



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Gaisrų miškuose atpažinimo sistemos tyrimas

Baigiamasis magistro projektas

Ignas Senovaitis

Projekto autorius

prof. dr. Vidas Raudonis

Vadovas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Gaisro miškuose atpažinimo sistemos tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Ignas Senovaitis

Projekto autorius

prof. dr. Vidas Raudonis

Vadovas

doc. dr. Virginijus Baranauskas

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Ignas Senovaitis

Gaisro miškuose atpažinimo sistemos 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.

Ignas Senovaitis

Patvirtinta elektroniniu būdu

Senovaitis, Ignas. Gaisro miškuose atpažinimo sistemos tyrimas. Magistro baigiamasis projektas / vadovas prof. dr. Vidas Raudonis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis: elektronikos inžinerija (inžinerijos mokslai).

Reikšminiai žodžiai: Neuroninių tinklų architektūros, duomenų bazė, iteracijos, greitimeika, tikslumas, atpažinimas.

Kaunas, 2022. 56 p.

Santrauka

Globaliniam atšilimui įgaunant pagreitį ir kasmet kylant vidutinei pasaulinei temperatūrai kartu su ja kyla miško gaisrų skaičius dėl vis dažniau vyraujančių sausrų. Gaisrų metu sunaikinamos ištisos ekosistemos, negrįžtamai pakeičiamas kraštovaizdis bei dirvožemio struktūra. Greitas ir tikslus dūmų aptikimas yra labai svarbus siekiant sumažinti gaisrų daromą žalą. Šiuo metu rinkoje yra keletas miško gaisrų prevencijos būdų, tačiau ne visi naudojami metodai yra tikslūs, greiti bei autonomiški.

Šiame darbe yra aprašomas *YOLOv5* metodo panaudojimas gaisro lokalizavimo užduočiai spręsti bei įvertinti. Šis naujas metodas yra naudojamas eismo, žmonių atpažinimo bei sekimo užduotims spręsti.

Šiame darbe yra atliekami algoritmo greitimeikos bei tikslumo tyrimai. Metodo tikslumo priklausomybės tyrimas panaudojant skirtingus bazinius modelius bei skirtingas duomenų bazines bei testavimo įrangą. Taip pat, atliekamas papildomas tyrimas norint sužinoti metodo tikslumo priklausomybę nuo skirtingų sąjungos ir sankirtos parametrų.

Senovaitis, Ignas. Research of forest fire detection system. Master's Final Degree Project / supervisor prof. dr. Vidas Raudonis, Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

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

Keywords: dataset, deep learning method, detection methods, machine learning.

Kaunas, 2022. 56 p.

Summary

As global warming gains momentum and average global temperatures are constantly rising, the number of forest fires is rising along with it, due to more frequent droughts. Forest fires can destroy entire ecosystems, permanently altering landscapes and soil structure. Rapid and accurate smoke detection is essential in order to reduce the damage caused by wildfires. There are currently several forest fire prevention methods on the market, but not all of them are accurate, fast and autonomous.

This paper describes how effective *YOLOv5* method can be for fire localization and evaluation tasks. This method was successfully used for solving traffic, human detection and tracking problems.

In this work, the speed and accuracy of the algorithm are investigated. The dependency of the accuracy is carried out using different base models on different databases and testing equipment. An additional study is performed in order to analyze the dependence of the accuracy with different union and intersection parameters.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Santrumpų sąrašas	11
Įvadas.....	12
1. Literatūros analizė.....	13
1.1. Skaitmeninis vaizdas	13
1.2. Vaizdų atpažinimas	13
1.3. Miško gaisrų žala.....	14
1.4. Miško gaisrų lokalizavimas	14
1.4.1. Termografijos sistema ankstyvam gaisro aptikimui.....	14
1.4.2. Antžeminės automatinės miško gaisrų stebėjimo sistemos.....	14
1.4.3. Žemės palydovų būdas	15
1.4.4. Miško gaisrų aptikimas pasitelkiant bepiločius orlaivius.....	15
1.5. Rinkoje naudojamų skirtingų orlaivių palyginimas	16
1.6. Dirbtinių neuroninių tinklų vaizdo atpažinimo metodai	17
1.7. Dirbtiniais neuroniniais tinklais pagrįstų lokalizavimo sistemų architektūros.....	17
1.8. Dirbtiniais neuroniniais tinklais pagrįsti lokalizavimo metodai.....	18
1.9. <i>YOLO</i> neuroninis tinklas	18
1.9.1. <i>YOLOv1</i> neuroninio tinklo architektūra	19
1.9.2. <i>YOLOv2</i> neuroninio tinklo architektūra	21
1.9.3. <i>YOLOv3</i> architektūra	21
1.9.4. <i>YOLOv4</i> architektūra	22
1.9.5. <i>YOLOv5</i> architektūra	23
2. Metodologija	25
2.1. <i>VTOL</i> orlaivio platforma	25
2.1.1. <i>VTOL</i> orlaivio valdymo sistema.....	25
2.1.2. Telemetrijos perdavimas	26
2.2. Programinė įranga	26
2.3. Duomenų bazė	27
2.4. Duomenų bazės praplėtimas sintetiniais duomenimis.....	28
2.5. Metodo tikslumo įvertinimas.....	31
2.5.1. Tikslumo ir atšaukimo rodikliai	31
2.5.2. Sankirtos ir sąjungos parametras	31
2.5.3. Bendrinis sankirtos ir sąjungos parametras	32
2.5.4. Atstumo sankirtos ir sąjungos parametras.....	33
2.5.5. Vidutinis tikslumo vidurkis ir <i>FI</i> kreivė	33
3. Eksperimentiniai tyrimai.....	35
3.1.1 <i>YOLOv5x</i> modelio įtaka metodo tikslumui	35
3.1.2 <i>YOLOv5l</i> modelio įtaka metodo tikslumui	38
3.1.3 <i>YOLOv5m</i> modelio įtaka metodo tikslumui	41
3.1.4 <i>YOLOv5s</i> modelio įtaka metodo tikslumui.....	43
3.1.5. <i>YOLOv5n</i> modelio įtaka metodo tikslumui	45
3.1.6. Skirtingų <i>YOLOv5</i> tinklo architektūrų su geriausiomis duomenų bazėmis palyginimas	48
3.1.7. Skirtingų persidengimo metodų palyginimas	49

3.1.8. Realios ir sintetinės duomenų bazės palyginimas	51
3.1.9. Įvesties duomenų testavimo laiko augmentacija	51
Išvados	53
Literatūros sąrašas	54

Lentelių sąrašas

1 lentelė. Skirtingų orlaivių parametrų palyginimas	16
2 lentelė. Skirtingų <i>VTOL</i> perėjimo metodų palyginimas.....	17
3 lentelė. Skirtingų architektūrų palyginimas	18
4 lentelė. <i>YOLOv5</i> modelių specifikacijos	24
5 lentelė. <i>VTOL</i> specifikacijos	25
6 lentelė. Kompiuterių parametrai	27
7 lentelė. <i>YOLOv5</i> modelių tikslumo priklausomybė nuo skirtingų persidengimo metodų.	50
8 lentelė. Realios ir sintetinės duomenų bazės atpažinimo tikslumo rezultatai	51

Paveikslų sąrašas

1 pav. Spalvoto pikselio sudėtis	13
2 pav. Vaizdo atpažinimo sistemų panaudojimas: a) miško gaisrų aptikimas, b) žmonių atpažinimas, c) eismo linijų ir jo dalyvių radimas,	13
3 pav. Termovizoriaus karščio aptikimas pro dūmus	14
4 pav. Bokštas su įmontuota kamera skirta miško būklės stebėsenai	15
5 pav. <i>DJI mavic pro</i> dronas	15
6 pav. a) <i>Skywalker</i> b) <i>Raven</i> c) <i>Flying dragon</i>	16
7 pav. Neuroninio tinklo struktūra [14]	17
8 pav. Supaprastinti modeliai: a) <i>Faster r-cnn</i> , b) <i>YOLOv3</i> , c) <i>SSD</i>	18
9 pav. Įvesties vaizdui pritaikytas <i>YOLO</i> modelis su 7x7 dydžio tinkleliu	19
10 pav. Ribinio lauko parametrai 3x3 tinklelio lange	19
11 pav. To paties tinklelio ribiniai langai dalijasi prognozavimo klasės rinkiniu	20
12 pav. Prognozuojamų ribinių langelių vektoriai	20
13 pav. Kiekvienam tinklelio langeliui (raudona spalva) modelis numato 5 skirtingų formų ribinius regionus (geltona spalva).....	21
14 pav. <i>ResNet</i> praleidžiamų jungčių architektūra.....	22
15 pav. <i>Darknet-53</i> architektūra su 5 blokais (ribiniais langeliais), kuriuose yra 1x1 ir 3x3 sąsukos sluoksniai [28].	22
16 pav. Tinklo šuns aptikimas pagal jo liemenį.....	23
17 pav. <i>YOLOv5</i> tinklo struktūra	23
18 pav. Skirtingų <i>YOLOv5</i> versijų mastelių iliustracija.....	24
19 pav. a) <i>Flying dragon 2160</i> modelis b) <i>Pixhawk 4</i> su dviem <i>GPS</i> moduliais	25
20 pav. <i>Mission Planner</i> programinė įranga	26
21 pav. Ryšio perdavimo sistema	26
22 pav. Duomenų bazių sandara	27
23 pav. Miško dūmų pavyzdžiai	28
24 pav. <i>Roboflow</i> įrankiu sužymėta nuotrauka. Žalia spalva pažymėti dūmai	28
25 pav. <i>Unity3D</i> sugeneruota miško aplinka	29
26 pav. Duomenų bazės augmentacijos pavyzdys: a) sintetinė nuotrauka, b) nuotrauka daryta su dronu.....	30
27 pav. Imitacinių dūmų dalelių pavyzdys	30
28 pav. Sintetinės duomenų bazės ribinio lango žymėjimas.....	30
29 pav. a) R b) $R+F$, c) $R+F+W$, d) $R+F+W+Y$	31
30 pav. <i>IoU</i> parametro skaičiavimas	32
31 pav. Aptiktų objektų klasifikavimas, kuomet <i>IoU</i> slenkstinė vertė lygi 0,5	32
32 pav. Geltona spalva pažymėtas apskaičiuojamas <i>mAP</i> plotas	34
33 pav. <i>YOLOv5x</i> tinklo regiono ir objekto nuostoliai	35
34 pav. Regiono ir objekto nuostoliai prie 100 iteracijų.....	36
35 pav. <i>YOLOv5x</i> tikslumo parametrai	37
36 pav. <i>YOLOv5x</i> apmokymo laiko grafikas	37
37 pav. <i>YOLOv5x</i> klaidingų neigiamų atpažinimų rezultatai.....	38
38 pav. <i>YOLOv5l</i> tinklo regiono ir objekto nuostoliai	39
39 pav. <i>YOLOv5l</i> tinklo tikslumo parametrai	39

40 pav. <i>YOLOv5l</i> tinklo skirtingų duomenų rinkinių apmokymo trukmė	40
41 pav. <i>YOLOv5l</i> tinklo klaidingų neigiamų atpažinimų rezultatai	40
42 pav. <i>YOLOv5m</i> tinklo regiono ir objekto nuostoliai	41
43 pav. <i>YOLOv5m</i> tinklo tikslumo parametrai	42
44 pav. <i>YOLOv5m</i> tinklo skirtingų duomenų rinkinių apmokymo trukmė	42
45 pav. <i>YOLOv5m</i> tinklo klaidingų neigiamų atpažinimų rezultatai	43
46 pav. <i>YOLOv5s</i> tinklo regiono ir objekto nuostoliai	43
47 pav. <i>YOLOv5s</i> tinklo įtaka metodo tikslumui	44
48 pav. <i>YOLOv5s</i> tinklo skirtingų duomenų rinkinių apmokymo trukmė	44
49 pav. <i>YOLOv5s</i> tinklo klaidingų neigiamų atpažinimų rezultatai	45
50 pav. <i>YOLOv5n</i> tinklo regiono ir objekto nuostoliai	45
51 pav. <i>YOLOv5n</i> tinklo įtaka metodo tikslumui	46
52 pav. <i>YOLOv5n</i> tinklo skirtingų duomenų rinkinių apmokymo trukmė	47
53 pav. <i>YOLOv5n</i> tinklo klaidingų neigiamų atpažinimų rezultatai	47
54 pav. a) <i>mAP@0,5</i> rezultatai b) <i>F1</i> rezultatai	48
55 pav. <i>YOLOv5</i> skirtingų tinklų vaizdų apdorojimo trukmė	49
56 pav. Skirtingų <i>YOLOv5</i> modelių apmokymo trukmė	49
57 pav. Skirtingų persidengimo metodų atpažinimo rezultatai	50
58 pav. Testavimo laiko augmentacijos įtaka <i>mAP@0.5</i> tikslumui	51
59 pav. Tikslumo, atšaukimo ir <i>F1</i> rezultatai	52

Santrumpų sąrašas

Santrumpos:

VTOL – vertikalaus kilimo ir tūpimo dronas (angl. *Vertical Take-Off and Landing*);

R-CNN – metodas, kuris apjungia regionų paieškos ir sąsukos neuroninių tinklų metodus;

YOLO – metodas, kuris aptinka ir atpažįsta įvairius objektus nuotraukoje (angl. *You Only Look Once*);

IoU – tai sankirtos ir sąjungos (angl. *Intersection Over Union*) parametras, dar kitaip vadinamas *Džakardo* indeksu (angl. *Jaccard index*);

DioU – atstumo sankirtos ir sąjungos parametras (angl. *Distance Intersection Over Union*);

CIoU – pilnas sankirtos ir sąjungos parametras (angl. *Complete Intersection Over Union*);

GIoU – bendrinis sankirtos ir sąjungos parametras (angl. *Generalized Intersection Over Union*);

NMS – maksimumų atrinkimas (angl. *Non Maximum Supression*).

Įvadas

Europos mokslinių tyrimų centro duomenimis, miško gaisrų skaičius kasmet auga. 2020 metais buvo užfiksuota virš 3400 km² sudegusio miško ploto, 40% iš jų sudarė saugomos teritorijos ir gamtos rezervatai [1]. Skaičiuojama, kad atstatyti žalai, kurią sukėlė gaisrai, prireiks ne vienerių metų. Gaisrų metu nukenčia ne tik gamta, bet ir ugniagesiai, civiliai. Rinkoje sutinkamos įvairios priešgaisrinės sistemos, tačiau didžiausio susidomėjimo sulaukia miško stebėseną pasitelkiant neuroninius tinklus. Dėl nuolat kintančių dūmų vaizdų, egzistuojančios dūmų aptikimo sistemos susiduria su mažu atpažinimo tikslumu bei patikimumu. Miško gaisrų stebėsenos metodų yra įvairiausių, todėl iš čia yra suformuluojama šio darbo pagrindinė užduotis – koks lokalizacijos būdas yra efektyviausias siekiant aptikti dūmus.

Šio darbo tikslas yra pritaikyti bei iširti *YOLOv5* gilaus apmokymo algoritmo panaudojimą gaisro lokalizavimo uždavinio sprendimui.

Šiam tikslui yra keliami šie uždaviniai:


1. atlikti literatūros analizę;
2. išanalizuoti rinkoje esančių gaisro lokalizavimo sprendimus bei naudojamas technologijas;
3. surinkti duomenų bazę su gaisro pavyzdiniais duomenimis bei ją anotuoti;
4. eksperimentiškai iširti *YOLOv5* gilaus neuroninio tinklo panaudojimą gaisro lokalizavimui;
5. eksperimentiškai iširti *YOLOv5* gilaus neuroninio tinklo tikslumą naudojant skirtingas bazines architektūras;
6. eksperimentiškai iširti *YOLOv5* gilaus neuroninio tinklo tikslumą naudojant padidintą sintetinius duomenimis duomenų bazę;
7. eksperimentiškai iširti *YOLOv5* gilaus neuroninio tinklo tikslumą naudojant skirtingus sankirtos ir sąjungos parametrus;
8. pateikti išvadas ir rekomendacijas.

1. Literatūros analizė

Kompiuterinė rega – tai dirbtinio intelekto sritis, leidžianti kompiuteriams ir sistemoms iš skaitmeninių vaizdų, vaizdo įrašų ir kitų vaizdinių įvesties duomenų išgauti reikšmingą informaciją, kuria remiantis įvykdomos specifinės užduotys. Jeigu dirbtinis intelektas kompiuteriams suteikia galimybę mąstyti, tai kompiuterinė rega suteikia galimybę matyti, suprasti ir įvertinti juos supančią aplinką.

1.1. Skaitmeninis vaizdas


Skaitmeninis vaizdas – tai objekto atvaizdavimas kompiuteryje iš dvimačių skaičių masyvų, sudarytų iš mažiausių vaizdo elementų – pikselių [2]. Kiekvieną pikselio vietą galima pavaizduoti kaip vektorių, nurodantį konkretaus pikselio koordinatas vaizde. Pikseliai gali turėti kelias reikšmes – spalvos kodus. Spalvotas vaizdas sudarytas iš pikselių, turinčių skirtingas reikšmes. Spalvoto pikselio pavyzdys pavaizduotas 1 paveiksle.



1 pav. Spalvoto pikselio sudėtis

1.2. Vaizdų atpažinimas

Nuo pirmojo A. Krizhevsky, I. Sutskever, ir G.E. Hinton mokslininkų sukurto *AlexNet* tinklo proveržio kompiuterinės regos srityje, vaizdų atpažinimas nuolat tobulėja [3]. Pagrindinis dalykas, kurio reikia gilaus mokymosi algoritmams, yra duomenys, o dėl įvairių kamerų technologijų pažangos, duomenų kiekis ir kokybė eksponentiškai didėja. Vaizdo atpažinimo sistemų pritaikymo pavyzdžiai pavaizduoti 2 pav.



2 pav. Vaizdo atpažinimo sistemų panaudojimas: a) miško gaisrų aptikimas, b) žmonių atpažinimas, c) eismo linijų ir jo dalyvių radimas,

Vaizdo atpažinimas pritaikomas įvairiose ir sudėtingose srityse, o algoritmai, naudojami vaizdo apdorojimui, tam tikrose srityse gali net tik padėti, bet ir tam tikrais atvejais pranokti žmogų. Nesvarbu, ar tai būtų medicininė diagnostika (biologija), gamybos automatizavimas (pramonė), rekomendavimo sistemos (rinkodara), ar kasdienė veikla, pavyzdžiui, vairavimas ar apsipirkimas - regos sistemos yra sutinkamos visur. Šiame darbe vaizdo analizė yra panaudojama miško gaisrų aptikimui.

1.3. Miško gaisrų žala


Miškai užima 33,4 proc. Lietuvos teritorijos bei dengia apie 30 proc. žemės sausumos paviršiaus ir yra pagrindinis atsikuriantis mūsų šalies aplinkos išteklius, reikšmingas mūsų krašto ekonomikai [4]. Pagal dabartines klimato prognozes Lietuvoje numatoma, kad vidutinė metų oro temperatūra gali pakilti iki 2,5 – 4°C [5]. Esant tokiems pokyčiams, išauga rizika pasireikšti didelėms sausroms, dėl kurių padidėja ir gaisrų tikimybė. Miško gaisrų žala sudaro didelį tiesioginį poveikį visai ekosistemai: sunaikinama smulkioji fauna ir flora, negrįžtamai pakeičiamas kraštovaizdis bei dirvožemio struktūra. Šiuo metu yra daug įvairių sprendimų, kaip kovoti su miškų gaisrais. Vienas iš būdų, kaip galima sumažinti gaisrų daromą žalą – tai ankstyvojo jų nustatymo metodų taikymas.

1.4. Miško gaisrų lokalizavimas

Siekiant tiksliai ir efektyviai aptikti gaisro židinių skirtinguose bei nuolat kintančiuose miškų fonuose - būtina išsirinkti tinkamą jos lokalizacijos priemonę. Šiuo metu rinkoje egzistuoja keletas ugnies židinio gamtoje aptikimo metodų.

1.4.1. Termografijos sistema ankstyvam gaisro aptikimui

Vienas iš gaisro aptikimo būdų – termovizorines (termo kameros) sistemos. Sistema leidžia automatiškai aptikti, nustatyti vietą ir stebėti miško gaisrus naudojant terminius vaizdus. Infraraudonųjų spindulių kamera fiksuoja temperatūros pasiskirstymą vietovėje ir automatiškai nustato karštus taškus. Šiluminių vaizdų kameros yra sukalibruotos ir realiuoju laiku gauna informaciją apie temperatūrą kiekviename pikselio taške, todėl automatiškai geba aptikti gaisro židinį. Be to, naudojant skaitmeninį išvesties modulį, galima automatiškai įjungti gesinimo sistemas arba siųsti el. laiškus pavojaus atveju [6]. Sistemos panaudojimo pavyzdys pateikiamas 3 paveiksle.



3 pav. Termovizoriaus karščio aptikimas pro dūmus

1.4.2. Antžeminės automatinės miško gaisrų stebėjimo sistemos

2010 metais Lietuvoje pradėta diegti antžeminė automatinė miškų gaisrų stebėjimo sistema. Sistema susideda iš kamerų, diegiamų ant jau esamų priešgaisrinio stebėjimo bokštų. Kameros geba sukurti aplink savo ašį ir aptikti dūmus 15 – 30 km. spinduliu (4 pav.). Kameroms aptikus dūmus, pranešimas su tiksliais dūmų koordinatėmis siunčiamas budinčiajam operatoriui. Eksploatavimo metu aptikti šios sistemos trūkumai. Skirtingos kameros nėra tarpusavyje sujungtos į bendrą tinklą, šviesiu paros metu gaunami klaidingi, gaisro židiniai palaikyti, pranešimai [7].



4 pav. Bokštas su įmontuota kamera skirta miško būklės stebėsenai

1.4.3. Žemės palydovų būdas

Kitas ugnies aptikimo būdas galimas panaudojant žemės palydovus. Būtent jais galima padengti didžiausią žemės ploto dalį. Tokios paslaugos kaštai taip pat yra vieni didžiausių. Be to, ne visų palydovų rezoliucija yra pakankama, norint tiksliai atpažinti kylančius gaisrus miškuose. Praktikoje palydovinės sistemos dažniausiai naudojamos įvertinti kilusio miško gaisro padarinius. Nors palydovų stebėseną gali būti vykdoma ištisą parą, jų galimybė stebėti žemę gali būti apribota nepalankių oro sąlygų, t.y debesuotumo. Dėl orbitos apribojimų, palydovai negali pateikti nuolatinio gaisro vaizdo, todėl stebėseną gali būti nutraukiama. Norint tinkamai apdoroti ir interpretuoti palydovų duomenis, taip pat yra reikalingi kvalifikuoti asmenys, kurie atitinkamai prisideda prie visos sistemos išlaikymo kaštų [8].

1.4.4. Miško gaisrų aptikimas pasitelkiant bepiločius orlaivius

Miškų būklės stebėjimas orlaivių pagalba apjungia anksčiau minėtų metodų pagrindinius privalumus. Dronuose gali būti įrengti terminiai jutikliai, kurie, naudodami infraraudonuosius spindulius, padeda aptikti gaisro židinius. Dronai ypač svarbūs miško gaisrams, kurie paprastai greitai tampa nekontroliuojami. Jie suteikia ugniagesiams galimybę iš paukščio skrydžio apžvelgti vietovę ir padeda nustatyti, kur gaisras judės toliau, todėl jie gali greitai priimti sprendimus, kur turėtų vykti komandos. Šiuo metu rinkoje dažnai naudojami *DJI* firmos dronai, kurie pasižymi savo valdymo paprastumu, iš naudotojo nereikalaujant papildomų valdymo įgūdžių ar patirties [9]. Populiariausias rinkoje naudojamas *DJI* modelis pavaizduotas 5 paveiksle.




5 pav. *DJI mavic pro* dronas

Pasirinkus drono sistemą, atmetami tokie papildomi kaštai kaip papildomos infrastruktūros kūrimas, t.y stebėjimo bokšto statymas, elektros bei interneto komunikacijų atvedimas, kvalifikuoto personalo įdarbinimas. Sistemai esant mobiliai, didėja jos panaudojimo galimybės ir pritaikymas ten, kur kitos sistemos negali veikti.

Tačiau dabartiniai metodai yra ne visuomet tikslūs, greiti bei autonomiški, dėl to šioje srityje yra bandoma taikyti neuroninių tinklų pagrindu veikiančius metodus

1.5. Rinkoje naudojamų skirtingų orlaivių palyginimas

Komercinėje rinkoje vyrauja du pagrindiniai bepiločių orlaivių tipai: fiksuoto sparno ir daugiarotoriai [10]. Abu turi privalumų ir trūkumų, priklausomai nuo norimos atlikti užduoties. Daugiarotoriais lengva skraidyti, pakilti ir nusileisti, be to, jie gali lengvai atlikti autonominius skrydžius [11]. Vis dėlto daugiarotorinių orlaivių skrydžio trukmė yra trumpesnė, tad ir padengiamas plotas yra mažesnis [12]. Kita vertus, fiksuoto sparno bepiločiai orlaiviai pasižymi ilga skrydžio trukme ir vienu skrydžiu gali aprėpti dideles teritorijas, tačiau jiems reikia tinkamos nusileidimo vietos, įskaitant tam tikrus piloto įgūdžius, kad jie galėtų minkštai nusileisti ir išvengti orlaivio ir jutiklių pažeidimų. Šios moderniausios sistemos pastaraisiais metais vystėsi labai sparčiai [13]. Bepiločių orlaivių gebėjimas skristi žemai su atitinkamais jutikliais tampa puikia priemone aplinkos stebėsenai. 6 paveiksle pateikiamos skirtingų orlaivių platformos.






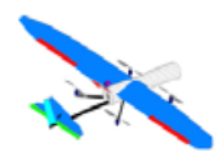
6 pav. a) *Skywalker* b) *Raven* c) *Flying dragon*

1 lentelė. Skirtingų orlaivių parametrų palyginimas

Tipas	<i>Skywalker</i>	<i>Raven</i>	<i>Flying dragon</i>
Orlaivio rūšis	Fiksuotas sparnas	Daugiarotorinis	VTOL
Svoris	4 kg	7.25 kg	4.5 kg
Krovinio svoris	0.5 kg	1 kg	2 kg
Dydis	Ilgis: 129 cm Plotis: 183 cm Aukštis: 42 cm	Ilgis: 59 cm Plotis: 59 cm Aukštis: 39 cm	Ilgis: 120 cm Plotis: 216 cm Aukštis: 40 cm
Skrydžio laikas	40 min	12 min	95 min
Vidutinis greitis	15 m/s	8 m/s	18-20 m/s
Akumulatorius	4s 8500 mah	20000 mah	6s 25000mah
Kaina	2000 USD	3500 USD	3000 USD

Vertikalaus kilimo ir tūpimo (angl. *vertical take-off and landing, VTOL*) dronai, tokie kaip „*Flying Dragon 2160*“, yra mišrus metodas, kuriame suderinami daugiarotorių ir fiksuoto sparno konstrukcijos elementai. Jie kyla ir leidžiasi vertikaliai kaip daugiarotoriai, tačiau skrydžio metu veikia kaip fiksuoto sparno dronai, tokiu būdu išsaugant skirtingų platformų geriausias savybes [14]. Skirtingi VTOL orlaiviai pasižymi skirtingais pereinamojo manevro būdais, t.y skrydžio režimo pakeitimu iš vertikalios pozicijos į horizontalią. Pagrindiniai orlaivių skrydžių perėjimo metodai aprašyti 2 lentelėje.

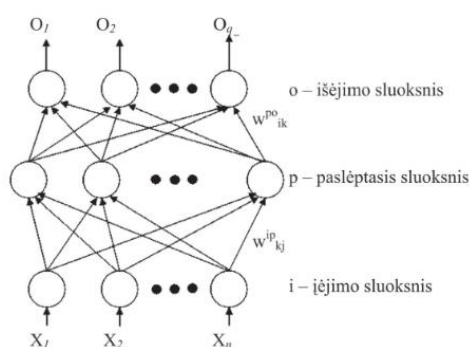
2 lentelė. Skirtingų VTOL perėjimo metodų palyginimas

Modelis	Tipas	Perėjimo metodas
	<i>Tailsitter</i>	Pakreipiamas visas orlaivis pasitelkiant valdymo paviršius
	<i>Tiltrotor</i>	Motorai pakreipiami iš horizontalios pozicijos į vertikalią
	<i>Tiltwing</i>	Pakreipiami orlaivio sparnai iš vertikalios į horizontalią poziciją
	<i>VTOL-FW</i>	Valdymo elementų perjungimas tarp VTOL ir FW nestabdant orlaivio

Šiame darbe buvo pasirinktas orlaivis su *VTOL-FW* perėjimo metodu.

1.6. Dirbtinių neuroninių tinklų vaizdo atpažinimo metodai

Dirbtinis neuroninis tinklas – tai matematinės funkcijos, nuosekliai jungtėmis apdorojančios informaciją [15]. Pirmiausia, įvairios kintamųjų reikšmės perduodamos per įėjimo jungtį į tinklą, jas apdorojus, atitinkamai per išėjimo jungtis gaunamos apytikslės funkcijų reikšmės. Pagrindiniai neuroninių tinklų apdorojimo elementai įprastai skirstomi į sluoksnius, matomus 7 paveiksle.



7 pav. Neuroninio tinklo struktūra [14]

1.7. Dirbtiniais neuroniniais tinklais pagrįstų lokalizavimo sistemų architektūros

Šiuo metu vieni populiariausių objektų lokalizavimo metodų yra *YOLOv3*, *Faster R-CNN* ir *SSD*, kurie, naudodami neuroninius tinklus, geba rasti objektus vaizde. Visus tinklus apmokius naudojant *Microsoft* atviro kodo *COCO* duomenų rinkinį, kad būtų užtikrintas homogeniškas atskaitos taškas, nustatyta, kad *YOLOv3* yra greičiausias, nuo jo nedaug atsilieka *SSD*, o paskutinėje vietoje yra *Faster RCNN* [16]. Objektyviai palyginti skirtingus atpažinimo modelius yra sudėtinga, kadangi jų našumas

priklauso nuo konkrečios užduoties. Kasmet skelbiami nauji algoritmai arba esamų algoritmų atnaujinimai, todėl šiame darbe pasirinkta naudoti naujausią *YOLO* tinklo architektūros versiją – *YOLOv5*. Architektūrų palyginimas pavaizduotas 3 lentelėje [16].

3 lentelė. Skirtingų architektūrų palyginimas


Metodas	<i>SSD</i>	<i>Faster R-CNN</i>	<i>YOLOv3</i>
Paveikslo apdorojimo laikas	21 ms	7 ms	1,5 ms
Pagreitėjimas	1x	3x	4x
<i>mAP</i>	79,41 %	87,17 %	80,69 %

1.8. Dirbtiniais neuroniniais tinklais pagrįsti lokalizavimo metodai

SSD metode, už mažų objektų aptikimą atsakingi didesnės skiriamosios gebos sluoksniai, matomi 8 paveiksle c dalyje. Tačiau šie sluoksniai yra mažiau naudingi klasifikavimui, kadangi juose yra žemesnio lygio požymių, pavyzdžiui, spalvų dėmių ar kraštų, todėl sumažėja bendras *SSD* našumas [17]. Siekiant didelio tikslumo, norimo objekto atpažinimui, reikalingas didelis duomenų kiekis *SSD* tinklo apmokymui. Priklausomai nuo užduoties, tai gali būti brangu ir užimti neproporcingai daug laiko.

Faster r-cnn algoritmo didelis tikslumas tiesiogiai atsispindi ilgoje tinklo apmokymo trukmėje. Šis modelis yra kelis kartus lėtesnis nei *YOLO*. Nepaisant to, kad jis yra modernesnis nei *RCNN* ar *Fast RCNN* - jam vis dar reikia kelis kartus pereiti per vieną vaizdą. [18].

Atsižvelgiant į modelio dydį, *YOLOv3* tinklas gali atitikti nedidelio našumo platformų reikalavimus ir užtikrina didelį aptikimo greitį. Todėl jis turi plačias tinklo tobulinimo galimybes ir praktinio taikymo vertę [19].



8 pav. Supaprastinti modeliai: a) *Faster r-cnn*, b) *YOLOv3*, c) *SSD*

1.9. *YOLO* neuroninis tinklas

YOLO – tai termino „tik kartą pažvelgsi“ (angl. „*You Only Look Once*“) santrumpa. Tai algoritmas, kuris aptinka ir atpažįsta įvairius objektus nuotraukoje (realiuoju laiku). *YOLO* neuroninių tinklų algoritmas buvo pristatytas 2015 m. Josepho Redmono ir kt. straipsnyje „*You Only Look Once: Unified, Real-Time Object Detection*“ ir sulaukė didelio kompiuterinės regos tyrėjų dėmesio.

Iki šiol yra išleistos penkios *YOLO* versijos. Kiekviena versija buvo atnaujinama ir integruojama su pažangiausiomis kompiuterinės regos tyrimų bendruomenės idėjomis. *YOLO* žinomas kaip vienas

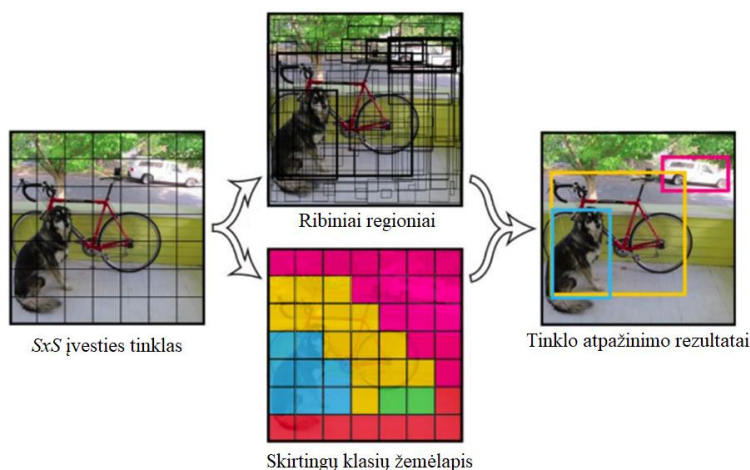
geriausių šiuolaikinių objektų aptikimo algoritmų. Prieš taikant naujausią *YOLOv5* modelį, būtina išsiaiškinti, kaip buvo patobulintos ankstesnės jo versijos.

1.9.1. *YOLOv1* neuroninio tinklo architektūra

Pagrindinė *YOLOv1* idėja - suskaidyti vaizdą į $S \times S$ (7×7 pagal nutylėjimą) dydžio tinklelį, pavaizduotą 9 paveiksle. Jei objekto centras patenka nors į vieną tinklelio regioną, tas tinklelio regionas yra atsakingas už to objekto aptikimą. Siekiant atpažinti ieškomą objektą, kiekvienas tinklelio regionas turi apribojimus su jų parametrais ir tų apribojimų įvertio matus, pavaizduotus 10 paveiksle [20]. Šie įvertio matai parodo objekto buvimą ar nebuvimą ribiniame regione. Patikimumo matas apibrėžiamas taip:


$$confidencescore = p(Object) * IOU_{predtruth}$$

Čia *confidencescore* patikimumo balas, $p(Object)$ - tai tikimybė, kad regiono viduje yra objektas, o $IOU_{predtruth}$ - sankirtos ir sąjungos parametras. $p(Object)$ yra intervale nuo 0 iki 1, todėl patikimumo reikšmė yra artima nuliui, jei tame regione nėra objekto. Priešingu atveju balas lygus $IOU_{predtruth}$.



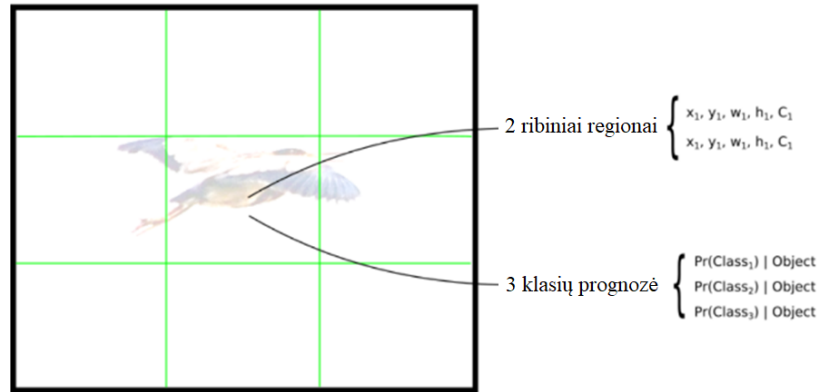
9 pav. Įvesties vaizdai pritaikytas *YOLO* modelis su 7×7 dydžio tinkleliu

Kiekvieną ribinį regioną sudaro 4 parametrai (x, y, w, h), kurie atitinka - centro koordinatės: x, y , plotį - w ir aukštį - h , pavaizduotus 10 paveiksle. Pridėjus patikimumo balą - kiekvieną ribinį regioną sudaro 5 parametrai.



10 pav. Ribinio lauko parametrai 3×3 tinklelio lange.

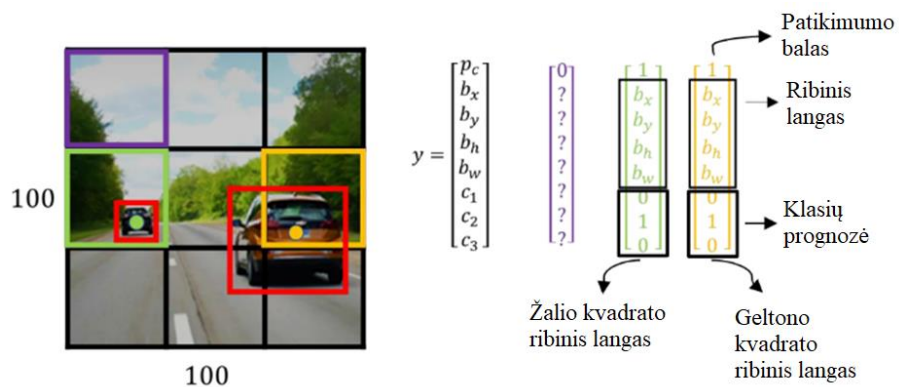
Kiekvieno objekto aptikimo tikimybė žymima p ($Class|Object$). Klasės pasitikėjimo reikšmės žymimos raide C . To paties tinklelio B apribojimo regionas turi bendrą objekto klasės prognozių rinkinį, t. y. visi to paties tinklelio riboženkliai turi tą pačią klasę. Kaip parodyta 11 paveiksle, centriniame kvadrate yra 2 prognozavimo langeliai. Nors turi skirtingus parametrus (x,y,w,h,c) , jie turi tas pačias 3 prognozių klases.



11 pav. To paties tinklelio ribiniai langai dalijasi prognozavimo klasės rinkiniu

Kiekviename langelyje prognozuojami ribiniai regionai, kuriuos sudaro 5 parametrai ir kurie dalijasi C klasių prognozavimo tikimybėmis. Bendra *YOLO* modelio parametrų išvestis yra $S \times S \times (5 \times B + C)$ [21]. Pavyzdžiui, vertinant *YOLO* modelį *COCO* duomenų rinkinyje, kuriame yra 80 klasių, ir nustatčius, kad kiekvienas regionas prognozuoja 2 ribinius laukus, bendri išvesties parametrai būtų $7 \times 7 \times (5 \times 2 + 80)$.

12 paveiksle pavaizduoti prognozuojamų ribinių langelių vektoriai. Realios pozicijos (angl. *ground truth*) ribinių langelių vektoriai atitinka vektorių – y . Violetiniame langelyje nėra jokio objekto, todėl ribinių langelių patikimumo balas violetiniame langelyje lygus 0.



12 pav. Prognozuojamų ribinių langelių vektoriai


YOLO taiko maksimumų atrinkimą (angl. *Non-Maximum Suppression, NMS*), kad panaikintų visus ribojamuosius laukus, kuriuose nėra jokio objekto arba kuriuose yra tas pats objektas kaip ir kituose ribojamuosiuose laukuose (9 pav.). Pasirinkus slenkstinę vertę, *NMS* pašalina visus persidengiančius ribojamuosius laukus, kurių susikirtimo su sąjunga (angl. *intersection over union, IOU*) vertė viršija nustatytą slenkstinę vertę [22].

1.9.2. YOLOv2 neuroninio tinklo architektūra

YOLOv1 tinklas pasižymėjo didelėmis atšaukimo (angl. *recall*) klaidomis, todėl *YOLOv2* daugiausia dėmesio skyrė atšaukimo ir lokalizavimo klaidų mažinimui, išlaikant tinklo klasifikavimo tikslumą [23]. *YOLOv2* buvo įdiegta nauja tinklo konstrukcija, pašalinant pilną jungčių sluoksnį ir partijos (angl. *batch*) normalizavimą. Įtraukus partijos normalizavimą į visus sąsukos sluoksnius, buvo pasiektas daugiau kaip 2% *mAP* pagerėjimas [24]. Klasifikatoriaus skiriamoji geba buvo padidinta nuo 224 iki 448 pikselių. Tai reiškia, kad perjungiant į aptikimą, tinklas tuo pat metu turi persijungti į mokymąsi aptikti objektą ir nustatyti naują įvesties skiriamąją gebą. Kita *YOLOv2* naujovė - padidintas kelių objektų atpažinimo tikslumas ir našumas naudojant fiksuoto regiono poziciją (angl. *Anchor Box*) [24].

Partijų normalizavimas yra vienas populiariausių normalizavimo metodų gilios mokymosi modelyje. Jis leidžia greičiau ir stabiliau mokytis giliuosius neuroninius tinklus, kadangi mokymo metu stabilizuoja įvesties sluoksnių pasiskirstymą [25]. Šio metodo tikslas - normalizuoti požymius iki nulinės vidutinės būsenos su standartiniu nuokrypiu 1.


YOLOv1 tinklas naudoja tinklelį, kuris yra atsakingas už objekto aptikimą. Todėl esant dviem ar daugiau objektų, kurių centras patenka į ta patį tinklelio langelį – jų aptikimo prognozė gali tapti klaidinga. Siekiant išspręsti šią problemą buvo pasiūlyta vienam tinklelio kvadratui atpažinti daugiau nei vieną objektą. *YOLOv2* autorius įdiegė fiksuotų regionų architektūrą, skirtą ribiniams langeliams prognozuoti. Fiksuotas regionas - tai iš anksto nustatytų langelių, geriausiai atitinkančių ieškomų objektų, sąrašas, pavaizduotas 13 paveiksle. Ribiniai langeliai buvo nuspėjami ne tik remiantis realiomis pozicijomis, bet ir iš anksto nustatytais fiksuotais regionais.



13 pav. Kiekvienam tinklelio langeliui (raudona spalva) modelis numato 5 skirtingų formų ribinius regionus (geltona spalva).

1.9.3. YOLOv3 architektūra

YOLOv2 naudojo 30 sąsukos sluoksnių *Darknet* architektūrą, t. y. daugiau nei *YOLOv1*, su 11 sluoksnių. Paprastai didesnis sluoksnių skaičius reiškia geresnį tikslumą, tačiau perduodant įvesties vaizdą į gilesnius sluoksnius kartu mažinama jo diskretizacija ir prarandamas smulkių objektų atpažinimo tikslumas. Dėl šios priežasties *YOLOv2* dažnai susidurdavo su mažų objektų aptikimo sunkumais. *ResNet* įdiegė praleidžiamųjų jungčių idėją, kuri padėjo, esant didesniai sluoksnių skaičiui, neprarasti smulkių detalių aptikimo tikslumo. Praleidžiamos jungtys pavaizduotos 14 paveiksle [26].



14 pav. *ResNet* praleidžiamų jungčių architektūra.

YOLOv3 modeliui buvo pritaikyta geresnė architektūra, kurioje požymių aptikimui panaudotas *YOLOv2*, *Darknet-53* (53 sąsukos sluoksniai) ir *ResNet* tinklo hibridas [27]. Tinklas buvo sudarytas naudojant siaurąją struktūrą (1x1 ir 3x3 sąsukos sluoksniai) kiekvieno liekamojo bloko viduje ir praleidžiamąją jungtį (11 pav.). Dėl *ResNet* tinklo sluoksnių perdengimas pagerina tinklo našumą. Be to, gilesni sluoksniai gavo daugiau informacijos tiesiogiai iš kitų sluoksnių ir todėl tai leido padidinti smulkių požymių aptikimo tikslumą. *ResNet* tinklo sluoksniai pavaizduoti 15 paveiksle.

	Type	Filters	Size	Output
	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
1x	Convolutional	32	1 × 1	
	Convolutional	64	3 × 3	
	Residual			128 × 128
	Convolutional	128	3 × 3 / 2	64 × 64
2x	Convolutional	64	1 × 1	
	Convolutional	128	3 × 3	
	Residual			64 × 64
	Convolutional	256	3 × 3 / 2	32 × 32
8x	Convolutional	128	1 × 1	
	Convolutional	256	3 × 3	
	Residual			32 × 32
	Convolutional	512	3 × 3 / 2	16 × 16
8x	Convolutional	256	1 × 1	
	Convolutional	512	3 × 3	
	Residual			16 × 16
	Convolutional	1024	3 × 3 / 2	8 × 8
4x	Convolutional	512	1 × 1	
	Convolutional	1024	3 × 3	
	Residual			8 × 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

15 pav. *Darknet-53* architektūra su 5 blokais (ribiniais langeliais), kuriuose yra 1x1 ir 3x3 sąsukos sluoksniai [28].

1.9.4. *YOLOv4* architektūra

Naujoje *YOLOv4* versijoje modifikuota *Darknet* sąsukos architektūra ir sukurta nauja požymių išskyrimo sistema, pavadinta *CSPDarknet53* [29]. Naujai sukurta architektūra sumažino skaičiavimo trikdžius ir pagreitino tinklo mokymąsi. Partijos normalizavimui (angl. *batch normalization*) panaudotas modifikuotas kryžminis mini partijos normalizavimas (angl. *Cross mini-batch normalization, CmBN*), kuris praplėtė palaikomų kompiuterinių vaizdo plokščių sąrašą. *YOLOv4* taip pat pradėjo naudoti „*DropBlock*“ atpažinimo metodą. Naudojant *DropBlock* vaizdo dalys paslepiamos nuo pirmojo sluoksnio. „*DropBlock*“ - tai metodas, leidžiantis vykdyti objekto atpažinimą iš atskirų jo

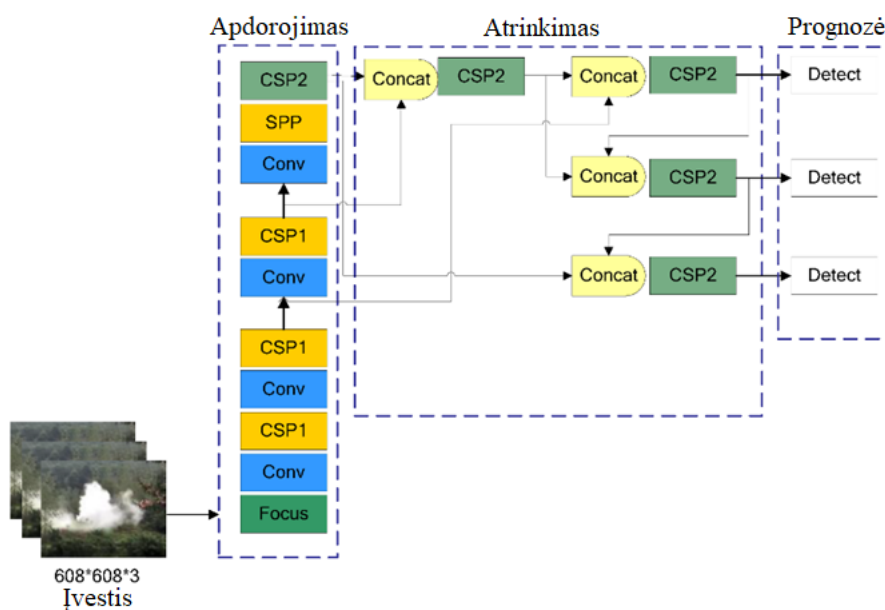
dalių. 16 paveiksle pateiktas pavyzdys, kuomet šunio galva yra nukirpta, tačiau tinklas turėtų sugebėti atpažinti šunį ne tik pagal galvą, bet ir pagal liemenį [30].



16 pav. Tinklo šuns aptikimas pagal jo liemenį

1.9.5. YOLOv5 architektūra

YOLOv5 yra naujausios kartos vaizdų apdorojimo tinklas iš YOLO serijos, kurį 2020 m. gegužės mėn. pristatė "Ultralytics". Priešingai negu ankstesnės versijos, parašytos C kalba, YOLOv5 paremta Python programavimo kalba. Tai palengvino padidinti tinklo integraciją bei diegimą į naujas sistemas. YOLOv5 tinklo struktūra pavaizduota 17 paveiksle [31].



17 pav. YOLOv5 tinklo struktūra


YOLOv5 struktūrą sudaro 4 pagrindiniai moduliai:

1. Vaizdo įvestis – šis modulis atsakingas už duomenų tobulinimą, vaizdo dydžio apdorojimą ir adaptyvaus fiksuoto regiono apskaičiavimą. Siekiant padidinti duomenų įvairovę, duomenų patobulinimui naudojamas 4 nuotraukų mozaikos derinys, o adaptyvaus fiksuoto regiono apskaičiavimas naudojamas siekiant padidinti aptikimo greitį.
2. Apdorojimo modulis – šį modulį sudaro fokusavimo ir kryžminių dalinių tinklų (angl. *Cross Stage Partial Networks, CSP*) moduliai [32]. Fokusavimo modulyje atliekama vaizdo apdorojimo suskaidymo operacija, kuri sumažina skaičiavimus ir pagerina greitį. CSP modulis naudingas gerinant tinklo mokymosi spartą ir mažinant atminties sąnaudas.
3. Atrinkimo modulis - šiame žingsnyje yra naudojamas požymių piramidės tinklas (angl. *feature pyramid network, FPN*) ir kelio paieškos tinklai (angl. *path aggregation network, PAN*). FPN ir PAN

struktūromis įgyvendinama aukšto lygio požymių ir žemo lygio požymių sujungimas ir papildymas. *FPN* požymiai yra išskiriami iš viršaus į apačią [33], o *PAN* naudoja požymių piramidę iš apačios į viršų [34]. Abu šie modeliai papildo vienas kitą, taip pagerindami modelio požymių išskyrimo galimybes.

4. Prognozavimo modulis – šis modulis apima ribinių nuostolių funkciją ir maksimumų atrinkimą. *YOLOv5* kaip nuostolių funkciją naudoja bendrinę sankirtos ir sąjungos metodą (angl. *Generalized Intersection Over Union, GIoU*), kuri atsakinga už nepersidengiančių ribinių langų problemą.

YOLOv5 turi penkias tinklo versijas: *YOLOv5n*, *YOLOv5s*, *YOLOv5m*, *YOLOv5l* ir *YOLOv5x*. Šie modeliai tarpusavyje skiriasi tinklo pločio ir gylio mastelio koeficientais, pavaizduotais 18 paveiksle. Iš jų *YOLOv5x* tinklas yra didžiausias, turintis didžiausią parametrų paketą, todėl atitinkamai ir ilgiausią tinklo apmokymo trukmę. Mažiausias tinklas yra *YOLOv5n*.



18 pav. Skirtingų *YOLOv5* versijų mastelių iliustracija

4 lentelėje pateikiamas *YOLOv5* modelių parametrų kiekis, sluoksnių skaičius ir *FLOPs* dydis. *FLOPs* – tai slenkančio taško operacijos, kurias sistema gali atlikti per sekundę (angl. *floating point operations per second, FLOPS*).

4 lentelė. *YOLOv5* modelių specifikacijos

Modelis	Parametrų skaičius	Sluoksnių skaičius	<i>FLOPs</i> @640
<i>YOLOv5x</i>	86231272	567	205,7
<i>YOLOv5l</i>	46147064	468	109,1
<i>YOLOv5m</i>	20879400	369	49,0
<i>YOLOv5s</i>	7027720	270	16,5
<i>YOLOv5n</i>	1767976	270	4,5

Šie modeliai yra išbandomi eksperimentiškai sprendžiant gaisro lokalizavimo uždavinį 3 skyriuje.

2. Metodologija

Šiame baigiamajame darbe dūmų aptikimui iširti buvo pasirinktas naudoti *YOLOv5* metodas, aprašytas 1.9.5 skyriuje. Šiame skyriuje aprašoma kokia buvo naudota techninė ir programinė įranga. Taip pat aprašoma kaip buvo surinkta duomenų bazė, bei koku būdu nustatytas pasirinktų gilaus apmokymo tinklų rezultatų tikslumo įvertinimas.

2.1. VTOL orlaivio platforma

Duomenų rinkimui pasirinktas *VTOL* tipo orlaivis. Konkretus drono modelis pavaizduotas 19 pav.



19 pav. a) *Flying dragon 2160* modelis b) *Pixhawk 4* su dviem GPS moduliais

Nagrinėjamai sistemai pasirinktas *flying dragon 2160* modelis. Šis orlaivis su 1 kg kroviniu geba atlikti 10 km misijas esant 8 - 9 m/s vėjui.

5 lentelė. VTOL specifikacijos

Tipas	<i>Flying Dragon 2160</i>
Orlaivio rūšis	<i>VTOL</i>
Krovinio svoris	0,5 – 1 kg
Dydis	Ilgis - 120 cm. Plotis - 216 cm Aukštis - 40 cm
Skrydžio laikas	80 - 120 min
Vidutinis greitis	15 - 22 m/s
Akumulatorius	6S 22.2V 10000mAh ~ 22000mAh LiPo
Kaina	2500 eur

2.1.1. VTOL orlaivio valdymo sistema

Pagrindinis *VTOL* orlaivio valdiklis pasirinktas *Pixhawk 4*. Tai vienas populiariausių įvairiems orlaiviams skirtų kompiuterių, paremtas atvirojo kodo (angl. *open source*) programine įranga, vadinamą *ArduPilot*. *ArduPilot* programinė įranga leidžia iš anksto suplanuoti ir nustatyti skrydžio maršrutus, geba vykdyti autonominius skrydžius. *Pixhawk 4* turi keletą integruotų apsaugos sistemų. Pagrindiniai jutikliai, atsakingi už skrydžio kontrolę ir stabilizavimą yra dubliuoti, t.y. sugedus vienam akselerometrui ar barometrui, skaičiavimus perima kitas, identiškas jam jutiklis. Taip pat turi palaikymą dviems GPS moduliams ir dviems magnetometrams. Skrydžio metu, kompiuteris nuolat lygina vertes tarp identiškų jutiklių ir tikrina, ar kuris nors iš jų nėra sugedęs ar kitaip pažeistas.



20 pav. *Mission Planner* programinė įranga

Bepiločio orlaivio skrydžio linijos atvaizduotos naudojant *Mission Planner* programinę įrangą, matoma 20 paveiksle. Orlaivio tyrimų skrydžių aukštis buvo 120 m. Atlikta daugiau nei 20 skrydžio valandų.

2.1.2. Telemetrijos perdavimas

Siekiant užtikrinti stabilų ryšį tarp orlaivio ir žemės stotelės (angl. *ground station*), buvo panaudotas *MAVLink* komunikacijos protokolas. Šis protokolas leidžia *RaspberryPI 3b+* kompiuteriui siųsti ir priimti duomenis ateinančius iš *Pixhawk 4* kompiuterio. Duomenys siunčiami per 4G mobiliojo interneto ryšį. Sistemos dalys pavaizduotos 21 paveiksle.



21 pav. Ryšio perdavimo sistema

2.2. Programinė įranga

YOLOv5 įgyvendinimas remiasi *Pytorch* atvirojo kodo mašininio mokymosi (angl. *machine learning*) sistema, pagrįsta *Python* programavimo kalba ir *torch* biblioteka. Tai viena iš populiariausių gilaus mokymosi platformų.

YOLOv5 veikimą galima įsivaizduoti kaip pažangią autonominę filtravimo sistemą, kadangi ši programinė įranga, tam, kad priimtų sprendimą, remiasi į ją sukelta, bei specialiai apmokyta duomenų baze. Pavyzdžiui, įkėlus į programą visiškai nematytą iki tol jai vaizdą, ji, palyginus visus duomenis su jau apmokyta duomenų baze - nuspręs vaizdo turinį. Dėl šių priežasčių *YOLOv5* dūmų aptikimo tikslumas bei greitis priklauso nuo duomenų bazės dydžio bei kokybės.

Rezultatų analizavimams naudota *Wandb* programinė įranga, skirta vizualizuoti tiriamų modelių nuostolius, vertinimo rodiklius, modelių topologiją bei gradientus.


Vaizdų apdorojimui orlaivyje pasirinktas *Nvidia Jetson Nano* kompiuteris. *Jetson Nano* turi keturių branduolių 64 bitų ARM procesorių ir 128 branduolių *NVIDIA Maxwell GPU*. Jis gali užtikrinti 472 *GFLOPs* skaičiavimo galią ir vykdyti pilną giliųjų neuroninių tinklų mokymą. Kompiuteris palaiko *Pytorch* sąsają ir geba dirbti su *YOLOv5* modeliu. Bandymams naudotų kompiuterių specifikacijos nurodytos 6 lentelėje.

6 lentelė. Kompiuterių parametrai

Komponentai	Personalinis kompiuteris	<i>Jetson Nano</i>
Procesorius	AMD Ryzen 1700X	64 bit ARM
Operacinė sistema	windows 10	Ubuntu
Darbinė atmintis	32 gb	4 gb
Vaizdo plokštė	NVIDIA GeForce GTX 1070 8 GB	NVIDIA Maxwell
Programinė įranga	Python 3.7.6 + Pytorch1.5.1 + CUDA 10.2 + cuDNN 7.6.5	Jetpack 4.6 + Python 3 + Numpy 1.19.4

2.3. Duomenų bazė

Tyrimams atlikti buvo sukurtos keturios skirtingos duomenų bazės, įvardijamos kaip *R*, *R+F*, *R+F+W* ir *R+F+W+Y*. Pirmąją duomenų bazę (pav. *R*) iš viso sudaro 212 nuotraukų. Nuotraukos gautos iš realaus skrydžio su dronu, dūmus inscenizuojant su dūminėmis šaškėmis. Antroji duomenų bazė (pav. *R+F*) buvo papildyta sintetinėmis nuotraukomis. Iš viso pridėta 291 nuotrauka. Trečioji duomenų bazė (pav. *R+F+W*) papildyta viešai prieinamu duomenų rinkiniu, iš stacionarių miško stebėjimo bokštų. Pridėta 737 nuotrauka. Ketvirta duomenų bazė (pav. *R+F+W+Y*) papildyta 100 nuotraukų, atrinktų iš skirtingų interneto šaltinių. Skirtingų duomenų rinkinių sandara pavaizduota 22 paveiksle.



22 pav. Duomenų bazių sandara

Pradiniam apmokymui ir testavimui buvo nufilmuota vaizdo medžiaga iš drono skrydžio. Duomenų bazę iš viso sudarė 212 nuotraukos. Nuotraukų rezoliucija - 2048x1080 pikseliai. Filmavimo metu kamera buvo statmenai nukreipta į žemę. Drono aukštis – 120 m. Gautos nuotraukos pavaizduotos 23 paveiksle.



23 pav. Miško dūmų pavyzdžiai

Duomenų bazės nuotraukos sumažintos iki 640x352 pikselių rezoliucijos, siekiant pagreitinti neuroninio tinklo apmokymo greitaveiką. Duomenų bazė paruošta naudojant *Roboflow* programinę įrangą. *Roboflow* - tai kompiuterinės regos kūrėjų programinė įranga, skirta patogesniai ir efektyvesniai duomenų rinkimui bei išankstiniam jų apdorojimui. *Roboflow* priima įvairius anotacijų formatus. Atliekant pirminį duomenų apdorojimą, atliekami tokie veiksmai, kaip vaizdų orientavimas, dydžio keitimas, kontrastavimas ir duomenų papildymas. Viešos duomenų bazės turi anotacijas. Siekiant apmokyti *YOLOv5* neuroninį tinklą su asmenine duomenų baze, buvo pasirinktas *YOLOv5 PyTorch* formatas. *Roboflow* įrankiu pažymėta nuotrauka pavaizduota 24 pav.



24 pav. *Roboflow* įrankiu sužymėta nuotrauka. Žalia spalva pažymėti dūmai

Duomenų bazė yra paruošiama *Pytorch* paketui. Pagal nutylėjimą, *Roboflow* sukuria tris direktorijas:

- Apmokymo rinkinys (angl. *train set*) - tai didžiausia duomenų dalis, skirta modeliui mokytis. Pagal nutylėjimą mokymo rinkiniui skiriama 70 % visų nuotraukų.
- Tikrinimo rinkinys (angl. *validation set*) - tai atskira duomenų dalis, kuri naudojama mokymo metu, siekiant įvertinti modelio vaizdų atpažinimo tikslumą. Tikrinimo duomenys nėra naudojami mokymo metu. Pagal nutylėjimą tikrinimo rinkiniui skiriama 20 % visų duomenų.
- Testavimo rinkinys (angl. *test set*) – kadangi tikrinimo rinkinys dažnai naudojamas kuriant modelį, svarbu turėti visiškai atskirą ir modeliui nematytą duomenų bazės dalį. Projekto pabaigoje atliekami testavimai ir palyginami rezultatai, kurie padeda suprasti kaip gerai veikia apmokytas modelis. Pagal nutylėjimą testavimo rinkiniui skiriama 10 % visų nuotraukų.

YOLOv5 dūmų radimo metodo *R* rinkinio apmokymui naudojama 221 nuotrauka. Modelio apmokymui naudojamos 155 nuotraukos. Tikrinimui – 41 nuotrauka. Modelio testavimui naudojamos 25 nuotraukos.

2.4. Duomenų bazės praplėtimas sintetiniais duomenimis


Sintetiniai duomenys - tai bet kokia dirbtinai sukurta informacija, kuri neatspindi realaus pasaulio įvykių ar objektų. Algoritmai sukuria sintetinius duomenis, kurie naudojami modelių duomenų

rinkiniuose testavimo arba mokymo tikslais. Sintetiniai duomenys gali imituoti operacinius arba gamybinius duomenis ir padėti apmokyti mašininio mokymosi modelius.

Duomenų bazės augmentacija papildomais sintetiniais duomenimis dažnai naudojama siekiant pagerinti neuroninių tinklų tikslumą. Q. Zhang ir J. Wang aprašytame tyrime į miško foną buvo įterpti imitaciniai dūmai, kad būtų išspręstas mokymo duomenų trūkumo klausimas. Tinklas apmokytas su vienodu nuotraukų skaičiumi tiek sintetinių vaizdų, tiek tikrų vaizdų. Rezultatai parodė, kad imitacinių dūmų duomenų bazė pasiekė vidutiniškai 5 procentų didesnę atpažinimo tikslumą [35].


Kadangi turimų miško gaisrų dūmų vaizdų, iš kurių galima apmokyti tinklus, kiekis ir įvairovė yra riboti, nuspręsta duomenų bazę praplėsti sintetiniais duomenimis.

Sintetinių nuotraukų generavimui panaudota *Unity3D* programinė įranga. Siekiant, kad miškas ir aplinka būtų panašios į turimą, realiai filmuotą iš drono medžiagą, buvo panaudotas miško aplinką bei reljefą imituojančių tekstūrų paketas. Miško aplinkos sukūrimui panaudotas procedūrinis generavimas (angl. *procedural generation*). Procedūrinis generavimas - tai algoritminis duomenų kūrimo būdas, paprastai derinant duomenis įvestus ranka ir algoritmus su kompiuterio sukurtu atsitiktinumu ir apdorojimo galia. Dūmai sugeneruoti įterpiant daleles (angl. *particles*) į gautą trimatį modelį. Tikroviškų tekstūrų sukūrimui taip pat naudojami fotogramterijos duomenys. Fotogrametrija – tai 3D modelių kūrimo procesas iš dvimačių vaizdų. Trimatį vaizdą galima atkurti suderinus vaizdų požymius ir įvertinus kiekvieno vaizdo kameros erdvinę padėtį. Tuomet gretimų vaizdų bendri taškai nustatomi 3D erdvėje ir taip suformuojamas 3D taškų debesis. Tada debesį galima paversti tinklu, sujungiant taškus poligonais, kurių tekstūra sudaryta iš matomos šviesos duomenų, surinktų iš 2D vaizdų. Rezultatas – tekstūruotas aplinkos arba objekto 3D modelis. Pavyzdys pateiktas 25 pav.



25 pav. *Unity3D* sugeneruota miško aplinka

Kuriant sintetinę duomenų bazę atsižvelgta, kad visas modelių išdėliojimas būtų atsitiktinis, imituojančio drono skrydžio aukštis būtų 120 m. Skrydžio kryptis imituojama kaskart atsitiktinai, siekiant išgauti skirtingas trajektorijas. Parinktas skirtingo kampo apšvietimas. Imituojamas skirtingas dienos metas. Imitacinių dūmų dalelių animacija periodiškai kinta laike, kinta dalelių dydis, greitis ir gyvavimo trukmė. Realaus ir sintetinio duomenų rinkinio pavyzdžiai pateikiami 26 pav.




a)

b)


26 pav. Duomenų bazės augmentacijos pavyzdys: a) sintetinė nuotrauka, b) nuotrauka daryta su dronu

Siekiant sužymėti ribinius langelius, rezultatai turi būti dvimatėje aplinkoje. Vykdamant nuotraukų žymėjimą trimatės dalelių ribos (pozicija ir dydis) yra konvertuojamos į dvimatį vaizdą (daroma projekcija į kamerą). Pagal koordinatas yra žymimi ribiniai langeliai. Dalelės išfiltruojamos, atsižvelgiant į jų matomumą ekrane, siekiant išvengti blogų anotacijų. Dalelės turi pakankamai gerai būti matomos, jų anotacijos negali būti už ekrano ribų. Kadangi dalelė turi labai daug tuščios erdvės (angl. *negative space*), siekiama, kad ribinis langelis pažymėtų visą. Imitacinių dūmų dalelių pavyzdys matomas 27 paveikslėlyje.




27 pav. Imitacinių dūmų dalelių pavyzdys

Kuriant sintetinę medžiagą siekiama atkurti kuo panašesnę drono skrydį. Gaunamos nuotraukos yra 640x352 dydžio. Raudona spalva žymima atskirų dalelių ribiniai langai, žalia žymimas suminis ribinis langas pavaizduotas 28 pav.



28 pav. Sintetinės duomenų bazės ribinio lango žymėjimas

Siekiant palyginti skirtingas duomenų bazes, pasitelkta atskirų duomenų bazių suminė anotacijų vizualizacija (angl. *heatmap*) pavaizduota 29 pav.



29 pav. a) R b) $R+F$, c) $R+F+W$, d) $R+F+W+Y$

Paveiksle nr. 29. dalyje a) matoma anotacijų vizualizacija atskleidžia būsimas modelio spragas. Apmokomas modelis su R duomenų baze, lokalizuos objektų paiešką, t.y. ieškos dūmų tik tose vietose, kurios buvo nurodytos duomenų bazėje. Vadinasi, yra didelė tikimybė, kad su R duomenų baze apmokytas modelis geriau atpažins dūmus centre, pažymėta žalia spalva ir prasčiau, jeigu dūmai papuls į baltą foną. 29 pav. b) dalyje matomas $R+F$ duomenų rinkinio suminis anotacijų plotas yra daug platesnis. Tai lėmė specialiai parengtos sintetinės duomenų bazės ribinių regionų išdėstymas, siekiant išgauti kuo įvairesnį dūmų pasiskirstymą nuotraukose. Pridėjus duomenis, gautus iš miško stacionarių bokštų, matomų 29 pav. c) dalyje, pastebimas dūmų ribinių laukų susiaurėjimas, kadangi šio duomenų rinkinio nuotraukose dūmai buvo pozicionuoti nuotraukų centre.

2.5. Metodo tikslumo įvertinimas

Tiriamąjį metodo patikimumas buvo vertinamas naudojant šiuos modelio tikslumo įvertinimo rodiklius: tikslumas (angl. *precision*), atšaukimas (angl. *recall*), vidutinis aptikimo tikslumas (angl. *mean average precision*), $F1$ įvertis.

2.5.1. Tikslumo ir atšaukimo rodikliai

Tikslumo ir atšaukimo rodikliai yra du pagrindiniai objektų aptikimo modelių vertinimo kriterijai. Tikslumas apibrėžiamas kaip teisingai aptiktų objektų dalis visose aptiktuose objektuose, o atšaukimas - kaip teisingai aptiktų objektų dalis visuose aptiktuose teigiamuose pavyzdžiuose. Šių dviejų rodiklių lygtys:

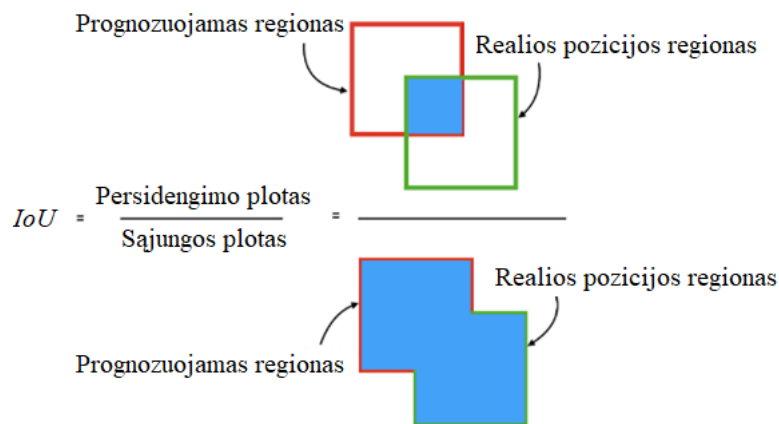
$$P = \frac{TP}{TP+FP}; \quad (1)$$

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

čia TP (angl. *true positive*) reiškia teisingai aptiktų dūmų skaičių, FP (angl. *false positive*) - papildomų dūmų, kurių nebuvo nuotraukoje, skaičių (klaidingi aptikimai), o FN (angl. *false negative*) - neaptiktų dūmų skaičių (praleidimo klaida).

2.5.2. Sankirtos ir sąjungos parametras

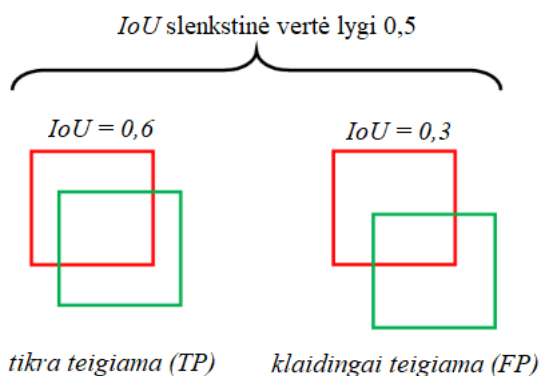
Sankirtos ir sąjungos parametras (angl. *Intersection over Union, IoU*) parodo realios (angl. *ground truth*) pozicijos bei rastos pozicijos sankirtos ir sąjungos santykį. IoU formulė pavaizduota 30 pav.



30 pav. IoU parametro skaičiavimas

Objektų aptikimo užduočių tikslumas (angl. *Precision*) ir atšaukimas (angl. *Recall*) apskaičiuojami naudojant IoU reikšmę su pasirinkta IoU slenkstine verte.

Pavyzdžiui, jei IoU slenkščio reikšmė pasirinkta 0,5, o prognozės IoU reikšmė yra 0,7, tuomet prognozė klasifikuojama kaip tikra teigiama (*TP*). Kita vertus, jei IoU reikšmė yra 0,3 - klasifikuojama kaip klaidingai teigiama (*FP*). Pavyzdys matomas 31 pav.



31 pav. Aptiktų objektų klasifikavimas, kuomet IoU slenkstinė vertė lygi 0,5

2.5.3. Bendrinis sankirtos ir sąjungos parametras

Bendrinis sankirtos ir sąjungos parametras (angl. *Generalized-IoU*, $GIoU$), yra apskaičiuojamas pagal 3 formulę .

$$GIoU(A, B) = IoU(A, B) - \frac{|C| - |A \cup B|}{|C|}; \quad (3)$$

$$Loss_{GIoU} = 1 - GIoU(A, B) = 1 - IoU(A, B) + \frac{|C| - |A \cup B|}{|C|}; \quad (4)$$

Čia C yra mažiausias langelis, kuriame yra A ir B . $GIoU$ gali būti laikoma apatine IoU riba, kuri yra mažesnė arba lygi IoU . $GIoU$ atkreipia dėmesį ne tik į persidengiančią sritį, bet ir į kitas nepersidengiančias sritis, kurios gali geriau atspindėti dviejų sričių persidengimo laipsnį. Kai du langeliai neturi persidengiančio ploto, $GIoU$ reikšmė kinta intervale tarp -1 ir 0. $GIoU$ yra gradientas, todėl galima atlikti optimizavimą. Optimizavimo kryptis palaipsniui didina atstumą tarp dviejų langelių.

2.5.4. Atstumo sankirtos ir sąjungos parametras

Atstumo sankirtos ir sąjungos parametras (angl. *Distance-IoU*, *DIoU*), yra apskaičiuojamas pagal 5 formulę.

$$DIoU = IoU - \frac{p^2(b, b^{gt})}{c^2}; \quad (5)$$

$$Loss_{DIoU} = 1 - DIoU = 1 - IoU + \frac{p^2(b, b^{gt})}{c^2}; \quad (6)$$

Čia b ir b^{gt} - tai atitinkamai prognozių langelio (angl. *prediction box*) b ir realios pozicijos (angl. *ground truth*) langelio b^{gt} centriniai taškai. c - minimalaus ribinio langelio įstrižainės ilgio kvadratas. p - apskaičiuotas *Euklido* atstumas tarp dviejų centrinių taškų. *DIoU* gali tiesiogiai sumažinti atstumą tarp dviejų tikslinių langelių, todėl konverguoja daug greičiau nei *GIoU*. Jei yra du langeliai horizontalia ir vertikalia kryptimis, *DIoU* nuostoliai gali labai pagreitinti regresiją, o *GIoU* nuostoliai beveik prilygsta *IoU* nuostoliams.

2.5.4.1. Pilnas sankirtos ir sąjungos parametras

Pilnas sankirtos ir sąjungos parametras (angl. *Complete-IoU*, *CIoU*), yra apskaičiuojamas pagal 7 formulę.

$$IoU = IoU - \left(\frac{p^2(b, b^{gt})}{c^2} + \alpha v \right); \quad (7)$$

$$Loss_{CIoU} = 1 - IoU + \frac{p^2(b, b^{gt})}{c^2} + \alpha v; \quad (8)$$

Čia α yra svorio parametras, o v naudojamas kraštinių santykiui matuoti.


$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{\pi^{gt}} - \arctan \frac{w}{h} \right)^2; \quad (9)$$

$$\alpha = \frac{v}{(1 - IoU) + v}; \quad (10)$$

Iš α apibrėžimo matoma, kad nuostolių funkcija yra labiau linkusi optimizuoti didėjančių persidengiančių sričių kryptimi, ypač kai *IoU* yra lygus nuliui.

2.5.5. Vidutinis tikslumo vidurkis ir *FI* kreivė

Vidutinis tikslumo vidurkis apima tikslumo ir atšaukimo rodiklius. Tai yra visų klasių vidutinio tikslumo (*AP*) vidutinė reikšmė. Šiuo atveju *mAP* yra lygus *AP*, nes yra tik vienas objektas (dūmai). *AP* galima pavaizduoti kaip plotą po tikslumo ir atšaukimo kreivė (32 pav.). *AP* išraiška pateikta 11 lygtyje.



32 pav. Geltona spalva pažymėtas apskaičiuojamas mAP plotas

$$AP = \int_0^1 P(R) dR; \quad (11)$$

FI rodiklis yra tikslumo ir atšaukimo matas. Kitaip apibūdinamas kaip šių dviejų rodiklių harmoninis vidurkis. Harmoninis vidurkis padeda įvertinti pusiausvyrą tarp tikslumo ir atšaukimo. FI rodiklis yra tinkamesnis vertinimas (pvz., tikslumui ir atšaukimui) nei tradicinis aritmetinis vidurkis. FI rezultatui apskaičiuoti naudojama tokia formulė:

$$2 * \frac{\text{tikslumas} * \text{atšaukimas}}{\text{tikslumas} + \text{atšaukimas}}; \quad (12)$$

FI rodiklis geba subalansuotai įvertinti tikslumą ir atšaukimą, t. y. abiejų rodiklių reikšmės turi būti didesnės, kad FI balas didėtų. Pavyzdžiui, jei tikslumas būtų 0.01, o atšaukimas - 1.0, gaunami tokie rezultatai :

- aritmetinis vidurkis: $(0,01+1,0)/2 = 0,505$;
- FI įvertis: $2*(0,01*1,0)/(0,01+1,0) = \sim 0,02$.

Iš rezultatų matoma, kad FI rodiklis yra jautresnis, kuomet vieno iš dviejų įėjimų vertė yra maža (šiuo atveju 0,01). Taigi, dėl labai mažo tikslumo arba atšaukimo - bendras rezultatas bus mažesnis. Tai padeda subalansuoti abu rodiklius.

3. Eksperimentiniai tyrimai

YOLOv5 modelis realizuojamas *Pytorch* pakete. Metodo apmokymas vykdomas naudojant *Python* programavimo kalbą, modelio tikslumo testavimas vykdomas *C#* programavimo kalboje. Atlikti šie *YOLOv5* metodo tyrimai:

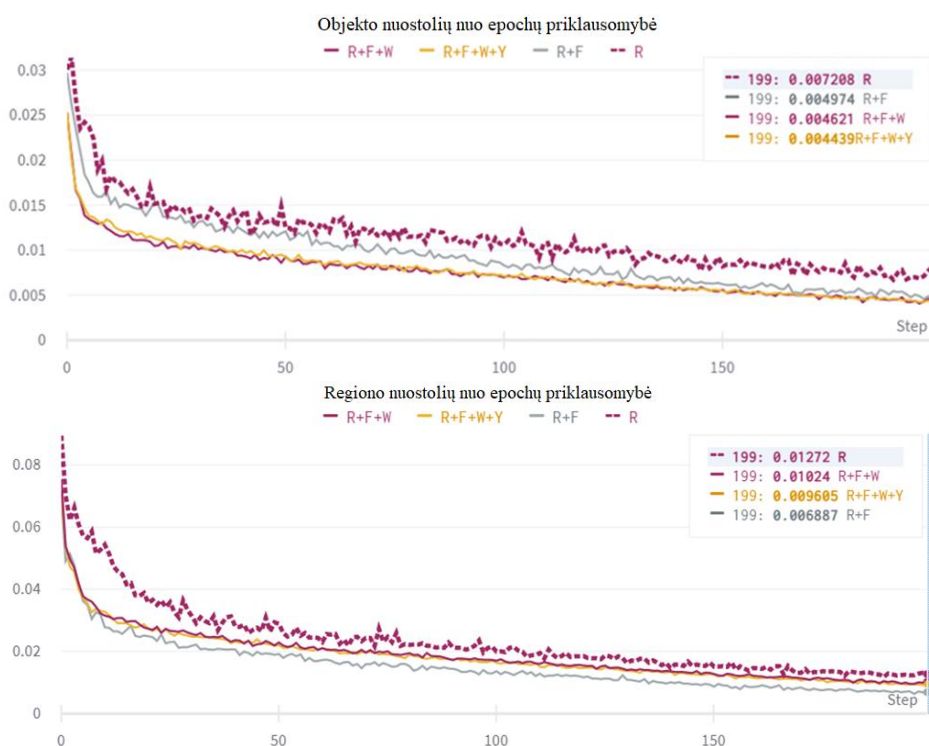
- *YOLOv5x* modelio bei skirtingų duomenų bazių įtaka metodo tikslumui
- *YOLOv5l* modelio bei skirtingų duomenų bazių įtaka metodo tikslumui
- *YOLOv5m* modelio bei skirtingų duomenų bazių įtaka metodo tikslumui
- *YOLOv5s* modelio bei skirtingų duomenų bazių įtaka metodo tikslumui
- *YOLOv5n* modelio bei skirtingų duomenų bazių įtaka metodo tikslumui
- Skirtingų *YOLOv5* tinklo architektūrų su geriausiomis duomenų bazėmis palyginimas
- Realios ir sintetinės duomenų bazės palyginimas
- Skirtingų persidengimo metodų palyginimas
- Įvesties duomenų testavimo laiko augmentacija

Visi bandymų rezultatai buvo gauti naudojant 20 skirtingų nuotraukų pagal 2.5 skyriuje aprašytus vertinimo metodus. Objektas pažymimas kaip rastas jei jo *IoU* vertė yra daugiau negu 0,5 su tikrąją pozicija.

3.1.1 *YOLOv5x* modelio įtaka metodo tikslumui

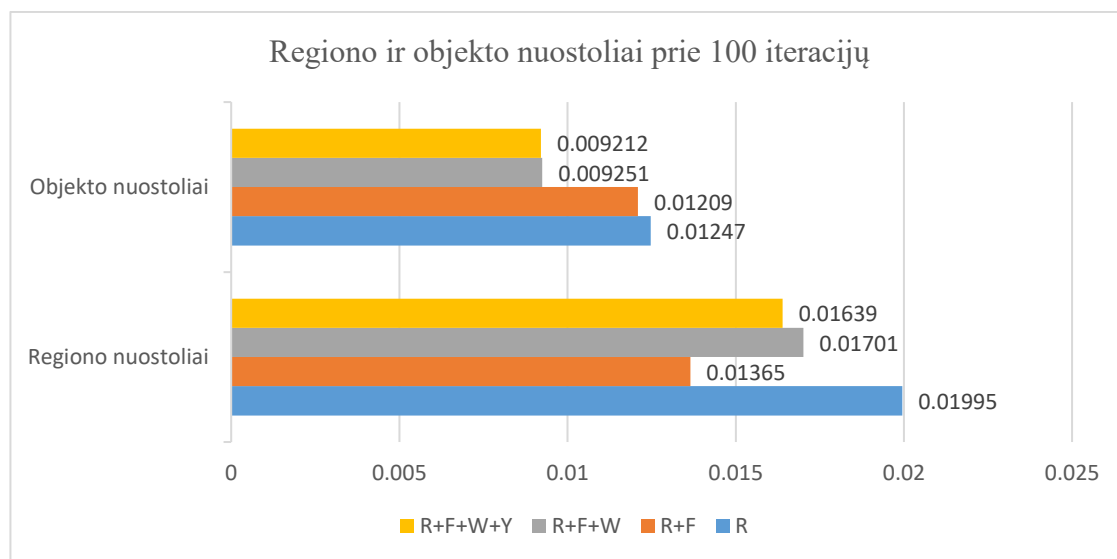
Atliktas eksperimentas, kuriuo vertinamas *YOLOv5x* modelio tikslumas su skirtingais duomenų rinkiniais, aprašytais 2.3 skyriuje.

Pasirinkus modelį ir atlikus 200 iteracijų - tinko mokymosi proceso eiga įvertinama panaudojus *WandB* programine įranga. *YOLOv5x* modelio mokymo proceso rezultatai pavaizduoti 33 pav.



33 pav. *YOLOv5x* tinklo regiono ir objekto nuostoliai

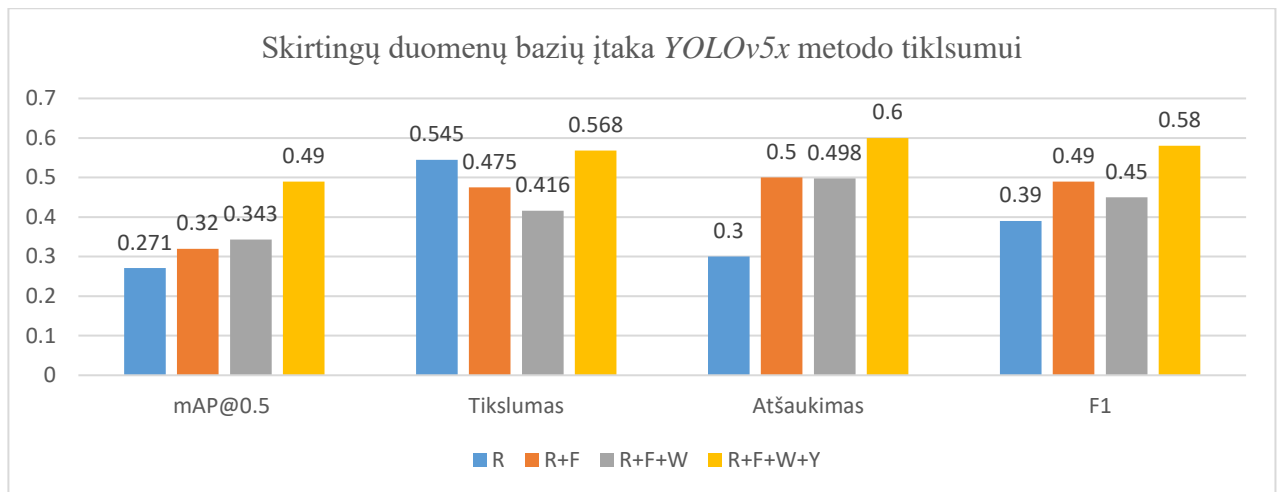
33 paveiksle pavaizduotos dviejų skirtingų įverčių diagramos: regiono nuostoliai ir objekto nuostoliai. Regiono nuostoliai parodo, kaip gerai algoritmas gali nustatyti objekto centrą ir kaip tiksliai jis yra pažymimas. Objekto nuostoliai parodo kokia yra tikimybė, kad objektas egzistuoja numanomoje srityje. Objekto atpažinimo tikslumas didėja regiono ir objekto nuostoliams artėjant nulinio link. 33 paveiksle matomi parametrai palaipsniui mažėja, didėjant iteracijų skaičiui. R duomenų rinkinio kreivės iki 50 iteracijų turi didžiausius regiono ir objekto nuostolių įverčius. Tokius prastus rezultatus lėmė pirmojo rinkinio mažiausias nuotraukų skaičius iš visų likusių duomenų bazių. Palyginus visus duomenų rinkinius galima matyti, jog regiono ir objektų nuostolių kreivės pradeda nusistovėti ties 100 iteracijų, todėl tolesniems bandymams buvo pasirinktas šis modelis. 34 paveiksle pateikiami regiono ir objekto nuostoliai prie 100 iteracijų.



34 pav. Regiono ir objekto nuostoliai prie 100 iteracijų

$YOLOv5x$ modeliui pasiekus 100 iteracijų matoma, kad didžiausią teisingo regiono nustatymo tikslumą, t.y 0,01365, pasiekė $R+F$ duomenų paketas. Šio duomenų paketo realios pozicijos regionai vidutiniškai sudarė daugiau negu 50 procentų visos nuotraukos, todėl tai buvo lengviausia duomenų bazė teisingam regionui nustatymui. Geriausiai objekto nuostolius parodė $R+F+W+Y$ duomenų paketas dėl savo didžiausios duomenų bazės. Mažiausiu regiono ir objekto tikslumu pasižymėjo mažiausias duomenų bazės rinkinys, t.y R duomenų paketas.


Tyrimams buvo atrinkta 20 nematytų nuotraukų. 35 Paveiksle pateikiami pagrindiniai modelio tikslumo parametrai.



35 pav. YOLOv5x tikslumo parametrai


Atlikus bandymą su nematytomis nuotraukomis *Yolo5x* tinklas geriausius rezultatus pasiekė su *R+F+W+Y* duomenų baze: *mAP@0,5* buvo lygus 0,49, o *F1* įvertis yra lygus 0,58. Tinklas su didžiausia duomenų baze buvo 1.801 karto tikslesnis nei su mažiausia duomenų baze. Mažiausiais tinklo tikslumas buvo su nepraplėsta *R* duomenų baze: *mAP@0,5* buvo lygus 0,271. Kaip matoma grafike, skirtingi metodo tikslumo nustatymai, skirtingai parodė to pačio modelio tikslumą. Kaip pavyzdys, pateikiami modelio, apmokyto su *R+F* duomenų baze, tikslumo įverčiai: *mAP@0,5* yra lygus 0,32. *R+F* duomenų rinkinys yra trečioje vietoje pagal tikslumą. *F1* įvertis yra lygus 0,49 būtų antroje vietoje ir pagal apmokymo laiką būtų. Mažiausios apimties *R* duomenų bazė pasiekė didžiausią tikslumą, t.y 0,568. Taip įvyko dėl to, kadangi nors tyrimas atliktas su tinklui nematytomis nuotraukomis, testavimo nuotraukos buvo gautos iš to paties miško, vadinasi, jos pasižymėjo itin artimais požymiais apmokyto tinklo duomenų rinkiniui.

36 pav. yra pateikiamas *Yolo5x* tinklo apmokymo laiko palyginimas su skirtingais duomenų rinkiniais.



36 pav. YOLOv5x apmokymo laiko grafikas

Apmokymo laikas su didžiausia $R+F+W+Y$ duomenų baze buvo lygus 28 valandoms ir 55 minutėms, ir buvo 6 kartus ilgesnis nei su mažiausia duomenų baze, o tikslumas padidėjo 1,801 karto. Didžiausias skirtumas yra matomas tarp $R+F$ ir $R+F+W$ duomenų bazių, kuri buvo apmokyta 2,335 karto lėčiau. Pagrindinis skirtumas yra dėl duomenų bazių dydžio, kuris skiriasi 2,44 karto, tačiau tikslumas $mAP@0,5$ padidėjo tik 1,07 karto, o naudojant $F1$ įvertį, sumažėjo 1,09 karto, todėl ši duomenų bazė $YOLOv5x$ modeliui padarė mažiausią įtaką metodo tikslumui. 37 paveiksle pateikiami metodo klaidingų teigiamų rezultatų skaičiai atliekant bandymus.

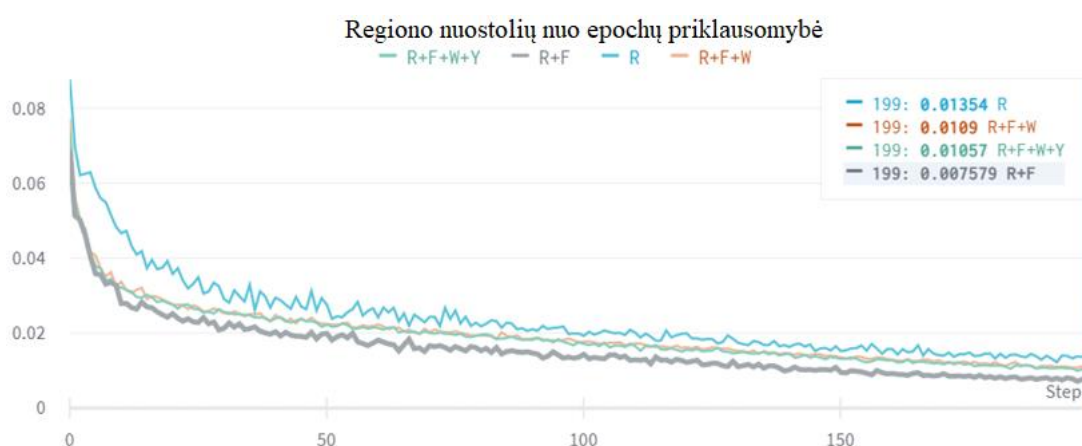


37 pav. $YOLOv5x$ klaidingų neigiamų atpažinimų rezultatai

Kaip matoma grafike, mažiausias klaidingų neigiamų atpažinimų skaičius buvo didžiausios duomenų bazės ir buvo lygus 10, o didžiausias skaičius buvo nepraplėsto ir praplėstos sintetiniai duomenimis duomenų bazės ir buvo lygus 13.

3.1.2 $YOLOv5l$ modelio įtaka metodo tikslumui

Atliktas eksperimentas, kuriuo vertinamas $YOLOv5l$ modelio tikslumas su skirtingais duomenų rinkiniais.






38 pav. YOLOv5l tinklo regiono ir objekto nuostoliai

Atlikus 200 iteracijų apmokymą su keturiais skirtingais duomenų rinkiniais gauti apmokymo rezultatų grafikai pavaizduoti 38 pav. Didžiausia duomenų bazė $R+F+W+Y$ po 200 iteracijų pasiekė geriausią regiono aptikimo tikslumą – 0,01057. Mažiausiu objekto nuostolių įverčiu pasižymėjo $R+F+W$ duomenų rinkinys pasiekęs 0,004911. Prasčiausius dūmų aptikimo rezultatus parodė mažiausias duomenų rinkinys R – atitinkamai pasiekęs 0,01354 regiono nuostolius ir 0,007821 objekto nuostolius.


Tyrimams buvo atrinkta 20 nematytų nuotraukų. 39 paveiksle pateikiami pagrindiniai modelio tikslumo parametrai.



39 pav. YOLOv5l tinklo tikslumo parametrai


Atlikus bandymus su nematytomis nuotraukomis, YOLOv5l tinklas geriausius mAP rezultatus pasiekė su $R+F+W$ duomenų rinkiniu, kuris buvo lygus 0,472. Tinklas su didžiausia duomenų baze buvo 1,28 karto tikslesnis nei su mažiausia duomenų baze. Mažiausias pasiektas tikslumas buvo su pirmuoju duomenų rinkiniu R , kurio mAP lygus 0,366. Geriausią $F1$ rezultatą pasiekė $R+F$ duomenų rinkinys su 0,54 rezultatu.

40 pav. yra pateikiamas YOLOv5l tinklo apmokymo laiko palyginimas su skirtingais duomenų rinkiniais.



40 pav. YOLOv5l tinklo skirtingų duomenų rinkinių apmokymo trukmė

Yolov5l apmokymas su didžiausia $R+F+W+Y$ duomenų baze užtruko 18 valandų ir 44 minutes, ir buvo 6 kartus ilgesnis nei su mažiausia duomenų baze, o tikslumas padidėjo 1.28 karto. Didžiausią mAP tikslumą pasiekusio $R+F+W$ duomenų rinkinio apmokymas truko 1.29 karto greičiau, negu $R+F+W+Y$ rinkinio, pasiekusiu mažesnę mAP įvertį. 41 paveiksle pateikiami metodo klaidingų neigiamų atpažinimų rezultatų skaičiai atliekant bandymus.

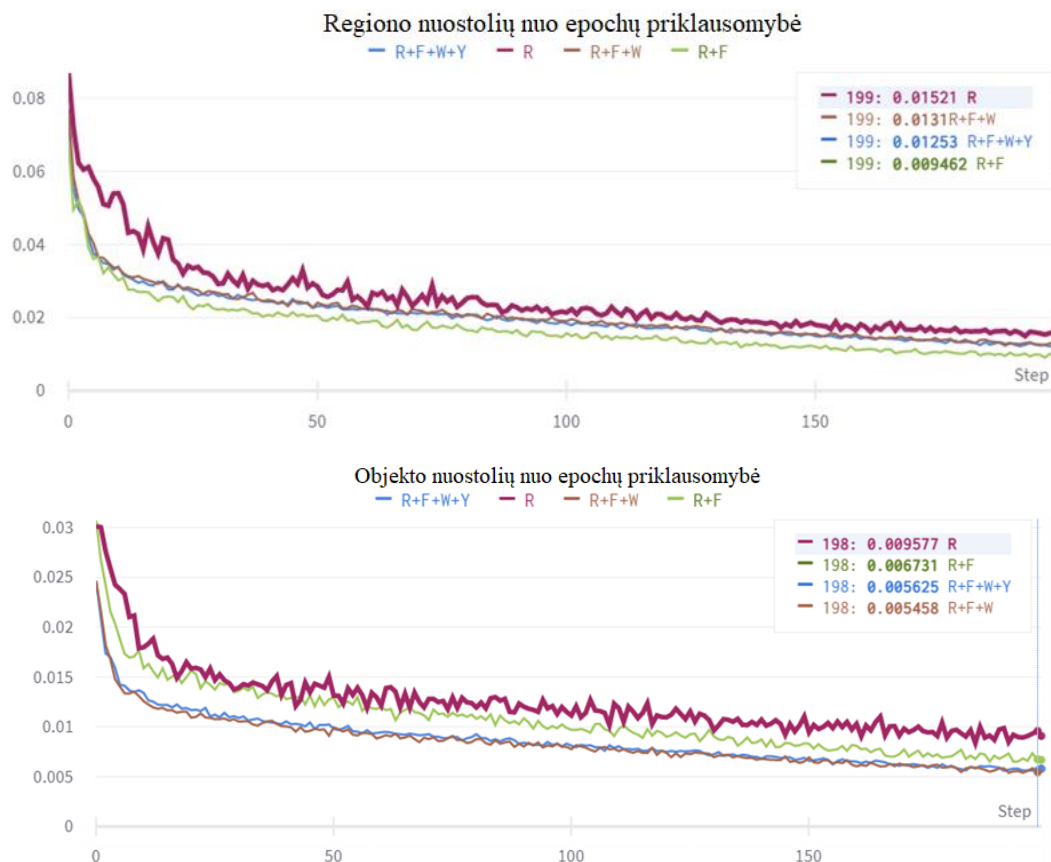


41 pav. YOLOv5l tinklo klaidingų neigiamų atpažinimų rezultatai

Kaip matoma grafike, didžiausius klaidingų neigiamų atpažinimų skaičius parodė R ir $R+F$ duomenų rinkiniai, tuo tarpu mažiausią klaidingų neigiamų atpažinimų skaičių parodė didžiausias duomenų rinkinys – 10.

3.1.3 YOLOv5m modelio įtaka metodo tikslumui


Atliktas eksperimentas, kuriuo vertinamas YOLOv5m modelio tikslumas su skirtingais duomenų rinkiniais.



42 pav. YOLOv5m tinklo regiono ir objekto nuostoliai

Atlikus 200 iteracijų apmokymą su keturiais skirtingais duomenų rinkiniais gauti apmokymo rezultatų grafikai pavaizduoti 42 pav. Duomenų rinkinys $R+F$ po 200 iteracijų pasiekė geriausią regiono aptikimo tikslumą – 0,009462. Mažiausiu objekto nuostolių įverčiu pasižymėjo $R+F+W$ duomenų rinkinys pasiekęs 0,005458. Prasčiausius dūmų aptikimo rezultatus parodė mažiausias duomenų rinkinys R – atitinkamai pasiekęs 0.01521 regiono nuostolius ir 0,009577 objekto nuostolius.


Tyrimams buvo atrinkta 20 nematytų nuotraukų. 43 paveiksle pateikiami pagrindiniai modelio tikslumo parametrai.



43 pav. YOLOv5m tinklo tikslumo parametrai


Atlikus bandymus su nematytomis nuotraukomis, *Yolov5m* tinklas geriausius $mAP@0,5$ rezultatus pasiekė su $R+F+W$ duomenų rinkiniu, kuris buvo lygus 0,456. Tinklas su didžiausia duomenų baze buvo 1,55 karto tikslesnis nei su mažiausia duomenų baze. Mažiausias pasiektas tikslumas buvo su $R+F$ duomenų rinkiniu, kurio $mAP@0,5$ lygus 0,252. Geriausią $F1$ rezultatą pasiekė $R+F+W$ duomenų rinkinys su 0,51 rezultatu.

44 pav. yra pateikiamas YOLOv5m tinklo apmokymo laiko palyginimas su skirtingais duomenų rinkiniais.



44 pav. YOLOv5m tinklo skirtingų duomenų rinkinių apmokymo trukmė

Yolov5m apmokymas su didžiausia $R+F+W+Y$ duomenų baze užtruko 10 valandų ir 5 minutes, ir buvo 5,5 kartus ilgesnis nei su mažiausia duomenų baze, o tikslumas padidėjo 1,55 karto. Didžiausią mAP tikslumą pasiekusio $R+F+W$ duomenų rinkinio apmokymas truko 1,32 karto greičiau, negu $R+F+W+Y$ rinkinio, pasiekusiu mažesnę mAP įvertį. 45 paveiksle pateikiami metodo klaidingų neigiamų rezultatų skaičiai atliekant bandymus.

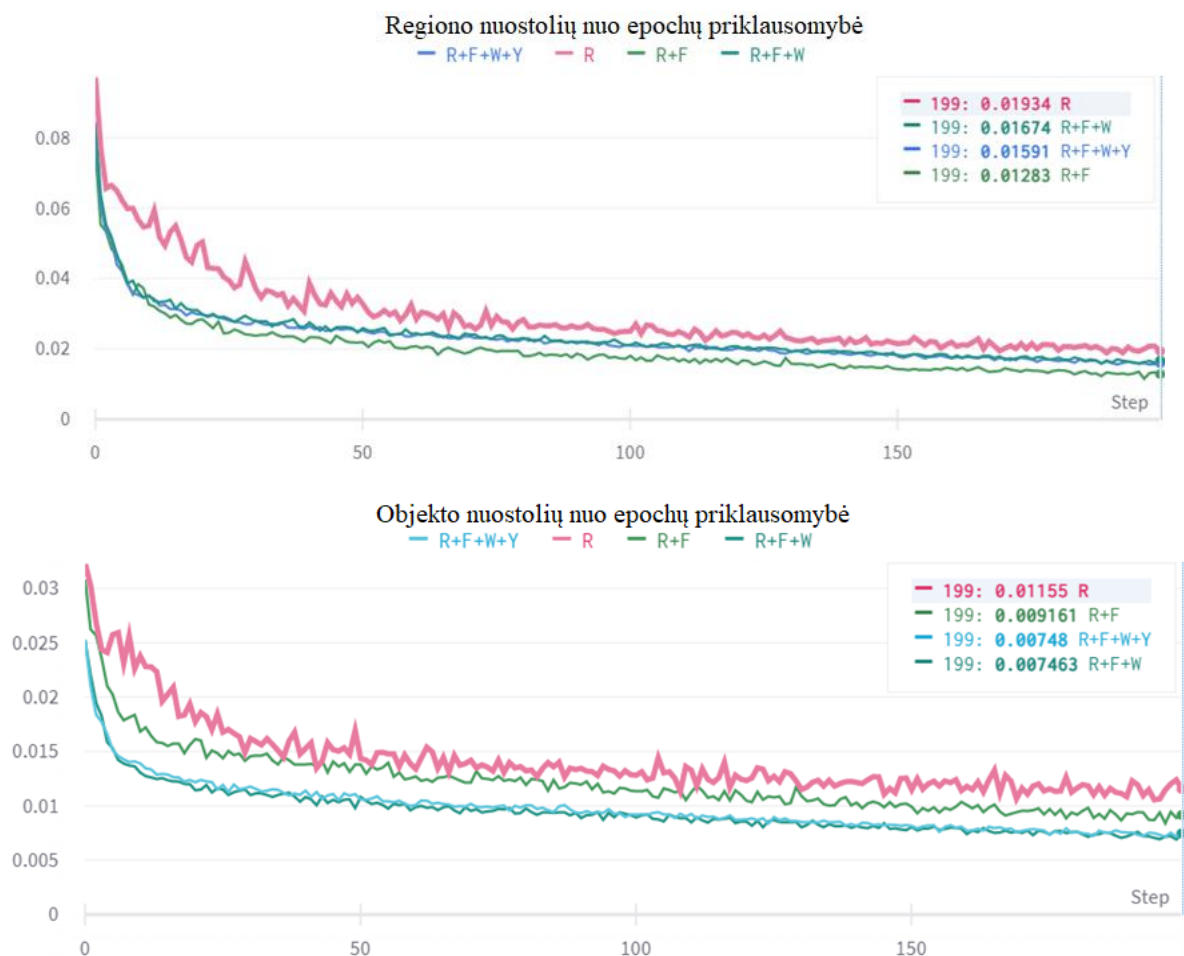


45 pav. YOLOv5m tinklo klaidingų neigiamų atpažinimų rezultatai

Kaip matoma grafike, didžiausius klaidingų neigiamų rezultatų skaičius parodė $R+F$ duomenų rinkinys, tuo tarpu mažiausią klaidingų neigiamų rezultatų skaičių parodė $R+F+W$ duomenų rinkinys – 10.

3.1.4 YOLOv5s modelio įtaka metodo tikslumui


Atliktas eksperimentas, kuriuo vertinamas YOLOv5s modelio tikslumas su skirtingais duomenų rinkiniais.



46 pav. YOLOv5s tinklo regiono ir objekto nuostoliai

Atlikus 200 iteracijų apmokymą su keturiais skirtingais duomenų rinkiniais gauti apmokymo rezultatų grafikai pavaizduoti 46 pav. Duomenų rinkinys $R+F$ po 200 iteracijų pasiekė geriausią regiono aptikimo tikslumą – 0,01283. Mažiausiu objekto nuostolių įverčiu pasižymėjo $R+F+W$ duomenų rinkinys pasiekęs 0,007463. Prasčiausius dūmų aptikimo rezultatus parodė mažiausias duomenų rinkinys R – atitinkamai pasiekęs 0,01934 regiono nuostolius ir 0,01155 objekto nuostolius.


Tyrimams buvo atrinkta 20 nematytų nuotraukų. 47 paveiksle pateikiami pagrindiniai modelio tikslumo parametrai.



47 pav. YOLOv5s tinklo įtaka metodo tikslumui


Atlikus bandymus su nematytomis nuotraukomis, *Yolov5s* tinklas geriausius *mAP* rezultatus pasiekė su didžiausiu duomenų rinkiniu - $R+F+W+Y$, kurio vertė lygi 0,44. Tinklas su didžiausia duomenų baze buvo 1,56 karto tikslesnis nei su mažiausia duomenų baze. Mažiausias pasiektas tikslumas buvo su pirmuoju duomenų rinkiniu R , kurio *mAP* lygus 0,282. Geriausią *F1* rezultatą pasiekė $R+F+W+Y$ duomenų rinkinys su 0,44 rezultatu.

48 pav. yra pateikiamas *Yolov5s* tinklo apmokymo laiko palyginimas su skirtingais duomenų rinkiniais.



48 pav. YOLOv5s tinklo skirtingų duomenų rinkinių apmokymo trukmė

Yolov5s apmokymas su didžiausia $R+F+W+Y$ duomenų baze užtruko 7 valandas ir 9 minutes, ir buvo 5,72 kartus ilgesnis nei su mažiausia duomenų baze, o tikslumas padidėjo 1,56 karto. 49 paveiksle pateikiami metodo klaidingų neigiamų rezultatų skaičiai atliekant bandymus.

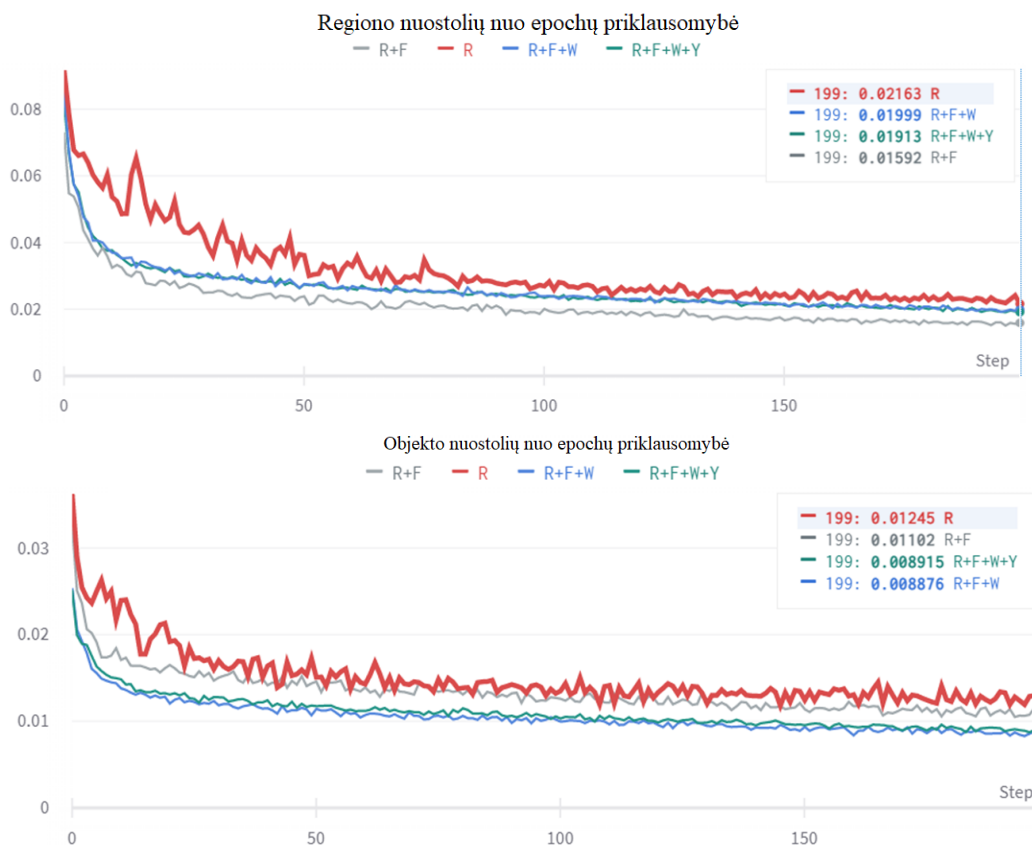


49 pav. *YOLOv5s* tinklo klaidingų neigiamų atpažinimų rezultatai

Kaip matoma grafike, didžiausius klaidingų neigiamų rezultatų skaičius parodė mažiausias duomenų rinkinys R , tuo tarpu mažiausią klaidingų neigiamų rezultatų skaičių parodė duomenų rinkinys $R+F+W - 10$.

3.1.5. *YOLOv5n* modelio įtaka metodo tikslumui


Atliktas eksperimentas, kuriuo vertinamas *YOLOv5n* modelio tikslumas su skirtingais duomenų rinkiniais.



50 pav. *YOLOv5n* tinklo regiono ir objekto nuostoliai

Atlikus 200 iteracijų apmokymą su keturiais skirtingais duomenų rinkiniais gauti apmokymo rezultatų grafikai pavaizduoti 50 pav. Duomenų rinkinys $R+F$ po 200 iteracijų pasiekė geriausią regiono aptikimo tikslumą – 0,01592. Mažiausiu objekto nuostolių įverčiu pasižymėjo $R+F+W$ duomenų rinkinys pasiekęs 0,008876. Prasčiausius dūmų aptikimo rezultatus parodė mažiausias duomenų rinkinys R – atitinkamai pasiekęs 0,02163 regiono nuostolius ir 0,01245 objekto nuostolius.


Tyrimams buvo atrinkta 20 nematytų nuotraukų. 51 paveiksle pateikiami pagrindiniai modelio tikslumo parametrai.



51 pav. YOLOv5n tinklo įtaka metodo tikslumui


Atlikus bandymus su nematytomis nuotraukomis, *Yolov5n* tinklas geriausius *mAP* rezultatus pasiekė su duomenų rinkiniu - $R+F+W$, kurio vertė lygi 0,465. Tinklas su didžiausia duomenų baze buvo 1,45 karto tikslesnis nei su mažiausia duomenų baze. Mažiausias pasiektas tikslumas buvo su pirmuoju duomenų rinkiniu R , kurio *mAP* lygus 0,255. Geriausią *F1* rezultatą pasiekė $R+F+W$ duomenų rinkinys su 0,55 rezultatu.

52 pav. yra pateikiamas *Yolov5n* tinklo apmokymo laiko palyginimas su skirtingais duomenų rinkiniais.



52 pav. YOLOv5n tinklo skirtingų duomenų rinkinių apmokymo trukmė

Yolov5n apmokymas su didžiausia $R+F+W+Y$ duomenų baze užtruko 6 valandas ir 5 minutes, ir buvo 5,7 kartus ilgesnis nei su mažiausia duomenų baze, o tikslumas padidėjo 1,45 karto. 53 paveiksle pateikiami metodo klaidingų neigiamų atpažinimų rezultatai atliekant bandymus.




53 pav. YOLOv5n tinklo klaidingų neigiamų atpažinimų rezultatai

Kaip matoma grafike, didžiausius klaidingų neigiamų atpažinimų rezultatus parodė mažiausias duomenų rinkinys R , tuo tarpu mažiausius klaidingų neigiamų atpažinimų skaičius parodė $R+F+W$ ir $R+F$ duomenų rinkiniai.

3.1.6. Skirtingų YOLOv5 tinklo architektūrų su geriausiomis duomenų bazėmis palyginimas

Iš visų apmokytų modelių buvo atrinkti 5 geriausi modeliai pagal $mAP@0,5$ ir $F1$ tikslumo įverčius. 55 paveiksle pateikiami $mAP@0,5$ bei $F1$ rezultatų grafikai.




54 pav. a) $mAP@0,5$ rezultatai b) $F1$ rezultatai


Kaip matoma 55 paveikslo a) dalyje, didžiausią $mAP@0.5$ pasiekė YOLOv5x modelis, kuris buvo lygus 0,49, tai yra didžiausią parametų kiekį turintis modelis. Mažiausias $mAP@0,5$ buvo pasiektas YOLOv5s modelio ir buvo lygus 0,44. Tai 1,11 karto mažesnis tikslumas nei didžiausią rezultatą pasiekusio modelio. Vienas didžiausių tikslumu naudojant $mAP@0,5$ įvertį buvo pasiektas YOLO5n modelio ir buvo lygus 0,465. Tai mažiausiai parametų turintis modelis, tačiau jo tikslumas buvo tik 1,05 karto mažesnis nei daugiausiai parametų turinčio modelio.

55 paveikslo b) dalyje pavaizduotas $F1$ įverčio geriausių atrinktų modelių palyginimas. Didžiausias $F1$ įvertis buvo pasiektas naudojant YOLOv5x ir YOLO5n modelius, atitinkamai pasiekusius 0,58 ir 0,55 rezultatus. YOLOv5x modelis buvo tikslesnis tik 1,054 karto, nors parametų kiekis tarp šių modelių skiriasi 45,63 karto.

55 ir 56 paveiksluose yra pateikiami nuotraukos apdorojimo bei modelių apmokymo laikų palyginimas.



55 pav. YOLOv5 skirtingų tinklų vaizdų apdorojimo trukmė




56 pav. Skirtingų YOLOv5 modelių apmokymo trukmė

Kaip matoma apdorojimo greičio palyginimo grafike, greičiausiai 1 nuotrauką apdorojo YOLO5n modelis (4 ms), ir buvo 9,12 kartų greitesnis nei YOLOv5x modelis. YOLOv5n modelio apmokymo laikas buvo 5 h ir 48 min, ir buvo 2,49 kartų greičiau apmokytas nei YOLOv5l modelis. Pagal ankstesnius grafikus, YOLO5n modelis pasiekė tik 1,05 karto mažesnę tikslumą negu daugiausiai parametrų turintis modelis, todėl šiai konkrečiai užduočiai turi geriausią nuotraukos apdorojimo laiko bei radimo tikslumo santykį ir jį būtų galima naudoti realioms greಿತaveikos bei tikslumo reikalaujančioms užduotims spręsti.

3.1.7. Skirtingų persidengimo metodų palyginimas

Atliktas eksperimentas, kurio metu nagrinėjama skirtingų YOLOv5 modelių tikslumo priklausomybė nuo skirtingų nuostalių funkcijų (*GIoU*, *DIoU*, *CIoU*). Gauti eksperimentiniai rezultatai pavaizduoti 57 pav.



57 pav. Skirtingų persidengimo metodų atpažinimo rezultatai

Pagal 57 pav. galima matyti, kad esant skirtingoms nuostolių funkcijoms, gauti skirtingi mAP tikslumo rezultatai. Didžiausias skirtumas matomas nagrinėjant *YOLOv5n* modelį. Čia mAP tikslumas tarp *CIoU* ir *DIoU* skiriasi 2,05 karto. Geriausią atpažinimo tikslumą pasiekė *YOLOv5x* modelis su *GIoU* nuostolių funkcija ir *YOLOv5l* modelis su *CIoU* funkcija. Lyginant mAP tarp skirtingų modelių, *CIoU* pasiekė 1,06 % didesnę atpažinimo tikslumą negu *GIoU* ir 11,28 % didesnę atpažinimo tikslumą nei *DIoU*. Tarp visų nagrinėtų modelių didžiausias vidutinis tikslumas buvo pasiektas *CIoU* nuostolių funkcijos ir buvo lygus 0,286.

7 lentelė. *YOLOv5* modelių tikslumo priklausomybė nuo skirtingų persidengimo metodų.

Modelis	Metodas	<i>GIoU</i>	<i>DIoU</i>	<i>CIoU</i>
<i>YOLOv5x</i>	Tikslumas	0.666	0.41	0,545
<i>YOLOv5l</i>		0.374	0.388	0,533
<i>YOLOv5m</i>		0.347	0.346	0,461
<i>YOLOv5s</i>		0.332	0.421	0,367
<i>YOLOv5n</i>		0.5	0.331	0,461
<i>YOLOv5x</i>	Atšaukimas	0,3	0,35	0,3
<i>YOLOv5l</i>		0,449	0,35	0,4
<i>YOLOv5m</i>		0,4	0,449	0,3
<i>YOLOv5s</i>		0,3	0,399	0,35
<i>YOLOv5n</i>		0,3	0,25	0,3
<i>YOLOv5x</i>	<i>F1</i>	0,41	0,38	0,39
<i>YOLOv5l</i>		0,41	0,37	0,46
<i>YOLOv5m</i>		0,37	0,39	0,36
<i>YOLOv5s</i>		0,32	0,41	0,36
<i>YOLOv5n</i>		0,37	0,28	0,36

Pagal 7 lentelę matoma, kad *YOLOv5x* modelis pasiekė didžiausią tikslumo rodiklį su *GIoU* nuostolių funkcija. Didžiausius atšaukimo rodiklius pasiekė *YOLOv5l* modelis su *GIoU* nuostolių funkcija ir *YOLOv5m* modelis su *DIoU* nuostolių funkcija. Didžiausią *F1* įvertį parodė *YOLOv5l* modelis su *CIoU* nuostolių funkcija. Vidutiniškai geriausius rezultatus parodė *CIoU*, po jo sekė *GIoU*, o blogiausiai veikė *DIoU* nuostolių funkcija. *DIoU* apdorojimo procese neatsižvelgiama į ribinio lango kraštinių santykį, todėl jo tikslumas buvo mažesnis nei *GIoU*.

3.1.8. Realios ir sintetinės duomenų bazės palyginimas

Siekiant įvertinti sintetinio duomenų rinkinio efektyvumą, buvo sukurta jai identiška, surinkta tik iš realių nuotraukų, gautų iš įvairių interneto šaltinių, duomenų bazė. Tyrimams atlikti pasirinktas *YOLOv5s* modelis. Atlikus apmokymus, gauti rezultatai, pavaizduoti 8 lentelėje.


8 lentelė. Realios ir sintetinės duomenų bazės atpažinimo tikslumo rezultatai

Modelis	Duomenų bazė	$mAP@0,5$	Tikslumas	Atšaukimas	FI
<i>YOLOv5s</i>	Reali	0,391	0,667	0,4	0,5
<i>YOLOv5s</i>	Sintetinė	0,34	0,667	0,3	0,41

Lyginant gautus duomenis matoma, kad to paties dydžio sintetinės duomenų bazės atpažinimo tikslumas $mAP @0.5$ sumažėjo 14 %. Duomenų rinkinio tikslumo rodikliai išliko vienodi. Atšaukimas sumažėjo 33 %. FI įvertis sumažėjo 21 % nuo 0,5 iki 0,41. Galime teigti, kad sintetinė duomenų bazė šiuo atveju nepadidino modelio tikslumo.


3.1.9. Įvesties duomenų testavimo laiko augmentacija

Siekiant padidinti atpažinimo tikslumą, buvo atliktas testavimo laiko augmentacijos (angl. *Test-Time Augmentation, TTA*) tyrimas. Testavimo laiko augmentacija sukuria daugybę skirtingų įvesties vaizdo versijų, įskaitant skirtingų regionų apkarpyimą, priartinimo lygio keitimą, nuotraukos apvertimą bei apdorojimą trimis skirtingomis rezoliucijomis prieš maksimumų atrinkimą (*NMS*). Dėl šių papildomų procesų, vienos nuotraukos apdorojimo trukmė vidutiniškai padidėja 2-3 kartus. Bandymams atlikti išsirinkti 3.1.2 skyriuje aprašyti modeliai, kurie parodė geriausius atpažinimo rezultatus. *TTA* rezultatai įvertinami palyginus mAP , tikslumo, atšaukimo bei FI įverčius.



58 pav. Testavimo laiko augmentacijos įtaka $mAP@0.5$ tikslumui

Nagrinėjant gautus mAP įverčius, 58 pav. galima matyti, kad tinklo atpažinimo tikslumas padidėjo ne visais atvejais. Didžiausias pokytis matomas *YOLOv5m* tinkle, kuomet po augmentacijos mAP įvertis padidėjo 20 %. *TTA* pokytis mažiausiai pastebimas didžiausiame *YOLOv5x* tinkle, kuomet atpažinimo tikslumas po augmentacijos sumažėjo tik 0,2 %. Papildoma įvesties vaizdų augmentacija 6 % vidutiniškai pagerino mAP rodiklius.



59 pav. Tikslumo, atšaukimo ir *F1* rezultatai

Pagal 59 pav. didžiausias tikslumo rodiklio pokytis pastebimas *YOLOv5m* tinkle, kuomet papildyto modelio tikslumas padidėjo 24 %. Modeliai su *TTA* įvesties vaizdais vidutiniškai parodė 5,9 % procento geresnius rezultatus. Naujas *YOLOv5m* tinklo atšaukimo rodiklis padidėjo 9 %. Gauti *TTA* atšaukimo rodikliai vidutiniškai pasiekė 5,6 % didesnes vertes. Didžiausias *F1* įvertis pasiektas su *YOLOv5m* modeliu ir *TTA* augmentacija ir buvo lygus 0,62.

Iš grafikų galima matyti, kad papildomai apdorotų įvesties vaizdų atpažinimo rezultatai yra geresni. Papildžius įvesties vaizdus, duomenys iš esmės nepasikeičia. Atpažinimo augmentacija naudojama tikintis, jog tinklas taps truputį atsparesnis labai menkiems pokyčiams tiems patiems duomenims, vadinasi, neatsparus tinklas kiekviename kadre rodys labai skirtingus rezultatus, tuo tarpu atsparus tinklas turėtų rodyti panašius, arba geriausiai - vienodus rezultatus. Atsižvelgiant į tai, galima sakyti, kad atsiradus skirtumui tarp paprasto testavimo duomenų rinkinio ir papildyto rezultatų, tinklas yra prastesnis.

Išvados

1. Atlikus literatūros analizę nustatyta, kad gaisro lokalizavimo uždavinys gali būti sprendžiamas panaudojant gilaus mokymo metodus tokius kaip *YOLOv5*. Remiantis šiuo teiginiu tolimesni bandymai buvo atlikti panaudojant šį metodą.
2. Panaudojus tik sintetinius duomenimis praplėstą duomenų bazę *YOLOv5s* modelio vidutinis tikslumo rodiklis sumažėjo 14 %.
3. Panaudojus duomenų bazę, kurią sudarė realios, sintetinės, ir praplėstos iš stacionarių miško stebėjimo bokštelių nuotraukos, didžiausią tikslumą pasiekė *YOLOv5x* modelis, kurio vidutinis tikslumo rodiklis buvo lygus 0,49, tačiau šio modelio nuotraukos apdorojimo ir apmokymo laikas buvo ilgiausias, atitinkamai 36,5 ms. ir 1735 min.
4. Geriausiai iš tiriamų modelių realaus laiko užduotims tiktų *YOLOv5n* modelis, kurio vidutinis tikslumo rodiklis pasiekė 0,465, tačiau šio modelio nuotraukos apdorojimo bei apmokymo laikai buvo vieni mažiausių, atitinkamai 4 ms bei 348 min, ir buvo 9,125 karto greitesnis nei *YOLOv5x* bei apmokomas 5 kartus greičiau.
5. Panaudojant skirtingus persidengimo metodus, didžiausias skirtumas yra matomas nagrinėjant *YOLOv5n* modelį. Čia vidutinis aptikimo tikslumas tarp pilno ir atstumo sankirtos ir sąjungos parametrų skiriasi 2,05 karto, o tarp visų nagrinėtų modelių didžiausias vidutinis tikslumas buvo pasiektas su pilna sankirtos ir sąjungos nuostolių funkcija ir buvo lygus 0,286.
6. Atliekant tik realios ir sintetinės duomenų bazės palyginimą, nustatyta, kad sintetinė duomenų bazė nepadidino modelio tikslumo, o atšaukimas sumažėjo 33 %. *F1* įvertis sumažėjo 21 %, nuo 0,5 iki 0,41.
7. Panaudojus duomenų testavimo laiko augmentaciją didžiausias pokytis matomas *YOLOv5m* tinkle, kuomet po duomenų rinkinio papildymo vidutinis aptikimo tikslumo įvertis padidėjo 20 %, o visuose modeliuose vidutiniškai testavimo laiko augmentacija tikslumo parametrus pagerino 6 %.

Literatūros sąrašas

1. Joint Research Centre (JRC). Forest Fires in Europe, 2020 [žiūrėta 2022-04-27]. ISSN 1831-9424. Prieiga per: <https://ec.europa.eu/jrc>
2. DERVINIS, Donatas. Vaizdų apdorojimas, Kaunas, 2012, ISBN-978-609-433-107-7
3. Joint Research Centre (JRC). Forest Fires in Europe, Middle East and North Africa, 2018 [žiūrėta 2022-04-20]. ISBN 978-92-76-11234-1. Prieiga per: <https://ec.europa.eu/jrc>
4. Dovilė Keršytė, Egidijus Rimkus, Justas Kažys. Klimato rodiklių scenarijai Lietuvos teritorijoje XXI a., Vilniaus universitetas, 2015 [žiūrėta 2022-02-05]. Prieiga per: <https://doi.org/10.6001/geol-geogr.v1i1.3069>
5. Bukantis A. Climatic fluctuations in Lithuania against a background of Global Warming. 2001 [žiūrėta 2022-02-06]. DOI: 10.1080/13921657.2001.10512366. Prieiga per: <https://www.researchgate.net>
6. S. Allison, M. Johnston, G. Craig, S. Jennings. Airborne Optical and Thermal Remote Sensing for Wildfire Detection and Monitoring, 2016 [žiūrėta 2022-02-07]. DOI: 10.3390/s16081310. Prieiga per: <https://www.mdpi.com/1424-8220/16/8/1310>
7. A. Heyns, W. Plessis, M. Kosch, G. Hough. Optimisation of tower site locations for camera-based wildfire detection systems, 2019 [žiūrėta 2022-02-08]. Prieiga per: <https://doi.org/10.1071/WF18196>.
8. D. Rashkovetsky, F. Mauracher, M. Langer, M. Schmitt. Wildfire Detection From Multisensor Satellite Imagery Using Deep Semantic Segmentation, 2021 [žiūrėta 2022-02-09]. DOI: 10.1109/JSTARS.2021.3093625. Prieiga per: <https://ieeexplore.ieee.org/>.
9. M. Allauddin, G. Kiran, R. Kiran, G. Srinivas, G. Mouli, P. Prasad. Development of a Surveillance System for Forest Fire Detection and Monitoring using Drones, 2019 [žiūrėta 2022-02-10]. DOI: 10.1109/IGARSS.2019.8900436. Prieiga per: <https://ieeexplore.ieee.org/>.
10. M. Boon, A. P. Drijfhout, S. Tesfamichae. Comparison of a fixed-wing and multi-rotor uav for environmental mapping applications, 2017 [žiūrėta 2022-02-11]. DOI:10.5194/isprs-archives-XLII-2-W6-47-2017. Prieiga per: <https://www.researchgate.net>.
11. R. Janušaitė, V. Karaliūnas, L. Bevainis. Application of Remote Sensing Methods in Research of Nearshore Sandbars, Curonian Spit, Lithuania, 2017. [žiūrėta 2022-02-12]. Prieiga per: <https://doi.org/10.22364/bjmc.2019.7.4.08>
12. M. Shahbazi, J. Theau, P. Menard. Recent applications of unmanned aerial imagery in natural resource management, 2014. [žiūrėta 2022-02-13]. DOI:10.1080/15481603.2014.926650. Prieiga per: <https://www.researchgate.net>
13. F. Cakici, M. K. Leblebicioglu. Analysis of a UAV that can hover and fly level, 2016 [žiūrėta 2022-02-15]. DOI: 10.1051/mateconf/20165907010. Prieiga per: <https://www.researchgate.net>.
14. E. DRAGAŠIUS, A. LIPNICKAS. *Intelektualios mechatroninės sistemos: mokomoji knyga*. Kaunas, 2008. ISBN 978-9955-20-285-1.
15. S. Srivastava, A. V. Divekar, C. Anilkumar, I. Naik, V. Kulkarni, V. Pattabiraman. Comparative analysis of deep learning image detection algorithms, 2021 [žiūrėta 2022-02-15]. Prieiga per: <https://doi.org/10.1186/s40537-021-00434-w>.
16. W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, C. Berg. SSD: Single Shot MultiBox Detector, 2015 [žiūrėta 2022-02-15]. Prieiga per: <https://doi.org/10.48550/arXiv.1512.02325>.

17. S. Ren, K. He, R. Girshick, J. Sun. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, 2017 [žiūrēta 2022-04-10]. DOI: 10.1109/TPAMI.2016.2577031. Prieiga per: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7485869>.
18. L. Tan, T. Huangfu, L. Wu. Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification, 2021 [žiūrēta 2022-04-20]. Prieiga per: <https://doi.org/10.1186/s12911-021-01691-8>.
19. J. Redmon, S. Divvala, R. Girshick, A. Farhadi. You Only Look Once: Unified, Real-Time Object Detection, 2015 [žiūrēta 2022-04-20]. Prieiga per: <https://doi.org/10.48550/arXiv.1506.02640>.
20. U. Handalage, L. Kuganandamurthy. Real-Time Object Detection Using YOLO: A Review, 2021 [žiūrēta 2022-05-05]. DOI:10.13140/RG.2.2.24367.66723. Prieiga per: <https://www.researchgate.net>.
21. Joseph Redmon, Ali Farhadi. YOLOv3: An Incremental Improvement, 2018 [žiūrēta 2022-03-08]. Prieiga per: <https://doi.org/10.48550/arXiv.1804.02767>.
22. N. Zaghari, M. Fathy, S.M. Jameii. The improvement in obstacle detection in autonomous vehicles using YOLO non-maximum suppression fuzzy algorithm, 2021 [žiūrēta 2022-03-06]. Prieiga per: <https://doi.org/10.1007/s11227-021-03813-5>.
23. J. Sang, Z. Wu, P. Guo, H. Hu, H. Xiang, Q. Zhang, B. Cai. An Improved YOLOv2 for Vehicle Detection. Sensors, 2018 [žiūrēta 2022-03-15]. Prieiga per: <https://doi.org/10.3390/s18124272>.
24. J. Redmon, A. Farhadi. YOLO9000: Better, Faster, Stronger, 2016 [žiūrēta 2022-02-05]. Prieiga per: <https://doi.org/10.48550/arXiv.1612.08242>.
25. Z. Lu, J. Lu, Q. Ge. Multi-object Detection Method based on YOLO and ResNet Hybrid Networks, 2019 [žiūrēta 2022-02-05]. DOI:10.1109/ICARM.2019.8833671. Prieiga per: <https://www.researchgate.net>.
26. L. Huang. An Improved YOLOv3 Model Based on ResNet50, 2020 [žiūrēta 2022-03-10]. DOI: 10.1109/IICSPI51290.2020.9332457. Prieiga per: <https://ieeexplore.ieee.org/>
27. D. Xu, Y. Wu. Improved YOLO-V3 with DenseNet for Multi-Scale Remote Sensing Target Detection, 2020 [žiūrēta 2022-03-04] Prieiga per: <https://doi.org/10.3390/s20154276>.
28. Joseph Redmon, Ali Farhadi. YOLOv3: An Incremental Improvement, 2018 [žiūrēta 2022-04-05]. Prieiga per: <https://doi.org/10.48550/arXiv.1804.02767>
29. A. Bochkovskiy, C. Wang, H. Liao. YOLOv4: Optimal Speed and Accuracy of Object Detection, 2020 [žiūrēta 2022-04-06]. Prieiga per: <https://doi.org/10.48550/arXiv.2004.10934>
30. G. Ghiasi, T. Lin, Q. V. Le. DropBlock: A regularization method for convolutional networks, 2018 [žiūrēta 2022-04-05]. Prieiga per: <https://doi.org/10.48550/arXiv.1810.12890>
31. D. Thuan. Evolution of Yolo Algorithm and Yolov5: The State-of-the-Art Object Detection Algorithm, 2021 [žiūrēta 2022-05-03]. Prieiga per: <https://urn.fi/URN:NBN:fi:amk-202103042892>
32. C. Wang, H. Mark Liao, I. Yeh, Y. Wu, Y. Chen, J. Hsieh. CSPNet: A New Backbone that can Enhance Learning Capability of CNN, 2019 [žiūrēta 2022-05-04]. Prieiga per: <https://doi.org/10.48550/arXiv.1911.11929>
33. W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Alexander, C. Berg. SSD: Single shot multibox detector, 2016 [žiūrēta 2022-05-05]. Prieiga per: https://doi.org/10.1007/978-3-319-46448-0_2

34. N. Xiang, C. Pan, X. Li. An Object Detection Algorithm Combining FPN Structure With DETR, 2021 [žiūrēta 2022-05-06]. Prieiga per: <https://doi.org/10.1145/3484274.3484284>
35. Q. Zhang, G. Lin, Y. Zhang, G. Xu. Wildland Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images, 2018 [žiūrēta 2022-05-06]. Prieiga per: <https://doi.org/10.1016/j.proeng.2017.12.034>