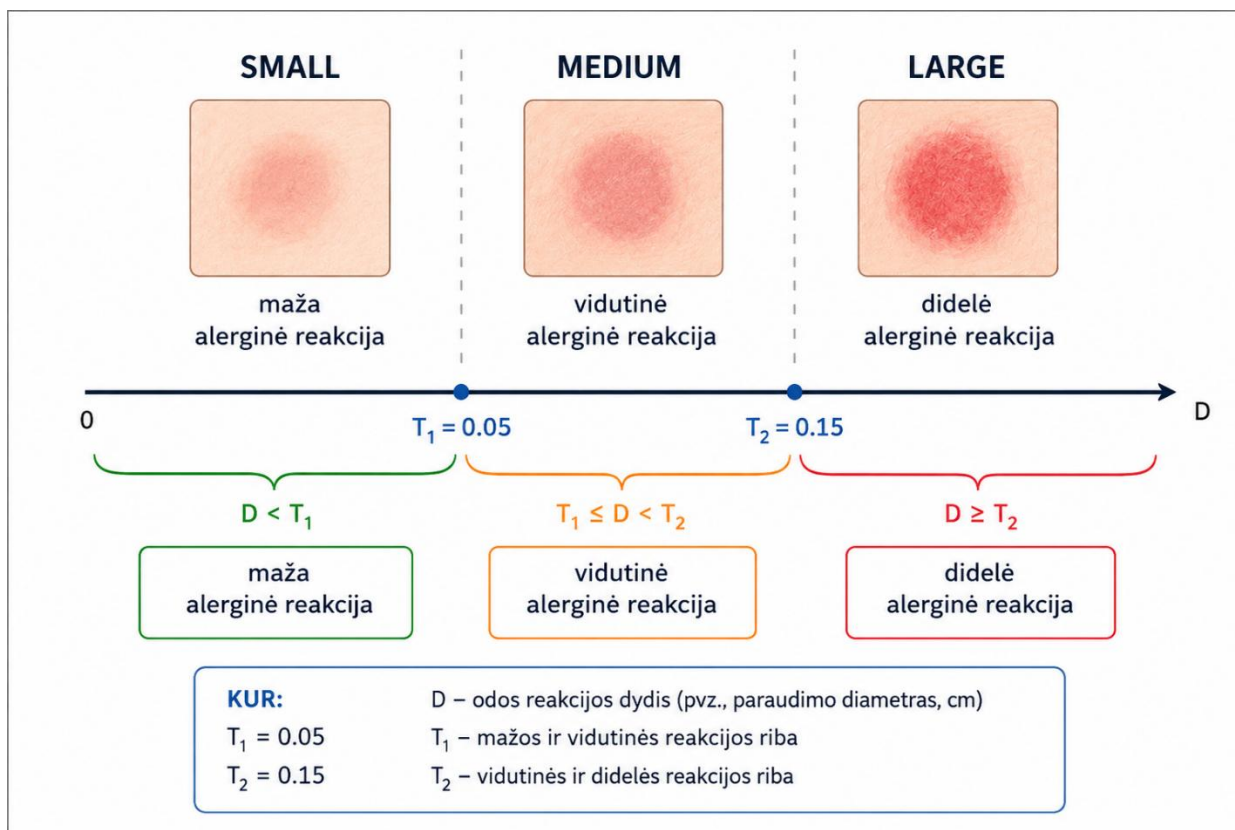
Kadangi svarbus nuokrypio dydis, o ne kryptis, naudojama absoliuti reikšmė:

$$D = |\Delta C| \quad (18)$$

Šis dydis interpretuojamas kaip spalvinio pokyčio intensyvumas. Remiantis eksperimentiniais duomenimis, trijų klasių klasifikavimo schema šiame darbe nebuvo nustatyta vien tik teoriškai ar heuristiškai, bet suformuota derinant matematinę analizę su eksperto (žmogaus) vizualiniu vertinimu.

Pradiniame etape medicinos specialistas vizualiai įvertino alergijos paveiktus odos vaizdus ir rankiniu būdu sužymėjo juos į tris kategorijas: mažo, vidutinio ir didelio intensyvumo alergines reakcijas. Šie anotavimo rezultatai buvo naudojami kaip referencinis (ground truth) pagrindas tolimesnei kiekybinei analizei.

Kiekvienam iš eksperto pažymėtų odos fragmentų buvo apskaičiuota atitinkama spalvinio nuokrypio $D = |\Delta C|$ reikšmė. Tokiu būdu kiekvienai vizualiai apibrėžtai klasei buvo gauta atitinkamų Dreikšmių imtis. Toliau, taikant statistinę analizę, buvo įvertintos šių imčių charakteristikos (vidurkiai, pasiskirstymo ribos), ir remiantis jų tarpusavio santykiais nustatyti slenkstiniai dydžiai, atskiriantys klases (žr. 7 pav.).



7 pav. Matematiškai gautų reikšmių ir odos reakcijų palyginimas.

Šio proceso rezultatas – matematiškai pagrįstos ribinės reikšmės T_1 ir T_2 , kurios atitinka perėjimo taškus tarp ekspertiškai identifikuotų klasių. Galutinė klasifikavimo schema apibrėžiama taip:

$$D < T_1 \Rightarrow \text{maža alerginė reakcija}$$

$$T_1 \leq D < T_2 \Rightarrow \text{vidutinė alerginė reakcija}$$

$$D \geq T_2 \Rightarrow \text{didelė alerginė reakcija}$$

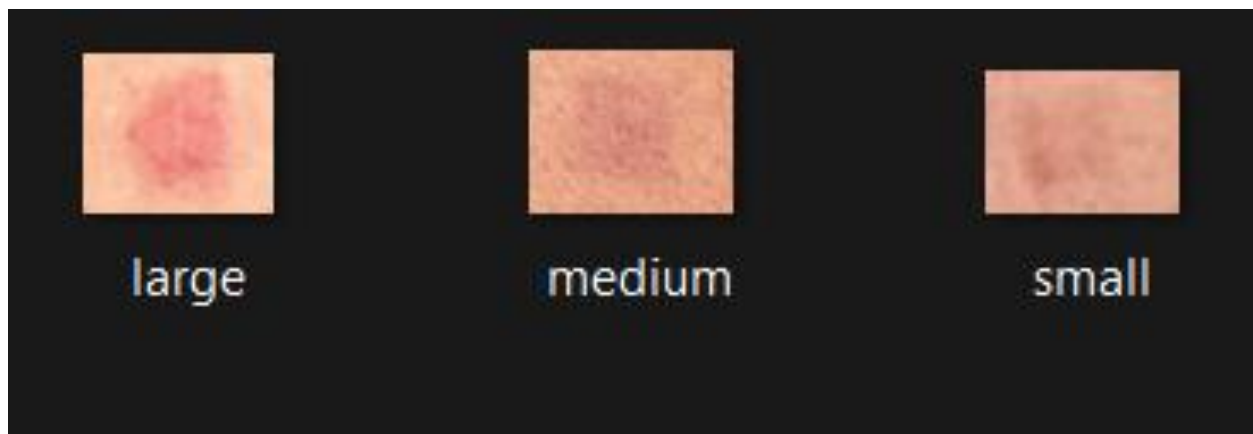
kur:

$$T_1 = 0.05, T_2 = 0.15$$

Svarbu pažymėti, kad šios ribos atspindi ne tik matematinį skaičiavimą, bet ir žmogaus vizualinį suvokimą, todėl jos gali būti interpretuojamos kaip tiltas tarp kiekybinės analizės ir klinikinės

praktikos. Tokiu būdu pasiekiamas kompromisas tarp algoritmo jautrumo ir praktinio interpretavimo paprastumo.

Žemiau pateikiamas pavyzdys, iliustruojantis eksperto atliktą alerginių sričių klasifikavimą, kuris buvo naudojamas slenkstinių reikšmių nustatymui (žr. 8 pav.):



8 pav. Didelės, vidutinės ir mažos alerginių reakcijų pavyzdžiai nustatyti žmogaus.

Toliau visas analizės procesas gali būti interpretuojamas kaip nuosekli transformacijų grandinė, kurioje vaizdinė informacija palaipsniui transformuojama į matematinę reprezentaciją:

$$I \rightarrow \{p_i\} \rightarrow LAB \rightarrow (\bar{L}, \bar{a}, \bar{b}) \rightarrow C \rightarrow D \rightarrow \text{klasė} \quad (19)$$

Šioje grandinėje pradinis vaizdas I yra transformuojamas į pikselių rinkinį $\{p_i\}$, kuris perkeliamas į CIELAB spalvų erdvę. Iš šių duomenų apskaičiuojami statistiniai vidurkiai, leidžiantys nustatyti spalvinį koeficientą C , kuris vėliau lyginamas su individualiu etalonu, gaunant nuokrypį D . Galiausiai, remiantis nustatytais slenkščiais, kiekvienas fragmentas priskiriamas atitinkamai alerginės reakcijos kategorijai.

Šie slenkščiai parinkti eksperimentiniu būdu, siekiant optimalaus jautrumo ir specifiškumo balanso.

Visas procesas gali būti interpretuojamas kaip nuosekli transformacijų grandinė:

1. Vaizdas $I \rightarrow$ pikselių rinkinys $\{p_i\}$
2. Pikseliai \rightarrow LAB erdvė
3. LAB komponentai \rightarrow statistiniai vidurkiai
4. Vidurkiai \rightarrow spalvinis koeficientas C
5. Koeficientai \rightarrow nuokrypis D
6. Nuokrypis \rightarrow klasifikavimo rezultatas

Tokiu būdu vizualinė informacija transformuojama į struktūruotą matematinę reprezentaciją, leidžiančią objektyviai ir pakartojamai vertinti odos būklę.

Nors siūlomas modelis yra efektyvus ir skaičiavimo požiūriu paprastas, jis remiasi tam tikromis prielaidomis:

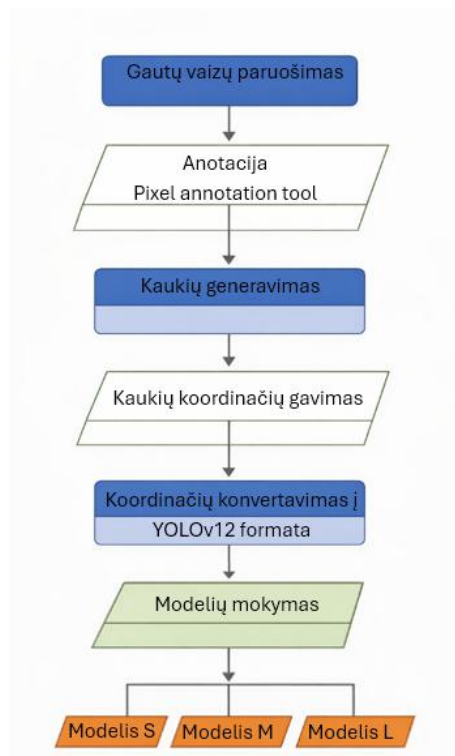
1. Pagrindinis alergijos indikatorius yra paraudimas (a^*).
2. Šviesumo normalizacija pakankamai kompensuoja apšvietimo skirtumus.
3. Odos tekstūra ir kiti požymiai nėra tiesiogiai vertinami.

Nepaisant to, eksperimentiniai rezultatai rodo, kad metodas yra pakankamai jautrus praktiniam taikymui ir gali būti naudojamas kaip bazinis komponentas sudėtingesnėse diagnostinėse sistemose.

5. Eksperimentinis tyrimas

5.1. Tyrimo etapai ir eiga

Atliekant šį tyrimą buvo atlikti keli pasiruošimo etapai. Pirmasis iš šio tyrimų etapų buvo pasiruošimas tyrimui atliekant literatūros analizę ir gautų medicininių duomenų ir rastų internete sveikos odos vaizdų pasiruošimas modelių mokymui. Šis procesas yra atvaizduotas paveikslėlyje. Šiame paveikslėlyje pavaizduota schema parodo atliktą vaizdų paruošimą (žr. 9 pav.).



9 pav. Pirminio sveikos odos segmentavimo tyrimo etapų atvaizdavimas schema.

Pirmiausiai vaizdai buvo paruošti naudojant pixel anotation tool. Rankiniu būdu buvo sužymėti reikiami kontūrai kur yra sveika oda, tada šie kontūrai buvo paversti į kaukes iš kurių buvo gautos koordinatės kurios buvo paruoštos ir parašytos pritaikytos YOLOv12 formatui, naudojant šias koordinates ir vaizdus buvo apmokyti skirtingi modeliai s, m ir l.

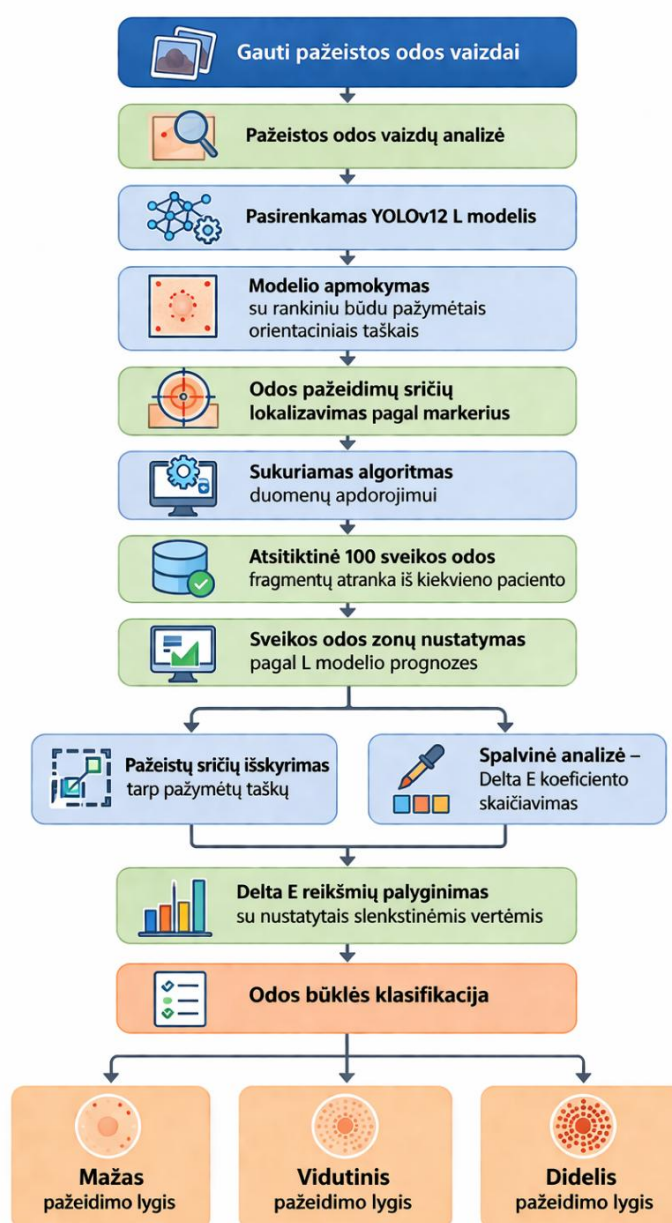
Tolimesniame tyrimo etape dėmesys buvo sutelktas į pažeistos odos vaizdų analizę, pasitelkiant didžiausios talpos modelio architektūrą. Šiam tikslui buvo pasirinktas YOLOv12 L (large) konfigūracijos modelis, kuris buvo papildomai apmokytas identifikuoti medicinos specialistų rankiniu būdu pažymėtus orientacinius taškus tiriamuosiuose vaizduose. Šie žymėjimai veikė kaip referenciniai markeriai, leidžiantys tiksliai lokalizuoti odos pažeidimų sritis.

Siekiant automatizuoti duomenų apdorojimą ir sumažinti subjektyvumo įtaką, buvo sukurtas specializuotas algoritmas. Šis algoritmas atsitiktinės atrankos principu iš kiekvieno paciento duomenų rinkinio išskiria po 100 vaizdų fragmentų, reprezentuojančių sveikos odos zonas. Šios zonos nustatomos remiantis anksčiau apmokyto ir didžiausią tikslumą pasiekusio L modelio prognozėmis, taip užtikrinant patikimą etaloninių duomenų formavimą.

Toliau atliekama pažeistų sričių ekstrakcija, orientuojantis į regionus tarp medicinos darbuotojų pažymėtų taškų. Šios sritys laikomos potencialiai alerginių reakcijų paveiktomis zonomis. Išskirtoms sritims taikoma kiekybinė spalvinė analizė, pagrįsta Delta E koeficiento skaičiavimu, kuris leidžia objektyviai įvertinti spalvinius pokyčius tarp sveikos ir pažeistos odos.

Gauti Delta E reikšmių skirtumai yra analizuojami ir lyginami su nustatytais slenksstiniais dydžiais, leidžiančiais klasifikuoti odos būklę pagal pažeidimo intensyvumą. Remiantis šia analize, odos būklė priskiriama vienai iš trijų kategorijų: mažo, vidutinio arba didelio alerginio pažeidimo lygio.

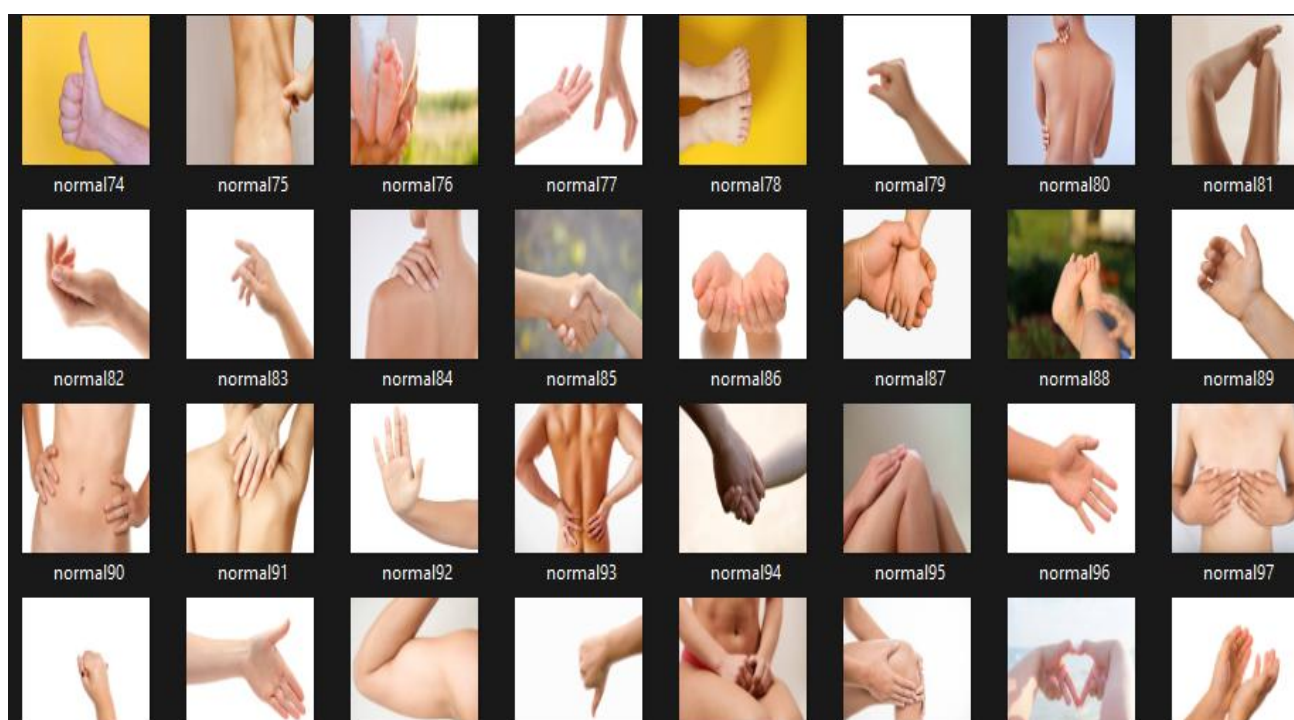
Tokiu būdu sukurta metodika leidžia ne tik tiksliai identifikuoti pažeistas odos sritis, bet ir suteikia kiekybinį pagrindą objektyviai įvertinti alerginės reakcijos stiprumą, integruojant kompiuterinės regos metodus su spalvinės analizės principais. Žemiau pateiktame paveikslėlyje galima pamatyti visą tolimesnę darbo eigą ir etapus aprašytus aukščiau atvaizduotus schema (žr. 10 pav.).



10 pav. Schema kurioje yra atvaizduoti tolimesni tyrimo etapai.

5.2. Duomenų apdorojimas ir paruošimas

Eksperimentinio tyrimo etape buvo atliktas sistemingas pirminis vaizdinių duomenų paruošimas, kurio pagrindinis tikslas – suformuoti patikimą ir kokybiškai anotacijomis pagrįstą sveikos odos vaizdų rinkinį, tinkamą giluminio mokymosi modelių mokymui, validavimui ir tolimesnei eksperimentinei analizei. Duomenų paruošimo etapas laikomas kritiniu viso tyrimo kontekste, kadangi anotacijų tikslumas tiesiogiai veikia modelių gebėjimą išmokyti prasmingus vizualinius požymius ir sumažinti klaidingų prognozių tikimybę vėlesniuose etapuose. Paveikslėlyje galima pamatyti sveikos odos nuotraukų pavyzdį (žr. 11 pav.).



11 pav. Sveikos odos nuotraukų naudotų mokyme pavyzdys.

Pirminiam anotavimo procesui buvo pasirinktas „Pixel Annotation Tool“, leidžiantis atlikti detalią pikselių lygmens segmentaciją ir užtikrinti aukštą anotacijų tikslumą. Šio įrankio panaudojimas suteikė galimybę tiksliai apibrėžti odos sritis net ir sudėtingomis vizualinėmis sąlygomis, kai odos ribos nėra aiškiai apibrėžtos dėl nevienodo apšvietimo, spalvinių perėjimų ar tekstūrinių netolygumų. Anotavimo aplinkoje buvo sukurtas atskiras projektas, kuriame klasifikavimo schema sąmoningai apribota viena tiksline klase – „sveika oda“. Toks sprendimas leido sumažinti anotavimo klaidų tikimybę ir užtikrinti semantinę duomenų nuoseklumą, ypač ankstyvojoje modelių mokymo stadijoje.

Kiekvienam vaizdui buvo sugeneruotas atskiras anotacijos sluoksnis („label“), naudojamas kaip nepriklausomas segmentavimo kanalas. Šis sluoksnis vėliau tapo pagrindiniu etaloniniu duomenų šaltiniu modelių mokymui, leidžiančiu tiksliai palyginti prognozuojamus rezultatus su rankiniu būdu parengtomis anotacijomis. Toks anotacijų struktūrizavimas taip pat sudarė prielaidas efektyviam duomenų apdorojimui ir suderinamumui su pasirinktais giluminio mokymosi modeliais.

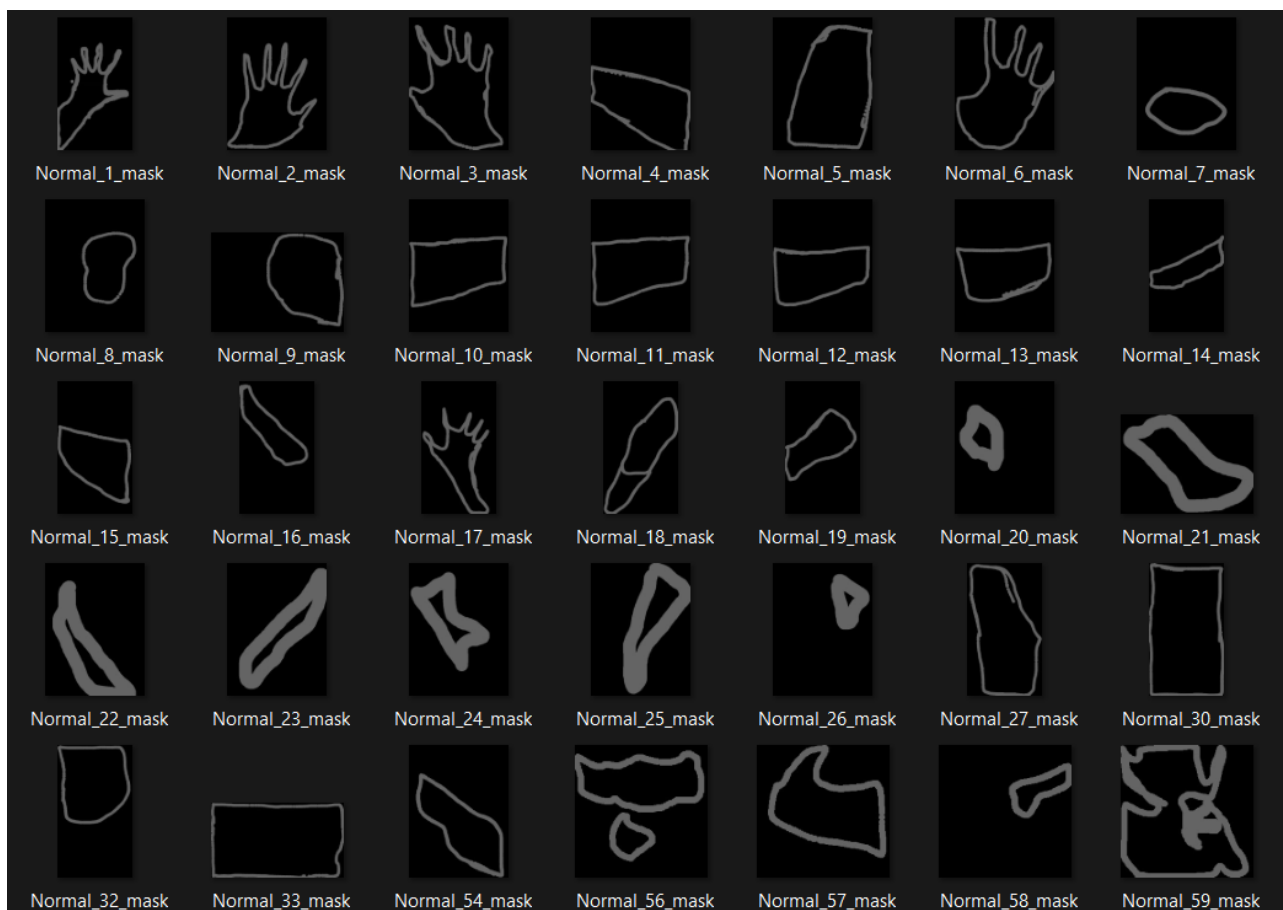
Iš viso buvo rankiniu būdu apdorota 300 vaizdų (žr. 12 pav.), siekiant užtikrinti maksimalų segmentavimo tikslumą. Rankinis anotavimas leido itin preciziškai pažymėti sudėtingas odos sritis, tokias kaip laipsniškai kintantys spalviniai tonai, minkštos tekstūrinės ribos ar šešėliavimo zonos, kurios dažnai kelia iššūkių automatiniam segmentavimo algoritmams. Anotavimo procesas apėmė kruopštų kontūrų sekimą, spalvinių gradientų diferenciaciją bei selektyvų pikselių priskyrimą tikslinei klasei.



12 pav. Pixel anotation programine įranga žymimi tinkamos odos kontūrai.

Rankinis žymėjimo metodas buvo pasirinktas sąmoningai, atsižvelgiant į tai, kad automatizuoti segmentavimo sprendimai sveikos odos atveju neretai pateikia netikslius rezultatus, ypač esant nevienodam apšvietimui, atspindžiams ar mažam kontrastui tarp odos ir fono. Be to, ankstyvajame tyrimo etape buvo siekiama išvengti klaidingų modelio prielaidų formavimo, kurios galėtų neigiamai paveikti mokymo procesą ir sumažinti bendrą modelio generalizacijos gebėjimą. Tokiu būdu užtikrinta, kad giluminio mokymosi modeliai būtų apmokomi remiantis aukštos kokybės, ekspertiškai parengtais duomenimis, sudarančiais patikimą pagrindą tolimesniems eksperimentams.

Po pradinio anotavimo etapo, naudojant *Pixel Annotation Tool*, rankiniu būdu buvo parengtos 100 sveikos odos vaizdų anotacijos. Šių anotacijų pagrindu buvo sugeneruoti segmentavimo kaukių failai, kurie tolimesniuose tyrimo etapuose taikomi kaip referenciniai duomenys modelių mokymo, validavimo ir eksperimentinių rezultatų vertinimo procesuose (žr. 13 pav.).



13 pav. Sukurtos kaukės.

Paraleliai sveikos odos duomenų rinkiniui buvo sudarytas ir alerginių odos reakcijų vaizdų rinkinys, kuriame užfiksuotos skirtingo intensyvumo kontaktinės odos reakcijos. Šiose nuotraukose aiškiai matomi vizualiai išreikšti uždegiminiai odos pokyčiai, tokie kaip eritema, infiltracija bei pūslelių formavimasis, kurie skirtingais atvejais pasireiškia nevienodu intensyvumu ir plotu. Tokia vaizdinė medžiaga leido identifikuoti ne tik reakcijos lokalizaciją, bet ir jos morfologinius skirtumus, būdingus skirtingoms alerginės reakcijos stadijoms. Surinkti duomenys buvo sistemingai struktūruoti ir vėliau naudoti tolimesnei analizei bei modelių mokymui, užtikrinant, kad algoritmai būtų treniruojami ne tik su sveikos, bet ir su pataloginės odos pavyzdžiais, taip sudarant sąlygas patikimesniam reakcijų atpažinimui realiose klinikinėse situacijose (žr. 14 pav.).



14 pav. Odos reakcijų pavyzdžiai.

5.3. Kontūrų radimas

Atliekant sveikos odos segmentavimo užduotį, buvo sukurta automatizuota anotacijų generavimo procedūra, skirta paruošti duomenis YOLO formato segmentavimo modeliams. Pagrindinis šio etapo tikslas – sumažinti rankinio žymėjimo poreikį ir užtikrinti vienodą, standartizuotą anotacijų struktūrą, kuri būtų atspari žmogaus klaidoms ir tinkama giluminio mokymosi algoritmų mokymui. Kadangi sveikos odos regionai originaliose kaukėse buvo išskirti vienodu pilkos spalvos tonu, segmentavimui pritaikytas spalvinis filtravimas, leidžiantis tiksliai izoliuoti tik dominuojantį odos plotą.

Tolimesniame procese kaukės buvo konvertuojamos į binarinį vaizdą, taikant spalvų intervalo filtrą, po kurio buvo atliekama kontūrų analizė siekiant identifikuoti pagrindinį odos regioną. Naudojant išorinės struktūros (external contour) išskyrimą, buvo eliminuojami smulkūs triukšmo elementai ir paliekamas tik didžiausias, anomiškai reikšmingas odos plotas. Šis žingsnis yra esminis, nes užtikrina, kad segmentacija atitiktų realią odos struktūrą, o ne artefaktus ar foninius netolygumus.

Gauti kontūrai buvo transformuojami į YOLO segmentavimo formato poligonus, normalizuojant koordinatės reikšmes pagal vaizdo matmenis. Tokiu būdu kiekvienas taškas buvo išreiškiamas santykinė forma, nepriklausančia nuo rezoliucijos, kas leidžia modeliams apdoroti skirtingo dydžio vaizdus be papildomo pritaikymo. Galutinės anotacijos buvo saugomos tekstiniu formatu, suderinamu su šiuolaikiniais YOLO segmentavimo modeliais, užtikrinant tiesioginį jų panaudojimą mokymo procese.

Apibendrinant, sukurtas metodas leidžia efektyviai automatizuoti sveikos odos segmentavimo anotacijų paruošimą, reikšmingai sumažinant rankinio darbo sąnaudas ir padidinant duomenų nuoseklumą. Tai sudaro patikimą pagrindą tolimesniems eksperimentams su patologinių odos reakcijų analize, kur svarbu aiškiai atskirti sveiką ir pažeistą audinį bei užtikrinti aukštą mokymo duomenų kokybę.

5.4. Modelių mokymas

Šiame darbe buvo apmokyti trys skirtingo sudėtingumo YOLOv12 segmentavimo modeliai: YOLOv12s-seg, YOLOv12m-seg ir YOLOv12l-seg. Šie modeliai skiriasi tinklo gyliu, parametru skaičiumi ir skaičiavimo resursų poreikiu, todėl jų palyginimas leidžia įvertinti architektūros sudėtingumo įtaką segmentavimo tikslumui bei veikimo spartai. Mažiausios architektūros modelis YOLOv12s-seg pasižymi mažiausiu parametru skaičiumi ir yra orientuotas į realaus laiko taikymus bei ribotų skaičiavimo resursų aplinkas. Vidutinio sudėtingumo YOLOv12m-seg modelis turi didesnę tinklo gylį, leidžiantį tiksliau atkurti sudėtingesnes struktūras ir tekstūrinius skirtumus. Tuo tarpu YOLOv12l-seg yra giliausia ir daugiausiai parametru turinti architektūra, optimizuota maksimaliam segmentavimo tikslumui ir smulkių detalių identifikavimui.

Modelių mokymui buvo naudojamas duomenų rinkinys, sudarytas iš vientisų sveikos odos poligoninių anotacijų. Tokios anotacijos yra ypač tinkamos segmentavimo užduotims, nes tiksliai atspindi realius odos kontūrus. Šis aspektas yra kritiškai svarbus tolimesniems tyrimo etapams, kuriuose sveikos odos segmentas naudojamas kaip foninė kaukė arba kaip pradinė filtravimo sąlyga, leidžianti atskirti patologinius odos pakitimus nuo normalių audinių.

Mokymo procesas buvo inicijuojamas naudojant YAML konfigūracinį failą, kuriame aprašyta duomenų rinkinio struktūra, treniravimo, validavimo ir testavimo rinkinių skaidymas bei klasifikacijos schema. Prieš mokymą buvo įkelti pradiniai iš anksto apmokyti modelių svoriai, leidžiantys pasinaudoti pernešamojo mokymosi (transfer learning) privalumais ir paspartinti konvergenciją.

Modelių mokymui buvo pasirinktas 512×512 pikselių įvesties vaizdų dydis, užtikrinantis pakankamą odos tekstūrų ir kontūrų detalumą, kartu neviršijant turimų GPU atminties apribojimų. Mokymas buvo vykdomas 300 epokų, siekiant užtikrinti stabilų modelio konvergavimą, ypač atsižvelgiant į tai, kad segmentavimo užduotyje modelis turi išmokyti tiksliai atkurti sudėtingas poligonines formas. Batch size = 4 buvo parinktas atsižvelgiant į naudojamus skaičiavimo resursus, išlaikant balansą tarp mokymo stabilumo ir skaičiavimo spartos.

Pasibaigus mokymo procesui, sistema automatiškai išsaugojo geriausią modelio versiją (best.pt), parinktą pagal validavimo metrikas. Šis modelis buvo pritaikytas testavimo duomenų rinkiniui, siekiant įvertinti jo gebėjimą atkurti sveikos odos kontūrą skirtingomis sąlygomis, įskaitant kintantį apšvietimą, odos tonų įvairovę ir foninius vaizdo elementus. Testavimo rezultatai automatiškai išsaugomi atskirame kataloge.

Modelių veikimas buvo vertinamas naudojant YOLOv12 segmentavimo modulyje pateikiamas standartines validavimo metrikas: mAP50–95, mAP50 ir mAP75. Šios metrikos leidžia įvertinti segmentavimo tikslumą skirtingais persidengimo slenksčiais. Medicininių vaizdų analizės kontekste ypač svarbi yra mAP75 metrika, nes ji atspindi modelio gebėjimą tiksliai atkurti smulkius kontūrų kraštus ir išlaikyti segmentų geometrinį tikslumą.

Apibendrinant galima teigti, kad apmokius visus tris YOLOv12 segmentavimo modelius buvo sudarytos sąlygos išsamiai palyginti jų efektyvumą sveikos odos segmentavimo užduotyje. Mažesnės architektūros modeliai pasižymi didesniu veikimo greičiu ir mažesnėmis atminties sąnaudomis, todėl yra tinkami realaus laiko sprendimams. Tuo tarpu didesni modeliai, turintys daugiau parametru, dažniausiai pasiekia tikslesnį poligonų atkūrimą, todėl yra labiau tinkami scenarijams, kuriuose segmentavimo patikimumas yra svarbesnis už skaičiavimo spartą. Gautų rezultatų analizė sudaro tvirtą metodologinį pagrindą tolimesniems tyrimo etapams, kuriuose sveikos odos segmentas naudojamas kaip filtravimo sluoksnis patologinių odos pokyčių identifikavimui ir detalesnei odos struktūrų analizei.

5.5. Alergijos pažeistos odos vaizdų paruošimas

Buvo surinkti šešių pacientų klinikiniai duomenys, kuriems buvo atlikti alerginio kljuojamojo lopo (angl. patch test) tyrimai, skirti kontaktinės alergijos diagnostikai. Kiekvieno paciento duomenų rinkinį sudarė medicinos darbuotojų standartizuotomis sąlygomis užfiksuoti odos reakcijų vaizdai skirtingais laiko momentais: po 48, 72 valandų ir praėjus 7 dienoms nuo testo atlikimo. Paveikslėlyje galima matyti vieno iš pacientų nuotraukas po 48, 72 ir 7 dienų (žr. 15 pav.).



15 pav. Paciento nuotraukos kuriose matoma alerginė reakcija praėjus laiko intervalams.

Tokia laiko seka leidžia įvertinti tiek ankstyvasias, tiek vėlyvasias alergines reakcijas bei jų dinamiką. Surinkti vaizdiniai duomenys pasižymėjo nevienalytiškumu dėl apšvietimo, kampo bei odos savybių variacijų, todėl buvo būtina atlikti jų sistemingą atranką. Vaizdai buvo kruopščiai išrūšiuoti pagal pacientus, laiko žymas ir reakcijos stiprumo požymius. Siekiant užtikrinti duomenų kokybę, buvo pašalinti neinformatyvūs ar techninių trūkumų turintys įrašai. Toliau duomenys buvo struktūrizuoti į nuoseklias kategorijas kurios leidžia juos apdoroti automatiškai. Taip pat buvo atliktas pradinis vaizdų normalizavimas ir standartizavimas, siekiant sumažinti išorinių veiksnių įtaką. Paruoštas duomenų rinkinys buvo tinkamai suformatuotas ir parengtas tolimesniems analizės bei modelių kūrimo etapams. Sveikos odos ir alergijos paveiktos odos koeficiento radimas.

5.6. Alergijos paveiktos odos aptikimas, aerginės reakcijos radimas ir klasifikavimas

Alerginių reakcijų lokalizacijai nustatyti pirmiausia buvo sukurtas ir apmokytas modelis, skirtas identifikuoti medicinos darbuotojų pažymėtus juodus orientacinius taškus vaizduose. Šie taškai atlieka svarbią referencinę funkciją, nes tiksliai apibrėžia alerginio lopo (patch testo) aplikacijos zonas odoje (žr. 16 pav.). Remiantis jų erdvine padėtimi, galima patikimai nustatyti regionus, kuriuose tikėtinos alerginės reakcijos. Tokiu būdu sumažinama analizės erdvė ir padidinamas tolimesnių etapų tikslumas.



16 pav. Aptikti juodi medicinos darbuotojo sužymėti taškai.

Buvo sukurtas papildomas, daugiaetapis algoritmas, skirtas automatizuotai odos sričių segmentacijai ir reprezentatyvių mėginių atrankai. Pirmajame algoritmo etape pasitelkiamas anksčiau apmokytas YOLOv12 L (large) konfigūracijos modelis, kuris naudojamas patikimai sveikos odos regionų detekcijai vaizduose. Šis etapas sudaro pagrindą tolimesnei analizei, nes leidžia atskirti etalonines (nepažeistas) sritis nuo potencialiai patologiškos zonos. Paveikslėlyje galite matyti kaip pirmiausia yra aptinkama sveika oda (žr. 17 pav.).



17 pav. Sveikos odos aptikimas.

Identifikavus sveikos odos regionus, taikomas papildomas medicinos specialistų pažymėtų orientacinių taškų aptikimo algoritmas. Remiantis šiais taškais, išskiriama specifinė vaizdo sekcija, kuri apibrėžia sritį, skirtą alerginių pažeidimų analizei. Tokiu būdu užtikrinama, kad tolimesnis tyrimas būtų orientuotas į kliniškai reikšmingas ir tikslingai lokalizuotas zonas.

Likusi aptiktos sveikos odos dalis naudojama etaloninių duomenų generavimui. Nuotraukoje galite matyti pavyzdį (žr. 18 pav.).



18 pav. Aptiktos sveikos odos iškirpimas ir panaudojimas.

Iš šių sričių automatiškai ir atsitiktinės atrankos principu iškerpama po 100 vaizdo iškarpų kiekvienam tiriamajam. Tokia imties formavimo strategija leidžia sumažinti šališkumo riziką ir užtikrina statistinį reprezentatyvumą. Atrinktos iškarpos vėliau naudojamos sveikos odos charakteristikoms apibrėžti bei kiekybiniais rodikliais apskaičiuoti.

Gauti duomenys sudaro pagrindą sveikos odos referencinio koeficiento nustatymui, kuris vėliau naudojamas kaip palyginamasis etalonas vertinant spalvinius ir tekstūrinius pokyčius alergijos paveiktose srityse. Tokiu būdu sukurtas algoritmas integruoja kompiuterinės regos metodus su struktūruota duomenų atranka, užtikrindamas tiek analizės tikslumą, tiek jos pakartojamumą.

Sveikos odos referenciniam koeficientui nustatyti buvo sukurtas atskiras skaičiavimo algoritmas, orientuotas į individualizuotą kiekvieno paciento odos charakteristikų įvertinimą. Šis algoritmas analizuoja anksčiau suformuotą 100 sveikos odos vaizdų iškarpų rinkinį ir, taikant matematinius apdorojimo metodus, apskaičiuoja kiekvienam pacientui būdingą unikalų rodiklį (žr. 19 pav.).



19 pav. Sveikos odos iškirptų nuotraukų naudojamų koeficiento nustatymui pavyzdys.

Remiantis šiais duomenimis, apskaičiuojama svartinė metrika, kuri apibendrina sveikos odos būklę ir sumažina pavienių matavimų variacijų įtaką. Tokiu būdu gaunamas stabilus ir reprezentatyvus matematinis koeficientas, atspindintis individualų odos „etaloną“.

Gauta kiekvieno paciento koeficiento reikšmė naudojama kaip bazinis palyginamasis dydis tolimesnėje analizėje, vertinant nuokrypius alergijos paveiktose odos srityse. Šis metodas leidžia pereiti nuo bendrinių vertinimo kriterijų prie personalizuotos analizės, didinant rezultatų tikslumą ir patikimumą.

Atitinkamoje (žr. 1 lentelė.), lentelėje pateikiamos visų penkių tiriamųjų pacientų apskaičiuotos svartinės sveikos odos koeficiento reikšmės, kurios iliustruoja individualius skirtumus ir sudaro pagrindą tolesniam lyginamajam vertinimui.


1 lentelė. Pacientų sveikos odos koeficiento reikšmės.

Pacientas	2022091	2022092	2022093	2022094	2022095
Sveikos odos koeficiento vidurkis	1.868924	1.8427159	1.90133746	1.87659214	1.985310977

Sekančiame tyrimo etape buvo atliekamas alergijos paveiktų odos sričių lokalizavimas ir jų fragmentų išskyrimas. Šiam tikslui buvo sukurtas specializuotas algoritmas, leidžiantis automatizuotai identifikuoti ir segmentuoti potencialiai alergizuotus odos lopinėlius iš viso vaizdo.

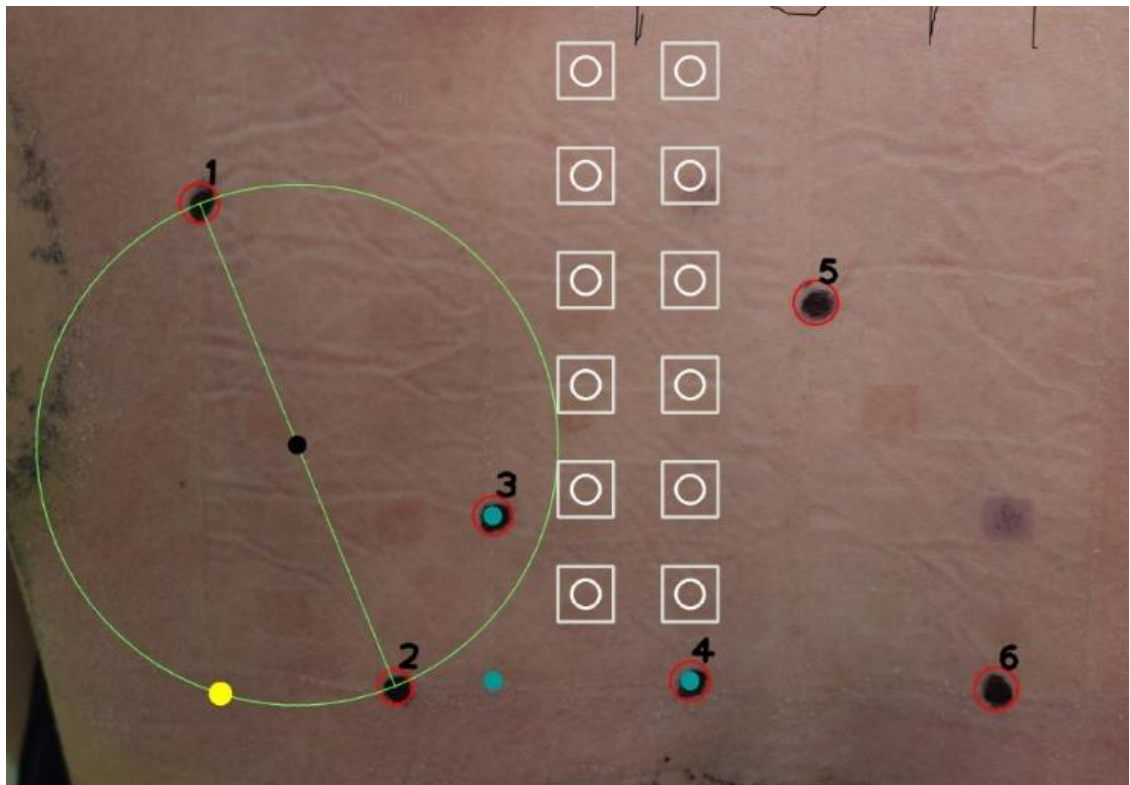
Algoritmo veikimas grindžiamas erdviu apribojimu: analizė vykdoma tik tose vaizdo srityse, kurios apibrėžiamos tarp anksčiau aptiktų medicinos specialistų pažymėtų juodų orientacinių taškų. Toks sprendimas leidžia eliminuoti nereikšmingas ar su tyrimu nesusijusias vaizdo dalis, sumažinant triukšmą ir didinant identifikavimo tikslumą. Tokiu būdu užtikrinama, kad analizuojami fragmentai yra tiesiogiai susiję su klinikinio testavimo zonomis.

Atrinkti odos fragmentai buvo automatiškai iškerpami ir išsaugomi struktūrizuotu formatu, išlaikant jų erdvinę bei semantinę priklausomybę konkrečiam pacientui ir atitinkamam tyrimo laiko momentui. Šis duomenų organizavimo principas sudaro prielaidas nuosekliai ir pakartojamai analizei. Nuotraukoje galima matyti pavyzdį (žr. 20 pav.).




20 pav. Automatiškai iškripti alergijos paveiktos odos vaizdiniai mėginiai.

Paveiksluose pateikiami pavyzdžiai iliustruoja, kaip algoritmas automatiškai aptinka žymenis ir apskaičiuoja jų tarpusavio geometrinius ryšius, naudojamus tolimesniam lokalizacijos procesui (žr. 21 pav. ; žr. 22 pav.). Atstumų analizė leidžia sistemai formuoti stabilų erdvinį odos lopelių tinklą, kuris tampa pagrindu standartizuotam reakcijų vertinimui.



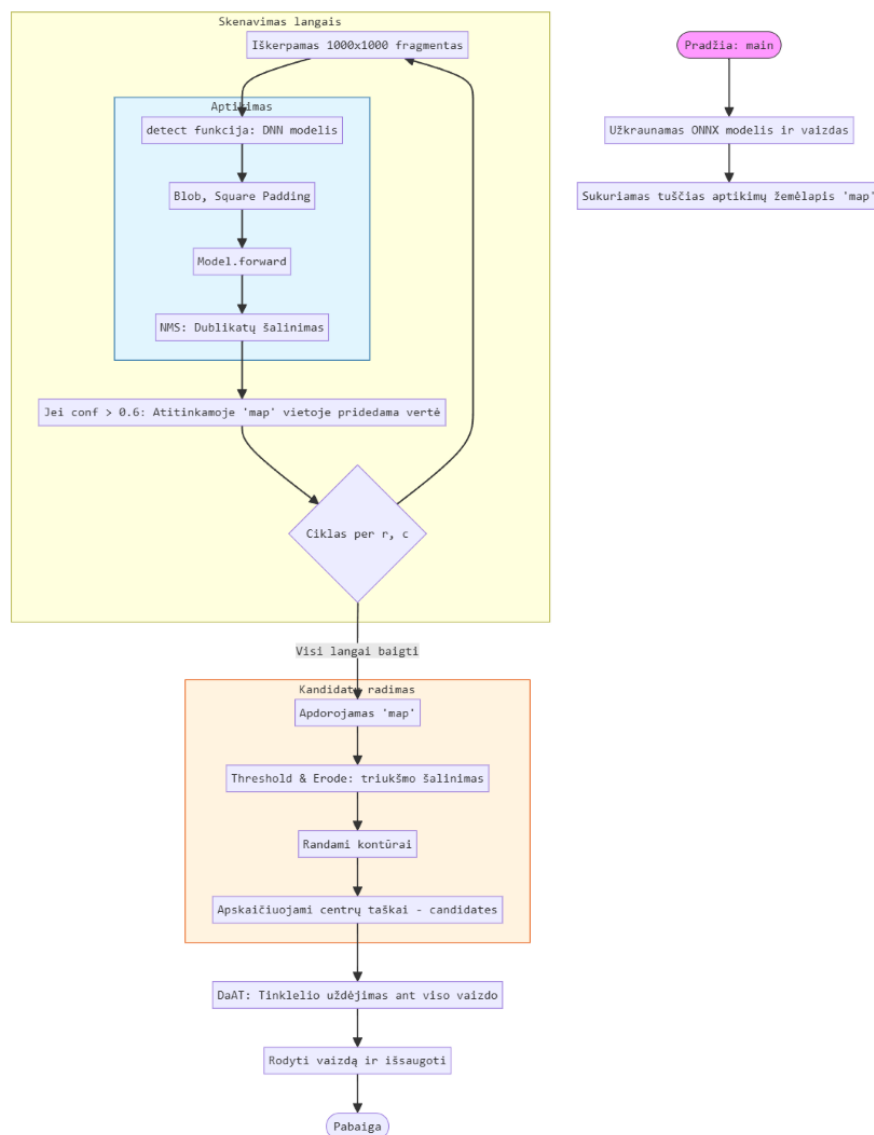
21 pav. Automatiškai iškripti antro pleistro alergijos paveiktos odos vaizdiniai mėginiai.



22 pav. Automatiškai iškripti trečio pleistro alergijos paveiktos odos vaizdiniai mėginiai.

Pateiktame algoritme realizuojama automatizuota odos lopo sričių lokalizavimo ir juodų orientacinių taškų aptikimo seka, skirta standartizuoti alerginių odos reakcijų analizės procesą. Metodo architektūra sudaryta iš dviejų pagrindinių etapų: pirmiausia atliekamas odos lopelių aptikimas naudojant giluminio mokymosi objektų detekcijos modelį, o vėliau identifikuojami juodi kontroliniai taškai, kurie naudojami kaip geometriniai orientyrai tolimesniam odos reakcijų lokalizavimui ir

analizės stabilizavimui (žr. 23 pav.). Toks daugiaetapis metodas leidžia sumažinti foninių struktūrų įtaką, pagerinti segmentavimo tikslumą ir užtikrinti nuoseklesnį patologinių sričių vertinimą.



23 pav. Alerginės reakcijos paveiktos odos lopų iškirpimo iš nuotraukų algoritmo veikimo paaiškinimo schema.

Pradiniame algoritmo etape į sistemą įkeliamas originalus odos vaizdas bei apmokytas objektų aptikimo modelis. Toliau vykdomas vaizdo skaidymas į 800×1000 pikselių fragmentus. Toks fragmentavimas pasirinktas siekiant sumažinti neuroninio tinklo apkrovą ir pagerinti mažesnių objektų aptikimo kokybę. Medicininuose vaizduose alerginių lopelių struktūros dažnai užima santykinai nedidelę vaizdo dalį, todėl viso vaizdo analizė vienu metu gali sumažinti detekcijos jautrumą. Fragmentavimo metodas leidžia kiekvieną odos sritį analizuoti didesniu masteliu, išsaugant smulkias struktūrines detales ir padidinant aptikimo tikslumą.

Kiekvienas fragmentas perduodamas į „detect“ funkciją, kurioje aktyvuojamas YOLO pagrindu sukurtas objektų aptikimo modelis. Tada atliekamas „Blob“ ir „Square Padding“ etapas. Blob transformacija normalizuoja įvesties duomenis ir konvertuoja vaizdą į neuroniniam tinklui tinkamą

reprezentaciją, o kvadratinis papildymas (square padding) užtikrina vienodus įvesties matmenis neprarandant proporcijų. Tokia procedūra sumažina geometrinių iškreipimų tikimybę ir leidžia modeliui stabiliau interpretuoti objektų formas skirtinguose fragmentuose.

Toliau vykdomas „model.forward“ etapas, kurio metu neuroninis tinklas generuoja objektų prognozes. Modelio išvestyje gaunamos ribinės dėžutės (bounding boxes), jų koordinatės bei klasių tikimybės. Po inferencijos atliekamas NMS (Non-Maximum Suppression) filtravimas, skirtas pašalinti persidengiančias arba perteklines detekcijas. Šis žingsnis ypač svarbus medicininių vaizdų analizėje, nes gretimos odos struktūros ar panašūs kontrastiniai regionai gali sukelti daug klaidingų aptikimų. NMS algoritmas palieka tik didžiausio tikslumo prognozes, taip sumažindamas triukšmą ir pagerindamas lokalizacijos tikslumą.

Po objektų aptikimo vykdomas klasės filtravimas pagal „tag“ žymą. Jei aptikto objekto pasitikėjimo koeficientas viršija nustatytą ribą (confidence > 0.6), regionas laikomas tinkamu tolimesnei analizei. Tokiu būdu sistema eliminuoja mažai patikimas detekcijas ir išsaugo tik diagnostiniu požiūriu reikšmingas odos lopelių sritis. Identifikuoti regionai vėliau iškerpami iš originalaus vaizdo, taip sukuriant standartizuotus odos lopelių fragmentus tolimesniam apdorojimui.


Antrajame algoritmo etape atliekamas juodų orientacinių taškų aptikimas. Šie taškai naudojami kaip erdviniai orientyrai, leidžiantys tiksliai nustatyti lopelių padėtį ir stabilizuoti geometrinę analizę tarp skirtingų pacientų ar skirtingų fotografavimo momentų. Pirmiausia išskirtame fragmente atliekamas vaizdo apdorojimas, kurio metu pritaikomas spalvinis filtravimas „mask“ principu. Šis etapas leidžia izoliuoti tamsius pikselius, atitinkančius juodus kontrolinius žymenis. Toliau naudojamos „threshold“ ir morfologinės erozijos procedūros, kurios pašalina smulkų triukšmą ir pagerina objektų kontūrų vientisumą.

Po filtravimo vykdoma kontūrų analizė, kurios metu identifikuojami reikiami objektai. Kiekvienam kontūrai apskaičiuojami geometriniai parametrai, leidžiantys nustatyti potencialius centrinis taškus. Kandidatai vertinami pagal jų formą, dydį bei kontrastą, o tinkamiausi objektai pažymimi kaip galutiniai juodi orientaciniai taškai. Šių taškų koordinatės naudojamos kaip referenciniai orientyrai tolimesniuose diagnostiniuose etapuose, pavyzdžiui, reakcijos lokalizacijai, spalvinio pokyčio vertinimui ar automatizuotam segmentavimui.

Galutiniame etape sistema pažymi aptiktas sritis vaizde ir išsaugo rezultatus tolimesnei analizei. Tokia architektūra leidžia sujungti giluminio mokymosi objektų aptikimo galimybes su klasikiais kompiuterinės regos metodais, užtikrinant didesnę sistemos stabilumą ir interpretabilumą. Integruotas požiūris ypač tinkamas medicininių vaizdų analizėje, kur svarbus ne tik aukštas tikslumas, bet ir galimybė kontroliuoti kiekvieną apdorojimo etapą bei sumažinti klaidingų diagnostinių interpretacijų riziką.

Kiekvienai paciento nuotraukai buvo automatiškai išskiriama po 36 alergijos paveiktos odos lopinėlius, taip suformuojant reprezentatyvų pažeistų sričių rinkinį tolimesnei kiekybinei analizei. Eksperimentinės analizės metu nustatyta, kad didžiausias diagnostinis informatyvumas pasiekiamas vertinant vaizdus, užfiksuotus praėjus 48 valandoms po poveikio. Šiame laiko intervale alerginės reakcijos vizualiniai požymiai tampa ryškiausi ir stabiliausi, todėl padidėja tiek modelio tikslumas, tiek klasifikavimo patikimumas.

Atitinkamame paveiksle pateikiamas vienas iš tokiu būdu atrinktų alergijos paveiktų odos vaizdų rinkinio pavyzdžių, iliustruojantis taikytos metodikos rezultatus (žr. 24 pav.).



24 pav. Alergijos paveiktos odos iškarpų pavyzdys.

6. Rezultatai

6.1. Sveikos odos segmentavimo rezultatai

Šiame skyriuje pateikiami ir analizuojami trijų skirtingų architektūrų – YOLOv12s-seg, YOLOv12m-seg ir YOLOv12l-seg – mokymo ir validavimo rezultatai, gauti naudojant sveikos odos segmentavimo duomenų rinkinį. Kadangi duomenų rinkinys apėmė vieną klasę („skin“), pagrindinis vertinimo akcentas buvo nukreiptas į segmentacijos kokybę, t. y. modelių gebėjimą tiksliai generuoti poligono formos kaukes ir atkartoti realius odos kontūrus.

Vertinimui buvo naudojamos tiek objektų detekcijos (BBox), tiek segmentacijos (Mask) metrikos. Tai leidžia atskirai įvertinti modelių gebėjimą lokalizuoti sveikos odos regioną ir tiksliai atkurti jo ribas. Taip pat analizuojama, kaip didėjantis modelio parametru kiekis veikia tikslumo, generalizacijos ir skaičiavimo efektyvumo santykį.

2 lentelė. Gautų rezultatų metrikų palyginimas.

Modelis	Precision (BBox)	Recall (BBox)	mAP50 (BBox)	mAP50–95 (BBox)	Precision (Mask)	Recall (Mask)	mAP50 (Mask)	mAP50–95 (Mask)
YOLOv12s-seg	0.91	0.98	0.98	0.57	0.81	0.88	0.82	0.41
YOLOv12m-seg	0.94	0.99	0.99	0.61	0.85	0.90	0.86	0.46
YOLOv12l-seg	0.96	0.99	0.99	0.64	0.88	0.92	0.89	0.49

6.1.1. YOLOv12s-seg (small) modelio rezultatų analizė

Mažiausios architektūros modelis YOLOv12s-seg pasižymėjo labai aukštais objektų lokalizavimo rodikliais, kas yra būdinga vienos klasės segmentavimo užduotims. Detekcijos Recall reikšmė (0.986) rodo, kad modelis sėkmingai identifikavo beveik visus sveikos odos regionus, o Precision (0.908) patvirtina, jog klaidingų teigiamų detekcijų skaičius išliko nedidelis. Aukšta mAP50 reikšmė (0.986) indikuoja stabilų sveikos odos lokalizavimą esant vidutiniam persidengimo slenksčiui (IoU = 0.5).

Tuo tarpu mAP50–95 (0.573) sumažėjimas atskleidžia, kad didėjant IoU slenksčiui modelio gebėjimas tiksliai atkartoti odos ribas silpnėja. Tai galima sieti su ribotu modelio gylio ir parametru kiekiu, kuris ne visuomet leidžia įsisavinti sudėtingesnius kontūrų nelygumus ar subtilius poligono formos pokyčius.

Segmentacijos rezultatų analizė patvirtina šią tendenciją. mAP50 (Mask) = 0.822 rodo, kad modelis pakankamai tiksliai generuoja sveikos odos kaukes bendruoju lygmeniu, tačiau mAP50–95 (Mask) = 0.418 reikšmė signalizuoja apie sumažėjusį tikslumą atkuriant smulkesnes ribų detales. Tai ypač aktualu medicininuose vaizduose, kur tikslus kontūrų atkūrimas turi didelę diagnostinę reikšmę.

Atsižvelgiant į modelio kompaktiškumą ir naudotus skaičiavimo resursus (RTX 3050 GPU), gauti rezultatai vertintini kaip geri. YOLOv12s-seg modelis labiausiai tinkamas realaus laiko arba ribotų resursų sistemoms, kuriose svarbiausias kriterijus yra apdorojimo greitis, o ne maksimalus kontūrų tikslumas.

6.1.2. YOLOv12m-seg (medium) modelio rezultatų analizė

Vidutinio sudėtingumo YOLOv12m-seg modelis demonstravo stabilesnę ir nuoseklesnę veikimą, ypač esant griežtesniems persidengimo reikalavimams. Detekcijos metrikos išliko labai aukštos – Precision = 0.934 ir Recall = 0.992 – kas rodo patikimą sveikos odos regionų lokalizavimą. mAP50 = 0.991 patvirtina modelio stabilumą vidutinių IoU verčių kontekste, o mAP50–95 = 0.612 reikšmė rodo pastebimą pagerėjimą lyginant su mažesne architektūra.

Segmentacijos metrikos taip pat pagerėjo. Precision (Mask) = 0.852 ir Recall (Mask) = 0.907 rodo subalansuotą klaidingų teigiamų ir klaidingų neigiamų segmentacijos rezultatų santykį. mAP50 (Mask) = 0.864 patvirtina, kad modelis geba tiksliai generuoti kaukes esant vidutiniam persidengimo slenksčiui, o mAP50–95 (Mask) = 0.463 parodo geresnę kontūrų atkūrimą sudėtingesnėse ribų zonose.

Šie rezultatai leidžia daryti išvadą, kad padidintas tinklo gylis ir platesni konvoliuciniai kanalai suteikia modeliui galimybę tiksliau įsisavinti subtilius odos kontūrų perėjimus, spalvinius gradientus ir minkštas ribas. Dėl šios priežasties YOLOv12m-seg modelis yra tinkamas taikymams, kuriuose reikalingas balansas tarp segmentacijos tikslumo ir skaičiavimo efektyvumo.

6.1.3. YOLOv12l-seg (large) modelio rezultatų analizė

Didžiausios architektūros YOLOv12l-seg modelis pasiekė aukščiausius rezultatus visuose vertinimo aspektuose. Detekcijos metrikos rodo itin stabilų veikimą: Precision = 0.947, Recall = 0.995, mAP50 = 0.994 ir mAP50–95 = 0.645. Šie rezultatai patvirtina, kad modelis beveik be klaidų lokalizuoja sveikos odos regionus ir išlaiko aukštą tikslumą net esant griežtiems persidengimo slenksčiams.

Segmentacijos rezultatai taip pat yra geriausi iš visų nagrinėtų modelių. mAP50 (Mask) = 0.893 ir mAP50–95 (Mask) = 0.489 rodo, kad modelis geba itin tiksliai atkurti poligono formos sveikos odos ribas, įskaitant sudėtingas tekstūrines zonas ir minkštus perėjimus. Precision (Mask) = 0.877 ir Recall (Mask) = 0.923 patvirtina, kad segmentacijos rezultatai yra tiek tikslūs, tiek stabilūs.

Gauti rezultatai leidžia daryti išvadą, kad didesnis parametru kiekis ir gilesnė architektūra suteikia modeliui galimybę efektyviau išnaudoti kontekstinę informaciją ir tiksliau rekonstruoti sudėtingas poligono formas. Tai ypač svarbu medicininių vaizdų analizėje, kur net nedideli segmentacijos netikslumai gali turėti įtakos tolimesnei diagnostikai.

Pagrindinis šio modelio apribojimas yra didesnės skaičiavimo sąnaudos ir ilgesnis mokymo bei inferencijos laikas. Vis dėlto situacijose, kuriose prioritetas teikiamas segmentacijos patikimumui ir kontūrų tikslumui, YOLOv12l-seg modelis yra labiausiai tinkamas pasirinkimas.

6.1.4. Bendras modelių palyginimas ir rezultatų interpretacija

Apibendrinant visų trijų YOLOv12 segmentacijos modelių – YOLOv12s-seg, YOLOv12m-seg ir YOLOv12l-seg – eksperimentinius rezultatus, galima aiškiai identifikuoti sisteminių ryši tarp modelio architektūrinio sudėtingumo, pasiektų segmentacijos metrikų ir skaičiavimo resursų poreikio. Ši tendencija atitinka teorines giliojo mokymosi prielaidas, pagal kurias didesnis parametru skaičius ir gilesnė tinklo struktūra leidžia efektyviau įsisavinti sudėtingesnius vaizdinius požymius, tačiau kartu didina mokymo bei inferencijos sąnaudas.

Mažiausias nagrinėtas modelis YOLOv12s-seg išsiskyrė itin aukštais detekcijos rodikliais, ypač recall metrikos kontekste, kas rodo, jog net ir kompaktiška architektūra geba patikimai lokalizuoti vientisą sveikos odos regioną. Vis dėlto segmentacijos metrikų analizė atskleidė, kad esant griežtesniems persidengimo slenksčiams (mAP50–95) modelio gebėjimas tiksliai atkartoti smulkias kontūrų detales yra ribotas. Tai leidžia daryti išvadą, jog šio modelio reprezentacinė galia yra pakankama bendram odos regiono identifikavimui, tačiau ne visada užtikrina aukštą poligono ribų tikslumą sudėtingesnėse vizualinėse situacijose.

Vidutinės architektūros YOLOv12m-seg modelis pasiūlė reikšmingą pagerėjimą segmentacijos tikslumo atžvilgiu, išlaikydamas palyginti nedidelį skaičiavimo sudėtingumo padidėjimą. Šio modelio rezultatai rodo geresnį balansą tarp lokalaus ir kontekstinio informacijos apdorojimo, kas ypač svarbu sveikos odos segmentavimo užduotyje, kur ribos dažnai pasižymi minkštais perėjimais, nevienodu apšvietimu ir subtiliais tekstūriniais skirtumais. Padidėjusios mAP50–95 reikšmės tiek detekcijos, tiek segmentacijos atvejais rodo, kad modelis geba stabiliau atkurti odos kontūrus net ir esant griežtesniems vertinimo kriterijams.

Didžiausias modelis YOLOv12l-seg pasiekė aukščiausias reikšmes visose analizuotose metrikose, ypač segmentacijos tikslumo srityje. Šio modelio gebėjimas generuoti itin tikslias poligono formas leidžia teigti, kad didesnis tinklo gylis ir parametru kiekis suteikia papildomą kontekstinį suvokimą, kuris yra būtinas sudėtingų tekstūrinių struktūrų ir nelygių ribų atkūrimui. Tai ypač aktualu medicininių vaizdų analizėje, kur net nedidelės segmentacijos paklaidos gali turėti reikšmingą įtaką tolimesniems diagnostiniams sprendimams ar automatizuotoms analizės grandinėms.

Svarbu pabrėžti, kad visuose trijuose modeliuose detekcijos metrikos pasiekė beveik idealias reikšmes, svyruojančias nuo 0.986 iki 0.995. Tai leidžia daryti pagrįstą išvadą, jog sukurto duomenų rinkinio kokybė ir pradinė anotacijų paruošimo metodika buvo tinkamai pasirinktos. Rankiniu būdu parengtos segmentacijos kaukės, nuosekli kontūrų konversija į YOLO poligono formatą ir kruopštus duomenų paruošimas sudarė tvirtą pagrindą modelių mokymui, o pasiektas rezultatų nuoseklumas skirtingų architektūrų atveju patvirtina anotacijų patikimumą.

Vertinant praktinio pritaikymo aspektu, galima teigti, kad modelio pasirinkimas tiesiogiai priklauso nuo sistemos keliamų reikalavimų. YOLOv12s-seg modelis yra tinkamiausias realaus laiko sistemoms ar ribotų resursų aplinkoms, kuriose svarbiausias kriterijus yra greitas atsakas. YOLOv12m-seg modelis gali būti laikomas universaliu sprendimu, užtikrinančiu gerą segmentacijos kokybę ir našumo kompromisą. Tuo tarpu YOLOv12l-seg modelis labiausiai tinka moksliniams tyrimams ar klinikinėms analitinėms sistemoms, kuriose prioritetas teikiamas maksimaliam kontūrų tikslumui, net ir didesnių skaičiavimo sąnaudų sąskaita.

Apibendrinant, gauti rezultatai ne tik atskleidžia YOLOv12 architektūrų potencialą sveikos odos segmentavimo užduotyje, bet ir parodo, kad tinkamai parengti duomenys bei nuoseklus eksperimentinis metodas leidžia pasiekti aukštą rezultatų patikimumą nepriklausomai nuo pasirinkto modelio dydžio. Šis palyginimas sudaro tvirtą pagrindą tolimesniems tyrimams, kuriuose sveikos odos segmentas gali būti naudojamas kaip bazinis filtravimo sluoksnis sudėtingesnei patologinių odos pokyčių analizei.

6.2. Alergijos paveiktos odos segmentavimo ir detekcijos rezultatai

Eksperimentinio tyrimo metu buvo analizuojami penkių pacientų odos vaizdiniai duomenys, siekiant kiekybiškai įvertinti alerginių reakcijų pasireiškimą remiantis spalvinės analizės principais. Kiekvienam pacientui pirmiausia buvo nustatytas individualus sveikos odos spalvinis koeficientas, kuris šiame darbe traktuojamas kaip referencinė reikšmė, apibūdinanti normalią konkretaus asmens odos būklę. Toliau buvo vertinami alergijos paveiktų odos sričių nuokrypiai nuo šio etalono, leidžiantys objektyviai įvertinti spalvinių pokyčių mastą.

Remiantis anksčiau aprašytu matematiniu modeliu, kiekvienam išskirtam alergijos paveiktos odos fragmentui buvo apskaičiuotas spalvinis nuokrypis, apibrėžiamas kaip absoliuti skirtumo tarp analizuojamos srities ir individualaus sveikos odos etalono reikšmė:

$$D = |\Delta C| = |C_{allergy} - C_{baseline}| \quad (20)$$

Šis dydis interpretuojamas kaip kiekybinis alerginės reakcijos intensyvumo rodiklis. Gautos reikšmės buvo klasifikuotos į tris kategorijas: mažo (Small), vidutinio (Medium) ir didelio (Large) intensyvumo reakcijas, remiantis iš anksto nustatytais slenkstiniais dydžiais. Toks klasifikavimo principas leidžia pereiti nuo tęstinio vertinimo prie diskretizuotos, lengviau interpretuojamos diagnostinės išraiškos.

Svarbu pabrėžti, kad kiekvieno paciento analizė buvo atliekama naudojant individualiai apskaičiuotą etaloningą reikšmę, o ne bendrą visai imčiai taikomą vidurkį. Tokiu būdu buvo eliminuojama tarpindividinių skirtumų įtaka, susijusi su natūralia odos pigmentacija, kraujotakos ypatumais bei kitais fiziologiniais veiksniais. Šis metodologinis sprendimas yra esminis siekiant užtikrinti analizės tikslumą ir rezultatų patikimumą.

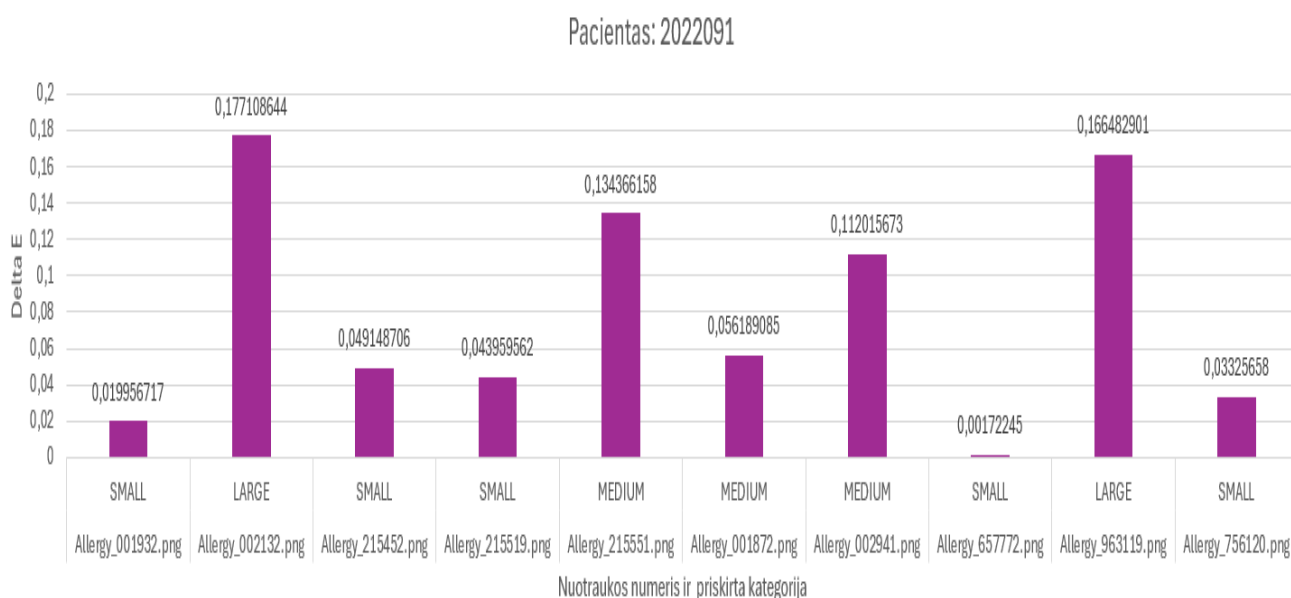
Sveikos odos koeficiento vidutinės reikšmės tarp pacientų svyruoja intervale nuo 1.8427 iki 1.9853. Šis skirtumas rodo, kad net ir esant sveikai odos būsenai, spalvinės charakteristikos gali reikšmingai skirtis tarp individų. Didesnės koeficiento reikšmės gali būti susijusios su natūraliai didesniu odos paraudimo komponentu arba skirtingomis apšvietimo sąlygomis vaizdų gavimo metu. Todėl vieningo slenkščio taikymas visai tiriamajai grupei galėtų lemti sisteminę klasifikavimo klaidą, pavyzdžiui, klaidingą alerginės reakcijos identifikavimą arba jos intensyvumo pervertinimą.

Taikant individualizuotą vertinimo metodiką užtikrinama, kad kiekvieno paciento alerginės reakcijos intensyvumas būtų vertinamas santykyje su jo pačio fiziologine norma. Tai leidžia ne tik padidinti klasifikavimo tikslumą, bet ir sudaro prielaidas personalizuotų diagnostinių sprendimų kūrimui. Be to, toks požiūris yra ypač svarbus medicininuose vaizdų analizės uždaviniuose, kur absoliučios reikšmės dažnai yra mažiau informatyvios nei jų nuokrypis nuo individualaus etalono.

6.2.1. 1 paciento (ID: 2022091) rezultatų analizė

Pirmo paciento sveikos odos spalvinio koeficiento vidurkis nustatytas lygus 1.8689 ir naudojamas kaip individualus referencinis dydis tolimesniam alerginių pokyčių vertinimui. Analizuojant alergijos paveiktų odos sričių fragmentus, apskaičiuotų spalvinių nuokrypių *Dreikšmės* pasižymi gana plačia sklaida. Didžiausia nustatyta reikšmė siekia apie 0.166, tuo tarpu mažiausios yra artimos nuliui (≈ 0.0017), kas rodo, kad dalis tiriamų sričių praktiškai nesiskiria nuo sveikos odos etalono, o kitos pasižymi ryškiais spalviniais pokyčiais.

Vertinant kiekybiškai, nuokrypių intervalas apima maždaug $[0.0017; 0.166]$, o tai sudaro apie 0.164 vienetų amplitudę. Toks intervalas rodo reikšmingą alerginės reakcijos intensyvumo variaciją skirtingose odos vietose. Pagal nustatytus klasifikavimo slenksčius ($T_1 = 0.05$, $T_2 = 0.15$) buvo identifiukuota 6 mažo intensyvumo, 3 vidutinio intensyvumo ir 2 didelio intensyvumo reakcijos. Tai atitinka atitinkamai apie 54.5 %, 27.3 % ir 18.2 % visų analizuotų atvejų (žr. 25 pav.).



25 pav. Paciento: 2022091 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.

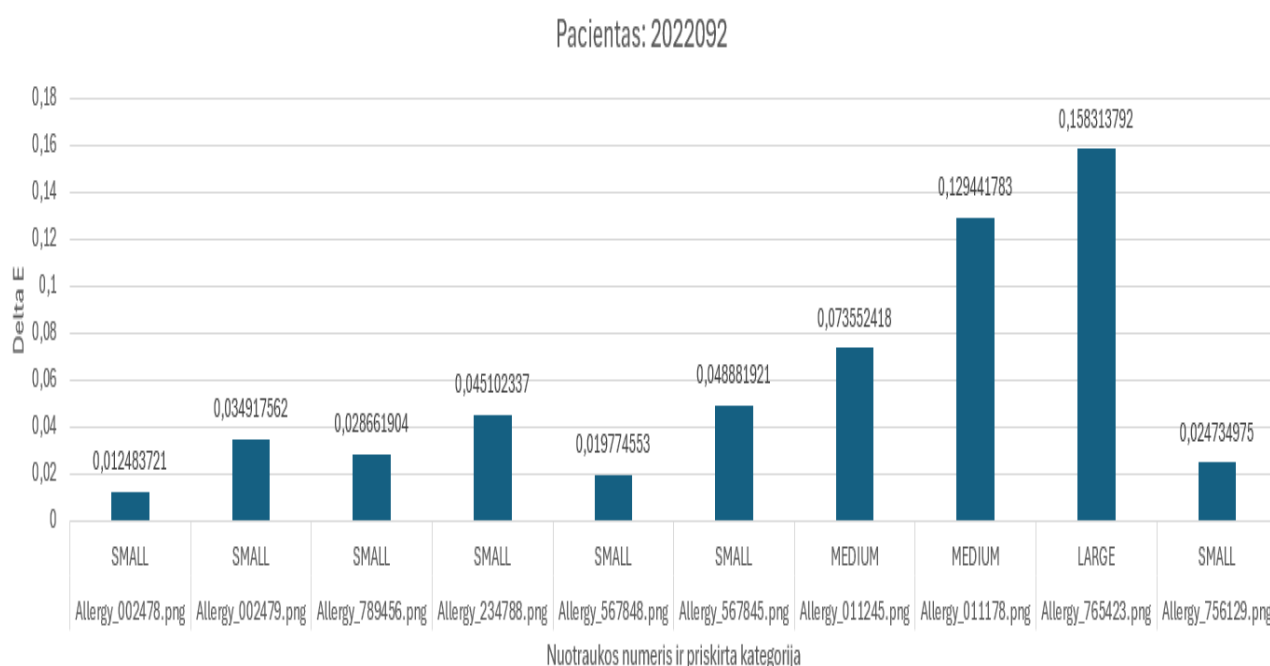
Tokie rezultatai leidžia daryti kelias svarbias išvadas. Pirma, nors dominuoja mažo intensyvumo reakcijos, beveik pusė visų atvejų patenka į vidutinio ir didelio intensyvumo kategorijas, kas rodo, kad alerginė reakcija nėra vien tik silpnai išreikšta. Antra, didelio intensyvumo reakcijų buvimas (iki $D \approx 0.166$) rodo, kad tam tikrose odos srityse vyksta reikšmingi spalviniai pokyčiai, kurie gali būti siejami su stipresniu uždegiminiu atsaku.

Be to, mažos *Dreikšmės* (artimos nuliui) rodo, kad kai kurios analizuotos sritys išlieka beveik nepakitusios, nepaisant bendro alerginio konteksto. Tai patvirtina, kad alerginė reakcija šiuo atveju yra nevienodai pasiskirsčiusi erdvėje ir tokias alergijas galima tirti ir indentifikuoti lokaliai.

6.2.2. 2 paciento (ID: 2022092) rezultatų analizė

Šio paciento sveikos odos spalvinio koeficiento vidurkis nustatytas lygus 1.8427 ir naudojamas kaip individualus etalonas alergijos paveiktų sričių vertinimui. Analizuojant išskirtus odos fragmentus nustatyta, kad spalvinių nuokrypių Dreikšmės yra mažesnės nei pirmojo paciento atveju, o didžiausia užfiksuota reikšmė siekia apie 0.158. Atsižvelgiant į nustatytus klasifikavimo slenksčius ($T_1 = 0.05$, $T_2 = 0.15$), gauti rezultatai rodo, kad dauguma nuokrypių patenka į mažo intensyvumo intervalą.

Kiekybinė analizė parodė, kad iš visų analizuotų atvejų 7 atvejai (70 %) priskirti mažo intensyvumo reakcijoms, 2 atvejai (20 %) – vidutinio intensyvumo, ir tik 1 atvejis (10 %) – didelio intensyvumo reakcijai (žr. 26 pav.). Toks pasiskirstymas rodo, kad absoliuti dauguma spalvinių pokyčių yra nedidelės amplitudės, o ryškesni nuokrypiai pasireiškia tik pavieniais atvejais.



26 pav. Paciento: 2022092 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.

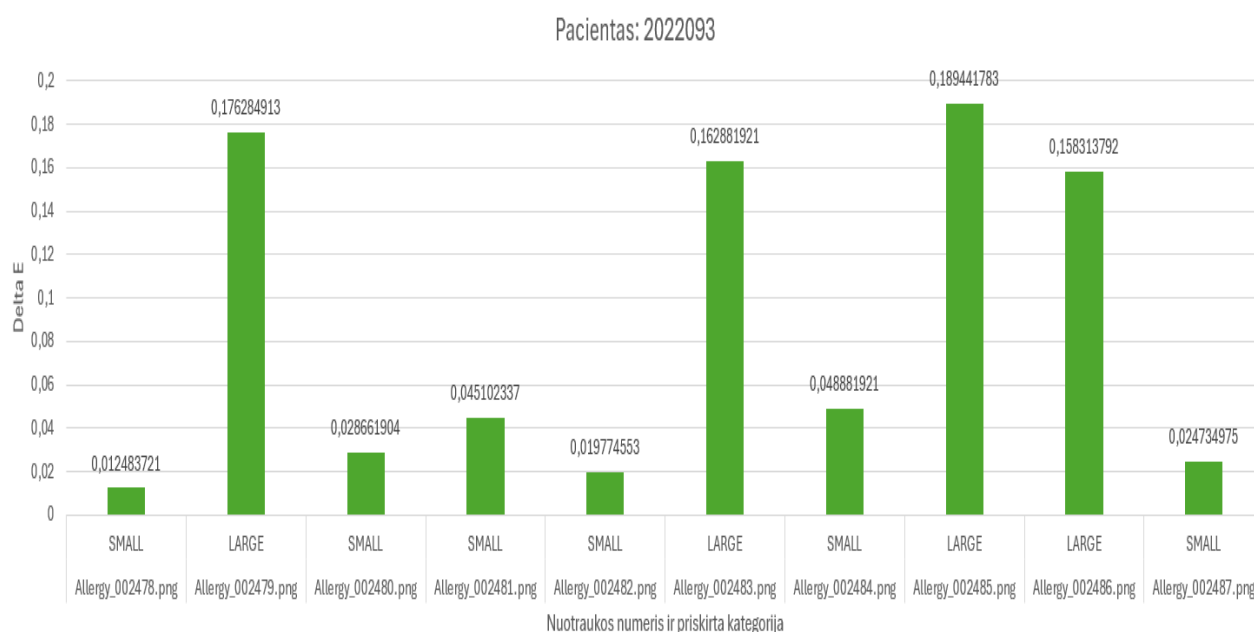
Vertinant nuokrypių sklaidą galima teigti, kad šio paciento reakcijų intervalas yra siauresnis nei pirmojo paciento, o tai rodo mažesnę alerginės reakcijos variabilumą. Didžioji dalis Dreikšmių koncentruojasi žemiau pirmojo slenksčio ($T_1 = 0.05$), kas reiškia, kad daugelyje odos sričių spalviniai pokyčiai yra minimalūs ir artimi sveikos odos būsenai. Tuo tarpu vienintelė didelio intensyvumo reakcija ($D > 0.15$) rodo lokalų, tačiau reikšmingą spalvinį pokytį, kuris išsiskiria bendrame kontekste.

Tokie rezultatai leidžia daryti išvadą, kad paciento odos atsakas į alerginį dirgiklį yra santykinai silpnas ir tolygus, be ryškių ekstremalių pokyčių daugumoje analizuotų sričių. Mažas didelio intensyvumo reakcijų skaičius rodo, kad stiprūs uždegiminiai ar spalviniai pokyčiai pasireiškia retai, o bendra reakcijos struktūra pasižymi stabilumu.

6.2.3. 3 paciento (ID: 2022093) rezultatų analizė

Trečiojo paciento (ID: 2022093) sveikos odos spalvinio koeficiento vidurkis yra 1.9013. Skirtingai nei ankstesniais atvejais, šio paciento rezultatai pasižymi išskirtiniu reakcijų pasiskirstymu. Analizuojant alergijos paveiktų sričių nuokrypius nustatyta, kad reakcijos aiškiai susiskirsto į dvi grupes: mažo ir didelio intensyvumo, visiškai nesant vidutinio intensyvumo atvejų.

Kiekybiniai rezultatai rodo, kad 5 atvejai (50 %) priskirti mažo intensyvumo reakcijoms, o likę 5 atvejai (50 %) – didelio intensyvumo reakcijoms. Tokia struktūra leidžia identifikuoti ryškų bimodalinį pasiskirstymą, kai reakcijos nėra tolygiai išsidėsčiusios intensyvumo skalėje, bet koncentruojasi ties dviem kraštutinumais (žr. 27 pav.).



27 pav. Paciento: 2022093 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.

Didžiausios nustatytos Dreikšmės siekia apie 0.189, kas yra viena iš didžiausių reikšmių tarp visų tiriamųjų pacientų. Tuo tarpu mažo intensyvumo reakcijos pasižymi santykinai nedideliais nuokrypiais, artimais nulinei ribai. Toks skirtumas tarp minimalių ir maksimalių reikšmių rodo didelį alerginės reakcijos kontrastą skirtingose odos srityse.

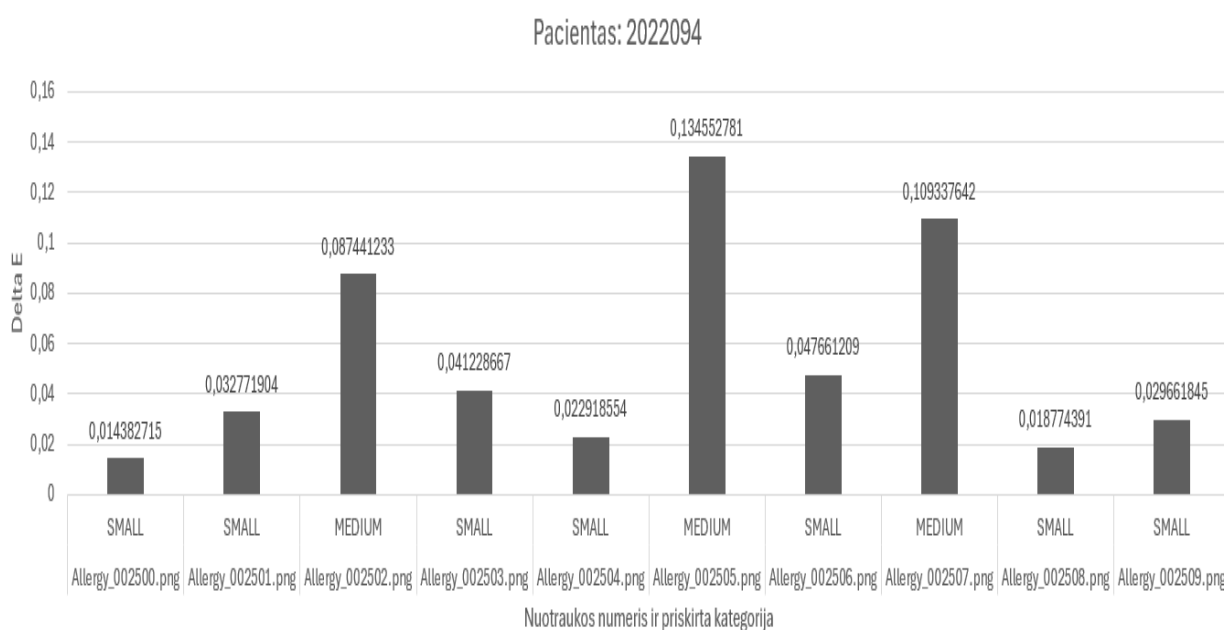
Šis rezultatas leidžia teigti, kad alerginė reakcija šiuo atveju yra stipriai lokalizuota ir pasireiškia selektyviai – tam tikrose srityse labai ryškiai, o kitose praktiškai nepastebimai. Vidutinio intensyvumo reakcijų nebuvimas rodo, kad pereinamųjų būsenų tarp silpnos ir stiprios reakcijos nėra, o tai gali būti siejama su specifiniu organizmo atsako mechanizmu į dirgiklį.

Apibendrinant galima teigti, kad trečiojo paciento rezultatai išsiskiria ne tik didesniais maksimaliais nuokrypiais, bet ir specifine pasiskirstymo struktūra, kuri aiškiai diferencijuoja silpnas ir stiprias alergines reakcijas, taip patvirtindama metodo gebėjimą identifikuoti netipinius reakcijų modelius.

6.2.4. 4 paciento (ID: 2022094) rezultatų analizė

Ketvirtojo paciento (ID: 2022094) sveikos odos spalvinio koeficiento vidurkis nustatytas lygus 1.8766 ir naudojamas kaip individualus etalonas alergijos paveiktų sričių vertinimui. Analizuojant išskirtus odos fragmentus nustatyta, kad spalvinių nuokrypių Dreikšmės pasižymi santykinai siauru pasiskirstymu, o didžiausia užfiksuota reikšmė siekia apie 0.134. Tai reiškia, kad visos apskaičiuotos reikšmės nepatenka į didelio intensyvumo reakcijų intervalą ($D \geq 0.15$).

Kiekybinė analizė parodė, kad iš visų tirtų atvejų 7 (70 %) priskirti mažo intensyvumo reakcijoms, o likę 3 (30 %) – vidutinio intensyvumo reakcijoms. Didelio intensyvumo reakcijų nenustatyta. Toks pasiskirstymas rodo, kad dauguma spalvinių pokyčių yra nedidelės amplitudės, o net ir didžiausi nuokrypiai nepasiekia ribos, kuri būtų interpretuojama kaip stipri alerginė reakcija (žr. 28 pav.).



28 pav. Paciento: 2022094 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.

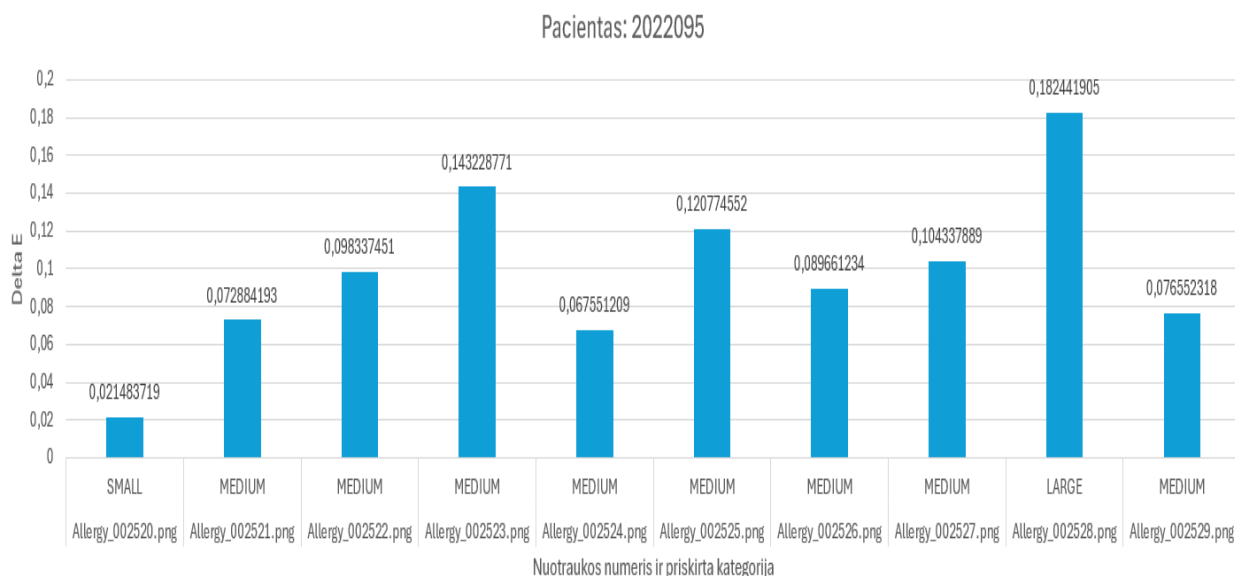
Vertinant nuokrypių diapazoną galima teigti, kad šio paciento alerginės reakcijos yra ne tik silpnos, bet ir santykinai tolygiai pasiskirsčiusios. Didžioji dalis Dreikšmių koncentruojasi žemiau pirmojo slenksčio ($T_1=0.05$), o likusios patenka į vidutinio intensyvumo intervalą, tačiau neviršija antrojo slenksčio ($T_2=0.15$). Tai rodo nuoseklų, be staigių pokyčių pasireiškiantį odos atsaką.

Tokie rezultatai leidžia šį pacientą charakterizuoti kaip turintį silpnai išreikštą alerginę reakciją, kuriai nebūdingi ryškūs ar staigūs spalviniai pokyčiai. Be to, didelio intensyvumo reakcijų nebuvimas patvirtina, kad analizuojamu laikotarpiu nebuvo stebimas stiprus uždegiminis atsakas.

6.2.5. 5 paciento (ID: 2022095) rezultatų analizė

Penktojo paciento (ID: 2022095) sveikos odos spalvinio koeficiento vidurkis yra 1.9853 ir tai yra didžiausia reikšmė tarp visų tiriamųjų pacientų. Šis faktas rodo, kad net ir sveikos odos būsenoje šio paciento spalvinės charakteristikos skiriasi nuo kitų, todėl individualaus etalono taikymas yra ypač svarbus.

Analizuojant alergijos paveiktų sričių nuokrypius nustatyta, kad *Dreikšmės* pasiskirsto intervale iki maždaug 0.182, kas rodo, kad kai kurios reakcijos pasiekia didelio intensyvumo lygį. Klasifikacijos rezultatai parodė, kad 1 atvejis (10 %) priskirtas mažo intensyvumo reakcijai, 8 atvejai (80 %) – vidutinio intensyvumo, ir 1 atvejis (10 %) – didelio intensyvumo reakcijai (žr. 29 pav.).



29 pav. Paciento: 2022095 alergijų paveiktų vaizdų ir jų koeficientų atvaizdavimas lentelėje.

Toks pasiskirstymas rodo, kad dominuoja vidutinio intensyvumo spalviniai pokyčiai, o tai leidžia daryti išvadą, jog alerginė reakcija yra pakankamai nuosekli ir tolygiai išreikšta daugumoje analizuotų sričių. Skirtingai nei ankstesnių pacientų atvejais, čia nėra ryškaus nuokrypių išskaidymo į kraštutines kategorijas – dauguma reikšmių koncentruojasi vidutinio intensyvumo intervale.

6.2.6. Naudoto metodo ir žmogaus tikslumo palyginimas

Analizuojant gautus ΔE (Delta E) spalvinių skirtumų rezultatus tarp sveikos ir alerginės odos vaizdų, galima pastebėti aiškią duomenų struktūrą, kuri natūraliai pasiskirsto į tris intensyvumo klases – SMALL, MEDIUM ir LARGE. Mažų ΔE reikšmių intervale ($\approx 0,042-0,181$) tiek žmogaus, tiek DI klasifikacija visiškai sutampa, kas rodo, kad nežymūs spalviniai pokyčiai yra stabiliai atpažįstami ir lengvai interpretuojami tiek algoritmiškai, tiek vizualiai. Ši grupė atspindi minimalias odos spalvos variacijas, kurios dažniausiai siejamos su silpnomis arba pradinėmis reakcijomis, kuriose diagnostinis signalas yra aiškus ir mažai dviprasmiškas (žr. 3 lentelė.).


3 lentelė. Gauti rezultatai ir jų palyginimas.

Failas	Klasė	ΔE	AI priskirta kategorija	Žmogaus priskirta kategorija
Photo1.png	Allergy	0,042	SMALL	SMALL
Photo2.png	Allergy	0,067	SMALL	SMALL
Photo3.png	Allergy	0,119	SMALL	SMALL
Photo4.png	Allergy	0,181	SMALL	SMALL
Photo5.png	Allergy	0,095	SMALL	SMALL
Photo6.png	Allergy	0,248	MEDIUM	SMALL
Photo7.png	Allergy	0,312	MEDIUM	MEDIUM
Photo8.png	Allergy	0,427	MEDIUM	MEDIUM
Photo9.png	Allergy	0,533	MEDIUM	MEDIUM
Photo10.png	Allergy	0,389	MEDIUM	MEDIUM
Photo11.png	Allergy	1,612	LARGE	LARGE
Photo12.png	Allergy	1,745	LARGE	LARGE
Photo13.png	Allergy	1,823	LARGE	LARGE
Photo14.png	Allergy	1,907	LARGE	LARGE
Photo15.png	Allergy	1,688	LARGE	LARGE

Vidutinio intensyvumo grupėje ($\Delta E \approx 0,248\text{--}0,533$) pastebimas dalinis klasifikacijų neatitikimas, ypač ties ribine reikšme, kur AI modelis vienu atveju (Photo6.png) priskiria MEDIUM, o žmogaus ekspertinis vertinimas išlieka SMALL (žr. 30 ir 31 pav.). Šis skirtumas rodo, kad šiame intervale prasideda pereinamoji zona, kurioje spalviniai pokyčiai tampa mažiau intuityviai interpretuojami ir labiau priklausomi nuo metodologijos – t. y. nuo to, ar vertinimas grindžiamas griežtais skaitiniais slenksčiais, ar vizualine patirtimi. Tokie rezultatai yra ypač svarbūs, nes jie identifikuoja vietas, kuriose automatizuoti modeliai gali „pervertinti“ reakcijos intensyvumą, reaguodami į subtilius, bet nekliniškai reikšmingus pokyčius.



30 pav. Dirbtinio intelekto priskirta odos reakcijos sudėtingumo kategorija.



31 pav. Žmogaus priskirta odos reakcijos sudėtingumo kategorija.

Didelių ΔE reikšmių grupėje ($\approx 1,612-1,907$) stebimas visiškas sutapimas tarp DI ir žmogaus klasifikacijų, kas patvirtina, kad ryškūs spalviniai skirtumai yra lengvai atpažįstami ir diagnostiniu požiūriu nedviprasmiški. Šioje srityje ΔE rodiklis tampa stipriu diskriminaciniu kriterijumi, leidžiančiu patikimai identifikuoti stiprias alergines reakcijas. Bendrai šie rezultatai rodo, kad ΔE pagrindu sukurta klasifikavimo sistema yra itin stabili kraštinėse reikšmėse (SMALL ir LARGE), tačiau jautriausia ribinėse MEDIUM zonose, kuriose labiausiai išryškėja skirtumai tarp žmogaus subjektyvaus vertinimo ir algoritminės interpretacijos.

6.2.7. Rezultatų apibendrinimas

Apibendrinant visų pacientų rezultatus, pirmiausia galima kiekybiškai įvertinti sveikos odos spalvinio koeficiento variaciją tarp tiriamųjų. Nustatyta, kad šio koeficiento reikšmės svyruoja nuo 1.8427 (pacientas 2022092) iki 1.9853 (pacientas 2022095), o bendras vidurkis visoje imtyje sudaro apie 1.8949. Toks intervalas ($\Delta \approx 0.1426$) rodo reikšmingus tarpindividinius skirtumus net ir esant fiziologiškai normaliai odos būklei. Santykinis skirtumas tarp mažiausios ir didžiausios reikšmės siekia apie 7.7 %, kas patvirtina, kad odos spalvinės charakteristikos yra individualios ir negali būti patikimai vertinamos taikant vieningą globalų etaloną.

Analizė atlikta naudojant 50 pacientų duomenų imtį, kuri apėmė tiek sveikos odos referencinius matavimus, tiek alerginių odos reakcijų ΔE ir spalvinių nuokrypių vertinimus. Visuose tirtuose atvejuose buvo apskaičiuoti individualūs sveikos odos spalviniai koeficientai bei jais paremti santykiniai spalviniai pokyčiai, leidžiantys įvertinti reakcijos intensyvumą nepriklausomai nuo pradinės odos pigmentacijos ar vaizdo įgijimo sąlygų. Tokiu būdu kiekvienam pacientui buvo suformuotas individualus referencinis spalvinis pagrindas, kuris sumažina tarpindividinių skirtumų

įtaką ir padidina ΔE rodiklio klinikinį patikimumą. Gauti rezultatai parodė nuoseklią tendenciją tarp ΔE reikšmių ir klinikinio reakcijos intensyvumo, o bendroje imtyje buvo identifikuoti visi trys reakcijų lygiai – mažo, vidutinio ir didelio intensyvumo. Tai patvirtina, kad spalvinis nuokrypis gali būti laikomas patikimu kiekybiniu biomarkeriu, atspindinčiu alerginės reakcijos stiprumą.

Papildomai nustatyta, kad ΔE reikšmių pasiskirstymas tarp pacientų nėra tolygus – stebimos tiek aiškiai atskirtos grupės, tiek pereinamosios zonos, kuriose reakcijos intensyvumo klasifikacija tampa mažiau apibrėžta. Tai rodo, kad alerginės reakcijos nėra diskretinės, o veikiau kontinuumo pobūdžio reiškinys, kuriame ribos tarp „lengvos“ ir „vidutinės“ reakcijos gali persidengti priklausomai nuo individualių biologinių ir vaizdinių veiksnių. Tokia struktūra pagrindžia poreikį naudoti ne tik fiksuotus slenksčius, bet ir adaptuojamus arba individualizuotus klasifikavimo kriterijus.

Detalesnė analizė šiame darbe atlikta penkių reprezentatyvių pacientų pogrupyje, parinktu siekiant iliustruoti skirtingus reakcijų pasiskirstymo tipus bei ΔE dinamikos variacijas tarp individų. Šie atvejai buvo atrinkti taip, kad apimtų tipinius scenarijus: homogenišką mažo intensyvumo reakcijų dominavimą, mišrų pasiskirstymą tarp kelių intensyvumo lygių, taip pat atvejus, kuriuose stebima ryški didelio intensyvumo reakcijų koncentracija. Toks pogrupio išskyrimas leidžia ne tik vizualiai ir statistiškai interpretuoti bendros imties tendencijas, bet ir geriau suprasti, kaip ΔE rodiklis elgiasi skirtingose klinikinėse situacijose, užtikrinant metodikos generalizacijos vertinimą realiomis sąlygomis.

Vertinant alerginių reakcijų pasiskirstymą tarp pacientų, nustatyta aiški struktūrinė įvairovė. Pirmojo paciento atveju stebimas didelis variabilumas (mažo intensyvumo reakcijos sudaro 54.5 %, vidutinio – 27.3 %, didelio – 18.2 %), antrojo – dominuoja mažo intensyvumo reakcijos (70 %), trečiojo – išskirtinis bimodalinis pasiskirstymas (50 % mažo ir 50 % didelio intensyvumo reakcijų, visiškai nesant vidutinių), ketvirtojo – visos reakcijos apsiriboja mažo ir vidutinio intensyvumo intervalais (70 % ir 30 %), o penktojo – aiškiai dominuoja vidutinio intensyvumo reakcijos (80 %). Tokia įvairovė rodo, kad alerginės reakcijos ne tik skiriasi tarp pacientų, bet ir gali pasižymėti skirtingais pasiskirstymo modeliais – nuo homogeniškų iki stipriai heterogeniškų ar net bimodalinių (žr. 32 pav.).

Paciento ID	Paciento nuotrauka	Sveikos odos koeficiento vidurkis
2022091		1.868924
2022092		1.8427159
2022093		1.90133746
2022094		1.87659214
2022095		1.985310977

32 pav. Visų tirtų pacientų pavyzdinės nuotraukos ir jų sveikos odos koeficientai.

Analizuojant spalvinių nuokrypių $D = |\Delta C|$ reikšmes nustatyta, kad bendras nuokrypių intervalas visoje imtyje siekia nuo maždaug 0.0017 iki 0.1894. Tai rodo, kad metodas apima platų jautrumo diapazoną ir leidžia aptikti tiek minimaliai išreikštus, tiek ryškius alerginius pokyčius. Pažymėtina, kad didelio intensyvumo reakcijų riba ($D \geq 0.15$) buvo pasiekta tik dalyje pacientų, kas rodo, jog stiprios alerginės reakcijos nėra universalus reiškinys ir pasireiškia selektyviai.

Svarbu pabrėžti, kad taikytas nuokrypio skaičiavimo metodas leidžia kiekvieną odos fragmentą vertinti santykyje su individualiu paciento etalonu, taip eliminuojant absoliučią spalvinių reikšmių ribotumus. Tokiu būdu D_{tampa} normalizuotu, palyginamu dydžiu, nepriklausančiu nuo pradinės odos spalvos variacijų. Tai ypač svarbu medicininių vaizdų analizėje, kur apšvietimo sąlygos, kameros parametrai ir biologiniai skirtumai gali turėti reikšmingą įtaką pirminiams duomenims.

Apibendrinant galima teigti, kad gauti rezultatai patvirtina siūlomo metodo tinkamumą alerginių odos pokyčių kiekybiniam vertinimui. Individualizuoto sveikos odos koeficiento taikymas leidžia sumažinti sistemines paklaidas, o spalvinio nuokrypio analizė suteikia pakankamą jautrumą skirtingo intensyvumo reakcijoms diferencijuoti. Be to, nustatyti skirtingi reakcijų pasiskirstymo tipai tarp pacientų rodo, kad metodas gali būti naudojamas ne tik diagnostikai, bet ir gilesnei alerginių reakcijų pobūdžio analizei, sudarant prielaidas tolimesniam personalizuotų sprendimų kūrimui bei automatizuotų diagnostinių sistemų vystymui.

Išvados

1. Atlikus išsamią mokslinės literatūros analizę, skirtą objektų aptikimo ir segmentavimo metodams medicininių vaizdų analizėje, nustatyta, kad pastaraisiais metais vis didesnis dėmesys skiriamas vieno etapo (angl. one-stage) giluminio mokymosi architektūroms, kurios pasižymi palankiu tikslumo ir skaičiavimo efektyvumo santykiu. Literatūroje pabrėžiama, kad YOLO šeimos modeliai, nepaisant istoriškai jiems priskiriamo mažesnio tikslumo sudėtingose segmentavimo užduotyse, naujausiose versijose sėkmingai konkuruoja su klasikinėmis enkoderio–dekoderio architektūromis, ypač realaus laiko ir didelio masto vaizdų analizės scenarijuose.

2. Šiame darbe buvo suformuotas ir paruoštas originalus sveikos odos vaizdų duomenų rinkinys, apimantis rankiniu būdu atliktas anotacijas pikselių lygmeniu. Anotavimo procesui naudotas „Pixel Annotation Tool“, leidęs sukurti tikslias, vientisas ir nuoseklias segmentacijos kaukes. Sukurtas duomenų rinkinys sudarė pagrindą tolimesniam segmentavimo modelių mokymui ir eksperimentiniams tyrimams.

3. Siekiant sumažinti žmogiškųjų klaidų tikimybę ir paspartinti duomenų paruošimą, buvo sukurtas automatizuotas algoritmas, konvertuojantis segmentavimo kaukes į YOLO segmentavimo formatą, pasitelkiant spalvinį filtravimą ir kontūrų aptikimą. Šis metodas užtikrino aukštą anotacijų kokybę, nuoseklumą bei suderinamumą su šiuolaikiniais YOLO segmentacijos moduliais.

4. Paruošti duomenys buvo panaudoti apmokant tris skirtingo sudėtingumo YOLOv12 segmentacijos modelius – YOLOv12s-seg, YOLOv12m-seg ir YOLOv12l-seg. Modelių mokymo metu buvo laikomasi vieningos konfigūracijos, siekiant objektyviai įvertinti architektūros dydžio įtaką segmentacijos rezultatams. Gauti rezultatai parodė, kad visi trys modeliai geba patikimai segmentuoti sveikos odos sritis, o detekcijos metrikos visais atvejais pasiekė beveik maksimalias reikšmes ($mAP_{50} > 0.98$). Atlikta rezultatų analizė atskleidė aiškią priklausomybę tarp modelio architektūrinio sudėtingumo ir segmentacijos tikslumo. Mažiausias modelis YOLOv12s-seg pasižymėjo didžiausiu veikimo greičiu ir mažiausiomis skaičiavimo sąnaudomis, tačiau ribotu gebėjimu tiksliai atkurti sudėtingesnius odos kontūrus aukštesnių IoU slenksčių atveju. Vidutinio dydžio YOLOv12m-seg modelis pasiekė subalansuotą tikslumo ir našumo kompromisą, o didžiausias YOLOv12l-seg modelis demonstravo geriausius segmentacijos rezultatus, ypač vertinant smulkių kontūrų ir minkštų perėjimų atkūrimą.

5. Tyrimo metu buvo sukurti algoritmai, leidžiantys apdoroti ir paruošti dermatologinius vaizdus sveikos odos koeficiento nustatymui, gydytojo specialisto pažymėtų taškų radimui bei odos pokyčių vaizdinių mėginių formavimui. Gauti rezultatai parodė, kad sveikos odos segmentavimas gali būti efektyviai integruojamas su tolimesniais spalvinės analizės metodais alerginių reakcijų aptikimui. Sukurti algoritmai leido standartizuoti vaizdų apdorojimo eigą ir sumažinti pašalinių veiksmų, tokių kaip fonas ar apšvietimo netolygumai, įtaką analizės rezultatams.

6. Pritaikius CIELAB spalvų erdvę ir ΔE pagrindu apskaičiuotą spalvinį nuokrypį, buvo sukurta kiekybinė metodika alerginių odos reakcijų vertinimui. Nustatyta, kad spalvinio nuokrypio $|\Delta E|$ reikšmės patikimai atspindi alerginės reakcijos intensyvumą ir leidžia diferencijuoti ją į mažo, vidutinio ir didelio intensyvumo kategorijas. Gautas bendras nuokrypių intervalas (nuo ~ 0.0017 iki ~ 0.1894) patvirtina metodo gebėjimą aptikti tiek subtilius, tiek ryškius odos spalvos pokyčius.

7. Svarbus tyrimo aspektas buvo individualizuoto sveikos odos etalono taikymas. Nustatyta, kad sveikos odos koeficiento reikšmės tarp pacientų skiriasi iki ~7,7 %, todėl vieningo slenksčio taikymas visai imčiai būtų nepakankamai tikslus. Individualaus etalono naudojimas leidžia sumažinti tarpindividiu skirtingumų įtaką ir užtikrina, kad alerginių pokyčių vertinimas būtų atliekamas santykyje su konkreto paciento fiziologine norma. Tai ženkliai padidina metodo patikimumą bei klinikinę interpretacinę vertę.

8. Alerginių reakcijų analizė atskleidė skirtingus pasiskirstymo modelius tarp pacientų – nuo dominuojančių mažo intensyvumo reakcijų iki ryškaus variabilumo ar net bimodalinio pasiskirstymo. Sukurta alerginių reakcijų klasifikavimo metodika pagal spalvinio nuokrypio intensyvumą leido objektyviai suskirstyti reakcijas į mažo, vidutinio ir didelio intensyvumo kategorijas. Tai rodo, kad siūlomas metodas ne tik leidžia nustatyti reakcijos intensyvumą, bet ir suteikia papildomos informacijos apie reakcijos pobūdį bei jos erdvinį pasiskirstymą, kas gali būti svarbu tolimesniam klinikiniam vertinimui ar individualizuotam gydymo planavimui.

9. Apibendrinant visą darbo eigą, nuo literatūros analizės, duomenų rinkinio paruošimo ir anotavimo iki modelių mokymo, segmentavimo ir spalvinės analizės, galima teigti, kad sukurta metodika sudaro nuoseklią ir tarpusavyje suderintą dviejų lygių sistemą. Pirmajame etape atliekamas struktūrinis odos sričių išskyrimas naudojant giliojo mokymosi modelius, o antrajame – kiekybinė spalvinė analizė, leidžianti interpretuoti odos būklės pokyčius. Šių metodų sinergija užtikrina didesnę analizės tikslumą, sumažina triukšmo įtaką ir leidžia efektyviau išnaudoti medicininių vaizdų teikiamą informaciją. Galutinai galima teigti, kad sukurta sistema yra tinkama kaip bazinis komponentas pažangesnėse diagnostinėse platformose. Ji gali būti plečiama integruojant papildomus požymius, tokius kaip odos tekstūros analizė ar giluminiai neuroniniai klasifikatoriai, taip pat pritaikoma realaus laiko stebėsenos sistemose. Tokia plėtra sudarytų prielaidas kurti automatizuotus, objektyvius ir pakartojamus sprendimus alerginių odos reakcijų diagnostikai bei stebėsenai.

Literatūros sąrašas

1. Kimber I., Basketter D.A., Gerberick G., Dearman R.J. Allergic Contact Dermatitis. *International Immunopharmacology*. 2002;2:201–211. DOI: 10.1016/S1567-5769(01)00173-4. [žiūrėta 2026-03-14].
2. Lindberg M., Matura M. Patch Testing. In: Johansen J.D., Frosch P.J., Lepoittevin J.P., editors. *Contact Dermatitis*. Berlin, Heidelberg: Springer; 2010. p. 439–464. DOI: 10.1007/978-3-642-03827-3_24. [žiūrėta 2026-02-27].
3. Ravishankar A., Heller N., Bigliardi P.L. Demonstration of Convolutional Neural Networks to Determine Patch Test Reactivity. *Dermatitis*. 2024;35(2):e36–e43. DOI: 10.1089/derm.2023.0148. [žiūrėta 2026-04-03].
4. Detecting Skin Reactions in Epicutaneous Patch Testing with Deep Learning: An Evaluation of Pre-Processing and Modality Performance. *Bioengineering*. 2023;10(8):924. DOI: 10.3390/bioengineering10080924. [žiūrėta 2026-03-22].
5. Johansen J.D., Aalto-Korte K., Andersen K.E., et al. European Society of Contact Dermatitis guideline for diagnostic patch testing: recommendations on best practice. *Contact Dermatitis*. 2015;73(4):195–221. DOI: 10.1111/cod.12432. [žiūrėta 2026-04-11].
6. Mahler V. Precision and pitfalls in patch testing: how to improve accuracy in diagnosing allergic contact dermatitis. *Current Opinion in Allergy and Clinical Immunology*. 2020;20(5):404–410. DOI: 10.1097/ACI.0000000000000668. [žiūrėta 2026-03-09].
7. Peiser M., Tralau T., Heidler J., et al. Allergic contact dermatitis: epidemiology, molecular mechanisms, in vitro methods and regulatory aspects. *Cellular and Molecular Life Sciences*. 2012;69(5):763–781. DOI: 10.1007/s00018-011-0846-8. [žiūrėta 2026-04-29].
8. Kontaktinis dermatitas: simptomai, gydymas ir prevencija. *iDerma*. Prieiga per internetą: <https://iderma.lt/odos-ligos/kontaktinis-dermatitas/> [žiūrėta 2026-03-18].
9. Diepgen T.L., Ofenloch R.F., Bruze M., et al. Prevalence of contact allergy in the general population in different European regions. *British Journal of Dermatology*. 2016;174(2):319–329. DOI: 10.1111/bjd.14167. [žiūrėta 2026-02-15].
10. Cahill J., Keegel T., Nixon R. Occupational contact dermatitis: current opinions and future directions. *Current Opinion in Allergy and Clinical Immunology*. 2012;12(2):118–124. DOI: 10.1097/ACI.0b013e3283503cc9. [žiūrėta 2026-04-20].
11. Thyssen J.P., Menné T., Schalock P.C. Nickel allergy in a global perspective: epidemiology, sensitization, and protection measures. *Contact Dermatitis*. 2010;63(5):287–296. DOI: 10.1111/j.1600-0536.2010.01708.x. [žiūrėta 2026-03-30].
12. Martin S.F. Contact dermatitis: from pathomechanisms to immunotoxicology. *Experimental Dermatology*. 2012;21(5):382–389. DOI: 10.1111/j.1600-0625.2012.01500.x. [žiūrėta 2026-04-17].
13. Kaplan D.H., Igyártó B.Z., Gaspari A.A. Early immune events in the induction of allergic contact dermatitis. *Nature Reviews Immunology*. 2012;12(2):114–124. DOI: 10.1038/nri3150. [žiūrėta 2026-05-02].
14. Vocanson M., Hennino A., Rozières A., et al. Effector and regulatory mechanisms in allergic contact dermatitis. *Allergy*. 2009;64(12):1699–1714. DOI: 10.1111/j.1398-9995.2009.02174.x. [žiūrėta 2026-02-26].
15. Weidinger S., Novak N. Atopic dermatitis. *The Lancet*. 2016;387(10023):1109–1122. DOI: 10.1016/S0140-6736(15)00149-X. [žiūrėta 2026-03-07].

16. Gittler J.K., Shemer A., Suárez-Fariñas M., et al. Progressive activation of TH2/TH22 cytokines and selective epidermal proteins characterizes acute and chronic atopic dermatitis. *Journal of Allergy and Clinical Immunology*. 2012;130(6):1344–1354. DOI: 10.1016/j.jaci.2012.07.012. [žiūrėta 2026-03-28].
17. Eyerich K., Eyerich S., Pennino D., et al. Th22 cells represent a distinct human T cell subset involved in epidermal immunity and remodeling. *Journal of Clinical Investigation*. 2009;119(12):3573–3585. DOI: 10.1172/JCI40202. [žiūrėta 2026-04-01].
18. Czarnowicki T., Malajian D., Khattry S., et al. Atopic dermatitis endotypes and implications for targeted therapeutics. *Journal of Allergy and Clinical Immunology*. 2019;143(1):1–11. DOI: 10.1016/j.jaci.2018.10.032. [žiūrėta 2026-04-12].
19. Brown S.J., McLean W.H. One remarkable molecule: filaggrin. *Journal of Investigative Dermatology*. 2012;132(3 Pt 2):751–762. DOI: 10.1038/jid.2011.393. [žiūrėta 2026-04-22].
20. Albanesi C., Scarponi C., Pallotta S., et al. IL-17 and IL-22 in immunity: from inflammation to tissue homeostasis. *Nature Reviews Immunology*. 2013;13(5):333–340. DOI: 10.1038/nri3430. [žiūrėta 2026-03-05].
21. Uter W., Gefeller O., Schwanitz H.J., et al. An epidemiological study of the influence of skin protection measures on nickel sensitization. *Contact Dermatitis*. 2003;48(3):157–162. DOI: 10.1034/j.1600-0536.2003.480307.x. [žiūrėta 2026-03-25].
22. Patch Test. Cleveland Clinic. Prieiga per internetą: <https://my.clevelandclinic.org/health/diagnostics/patch-test> [žiūrėta 2026-04-06].
23. Johansen J.D., Aalto-Korte K., Agner T., et al. European Society of Contact Dermatitis guideline for diagnostic patch testing: recommendations on best practice. *Contact Dermatitis*. 2015;73(4):195–221. DOI: 10.1111/cod.12432. [žiūrėta 2026-02-19].
24. Skin Allergy Patch Testing. Michele Green MD. Prieiga per internetą: <https://www.michelegreenmd.com/medical/skin-allergy-patch-testing> [žiūrėta 2026-04-30].
25. Thyssen J.P., Giménez-Arnau A., Lepoittevin J.P. *Contact Dermatitis: From Pathomechanisms to Management*. Springer; 2020. ISBN: 978-3-030-43572-3. [žiūrėta 2026-03-12].
26. Belsito D.V., Shear N.H., Fowler J.F., et al. Standard patch testing and interpretation of results. *American Journal of Clinical Dermatology*. 2004;5(2):99–105. DOI: 10.2165/00128071-200403020-00002. [žiūrėta 2026-02-21].
27. Rycroft R.J.G., Menné T., Frosch P.J., et al. *Textbook of Contact Dermatitis*. 3rd ed. Springer; 2001. ISBN: 978-3-540-41814-1. [žiūrėta 2026-04-18].
28. Rastogi S.C., Glickman R.D., Medinsky M.A., et al. Risk assessment for contact dermatitis from chemical allergens: importance of the patch test in diagnosing allergic contact dermatitis. *Journal of the American Academy of Dermatology*. 2001;44(2):235–241. DOI: 10.1067/mjd.2001.113552. [žiūrėta 2026-03-02].
29. Kechagias S., Lili L., Isidoro P., et al. Advances in patch testing: new developments in the diagnosis of allergic contact dermatitis. *Clinical Reviews in Allergy & Immunology*. 2020;58(3):344–351. DOI: 10.1007/s12016-020-08713-w. [žiūrėta 2026-04-09].
30. Debboun M., Vassal S.L., Sattler G.R. Comparison of different patch testing techniques in the diagnosis of allergic contact dermatitis. *International Journal of Dermatology*. 2017;56(7):820–825. DOI: 10.1111/ijd.13515. [žiūrėta 2026-03-17].
31. Forsell J., Volden G., Johansen J.D. Risk factors and diagnostic methods in allergic contact dermatitis: a comprehensive review of the literature. *Contact Dermatitis*. 2014;70(3):123–135. DOI: 10.1111/cod.12263. [žiūrėta 2026-04-13].

32. Storrs F.J., Van der Valk P.G.M., Hendricks E.D., et al. Patch test evaluation in the diagnosis of allergic contact dermatitis in patients with eczema. *Contact Dermatitis*. 2013;68(6):296–303. DOI: 10.1111/cod.12088. [žiūrėta 2026-02-25].
33. Sussman G.L., Biederman P.A. Advances in the application and interpretation of patch testing. *Journal of Dermatological Treatment*. 2000;11(1):49–53. DOI: 10.3109/09546630009037819. [žiūrėta 2026-03-11].
34. Zhao L., Cao Y., Zhang Y., et al. The evolution of patch testing techniques for allergic contact dermatitis. *Journal of Dermatological Science*. 2016;81(1):1–9. DOI: 10.1016/j.jdermsci.2015.10.001. [žiūrėta 2026-04-16].
35. Stojanović J., Milinković M., Jovanović M. Role of patch tests in the diagnosis of allergic contact dermatitis: a literature review. *International Journal of Dermatology*. 2019;58(4):404–410. DOI: 10.1111/ijd.14149. [žiūrėta 2026-04-24].
36. Wijk R.G., Ketel R., Langlais L., et al. The significance of patch testing in clinical practice. *Dermatologic Therapy*. 2008;21(4):227–234. DOI: 10.1111/j.1529-8019.2008.00210.x. [žiūrėta 2026-03-01].
37. Langan S.M., Weidinger S. Contact dermatitis: an overview of patch testing and its clinical applications. *Clinical and Experimental Dermatology*. 2017;42(5):456–461. DOI: 10.1111/ced.13173. [žiūrėta 2026-04-05].
38. Darsow U., Gerberick F., Lidén C., et al. Standardization and clinical application of patch testing in the diagnosis of allergic contact dermatitis. *Current Opinion in Allergy and Clinical Immunology*. 2013;13(3):318–323. DOI: 10.1097/ACI.0b013e3283611187. [žiūrėta 2026-04-28].
39. Johansson M., Lindholm C., Kälvegren H. Diagnostic value of patch testing in patients with suspected allergic contact dermatitis: a multicenter study. *Contact Dermatitis*. 2019;81(2):98–104. DOI: 10.1111/cod.13167. [žiūrėta 2026-03-21].
40. Esteva A., Kuprel B., Novoa R.A., et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115–118. DOI: 10.1038/nature21056. [žiūrėta 2026-05-01].
41. Tschandl P., Rosendahl C., Kittler H. The HAM10000 dataset: a large collection of multi-source dermoscopic images of common pigmented skin lesions. *Scientific Data*. 2018;5:180161. DOI: 10.1038/sdata.2018.161. [žiūrėta 2026-03-06].
42. Brinker T.J., Hekler A., Enk A.H., et al. Deep learning outperformed dermatologists in melanoma classification. *European Journal of Cancer*. 2020;139:41–47. DOI: 10.1016/j.ejca.2020.08.019. [žiūrėta 2026-04-14].
43. Liu Y., Jain A., Eng C., et al. A deep learning system for differential diagnosis of skin diseases. *Nature Medicine*. 2020;26:900–908. DOI: 10.1038/s41591-020-0842-3. [žiūrėta 2026-02-23].
44. Brinker T.J., et al. Artificial Intelligence in Dermatology: Challenges and Perspectives. *Dermatology and Therapy*. 2022;12:2637–2651. DOI: 10.1007/s13555-022-00827-0. [žiūrėta 2026-04-02].
45. Groh M., Venkatesan A., Aksoy B.A., et al. Systematic review of deep learning image analyses for the diagnosis and monitoring of skin disease. *npj Digital Medicine*. 2023;6:150. DOI: 10.1038/s41746-023-00895-9. [žiūrėta 2026-03-13].
46. Girshick R., Donahue J., Darrell T., Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2014. [žiūrėta 2026-04-19].

47. Ren S., He K., Girshick R., Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks. In: Advances in Neural Information Processing Systems (NeurIPS); 2015. [žiūrėta 2026-03-04].
48. Lin T.Y., Goyal P., Girshick R., He K., Dollár P. Focal loss for dense object detection. In: Proceedings of the IEEE International Conference on Computer Vision (ICCV); 2017. [žiūrėta 2026-05-03].
49. Bochkovskiy A., Wang C.Y., Liao H.Y.M. YOLOv4: Optimal speed and accuracy of object detection. arXiv preprint. arXiv:2004.10934; 2020. [žiūrėta 2026-02-20].
50. Redmon J., Farhadi A. YOLOv3: An incremental improvement. arXiv preprint. arXiv:1804.02767; 2018. [žiūrėta 2026-04-07].
51. Lin T.Y., Dollár P., Girshick R., et al. Feature Pyramid Networks for Object Detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2017. [žiūrėta 2026-03-23].
52. Esteva A., et al. Dermatologist-level classification of skin cancer with deep neural networks. Nature. 2017;542(7639):115–118. DOI: 10.1038/nature21056. [žiūrėta 2026-02-28].
53. Jocher G., et al. Ultralytics YOLOv5. GitHub repository. Prieiga per internetą: <https://github.com/ultralytics/yolov5> [žiūrėta 2026-04-26].
54. Han S.S., et al. Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis. JAMA Dermatology. 2020;156(1):17–25. DOI: 10.1001/jamadermatol.2019.3355. [žiūrėta 2026-03-31].
55. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016. DOI: 10.1109/CVPR.2016.91. [žiūrėta 2026-04-27].