



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Judančių motorinių transporto priemonių klasifikavimo tyrimas

Baigiamasis magistro projektas

Tomas Rumšas

Projekto autorius

prof. dr. Darius Andriukaitis

Vadovas

Kaunas, 2021



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Judančių motorinių transporto priemonių klasifikavimo tyrimas

Baigiamasis magistro projektas

Elektronikos inžinerija (6211EX012)

Tomas Rumšas

Projekto autorius

prof. dr. Darius Andriukaitis

Vadovas

doc. dr. Mindaugas Žilys

Recenzentas

Kaunas, 2021



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Tomas Rumšas

Judančių motorinių transporto priemonių klasifikavimo tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdamas kitų asmenų autoriaus ar kitų teisių, laikydamasis 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;
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalintas iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Tomas Rumšas

Patvirtinta elektroniniu būdu

Rumšas, Tomas. Judančių motorinių transporto priemonių klasifikavimo tyrimas. Magistro baigiamasis projektas/ vadovas prof. dr. Darius Andriukaitis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Elektronikos inžinerija, inžinerijos mokslai.

Reikšminiai žodžiai: klasifikavimas, požymis, aptikimas, transporto priemonės, vaizdo apdorojimas.

Kaunas, 2021.53 p.

Santrauka

Magistro baigiamajame projekte yra tiriamas ir analizuojamas judančių motorinių transporto priemonių klasifikavimas. Įvade aptariama pagrindinės problemos, kodėl turi būti klasifikuojamos transporto priemonės ir pagal kokius galimus parametrus identifikuojamos. Suformuluoti darbo tikslas ir darbo uždaviniai, kuriais atliekama judančių transporto priemonių klasifikavimo modelio tyrimas.

Pirmoje, literatūros šaltinių analizės dalyje atliekama trijų skirtingų matavimo būdų apžvalga. Aptariama, kaip yra taikomi kiekvienas iš jų. Sprendžiama, kiek ir kokių parametrų gali nustatyti kiekvienas iš galimų matavimo metodų, remiantis įvairiais šaltiniais. Pagal išskirtus parametrus sprendžiama, kuri iš galimų sistemų yra tikslesnė ir mažiau veikiama pašalinių veiksnių. Palyginama, kuris metodas tiksliausias ir pasirenkamas tolimesniam sistemos modelio tyrimui atlikti.

Antroje dalyje aptariamos trys pasirinkto metodo rinkoje esančios transporto nustatymo ir klasifikavimo sistemos. Apžvelgiami esantys produktai ir jų nustatymo metodikos, lyginami jų parametrai ir aptariamos klasifikavimo metodikos. Remiantis sistemų aptikimo ir identifikavimo tikslumu, siekiama, kad sistemos modelis būtų kuo arčiau nurodytų verčių.

Trečioje dalyje nurodomi pasirinkto metodo parametrai, kuriais dažniausiai yra klasifikuojamos transporto priemonės. Aptariama kiekvieno parametro preliminarus parametro išskyrimo principas. Pateikiama kiekvieno iš galimų parametrų tikslumo įvertinimas procentine dalimi.

Sekančioje dalyje sudaromas preliminarus klasifikavimo sistemos modelis. Pateikiami jo algoritmai. Paaškinama kiekvienos dalies veikimas. Pasirenkamas judančių vaizdų (objektų) apdorojimas. Vaizdas apdorojamas papildomai sukurtais filtrais. Atitinkamai išskiriami požymiai ir sudaromas klasifikavimui reikalingos duomenų bazės su preliminariomis transporto klasėmis. Sudaromas galutinis transporto klasifikavimo sistemos modelio algoritmas.

Paskutinėje dalyje atliekami eksperimentiniai bandymai, pagrindžiantys sudaryto klasifikavimo sistemos modelio veikimą. Tuo tikslu atliekamas pirminis klasifikavimo tikslumo, nuo įvairių duomenų bazių dydžio įvertinimas ir aptinkamo transporto statistinis įvertinimas. Tiriamos sudarytos duomenų bazių skirtumas tarp klasių, tarp pačių parametrų ir parametrų kiekio. Bandymų pabaigoje pateikiamas bendras sistemos veikimo statistinis pagrindimas nuo aptikto transporto, išrenkant geriausią klasifikatorių, ir požymių kiekį. Pateikiama rekomendacija tolimesniam sistemos tobulinimui.

Išvadų dalyje atliekamas viso darbo apibendrinimas, aptariami rezultatai.

Rumšas, Tomas. Research of Moving Motor Vehicles Classification. Master's Final Degree Project / supervisor Prof. Dr. Darius Andriukaitis; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): Electronics Engineering, Engineering Sciences.

Keywords: classification, feature, detection, vehicles, image processing.

Kaunas, 2021. 53 pages.

Summary

This final project focuses on the topic of moving motor vehicles classification. The introduction discusses the main problems of why vehicles should be classified and what the possible parameters should be identified. The tasks and the purpose of research work are formulated, by which shall be performed moving vehicles classification model research.

The first part of the literature analysis provides an overview of three different measurement methods. Discuss how each one is applied. It is decided how many and which parameters each detection method can detect based on different sources. The extracted parameters determine which of the available systems is more accurate and less affected by extraneous factors. A comparison is made between which method is most accurate and possibly which would be chosen for further system model study.

The second part deals with three vehicles detection and classification systems available on the market of the chosen method. Products are reviewed by their detection methods, their parameters which are compared and their classification methodology. Based on the accuracy of system detection and identification, the aim is to keep the system model as close as possible to the specified values.

The third part specifies the parameters of chosen method which are most often used to classify vehicles. The preliminary principle of parameter separation for each parameter is discussed. Accuracy is estimated of each of the possible parameters as a percentage part.

The following section provides a preliminary model of the classification system. Algorithms are presented. The operation of each part is explained. Moving images (objects) are chosen for processing. The image frames are processed by additional filters. Accordingly, features are extracted and required databases are created with preliminary vehicles classes. The final algorithm of the vehicles classification system model is developed.

In the last part, experimental tests are performed to substantiate the operation of the developed classification system model. To this end, an initial assessment of the accuracy of the classification, the size of the various databases and the statistical assessment of the vehicles detected are carried out. The difference is investigated between the classes, between the parameters themselves and the number of parameters. Finally, an overall operation of the system is provided by statistical justification from detected vehicles, the amount of features and the best classifier is selected. A recommendation is provided for further system improvements.

The conclusion section summarizes the whole work, discusses the results.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Santrumpų ir terminų sąrašas	10
Įvadas.....	11
1. Transporto priemonių klasifikavimo būdai.....	12
1.1. Transporto priemonių nustatymas ir klasifikavimas vaizdo kameromis.....	12
1.1.1. Duomenų rinkimas vaizdo kameromis.....	12
1.1.2. Objekto išskyrimo metodai.....	13
1.1.3. Klasifikavimas pagal išreikštus požymius.....	15
1.2. Transporto priemonių klasifikavimas magnetinio jutiklio signalu.....	15
1.2.1. ARM jutiklio metodas	16
1.2.2. Signalų požymių įvertinimas ir klasifikavimas	16
1.3. Transporto priemonių aptikimas ir klasifikavimas ultragarsu.....	17
1.4. Analizės apibendrinimas	18
2. Rinkoje siūlomos judančių transporto priemonių klasifikavimo sistemos	19
2.1. „ViNotion“ judančių objektų aptikimo sistemos.....	19
2.2. Judančio transporto aptikimo „Kapsch TrafficCom“ sistemos	19
2.3. „AutoSense“ transporto aptikimo sistemos	20
2.4. Apibendrinimas	21
3. Sistemų parametrai ir klasifikatoriai, kuriais skirstomos transporto priemonės	22
3.1. Galimi sistemų parametrai.....	22
3.1.1. Kampų išskyrimo požymiais	22
3.1.2. Gauso „Mixture“ Modelis	23
3.1.3. Pagreitinios sutapties požymiai	25
3.1.4. Orientuoto gradiento histograma.....	25
3.2. Transporto klasifikavimo metodai.....	26
3.2.1. Atraminė vektorių mašininis klasifikatorius	26
3.2.2. K-artimųjų kaimynų klasifikatorius	27
3.2.3. „Naive Bayes“ klasifikatorius	28
3.3. Mokslinės problemos formulavimas	28
3.4. Apibendrinimas	28
4. Klasifikavimo sistemos modelio projektavimas.....	29
4.1. Pradinis sistemos modelis.....	29
4.2. Sistemos sudarymo principas ir pirminis vaizdo apdorojimas.....	29
4.2.1. Vaizdų kadru apdorojimas.....	29
4.2.2. Aplinkos ir objekto išskyrimas.....	30
4.2.3. Objekto kraštinių identifikavimas	31
4.3. Vaizdo įrašo apdorojimo principas.....	32
4.4. Judančio transporto klasifikavimo sistemos sudarymas.....	33
4.5. Apibendrinimas	38
5. Eksperimentiniai bandymai sudarytai sistemai pagrįsti	39
5.1. Klasifikavimo bandymai	39
5.2. Trečio klasifikatoriaus bandymai	40
5.3. Transporto aptikimo vertinimas	40

5.4. Duomenų bazių praplėtimas ir vertinimas.....	43
5.5. Požymių vertinimas	44
5.6. Duomenų bazių tikslumo vertinimas.....	46
5.7. Bendras sistemos įvertinimas	47
5.8. Rekomendacija	47
5.9. Apibendrinimas	48
Išvados	49
Literatūros sąrašas	50
Priedai.....	54
1 priedas. Aptikto transporto lentelė nustatant tinkamus aptikimo parametrus	54
2 priedas. Viso transporto kiekis esantis vaizdo įrašuose.....	55
3 priedas. Klasifikavimo lentelė po duomenų bazės praplėtimo, kai pilnas vaizdas	56
4 priedas. Klasifikavimo lentelė po duomenų bazės praplėtimo, kai dominantis vaizdas	57
5 priedas. Klasifikavimo rezultatai, keičiant parametrų kiekį	58

Lentelių sąrašas

1 lentelė. „ViSense“ sistemų parametrai	19
2 lentelė. „AutoSense“ įrenginių parametrai	21
3 lentelė. Algoritmų patikimumas bandant aptikti transporto priemones	23
4 lentelė. Gauti bandymo rezultatai viso vaizdo apmokymu	39
5 lentelė. Gauti rezultatai dominančiu vaizdo regiono apmokymu	39
6 lentelė. Apmokymo duomenų bazės vertinimas	40
7 lentelė. Gauti trečio klasifikatoriaus rezultatai	40
8 lentelė. Rezultatai, kertant 3 VAL linijas vienu metu	41
9 lentelė. Rezultatai, kertant bent 1 iš 3 VAL	41
10 lentelė. Statistinis aptikimo palyginimas	42
11 lentelė. Klasifikavimo rezultatai, po parametrų praplėtimo, imant visą vaizdą	43
12 lentelė. Klasifikavimo rezultatai, po parametrų praplėtimo, imant dominančio regiono vaizdą..	43
13 lentelė. Statistinis lengvojo automobilio požymių įvertinimas	44
14 lentelė. Statistiniai rezultatai lyginami tarp parametrų klasių	45
15 lentelė. Statistinė lentelė, keičiantis požymių skaičiui	47
16 lentelė. Sistemos statistinis įvertinimas	47

Paveikslų sąrašas

1 pav. Vaizdo kameros padėtis fiksuoti transporto priemonei [5].....	12
2 pav. Transporto priemonė kertanti VAL liniją [9]	13
3 pav. Daugialypiu metodo vaizdo apdorojimas: a) daugialypis vaizdas; b) kraštinių aptikimas; c) išskirtas vaizdas [9]	14
4 pav. a) transporto vaizdas; b) klasterizavimo metodu išskirtas transporto vaizdas rėmu [12].....	14
5 pav. Transporto klasifikavimas į klases pagal aptiktus parametrus [7].....	15
6 pav. Magnetinio lauko kitimas gretimoje ir negretimoje važiavimo linijose [17]	16
7 pav. a) Z ašies signalas; b) Z-ašies signalo kitimas atitinkamai slenkstiniam signalo lygiui [16].	17
8 pav. Analizuojama transporto priemonė ultragarsui esant horizontalioje padėtyje [20].....	18
9 pav. „ViSense: traffic Dynamics“ sistema [21].....	19
10 pav. a) nVDC įrenginys; b) programinė įranga klasifikuoti transportui [22].....	20
11 pav. „AutoSense“ AS615 detektorius ir klasifikatorius [23].....	20
12 pav. a) „Harris“ algoritmas; b) „Shi-Tomas“ algoritmas; c) FAST algoritmas [28].....	23
13 pav. a) išskirtas objektas iš aplinkos; b) nufiltruoti objekto triukšmai [37]	24
14 pav. SURF simetrinių požymių skyrimas [42]	25
15 pav. Automobilio HOG [45].....	26
16 pav. a) tiesinio pasiskirstymo modelis; b) netiesinio pasiskirstymo modelis [47]	27
17 pav. KNN algoritmo taikymas [50]	27
18 pav. Pirminis sistemos modelis	29
19 pav. Apdorotas transporto priemonės vaizdas	30
20 pav. a) ir b) išskirtos transporto priemonės, c) išskirta transporto priemonė ir dalis aplinkos.....	31
21 pav. Atspalvių radimo algoritmas.....	31
22 pav. „Canny“ metodu išskirtas objekto ribos	32
23 pav. Vaizdas ir jo atspalvio vidurkis	32
24 pav. Dominančio vaizdo išskyrimas	33
25 pav. Apdorotas vaizdas su „Canny“ algoritmu.....	34
26 pav. Vaizdas po HLF apdorojimo, 14 taškų linija.....	35
27 pav. HLF algoritmas	35
28 pav. VAL algoritmas	36
29 pav. Paruoštas galimas kandidatas	36
30 pav. Išklasifikuota transporto priemonė	37
31 pav. Sudarytas galutinis sistemos modelio algoritmas	37
32 pav. HOG parametro statistinis lyginimas tarp klasių.....	46

Santrumpų ir terminų sąrašas

Santrumpos:

2D – dvimatis

AMR – anizotropinis magneto-rezistyvus jutiklis.

GMM – Gauso „Mixture“ modelis.

HOG – orientuoto gradiento histograma.

FAST (angl. „*Features from Accelerated Segment Test*“) – Požymiais iš pagreitinato segmento testo.

HLF – horizontalios linijos filtras.

KNN – k-artimieji kaimynai.

SURF (angl. „*Speeded Up Robust Features*“) – Pagreitintos sutapties požymiai.

SVM – atraminių vektorių mašina.

VAL – virtuali aptikimo linija.

VDC (angl. „*Vehicle detections and classification*“) – transporto priemonių aptikimas ir klasifikavimas.

Terminai:

Klasifikavimas – tai tam tikrų objektų suskirstymas į tam tikras klases įvertinus, jų ir apmokytų objektų požymių panašumą, pritaikius mašininio mokymo algoritmus.

Transportas – tai priemonės padedančios žmonėms ar kroviniams įveikti tam tikrus atstumus iš vieno taško į kitą. Dažniausiai galimos transporto kategorijos yra motorinės: automobiliai, vilkikai, traukiniai, autobusai, laivai, ir nemotorinės: burlaiviai, dviračiai, parašiutai.

Mašininis mokymas – tai vienas iš dirbtinių intelekto metodų, kurio metu, be žmogaus įsikišimo duomenys yra analizuojami tam tikrais algoritmais. Taip sistemos gali pačios automatiškai mokytis iš naujų duomenų ar net nustatyti tinkamus sprendimus.

Įvadas

Šiomis dienomis judančių transporto priemonių skaičius keliuose yra gerokai padidėjęs. Lyginant su pastaraisiais 10 metų gerokai daugiau transporto priemonių įsigyja jaunesnio amžiaus žmonės. Taip pat matomas pokytis šeimose, seniau jos turėdavo tik po vieną motorinę priemonę, dabar galima suskaičiuoti po 2–3 transporto priemones beveik kiekvienoje šeimoje.

Ši kylanti transporto priemonių naudojimosi tendencija atneša daugybę privalumų, kurių seniau žmogus negalėjo sau leisti. Privalumai naudojantis transporto priemonėmis yra tai, kad žmonės gali nuvykti į norimas vietas, pvz., parduotuvę, darbovietę, mokymosi įstaigas, ligonines, kitus svarbius objektus, vykti į keliones ir t.t. Taip reikiamos vietos pasiekiamos greičiausiai sunaudojant mažiausiai laiko, kurį žmogus gali panaudoti kitiems svarbiems dalykams.

Nors turint transporto priemonę yra gaunama labai daug naudos, tačiau reikia nepamiršti, kad jos taip pat turi ir gausybę įvairių trūkumų. Viena iš problemų, su kuria yra susiduriama vairuojant transporto priemonę yra saugumas, taip pat paminėta tai, kad padaugėja eismo įvykių skaičius, susidaro spūstys, parkavimo problemos automobilių stovėjimo aikštelėse, laiko eikvojimas pasirinkus blogą maršrutą [1]. Patekus į vieną iš šių situacijų yra galimas pavojus savo arba aplinkinių gyvybei.

Norint išvengti šių problemų keliuose, reikia ištirti kokių ir kiek transporto priemonių yra važiuojamame kelio ruože. Taip galima sekti transporto srautus, kategorijas, iš kurių galima daryti prielaidas, spėjimus iš objekto judėjimo pobūdžio. Tam geriausiai tinka įvairios stebėjimo sistemos, kurios netrukdo žmogui vairuoti. Jomis geriausiai tinka įvertinti tam tikrus transporto parametrus pagal kuriuos galima skirstyti transporto priemones į tam tikras klases ir stebėti eismą, automobilių stovėjimo aikštelių vietų skaičių, parinkti saugų ir patogų maršrutą, perduodant duomenis į kitas sistemas. Taip iš nustatytų transporto priemonių galima priimti sprendimus, ką reikėtų pakeisti tam tikroje kelio dalyje, kad būtų užtikrinamas sklandus transporto judėjimas, sumažinantis pavojaus atsiradimo tikimybę. Taigi galima iškelti problemą: kiek, kokius parametrus ir kokią klasifikavimo metodą naudoti, norint tinkamai aptikti ir suskirstyti transportą į atitinkamas klases.

Darbo tikslas – identifikuoti judančias motorines transporto priemones ir atlikti klasifikavimą identifikuojant charakteringus parametrus.

Darbo uždaviniai:

1. apžvelgti taikymo būdus transporto priemonei nustatyti ir išsikelti mokslinę problemą;
2. atlikti metodų, kuriais gauti identifikuojami parametrai, analizę;
3. išanalizuoti rinkoje esančias identifikavimo sistemas;
4. įvertinti sistemų parametrus ir jų pasikliaujamumą;
5. sudaryti klasifikavimo modelį;
6. sudaryti modelio veikimo algoritmus;
7. pagrįsti sudarytą modelį eksperimentiniais bandymais.

1. Transporto priemonių klasifikavimo būdai

Siekiant išsiaiškinti kaip galima atlikti transporto nustatymą ir klasifikavimą, toliau bus nuosekliai aptarti būdai, išskiriantys ir identifikuojantys judantį transportą. Tokiose srityse, kaip transporto priemonių eismo judėjimo ir jo valdymo, sekimo, saugumo sistemose, spūsčių prevencijos ar avarijų išvengimo, reikia įvertinti kiek motorinių transporto priemonių ir kokių jų kategorijų yra kelyje. Taip gali būti sukuriama išmanioji eismo stebėjimo sistema, kuri suklasifikavusi šias priemones galėtų siųsti tam tikrą informaciją apie pasikeitusį eismą gatvėje arba leistų stebėti ir atlikti tam tikrus stebėjimus.

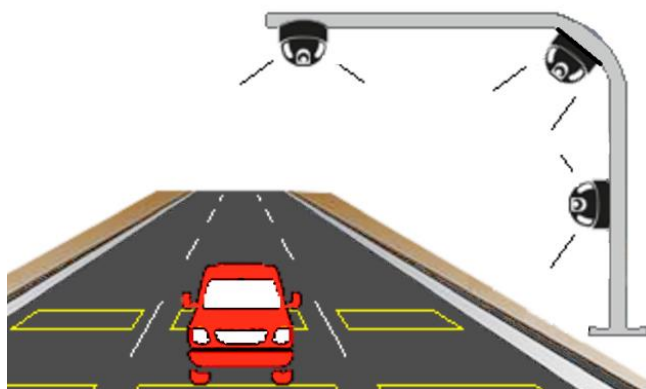
Tam padaryti geriausiai tinka tam tikrų, judančių transporto priemonių parametrų išskyrimas. Parametrus galima stebėti įvairius, tokius kaip greitis, pravažiavusių priemonių kiekis, ilgis, energija, atspindžius nuo paviršių, aukščio ir pločio įvertinimas. Norint surinkti ir įvertinti šiuos parametrus yra naudojama vaizdo kameros, ultragarsas, infraraudonieji ar magnetiniai jutikliai.

1.1. Transporto priemonių nustatymas ir klasifikavimas vaizdo kameromis

Vienas iš klasifikavimo būdų yra vaizdų apdorojimas. Šis būdas yra ganėtinai platus ir turi daug įvairių metodikų kaip galima išskirti transporto priemonių parametrus ir turint juos atlikti jų klasifikavimą ir nusakyti dabartinę padėtį tam tikrame kelio ruože. Norint identifikuoti motorines priemones vaizdų būdų reikia atlikti šiuos pagrindinius 7 etapus: 1) surinkti vaizdo duomenis; 2) segmentuoti vaizdus; 3) stebėti transporto priemonės regioną; 4) sekti transporto priemonę; 5) nustatyti jos parametrus; 6) vykdyti objekto identifikavimą; 7) paskirti klasę transporto priemonei [2, 3]. Atlikus šiuos etapus galima nustatyti motorinės transporto priemonės rūšį ir atitinkamai priimti tolimesnius sprendimus.

1.1.1. Duomenų rinkimas vaizdo kameromis

Pirmiausia reikia atlikti duomenų surinkimą, kuriais remiantis bus nustatomi parametrai ir suklasifikuojamos motorinės priemonės. Norint tai įvykdyti būtina vaizdo kameras išdėstyti atitinkamose padėtyse, pavyzdžiui, vaizdo kamerą galima įrengti iš viršaus, iš priekio, iš šono judančiai transporto priemonei. Taip pat gali būti įrengta taip, kad transporto priemonės vaizdas būtų gaunamas kampu (žr. 1 pav.) [4, 5].



1 pav. Vaizdo kameros padėtis fiksuoti transporto priemonei [5]

Tačiau, kai kurios iš šių vaizdo kamerų padėčių nėra efektyvios dėl didelio klaidų pasitaikymo tolimesniuose apdorojimo etapuose – segmentacijoje, parametrų nustatyme, todėl plačiausiai yra naudojama vaizdo kamera įrengta tam tikru kampu [6].

1.1.2. Objekto išskyrimo metodai


Turint vaizdą atliekami įvairūs segmentacijos metodai, kuriais nusakoma transporto priemonės parametrai. Vienas iš segmentacijos būdų yra laiko erdvinio vaizdo išskyrimas judančioms transporto priemonėms [7]. Šiuo segmentacijos metodu sukuriamas vaizdas yra pateikiamas pikselių rėmelių juosta ant virtualios aptikimo linijos (VAL) chronologine tvarka (žr. 2 pav.) [8].



2 pav. Transporto priemonė kertanti VAL liniją [9]

Atitinkamai kirtus šią liniją, vaizdų seka yra perdaroma į kitą – artimą 2D vaizdą, iš kurio pagal objekto vertikalų matmenį (plotį) galima spręsti, koks yra judančios priemonės greitis. Pagal horizontalų matmenį (ilgį) galima spręsti apie esamą judančio objekto plotį [9]. Taip pat šiuo metodu atliekamas kontūro išskyrimas užmaskuojant ir taip pašalinant aplinką. Tai leidžia geriau aptikti objekto parametrus. Siekiant tai atlikti yra naudojamas „Canny“ ar kitas kraštinių aptikimas, kuris atlieka erozijos iš išsiplėtimo operacijas su aptiktais objektais, kad segmentinis regionas atitiktų kiekvieną esantį objektą laiko erdviame vaizde.

Kitas panašus segmentacijos metodas yra daugialypės laiko erdvinio vaizdo metodas. Šis metodas labai panašus į prieš tai aptartą metodą, tačiau jis yra tikslesnis, todėl sumažėja klaidingų parametrų išskyrimas, nes transporto priemonei aptikti naudojama ne viena, o 2–3 ar daugiau VAL [10, 11]. Perėjus šias linijas atliekamas kraštinių aptikimas (žr. 3 pav. a)), aplinkos panaikinimas (žr. 3 pav. b) ir c)).



3 pav. Daugialypiu metodo vaizdo apdorojimas: a) daugialypis vaizdas; b) kraštinių aptikimas; c) išskirtas vaizdas [9]

Padidinus tikslumą pablogėja horizontalus matmuo, bet pagerėja vertikalus, kuris atitinka transporto priemonės plotį. Abiejų metodų esmė yra gauti atraminį vidurio tašką. Pagal jį atitinkamai yra perskaičiuojami transporto priemonės parametrai. Taikant šį metodą sumažinama transporto priemonės šešėlio įtaka parametru išskyrimui.

Kitas iš paminėtų metodų yra klasterizavimas. Jo metu atliekamas k -vidurkių (angl. „*k-means*“) klasterizavimas, kurio metu yra išskiriami norimo vaizdo parametrai. Atliekant šį metodą dažniausiai analizuojama prekinė transporto priemonės dalis. Taip turimam vaizdui (žr. 4 pav. a)) atliekamas dydžio pakeitimas bei konvertavimas į pilką vaizdą. Toliau atliekama segmentacija. Ji atskiria aplinką, taip paliekant tik tiriamosios transporto priemonės regioną [9, 12]. Iš turimo regiono atliekamas objekto kraštinių aptikimas, iš kurių suradus minimalius ir maksimalius taškus uždedamas rėmas (žr. 4 pav. b)).



4 pav. a) transporto vaizdas; b) klasterizavimo metodu išskirtas transporto vaizdas rėmu [12]

Šio metodo trūkumas lyginant su prieš tai pateiktais metodais yra tai, kad jis yra dvimatis vaizdų apdorojimo metodas ir vaizdo kameros kampas nėra vertinamas, kas galėtų lemti blogesnius rezultatus. Tačiau šis apdorojimo procesas yra greitesnis lyginant su aptartais.

1.1.3. Klasifikavimas pagal išreikštus požymius

Pagal aptartus vaizdų išskyrimo metodus galima identifikuoti tam tikrus parametrus ir spręsti kokia yra transporto rūšis.

Laiko erdvinio ir daugialypio laiko erdvinio metodais transporto parametrai gaunami pagal atraminį vidurio tašką ir vertikalų ilgį, pagal juos uždedamas tam tikras rėmas ant objekto. To rezultatas tai, kad visi požymiai apie objektą yra gaunami iš uždėto rėmo. Gaunamas plotis yra aproksimuojamas pagal segmentavimo regioną, gauti tikram ilgiui. Plotas nusakoma kiek yra pikselių išskirtame segmente. Kompaktiškumo požymiu įvertinamas segmentinės dalies ploto santykis su apskritimo formos perimetru [9]. Galimas ir stačiakampių panašumo įvertinimas lyginant jo kraštinių panašumus su kitų transporto priemonių segmentais.

Klasterizavimo metu naudojamas mašininis mokymas, kurio rezultate iš apdoroto vaizdo segmento gauti duomenys lyginami tarpusavyje su sudaryta duomenų baze [13]. Turima duomenų bazė turi būti sudaryta iš įvairių transporto priemonių duomenų. Panaudojant šį vektorių metodo palyginimą, atrenkama panašiausias parametrus turinti transporto priemonė ir parenkama jos klasė [14]. Taip atrinkus kuo daugiau panašių požymių bus vykdomas tikslesnis motorinės transporto priemonės klasifikavimas.

Taip atlikus parametrų palyginimus galima nustatyti tam tikras transporto klases (žr. 5 pav.): dviratis arba motociklas (1 klasė), automobilis arba pikapas (2 klasė), krovininis sunkvežimis, sunkvežimis, autobusas, furgonas (3 klasė) [15].



5 pav. Transporto klasifikavimas į klases pagal aptiktus parametrus [7]

1.2. Transporto priemonių klasifikavimas magnetinio jutiklio signalu

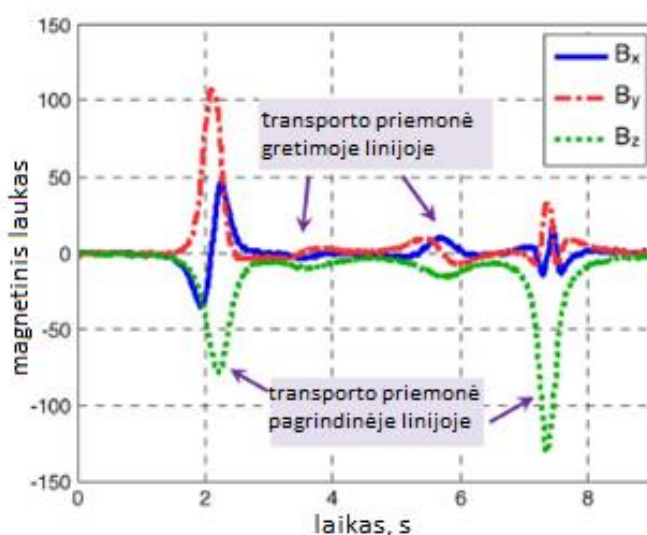
Be vaizdų apdorojimo būdų yra ir dar vienas labai paplitęs transporto priemonių klasifikavimo metodas anizotropiniu magneto-rezistyviniu jutikliu (AMR). Tokias matavimo sistemas dažniausiai sudaro AMR jutikliai, kurių pasirinktinai gali būti nuo 1 iki 4 ar daugiau ir duomenų apdorojimo įrenginys. Tokių jutiklių sistema gali būti įtaisyta transporto priemonių važiuojamoje kelio dalyje arba šalia jos matuojant gretimą eismo juostą [16]. Su AMR sistemomis galima įvertinti judančių objektų greitį, jų ilgį ir kitus parametrus. Pagal rastus dydžius tokios sistemos dažniausiai naudojamos automobilių stovėjimo aikštelėse, norint suskaičiuoti užimtas vietas, šviesoforams reguliuoti, kur

eismas viena kryptimi yra intensyvus arba priešingai, neintensyvus. Taip pat anksčiau minėtose situacijose.

1.2.1. ARM jutiklio metodas

Šio metodo principas yra keisti magnetinį žemės lauką, kai jutiklis yra kertamas judančios transporto priemonės. Taip atsiranda trumpi magnetinio lauko kitimo signalai, kurie iš karto perduodami į apdorojimo įrenginį, kuriame atliekami skaičiavimai. Duomenys perduodami todėl jog signalas yra ganėtinai trumpo laiko, ir todėl nespėjama jį apskaičiuoti pačiame įrenginyje arba gaunamas naujas signalas. Taip dėl daugybės atliekamų skaičiavimų duomenys gali pakisti ir signalas neapdorojamas arba įvedama klaida [17].

Naudojantis šiais AMR jutikliais dažniausiai matavimai atliekami visomis trejomis X, Y ir Z ašimis, kur X ašis atitinka transporto priemonės judėjimo ašį, Y ašis atitinka statmenį važiavimo priemonės kryptį, o Z ašis statmena kelio dangai [18]. Kaip kinta magnetinis laukas esant jutikliui, padėtam greta linijos pravažiuojant dviem skirtingomis linijomis, pavaizduota 6 paveiksle.



6 pav. Magnetinio lauko kitimas gretimose ir negretimose važiavimo linijose [17]

Akivaizdu, kad magnetinis laukas taip pat keičiasi, kai transporto priemonė yra užfiksuojama ir kitoje juostoje. Taip užfiksuotas signalas gali būti netinkamai apskaičiuotas ir todėl bus gaunami blogi parametrai bei bus klaidingai klasifikuota transporto priemonė. Siekiant tai išvengti reikia manyti, kad gretimose juostoje judantys objektai nekelia AMR sistemai klaidų arba jas reikia atitinkamai įvertinti.

1.2.2. Signalų požymių įvertinimas ir klasifikavimas

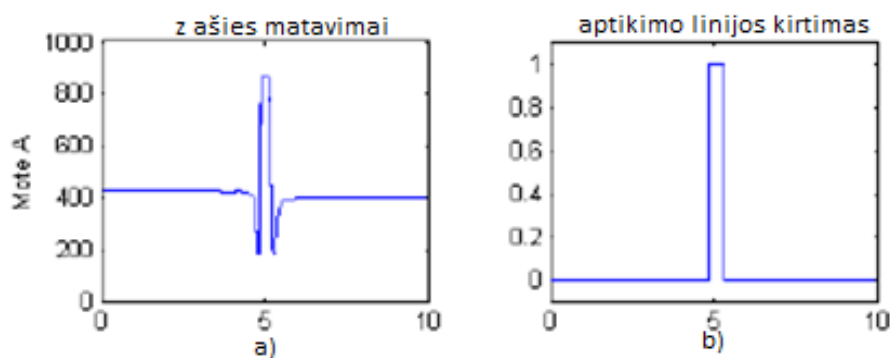
AMR jutikliais galima įvertinti santykinį judančio objekto ilgį pagal (1) formulę, kuri remiasi signalo ilgio ir numatomo transporto priemonės ilgio.

$$L = \frac{M}{L_d}; \quad (1)$$

čia L – santykinis judančio objekto ilgis; M – signalo ilgis; L_d – numatomas transporto priemonės ilgis.

L_d įvertinamas pagal nulio-kirtimo taškus arba pagal vėlavimo atskaitų skaičių tarp dviejų AMR jutiklių. Pagal esamą ilgį galima spręsti, kokiai transporto priemonių klasei juos galima priskirti.

Kitas parametrų matavimo metodas yra pritaikant „*Hil-Pattern*“ pikų aptikimą. Šiuo metodu parametrai išgaunami iš X ir Z ašių magnetinio lauko signalo (žr. 7 pav. a)). Turint gautus dviejų ašių signalus juos atskirai lyginame su slenkstinėmis ribomis (diskretizavimo dažnis abiem atvejais vienodas). Jeigu signalas pasiekia slenkstinę teigiamą ribą priskiriama +1 lygio reikšmė (žr. 7 pav. b)), jeigu pasiekiamą slenkstinę neigiamą ribą, priskiriamas -1 lygio reikšmė [17].



7 pav. a) Z ašies signalas; b) Z-ašies signalo kitimas atitinkamai slenkstiniam signalo lygiui [16]

Dar vienas metodas, kaip būtų galima klasifikuoti transporto priemones yra diferencialinis energijos skaičiavimas. Taip pravažiuojant automobiliui ar kitai priemonei, magnetinis laukas padidėja ir atsiranda energijos pokytis. Šis metodas tinkamas, kai judėjimo greitis yra pastovus. Normalizuota energija (2) paskaičiuojama pagal diferencinį magnetinio lauko sumos didumo M_n^m sandaugą su objekto greičiu esant tam tikram diskretizavimo periodui ir santykiniam ilgiui [16].

$$E_{norm} = \frac{vt_s \sum M_n^m}{L}; \quad (2)$$

čia E_{norm} – normalizuota energija; v – objekto greitis; t_s – diskretizavimo dažnis; M_n^m – magnetinio lauko didumas.

Taigi įvertinant visus signalus ir lyginant juos su jau ištirtais, galima klasifikuoti judančius objektus į atitinkamas grupes. Taip atliekamas signalų panašumo palyginimas ir iš jų sprendžiama kokiai transporto klasei galime priskirti pravažiuojančią priemonę. Jų klasifikavimas yra, kur kas efektyvesnis negu turint tik vieną iš aptartų parametrų. Taip išgaunamas didesnis tikslumas, tačiau lyginant su ankstesniu vaizdų apdorojimo metodu juo daroma klasifikavimo klaida yra kur kas didesnė.


1.3. Transporto priemonių aptikimas ir klasifikavimas ultragarsu

Taip pat gerai žinomas aptikimo būdas yra naudojant ultragarso sistemą. Ši sistema gali būti įmontuota horizontaliai, vertikaliai ar specialiu kampu. Iš tam tikros pozicijos įrenginys skleidžia ultragarso bangas, kurios nustačiusios judantį objektą nuo jo atsispindi ir sugrįžta į įrenginio imtuvą. Imtuve gaunamas atsispindėjęs signalas, kurį galime matyti laikinėje srityje, kuris atsikartoja kas tam tikrą periodą. Taip galima spręsti, kada objektas yra aptinkamas ir kada ne ir nustatyti jo ilgį, greitį, dydį.

Vienas iš svarbiausių ultragarso parametrų yra ultragarsinis greitis (3). Iš formulės matyti, kad greitis priklauso nuo temperatūros, todėl matavimuose geriausiai yra naudoti papildomą jutiklį, kuris matuotų oro temperatūrą [19].

$$v = 331,5 + (0,61 * \text{temperatūra}); \quad (3)$$

Iš gautų parametrų galima apskaičiuoti bendrą atstumą (objekto plotį) be vieno iš aplinkos veiksnių. Taip pat svarbus dalykas sumažinti paklaidas dėl suvartojamos prietaiso energijos, todėl geriausia pasirinkti atstumą, kad atspindžio intervalas nebūtų per daug dažnas ir nebūtų per daug ilgas, kitaip gali atsirasti klaidų aptikimas klasifikuojant transporto priemonę [20]. Taigi sprendžiant šią problemą geriausia ultragarso įrenginį padėti horizontalioje padėtyje (žr. 8 pav.), kad atspindys kristų daugiausiai nuo lygesnio ir mažiau kintančio paviršiaus. Taip vertinamas transporto ilgis yra kur kas tikslesnis negu kintant didesniai atstumui iki objekto.



8 pav. Analizuojama transporto priemonė ultragarsui esant horizontalioje padėtyje [20]

1.4. Analizės apibendrinimas

Atliktoje literatūros šaltinių analizės dalyje aptarti trys dažniausiai naudojami judančių transporto priemonių parametrų identifikavimo metodai: vaizdų apdorojimas, ARM jutiklis ir ultragaras. Aptarus parametrus ir jų apdorojimui reikiamus algoritmus pastebėta, kad vienas iš populiariausių ir mažiausią paklaidą turinčių metodų klasifikuoti transporto priemones yra vaizdų apdorojimas. Po vaizdų apdorojimo seka AMR jutikliai, kurie taip pat naudojami įvairiose transporto aptikimo srityse. Blogiausiai ir daugiausiai įtakos klaidos aptikimui klasifikuojant objektus gaunama su ultragarsu dėl didelės įtakos iš aplinkinių veiksnių. Todėl šiame tyrime pasirinkta transporto identifikavimo sistemą tirti vaizdų apdorojimo metodu.

2. Rinkoje siūlomos judančių transporto priemonių klasifikavimo sistemos

2.1. „ViNotion“ judančių objektų aptikimo sistemos.

„ViNotion“ tai viena iš daugumos kompanijų, kuri užsiima vaizdų apdorojimu sekant judančius objektus. Naudodama novatoriškas technikas, tokias kaip mašininis ir gilusis mokymas, sukuriama programinė įranga, kuri sugeba automatiškai aptikti ir klasifikuoti objektus realiu laiku [21].

Ši kompanija siūlo keturis produktus objektams aptikti: „ViSense: crowd Dynamics“, „ViSense: traffic Dynamics“, „ViSense: urban Dynamics“ ir „ViSense: maritime Dynamics“ [21]. Šios sistemos geba klasifikuoti objektus nuo žmonių iki laivų. Visų sistemų specifikacijos pateikiamos 1 lentelėje.

1 lentelė. „ViSense“ sistemų parametrai

Parametrai	„ViSense“ Sistemos			
	„Crowd Dynamics“	„Traffic Dynamics“	„Urban Dynamics“	„Maritime Dynamics“
Klasifikacija	Žmonės, dviračiai	Transporto priemonės	Žmonės, dviračiai ir transporto priemonės	Laivai
Skaičiavimo plotis	18 m.	4 eismo juostos	30 m.	500 m.
Realaus laiko	Taip	Taip	Ne	Ne
Kameros aukštis	6–10 m.	9–12 m.	6–10 m.	12–30 m.
Skyra	1280x720	1280x720	1920x1080	1920x1080
Kadrų skaičius	25–30	25–30	25–30	25–30

„ViSense: traffic Dynamics“ sistema (žr. 9 pav.) skirta eismo stebėjimu, kuri paremta mašininis ir giliu mokymu. Pati sistema naudoja tik vieną aukštos kokybės kameros jutiklį ir energiją taupantį analizuojantį bloką. Sistema klasifikuoja visas pravažiuojančias transporto priemones, jų modelius ir markes, skaičiuoja jas ir jų greitį.




9 pav. „ViSense: traffic Dynamics“ sistema [21]

Prietaisas turi programinę įrangą, kuri leidžia valdyti sistemas. Labiausiai naudojama keliuose eismo valdymui, įvertinant transporto greitį, važiavimo pokyčius, spūstis. Klasifikavimo pagrindu sistema leidžia nustatyti kelio rinkliavos normas, atsižvelgiant į tai koks transportas važiuoja. Taip pat nusikaltimams mažinti panaudojant numerių atpažinimą bei iškart klasifikuojant judančio transporto modelį.

2.2. Judančio transporto aptikimo „Kapsch TrafficCom“ sistemos

„Kapsch TrafficCom“ tai dar vienos kompanijos naujai sukurtos transporto aptikimo sistemos. Jos transportą gali aptikti ne vien vaizdo kameromis, bet ir infraraudonųjų spindulių ar lazerio skenavimu, magnetinės indukcijos ir infraraudonaisiais jutikliais bei svėrimo judant (angl. „weigh-in-motion“) jutikliais, registruojant transporto ašių svorius [22].

„Kapsch TrafficCom“ nVDC (angl. „*Vehicle detections and classification*“) sistema skirta nustatyti, sekti, klasifikuoti realiu laiku. Didelis šios sistemos privalumas yra tai, kad įrenginys gali tinkamai funkcionuoti visose eismo sąlygose, neatsižvelgiant kokios yra oro sąlygos. Kameros sistemos sudarytos iš trimačio srautinio vaizdo jutiklio, procesoriaus, kuriuo yra aptinkamos ir nustatomos transporto srauto juostos ir infrarodinio apšvietimo. Sistema (žr. 10 pav.) matuoja transporto profilį įskaitant ilgį, plotį, aukštį, taip pat greitį, aptinka ašis [23].



10 pav. a) nVDC įrenginys; b) programinė įranga klasifikuoti transportui [22]

Šis prietaisas turi 30 metrų matymo lauką ir gali susidoroti su 25 metru pločio keliu. Kadangi ji naudoja srautinį vaizdo įrašą ir duomenys perduodami internetu giga-bitine sparta, galima atlikti detalesnę vaizdų analizę ir nustatyti skirtumus tarp konkrečių transporto priemonių pavyzdžiui, autobusai, sunkvežimiai ir transporto priemonės su priekabomis. Didžiausias šios sistemos privalumas yra tai, kad jai nesvarbu ar eismas vyksta greitai ar visiškai sustojęs ar keičiamos juostos ar yra susiliejimų (transporto priemonė šalimai kitos).

Pasinaudojant kompanijos sukurta programine įranga, sekimas yra kur kas paprastesnis, kai yra atliekami įvairūs apdorojimo algoritmai. Taip pat yra galimybė tiesioginį vaizdą įrašyti, jeigu pasitaikytų įvairūs autoįvykiai.

2.3. „AutoSense“ transporto aptikimo sistemos

Remiantis transporto ilgiu, pločiu, aukščiu, profiliu, tūriu „OSI LaserScan“ firma siūlo „AutoSense“ įrangą objektų aptikimui ir klasifikavimui. Šie įrenginiai sudaryti iš dvigubų lazerinių spindulių, kurių skenavimo dažnis 360 kartų per sekundę. Tai leidžia sistemai užtikrinti ganėtinai didelį tikslumą ir užtikrintai aptikti transporto priemones net greitkeluose. Turint didelį našumą sistema gerai veikia atviroje aplinkoje.

Pagrindinė „AutoSense“ (žr. 11 pav.) savybė yra tai, kad nustatant priemones atliekamas pikselių persidengimas, kuris leidžiama aptikti net velkamas standžias transporto jungtis (traukiamas automobilis, automobilis su priekaba).



11 pav. „AutoSense“ AS615 detektorius ir klasifikatorius [23]

Ši įmonė siūlo didelį pasirinkimą tarp vienos juostos su 30–35 laipsniais matymo lauku arba dviejų juostų su 60 laipsnių matymo lauku įrenginius. Dažniausi šie įrenginiai statomi virš važiujamo transporto ruožo, kad atitinkamas modelis galėtų tinkamai jas identifikuoti [24]. Tačiau jeigu norima naudoti vieną įrenginį nustatant transportą dvejose juostuose, dėl esamo kampo automobilis sistema atpažįsta, kaip sunkvežimius. 2 lentelėje pateikiama šio gamintojo skirtingų įrenginių parametrai.

2 lentelė. „AutoSense“ įrenginių parametrai

Parametrai	„AutoSense“ įrenginiai		
	AS618-UDH [25]	AS825-EDH [26]	AS9390 [27]
Naudojama juostose	Vienos juostos	Kelių juostų	Kelių juostų
Statoma padėtis	5,9–7,6m.	7,6–9,2 m.	5,5–9,2 m.
Matymo laukas	35°	60°	90°
Klasifikavimo kategorijos	11	11	–
Aptikimo tikslumas	>99 %	>99 %	>99 %
Identifikavimo tikslumas	>95 %	>95 %	–
Maitinimo įtampa	90–140 V	200–264 V	24 V
Svoris	9,3 kg	13,1 kg	5,4 kg
Duomenų sąsajos	RS–422	RS–422	RS–422, RJ–45

Šių sistemų transporto aptikimo tikslumas labai didelis, kas užtikrintai leidžia realiu laiku stebėti ir vertinti eismą ir nustatyti kokių ir kiek objektų buvo aptikta. Tačiau didžiausia problema yra tai, kad jos neatspaus dideliems aplinkos pokyčiams.

2.4. Apibendrinimas

Aptarus trijų gamintojų kuriamas sistemas, pastebėta, kad visos yra ganėtinai skirtingos su tam tikromis metodikomis. Vienos naudojasi tik vaizdų aptikimu ir nuo aplinkos pokyčių mažai priklauso. Kitos identifikavimo sistemos naudojasi tiek magnetiniais, infraraudonaisiais jutikliais ar lazerio skenavimu. Visos sistemos ganėtinai stabilios ir transportą klasifikuoja atsižvelgiant pagrinde į aptiktą, ilgį, plotį, aukštį ir tūrį. Visos geba nustatyti jų greičius ir srauto kieki.

3. Sistemų parametrai ir klasifikatoriai, kuriais skirstomos transporto priemonės

Kameros reaguoja į vietinius pikselių lygio ryškumo pokyčius tuo metu, kai jų pokytis yra ganėtinai didelis. Šie pokyčiai apibūdinami, kaip įvykiai, kurie perduodami ir pažymimi laiko tikslumu. Vaizdų apdorojime yra nemažai algoritmų, kuriuos pritaikius galima išskirti transporto priemonėms tam tikrus parametrus, pagal kuriuos galima atskirti, būtent kur ji yra. Taip pat pagal šiuos būdingus požymius lengviau atitinkamai suskirstyti transporto priemones į tam tikras klases pritaikius mašininio mokymo klasifikatorius arba dirbtinį intelektą.

3.1. Galimi sistemų parametrai

3.1.1. Kampų išskyrimo požymiais

Vienas iš galimų požymių išskyrimų yra kampų aptikimas, kai pritaikant tam tikrus algoritmus iš pikselių nustatomas kampas. Kaip pavyzdys automobilių kampų požymiams nustatyti gali būti naudojami trys algoritmai: „Harris“ kampų algoritmas, „Shi-Tomasi“ algoritmas ir „Požymiais iš pagreitinto segmento testo“ (angl. *Features from Accelerated Segment Test* – FAST) [28].

„Harris“ kampų algoritmu yra skaičiuojamas kiekvienas pikselis, kuris nusako kampo pasirinkimo kriterijų. Šio metodo idėja yra aptikti taškus atsižvelgiant į kitimą ties gretimais taškais. Tai reiškia, kad mažame regione ties norimu objektu (kampu) turi būti didelis intensyvumo pokytis [28, 29]. Taip parenkamas pikselis bus pažymimas, kaip tikrasis pikselis jeigu atitinkama reikšmė kirs tam tikrą vertės ribą. Pagrindinės formulės skaičiuojant ribą, kuri kerta slenkstinę vertę.

$$R = \det M - k(\text{trace} M)^2; \quad (4)$$

$$\det M = \lambda_1 \cdot \lambda_2; \quad (5)$$

$$\text{trace} M = \lambda_1 + \lambda_2; \quad (6)$$

čia R – kampo atsako funkcija; $\det M$ – įstrižainės reikšmių λ_1 ir λ_2 determinantas; $\text{trace} M$ – tiesinis, kvadratinės matricos pėdsakas, apibrėžiantis pagrindinę įstrižainę.

Naudojant šį metodą dažniausiai pritaikomi penki kriterijai: 1) spalvos keitimas į pilkų atspalvių lygį, skaičiavimas greičiui paspartinti; 2) erdvinių išvestinių skaičiavimas; 3) struktūros tenoro nustatymas; 4) atsako skaičiavimas; 5) ne maksimalus slopinimas, kuriuo parenkamos optimalios kampų reikšmės [30].

Kitas metodas yra „Shi-Tomasi“ kampų aptikimas. Šis metodas yra gana panašus į prieš tai minėtą, nes kilo būtent iš „Harris“ kampų aptikimo algoritmo [31]. Tačiau pagrindinis skirtumas tarp jų yra, tai kad paimamas visai kitas kriterijus, kas lėmė jo geresnį veikimą lyginant su pirmtaku. Sritis, nesvarbu kuria kryptimi yra daug esminių pokyčių, todėl ar pikselis yra tikrasis galima naudoti tik ribines vertes.

$$R = \min(\lambda_1, \lambda_2); \quad (7)$$

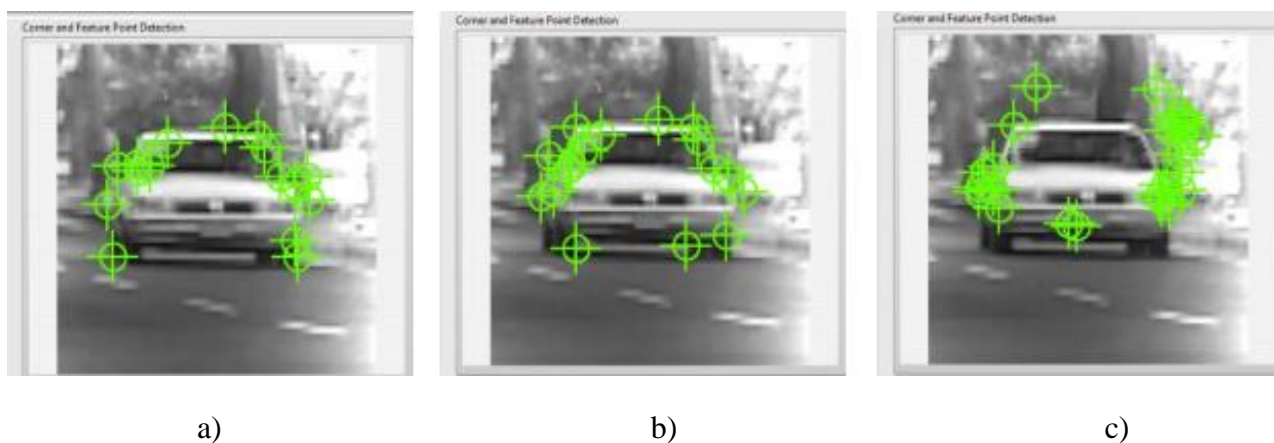
čia R – kampo atsako funkcija, imant įstrižainių matricos λ_1 ir λ_2 reikšmes.

Taip šiuo metodu randamų taškų kiekis yra daug mažesnis negu prieš tai buvęs ir leidžia daugiau išlaikyti objekto formą ir sumažinti skaičiavimų kiekį [32]. Tai pritaikius automobilių nustatyme

galima surasti pagrindinius taškus. Iš jų išsaugojant kiekvienos klasės duomenis galima bandyti vykdyti klasifikavimą.

Trečias iš metodų yra FAST kampų aptikimas, kuris naudojamas mašiniųjų mokymų problemoms spręsti. Šio metodo privalumas, tai kad jis greičiausias iš minėtų ir jį galima pritaikyti realaus laiko sistemose [33, 34]. Pagrindinis dalykas tas, kad kampas yra nusakomas iš 16 pikselių apskritimo ir randamas jo centre. Šis centras nutolęs per 3 pikselius ir dar vadinamas „Bresenhamo“ apskritimu. Metodo esmė yra kiekvieną pikselį apskritime lyginti su nurodytų pikselių apskritimo reikšmėmis ir tikrinti ar turimo pikselio pilkumo intensyvumas yra drastiškai mažesnis arba didesnis už nurodytų pikselių slenkstines reikšmes. Taip iš karto yra nustatomas kampas. Norint paspartinti programos veikimą nebūtinai reikia imti visus 16 taškų, galima imti ir mažiau, nuo 9 iki 12 taškų [35].

Taigi pritaikius šiuos algoritmus transporto priemonėms nustatyti galima gauti tokius kampų požymius (žr. 12 pav.). Turint atitinkamą duomenų bazę, mašiniųjų mokymą arba neuroninius tinklus galima atlikti klasifikavimą [36].



12 pav. a) „Harris“ algoritmas; b) „Shi-Tomasi“ algoritmas; c) FAST algoritmas [28]

Taip pat metodų patikimumas išbandytas su dirbtiniu neuroniniu tinklu pateikiamas 3 lentelėje. Apmokant sistemą pirmais dviem būdais rezultatai buvo prastesni negu ją bandant lyginti su trečiuoju metodu. Nors ir greičiausias ir patikimiausias metodas yra FAST kampų aptikimas. Tačiau galima pastebėti, kad daugiau specifinių kampų randama ne ant objekto, o ant aplinkos.

3 lentelė. Algoritmų patikimumas bandant aptikti transporto priemones

	Algoritmų pavadinimai		
	„Harris“	„Shi-Tomasi“	„FAST“
Apmokant	88,86 %	86,86 %	91,14 %
Testuojant	89,09 %	88,48 %	90,3 %


3.1.2. Gauso „Mixture“ Modelis

Kitas metodas, kuriuo galima nustatyti transporto priemones yra Gauso „Mixture“ modelis. Tai daugiau tikimybinis modelis leidžiantis užtikrinti, kad visi duomenų taškai bus sugeneruojami sumaišant baigtinį skaičių Gauso (normaliųjų) pasiskirstymų su nežinomais parametrais. Daugumoje manoma, kad tai atitinka k -reikšmių klasterius, kuriais siekiama įtraukti informaciją apie duomenų struktūrą ir gauti Gauso centrą [37].

Gauso modelis yra žinomas, kaip praktiškai vienas tiksliausių metodų aproksimuojant vaizdo pikselius. Kiekvienas iš šių pikselių yra pakankamas, kai vaizdo elementas sudaromas į vieną paviršiaus elementą. Laikui kintant modelis gali būti atnaujinamas, todėl nepatartina naudoti tik vieno Gauso „Mixture“ modelio ir paprastai naudoti reikėtų nuo 3 iki 5 modelių [38]. Kiekvienas iš jų rodo triukšmo pasiskirstymą, todėl naudojant daugiau Gauso modelių reikia mažesnės atminties ir mažiau laiko skaičiavimams atlikti. Pirmiausia metodas pritaikomas fono išskyrimui, o kai į jį patenka kitas vaizdas (transporto priemonė), Gauso modelis greitai reaguoja ir sugeneruoja potencialius taškus dominančiam vaizdui.

Algoritmą galima pritaikyti ir judantiems objektams, kai kiekvienas kadras atitinkamai apskaičiuojamas. Tačiau dauguma GMM pagrįstų metodų kenčia dėl riboto triukšmo patikimumo, per didelio sklaidumo segmentų atžvilgiu ir trūkstamo lankstumo pritaikyti duomenis.

Pikseliai, kurių panašumo vertės mažesnės už standartinį nuokrypį ir didžiausią svorio koeficientą, laikomos fonu, o pikseliai su didesniu standartiniu nuokrypiu ir mažesniu svorio koeficientu laikomi pagrindiniais. Atsižvelgus į transporto priemonių aptikimą, kai pikselio spalva atitinka aplinkos fono spalvą, tai priskiriama nulinė reikšmė (juoda spalva). Jeigu atsiranda objektas fone tai vaizdas bus naujai gautas ir jam suteikiama vieneto reikšmė (balta spalva). Taip praktiškai gaunama baltai juodas vaizdas [39]. Baltas plotas po šio apdorojimo nėra visiškai geras ir reikia jį papildomai apdoroti filtrais nuslopinant nereikalingus objektus. Aptikta judanti priemonė yra ne tik vientisas baltas fonas, o susidarantis ir iš skylių (žr. 13 pav.). Pritaikomas skylių užpildymas, kuriuo nufiltruojamas objekto pikselių triukšmas. Tokių sistemų, kurios naudoja būtent Gauso „Mixture“ modelį patikimumas gali būti įvairus, nuo 85 iki 95 %.



13 pav. a) išskirtas objektas iš aplinkos; b) nufiltruoti objekto triukšmai [37]


Turint išskirtą transporto priemonę ją atitinkamai galima apdoroti uždedant ribą – regiono kvadratą. Tai leidžia nusakyti pirminį transporto priemonės ilgį ir plotį, pagal kuriuos galima klasifikuoti į atitinkamas grupes.

3.1.3. Pagreitinotos sutapties požymiai

Pagreitinotos sutapties požymiai (angl. *Speeded Up Robust Features – SURF*) yra greitas ir patikimas algoritmas objektų vaizdų panašumams nusakyti ir juos atitinkamai įvertinti. Pagrindinis metodo tikslas yra greiti operacijų skaičiavimai, kuriais realizuojamos realaus laiko programos, vykdomi stebėjimai ir objektų atpažinimai.

Objektams aptikti šiuo metodu labiausiai naudojama tam tikro vaizdo pikselių vertės arba stačiakampio tinklelio pogrupis [40]. Iš jo apskaičiuojama vidutinis vaizdo intensyvumas ir pateikiamas kaip vienas iš vaizdo požymių. Vaizdo požymiams nustatyti atliekami du etapai. Pirmuoju žingsniu yra atkuriamas orientuotas fiksavimas remiantis informacija iš apskritimo regiono aplink tam tikrą tašką. Tam naudojami „Haro“ bangelių atsakai [41]. Antras žingsnis yra daromas kvadrato plotas, suretintas su pasirinkta orientacija ir skaičiuojama vertikalių ir horizontalių bangelių atsakas į skenuojamą plotą. Po to iš kvadrato ištraukiama atitinkama SURF informacija.

Su šiuo metodu naudojamas ir simetriškas SURF detektavimas (žr. 14 pav.). Tai leidžia vienoje pusėje suskaičiuoti ir rasti naudingus požymius ir pritaikant veidrodžio atspindį juos perkelti į kitą vaizdo pusę. Jeigu tie taškai sutampa, vadinasi tai vienas iš pagrindinių taškų. Histograma nusakoma ar sutapusi taškų pora sutampa su norimu požymio centru [42]. Turint kitą vaizdą arba panašų į jį atliekamas prieš tai surastų požymių aptikimas ir pagal norimą kiekį galima spręsti ar objektas buvo aptiktas ar ne.



14 pav. SURF simetrinių požymių skyrimas [42]

Kaip matyti iš prieš tai pateikto paveikslo, pritaikius šiuos požymius geriausiai galima aptikti transporto priekinę ir galinę dalį. Atitinkamai, pagal simetrinius SURF parametrus, sudarius duomenų bazę ir pritaikius mašininį mokymą galima transportą klasifikuoti į grupes. Netaikant simetrinio, o naudojant tik SURF galimas variantas klasifikuoti iš įvairių pusių. Pritaikant šį požymių aptikimą galimas patikimumas iki 93 %.


3.1.4. Orientuoto gradiento histograma

Dar vienas platus būdas objektų požymiams nustatyti naudojama histogramos. Jų gali būti įvairių: orientuoto gradiento histograma (HOG), kraštinių orientuota histograma. Plačiau naudojama tik HOG, nes ja gaunamas tikslesnis rezultatas.

HOG labiausiai naudojama, kai reikia iš vaizdo kamerų išgauti duomenis įvertinant kitimo kampą. Didžiausias dėmesys yra skiriamas objekto struktūrai arba formai [43]. Jo didžiausias privalumas, lyginant su kraštinių požymių aptikimu yra tai, kad jis parodo objekto formos kryptį, paimant krašto nuolydį ir kur jis orientuotas, kas lemia didesnę tikslumą. Orientacijai gauti apskaičiuojamas vaizdo

gradientų orientacijos vietos histogramos tinklelyje. Dažniausiai vaizdas yra skaidomas į apdorojimo langelius nuo 8x8 ir didesnius. Taip kiekvienam langeliui paskaičiuojamas kiekvieno pikselio orientacijos histograma [44]. Iš turimų langelio histogramų atliekamas normalizavimas, kuriuo sutraukiamos panašios išsidėstymo struktūros į didesnes struktūras, kas palengvina ir pagreitina skaičiavimus. Kiekvienai sudarytai struktūrai randamas pagrindinis orientuotas blokas [45, 46]. Taip kiekvienos eilutės ir stulpelio pikselių skaičius kiekvienoje ląstelėje, kiekvienam gradientui, kuriam apskaičiuojama histograma. Tačiau didesnė paklaida gaunasi pačios formos aptikime. Jas įvertinus ir pritaikius mašininį mokymą klasifikatoriais ar neuroniniais tinklais, tokių sistemų patikimumas siekia iki 98 % [46].

Pritaikytas HOG metodo vaizdas atrodyto kaip 15 paveiksle.



15 pav. Automobilio HOG [45]

3.2. Transporto klasifikavimo metodai

Klasifikavimas yra ganėtinai didelė problema nustatant, kuriai iš kategorijų gali priklausyti naujai stebimas objektas. Šiai problemai spręsti tinkama naudoti tam tikrus mokymo rinkinius – duomenų bazes, su kuriomis pritaikius mašininio mokymo ar statistinius algoritmus galima automatiškai priimti sprendimą, kuris narys priklauso ar nepriklauso reikiamai kategorijai.

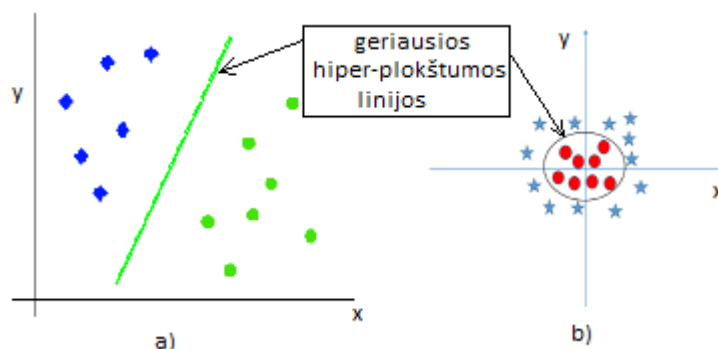
Sudarant transporto sistemos modelį, taip pat reikia naudotis bent vienu iš mašininio mokymo algoritmų, todėl keletas jų aptariama ir pritaikoma sistemos įgyvendinime

3.2.1. Atraminių vektorių mašininis klasifikatorius

Atraminių vektorių mašininis (angl. „*support vector machine*“ – SVM) klasifikatorius yra vienas iš populiariausių tarp mašininio mokymo algoritmų sprendžiant įvairius klausimus susijusius su automatinio sprendimo priėmimu. Šis algoritmas tinkamas naudoti ne tik esant dviejų kategorijų duomenų skirstymui, bet ir esant daugiau kategorijų ar kuriant sunkius mašininis modelius [47].

Šio metodo veikimas yra remtas sprendimo ribų suradimu iš surastos hiper-plokštumos, kuri susidaro tarp kraštutinių taškų arba vektorių, dar kitaip žinomais, kaip palaikymo vektoriais (angl. „*support vectors*“) [48]. Taigi jeigu imamas duomenų kiekis susidarys iš dviejų grupių tai hiper-plokštumą bus sudaryta tik iš vienos tiesios linijos. Jeigu duomenų kiekis atitinkamai bus sudarytas iš trijų, keturių ar daugiau grupių, hiper-plokštumų bus sudaryta atitinkamai viena, dvejomis ar trejomis daugiau.

Priklausomai nuo norimų duomenų grupių skirstymo, gali būti naudojami tiesinio ir netiesinio modelio funkcijų atvejais. Šie atvejai atvaizduoti 16 paveiksle su sudarytomis geriausiomis hiper-plokštumomis.




16 pav. a) tiesinio pasiskirstymo modelis; b) netiesinio pasiskirstymo modelis [47]

Taip SVM būdu galima iš duomenų bazės suskirstyti kiekvienos klasės požymius pagal plokštumas. Iš jų atitinkamai sistemos, pagal sudarytas plokštumų linijas, gali priimti sprendimus apie testuojamų duomenų padėti [49]. Įvertinus kiekvieno požymio esamą padėtį plokštumoje, jam priskiriama atitinkamos klasės vertė, o likusi nepanaudota požymio vertė priimama, kaip klaidos galimybė, kad nustatyta klasė galimai yra netiksli. Ištyrus visus požymius, priimamas bendras sprendimas, pagal didžiausią kiekį nustatytų plokštumos zonų ir priskiriama galutinė klasė, nurodantį sistemai atsakymą apie bandomų duomenų grupę.

3.2.2. K-artimųjų kaimynų klasifikatorius

K-artimųjų kaimynų (angl. „*k-nearest neighbors*“ – KNN) klasifikatorius plačiai taikomas klasifikavimo ir regresinių spėjimų problemoms spręsti. Labai paplitęs industriniuose sprendimuose dėl lengvo naudojimo interpretuojant išvedimo rezultatus, dėl greito apdorojimo laiko ir spėjimo patikimumo [50]. Šio metodo veikimas yra paremtas artimiausios duomenų atitikties suradimu. Tai reiškia, kad reikia nurodyti tam tikrą k reikšmę, kuri nurodo kiek artimų duomenų imti nustatant erdvinę plokštumą (žr. 17 pav.).



17 pav. KNN algoritmo taikymas [50]

Algoritmas atitinkamai išskiria šiuos kaimynus ir suranda jų atstumą iki bandomo duomenų taško. Pagal tai kiek turimų duomenų atstumų buvo artimiausi su bandiniu, priimamas sprendimas, kad

duomenų tipas priklauso tai klasei [51]. Kaip pateikta 17 pav., matyti kad iš artimiausių atstumų, kai $k=5$, naują duomenų tašką galima priskirti prie raudonos kategorijos duomenų. Tačiau KNN algoritmui galima būti taikomos įvairios atstumo skaičiavimo metodikos, todėl atitinkamai reikia jas pasirinkti, įvertinus kiek duomenų yra naudojama tam tikrose klasifikavimo sistemose. Vienos iš plačiausiai naudojamų KNN klasifikatoriui atstumo matavimo metrikų yra: Euklidiano, Minkovskio, kosinuso, Hamingo, Jakardo [52]. Taip pat jeigu tarp duomenų klasių yra daugiau parametrų atitinkamai visi palyginami n kartų su KNN algoritmu ir surandamas bendras sprendimas, pagal dažniausiai pasikartojantį tam tikrų klasių skaičiaus rezultatą.

3.2.3. „Naive Bayes“ klasifikatorius

„Naive Bayes“ klasifikatorius yra vienas iš lengviausių ir mažiausiai apdorojimo laiko reikalaujančių klasifikavimo algoritmų. Šis metodas priklauso tikimybiniam algoritmui ir remiasi statistine Bayes teorema (8). Paprasčiau tariant, „Naive Bayes“ klasifikatorius daro prielaidą, kad tam tikro požymio buvimas klasėje nėra susijęs su bet kurio kito požymio buvimu [53].

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}; \quad (8)$$

čia A ir B atsitiktiniai įvykiai; P – įvykių tikimybė.

Taip algoritmas priima prielaidas, kad kiekvienas nagrinėjamas požymis yra nepriklausomas. Taip pat šiuo metodu naudojamos kelios duomenų pasiskirstymo metodikų: Gauso, multinominio ir Bernulio [54]. Pagal jas atitinkamai parenkama statistinė erdvė, kurioje taikoma Bayes teorema. Šio klasifikatoriaus veikimas turint požymius, jų klasių etiketes ir pagal turimą metodiką, yra sudarant tam tikras duomenų grupes. Į sistemą įvedus naujus duomenis, surandama, kiek ir kokių duomenų yra aplinkui nurodytą tašką. Taip pagal Bayes teoremą statistiškai pagrindžiama ir priskiriama nauja klasė [55]. Šis metodas tinkamas, kai klasių ir duomenų yra ganėtinai daug, ir suradus dalines tikimybinių klasių dalis priimamas sprendimas ir išvedamas atsakymas.

3.3. Mokslinės problemos formulavimas

Aptartos sistemos veikia su daugybe požymių ir skirtingais klasifikavimo metodais ir ne visos sugeba nustatyti visas transporto priemones. Rinkoje esančios aukšto patikimumo sistemos yra ganėtinai sudėtingos ir brangios, todėl siekiama sukurti klasifikavimo sistemą, turinčią atitinkamą požymių kiekį identifikuojant transportą. Sistemai ištirti išsikelia pagrindinė problema:

Koks minimalus požymių kiekis ir koks klasifikavimo metodas leis sudarytai sistemai suskirstyti transporto priemones į tam tikras klases, kad prarandamo ir klaidingai suskirstyto judančių transporto priemonių kiekis bus mažiausias.

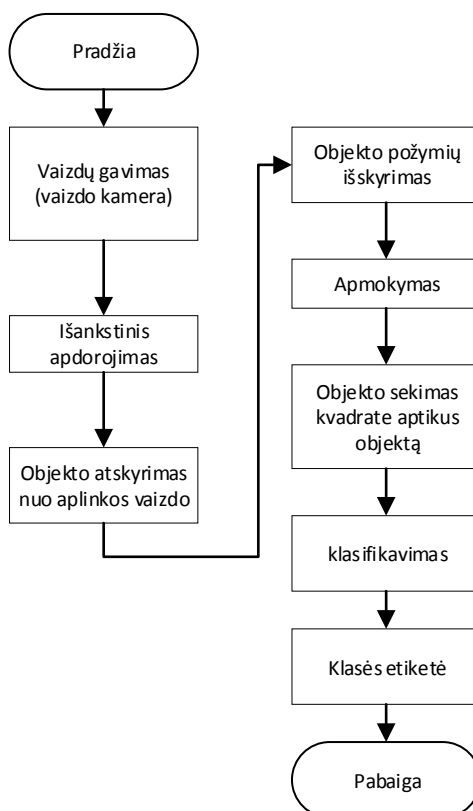
3.4. Apibendrinimas

Taigi yra įvairių požymių išskyrimo technikų, tačiau vienos iš jų yra ganėtinai tikslesnės negu kitos. Bendru atveju norint klasifikuoti transporto priemones tikslumas gali būti gaunamas nuo 86 iki 98 %. Vieną iš požymių pasirenkama naudoti HOG, dėl didelio kiekio taškų įvertinimo, didelio tikslumo ir kampų įvertinimo. Taip pat reikia nuspręsti kokius parametrus naudoti transporto požymiams išskirti. Aptarti klasifikavimo algoritmai, leidžiantys transportą skirtingais metodais, pagal turimus duomenis suskirstyti į tam tikras klases. Aptarus galimus požymius ir klasifikavimo metodikas išsikelta mokslinė problema, kuri bus pagrindžiama tyrimo metu gautais duomenimis.

4. Klasifikavimo sistemos modelio projektavimas

4.1. Pradinis sistemos modelis

Sistemai sukurti ir iškeltai problemai išspręsti pirmiausia sukuriamas preliminarus jos veikimo modelis. Viskas prasideda nuo vaizdų gavimo su vaizdo įrenginiu. Tam bus naudojama stacionari „MOBOTIX“ vaizdo kamera, įrengta netoli važiuojamojo kelio ruožo bei leidžianti stebėti transporto eismą tiesiogiai internete. Taip iš vaizdo kameros pasiimami vaizdai, kurie išsaugomi tolimesniam apdorojimui, požymių išskyrimui, apmokymui, klasifikavimui. Visas bendras pirminis modelis pateikiamas 18 paveiksle.



18 pav. Pirminis sistemos modelis

4.2. Sistemos sudarymo principas ir pirminis vaizdo apdorojimas

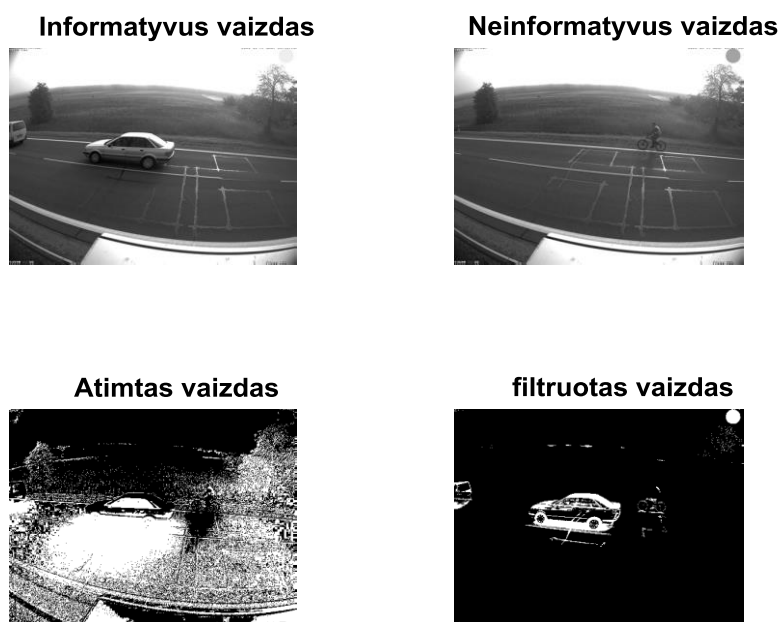
Norint sukurti sistemą pagal nurodytą modelį yra išsisaugomos nuotraukos, kuriomis remiantis bandoma padaryti išankstinį apdorojimą. Jį sudaro vaizdų apdorojimas, aplinkos šalinimas ir objekto išskyrimas. Iš turimo vaizdo išskiriami požymiai, linijų ir kampų metodais. Galiausiai sistema apmokoma sudarant duomenų bazę ir klases. Sekant objektą vykdomas jo požymių išskyrimas ir klasifikavimas, pasitelkiant keletą mašininio mokymo algoritmų. Identifikuotas transportas pateikiamas tam tikros klasės etikete.

4.2.1. Vaizdų kadru apdorojimas

Išankstiniame apdorojime vykdomas nuotraukos pavertimas iš spalvoto vaizdo į pilkos spalvos vaizdą. Kadangi vaizdas susideda iš trijų spalvų kanalų, yra paliekamas tik vienas, kas vėliau supaprastina vaizdo apdorojimą greitaveikos atžvilgiu. Taip pat yra pakeičiamas nuotraukos dydis, kas sutaupys laiko skaitant vaizdus.

4.2.2. Aplinkos ir objekto išskyrimas

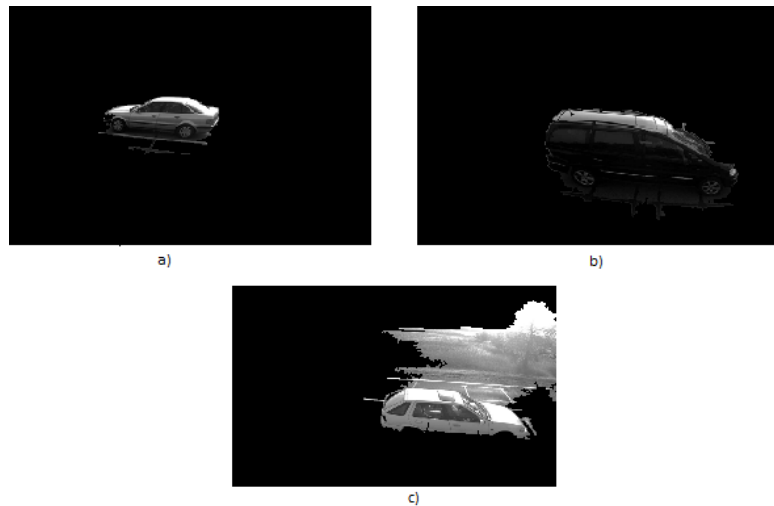
Norint paspartinti apdorojimą, kad požymiai būtų randami tik transporto priemonės yra išskiriamas tiriamasis objektas nuo aplinkos vaizdo. Tuo tikslu paimama tik aplinkos arba su mažai reikšmingu objektu nuotrauka. Šiuo atveju paimamas vaizdas su dviratiniu ir bandoma išskirti aplinką nuo vaizdo juos atimant. Kadangi tarp atimto vaizdo gautos reikšmės yra ne vien teigiami skaičiai, todėl paimamas jų modulis, o kad nematytumėme labai daug triukšmo, vaizdas yra filtruojamas su slenkstine riba, to rezultatu jau beveik gaunamas norimas objektas. Tačiau taip pat yra ir pašalinių objektų (žr. 19 pav.).



19 pav. Apdorotas transporto priemonės vaizdas

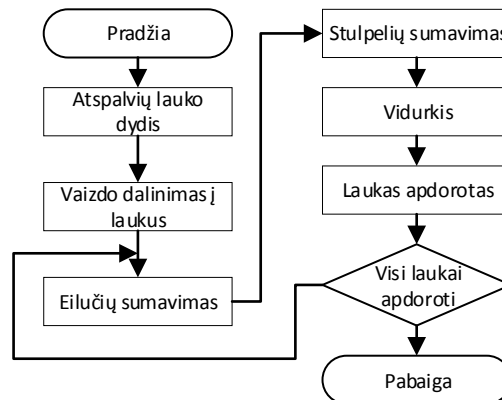
Toliau gautas vaizdas yra dauginamas su pradiniu vaizdu pritaikant dvejetainį elemento su elementu dauginimą dviem masyvams su pavieniu jų išplėtimu.

Kadangi norima atskirti visą transporto priemonę, pritaikytas standartinės deviacijos filtras, leidžiantis nufiltruoti pikselius ieškant artimiausių 3x3 matricos elementų nuo tiriamojo pikselio reikšmės. Pritaikius histogramą matoma kur yra didžiausias pasiskirstymas. Toliau apdoroti praleidžiami tik didesnį slenkstį turinčios reikšmės. Užpildžius vaizdo regioną, likusias skylės ir išrinkus didžiausią objekto plotą buvo gautos transporto priemonės (žr. 20 pav. a) ir b)). Tačiau vaizdas (žr. 20 pav. c)) yra su dalimi aplinkos ir tai jau lemia galimas paklaidas norint priskirti požymius tik transporto priemonei, todėl šio metodo teko atsisakyti.



20 pav. a) ir b) išskirtos transporto priemonės, c) išskirta transporto priemonė ir dalis aplinkos

Kitas žingsnis yra bandymas susirasti tam tikrų regionų atspalvių vidurkius visame turimame vaizde. Tam įgyvendinti geriausiai atitinka algoritmas pavaizduotas 21 paveiksle.



21 pav. Atspalvių radimo algoritmas


Vaizdas yra išskaidomas į 128 regionus (16x8). Kiekvienam regionui atitinkamai skaičiuojamas jo atspalvio vidurkis per vieną bloką, sudedant eilutes, o paskui stulpelius. Paimamas jų vidurkis iš maksimalaus pikselių skaičiaus viename bloke. Šis algoritmas pritaikomas tiek aplinkos vaizdui tiek vaizdui su objektu iškart po išankstinio apdoravimo. Su surastais atspalviais abu vaizdai yra atimami vienas iš kito ir gaunamas jų skirtumas tame regione, kuris lyginamas su tam tikra slenkstine riba, iš kurios gaunama binarinė matrica. Gautai matricai pritaikomas didžiausio ploto ir tik vieno objekto išskyrimas, likę plotai užpildomi nulinėmis reikšmėmis.

Turint mažą 16x8 dydžio binarinę matricą iš jos atitinkamai vaizdas yra koreguojamas. Aptikus vieneto ar nulio reikšmę, iš anksto apdorotas vaizdas yra dauginamas iš tos reikšmės kol užpildomas visas reikiamas bloko dydis, prieš atspalvių radimą.

4.2.3. Objekto kraštinių identifikavimas

Turint vaizdą pritaikomi trys kraštinių aptikimai: „Sobel“, „Canny“ ir „Roberts“, leidžiantys įvertinti vaizdo intensyvumo pokytį su vaizdo intensyvumo pertraukimu. Pasinaudojant funkcijomis objektas yra filtruojamas Gauso filtru, kuris sumažina krašto stiprumo ir triukšmo santykį. Apskaičiavus gradiento dydį surandama intensyvūs verčių pokyčiai ir aptinkamos kraštinės.

Šiuo atveju daugiausiai informacijos suteikia „Canny“ kraštinių metodo pritaikymas, kuriuo yra gaunama daugiausiai transporto priemonei atitinkančio vaizdo (žr. 22 pav.). Tačiau taip pat yra gaunama ir daug smulkesnių kraštinių, kurios yra ne visai informatyvios.



22 pav. „Canny“ metodu išskirtas objekto ribos

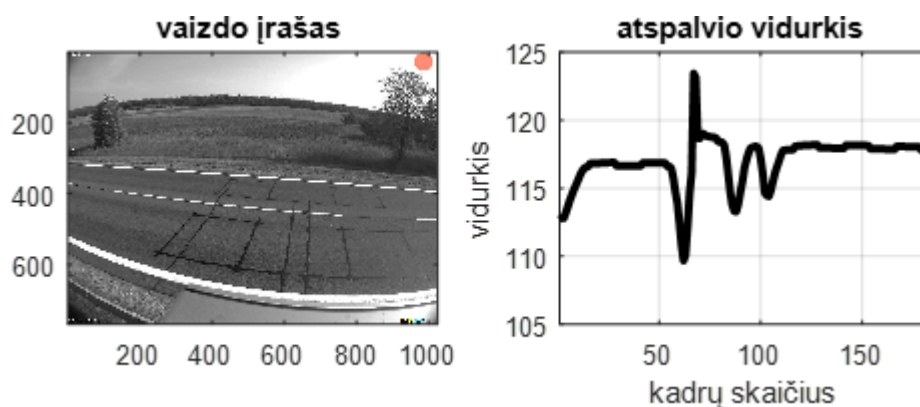
Šis metodas skaidyti aplinką per atspalvius taip pat nepasitvirtino, dėl staigių aplinkos pokyčių, dėl prarandamos informacijos, nes kiekvienu metu tektų keisti slenkstinę skirtumo ribą ir dėl to, kad pasižymi išskirto regiono perimetras, kuris nėra informatyvus. Todėl nuspręsta vaizdus iš kameros apdoroti įsirašius vaizdo įrašus ir atitinkamai stebėti aplinkos pokyčius.

4.3. Vaizdo įrašo apdorojimo principas

Dienos metu įsirašyti 0,15–3 minučių vaizdo įrašai pakeičiami į atitinkamą formatą, kad būtų galima juos skaityti tiesiogiai su programine įranga.

Tai reiškia, kad kiekvienas vaizdo kadras turės būti apdorojamas. Viena iš galimybių matyti pokytį, kaip keičiasi vaizdas yra geriausiai stebėti jo atspalvio kitimą. Tam pasitelkiama skaičiuoti jo vidurkį iš visų esamų vaizdo įrašo pikselių. Prieš tai vykdomas jo išankstinis apdorojimas nuimant spalvų kanalus ir paliekant tik pilkumo skalę, kuri apskaičiuojama ir įvertinama.

Iš 23 paveikslo matyti, kad atspalvio vidurkis nėra pastovus kintant kadrams. Tai gali lemti daug faktorių.



23 pav. Vaizdas ir jo atspalvio vidurkis

Atitinkamai keičiantis vaizdai matomi staigūs vidurkio šuoliai ir kritimai, kas parodo, kad nekintantis aplinkos vaizdas yra sutrikdytas transporto priemonių. Jo šuolis taip pat nusako, koks tai gali būti


objektas. Pavyzdžiui mažesni kitimai gali rodyti, kad tai buvo lengvasis automobilis, motociklas, ar kitas mažų gabaritų transportas. Analogiškai didelis kitimas reiškia, kad tai galėjo įvykti lenkimas arba transporto priemonė yra ganėtinai aukšta. Tai rodo, kad pravažiavo mikroautobusas, krovininis transportas ir t.t.

Taip pat pastovus ir mažai kintantis skaičius rodo aplinką. Jos kitimas keičiantis kadrams nėra labai žymus. Todėl nuspręsta, kad pritaikius atspalvių vidurkį, kaip kitimo ribą, galima atmesti vaizdo kadrus kurių apdoroti nereikia, o likusiems kadrams pritaikyti kitus apdorojimo algoritmus.

4.4. Judančio transporto klasifikavimo sistemos sudarymas

Kadangi vaizdo įrašas, šiuo atveju, įvertinus pilkumo atspalvių skalę, yra daug informatyvesnis negu tiesiog nuotrauka, toliau nuspręsta sistemą sudaryti tik apdorojant vaizdo įrašus. Taip apdorojus kiekvieną kadrą ir suradus jų atspalvio vidurkių reikšmes pagal pateiktą grafiką (žr. 21 pav.), galima pasiimti aplinkos vaizdą, kuris padeda eliminuoti aplinką ir daugiau išskirti tik reikiamus tyrimo objektus. Iš turimų vidurkių atrenkamas dažniausiai pasikartojantis atspalvio vidurkis, kuris ir tinkamiausiai reprezentuoja aplinką. Aplinkos stebėjimui imama iki 50 kadru. Po apdorojimo aplinka atnaujinama, kad viso vaizdo įrašo apdorojimo metu, aplinkos daroma įtaka būtų minimali. Staigus pokytis leidžia optimizuoti vykdymo laiką apdorojant tik tuos kadrus kuriuose yra staigus pokytis nuo dažniausios vertės ieškant dalinių maksimumų ar minimumų. Jie randami atitinkamai ieškant vis didesnės arba vis mažesnės atspalvio vidurkio vertės nuo nurodytos vertės iki kol rasta kadro vidurkio vertė pradeda vėl mažėti arba didėti. Gaunami kadrai tik transporto priemonei judant.

Turint aplinką atliekamas to kadro skirtumo skaičiavimas su kiekvienu vaizdo kadru (žr. 24 pav. a)). Tai parodo kokios vietos labiausiai kinta. Taip pat sukuriami vaizdo kaukė – slenkstinė skirtumo modulio riba, kuri leidžia nufiltruoti triukšmus (žr. 24 pav. b)) po skirtumo. Gautam kadrai yra atliekamas skylių pašalinimas jas užpildžius ir išskiriami bent du didžiausi objektai likusiame vaizde (žr. 24 pav. c)).



24 pav. Dominančio vaizdo išskyrimas


Turimam vaizdui gražinus jo atspalvius pritaikomas „Canny“ kraštinių aptikimo algoritmas. Jis atlikdamas keturis veiksmus: triukšmo mažinimą, vaizdo intensyvumo gradiento radimą, ne maksimalų slopinimą, histerizės slenksčio nustatymą, suteikia vaizdui daugiausia kraštinių. Taip pat panaudojamos ir dvi slenkstinės atspalvio ribos, iš kurių jeigu viena yra viršijama, tada priimama, kad tai yra kraštinė, o jeigu nepasiekiami antros slenkstinės ribos viskas nustatoma į nulinę vertę – juodą spalvą. Gautos kraštinės yra informatyvios, tačiau problema yra kad aptinkama ir dalis judančios aplinkos. Šiuo atveju „Canny“ kraštinių aptikimas pritaikomas vaizdui iš šono. Gautas vaizdas pateikiamas 25 paveiksle.



25 pav. Apdorotas vaizdas su „Canny“ algoritmu

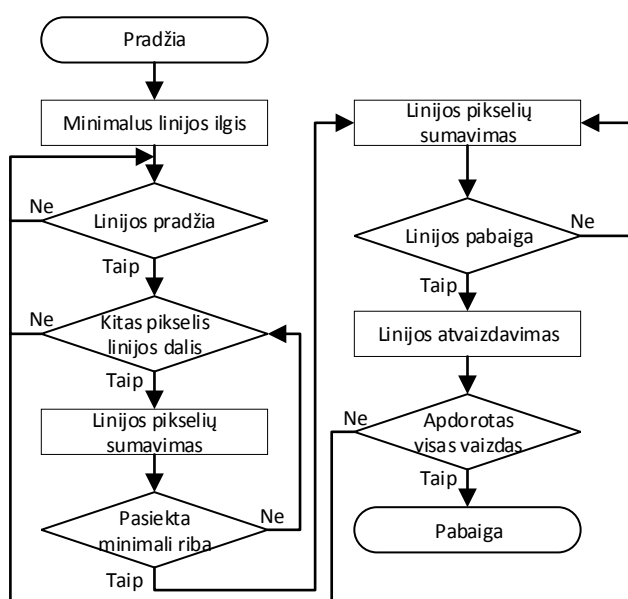
Iš gauto vaizdo pastebima, kad yra daug tiesių horizontalių linijų, kurios yra svarbiausios ir priklausančios transporto priemonei. Jos nurodo transporto priemonės stogo, kapoto, apatinės transporto priemonės dalies, durelių, langų ir t.t. vietas.

Priklausomai nuo esamo vaizdo sukurtas horizontalių linijų filtravimo (HLF) algoritmas, kuris pritaikomas tik po „Canny“ metodu išskirtų kraštinių. Jo paskirtis tikrinti kiekvienoje vaizdo matricos eilutėje esančių baltų ir juodų pikselių reikšmes. Šiuo atveju tikrinama binarinė matrica. Sudarytas HLF tenkina tik nurodant minimalų linijos ilgį, kuris gali būti sudarytas minimaliai iš dviejų taškų. Taip aptikus pirmąjį vienetą yra tikrinama sekančių gretimų elementų reikšmės ir jos skaičiuojamas jų kiekis. Jeigu randama minimali užsiduota linijos ilgio riba, HLF toliau pabaigia ieškoti linijų iki kol linija pasibaigia (aptinkamas nulis) arba baigiasi vaizdo eilutė. HLF algoritmas pateikiamas 27 paveiksle. Visi neinformatyvūs taškai ir linijos kurių ilgis yra mažesnis užsiduotam, atitinkamai perverčiami į 0. Bendrame vaizde matyti tik nesujungtos, atskiros informatyvios linijos (žr. 26 pav.). Šiam tiriamajam darbui pasirinktina minimalų linijos ilgį naudoti nuo 10 iki 16 taškų.



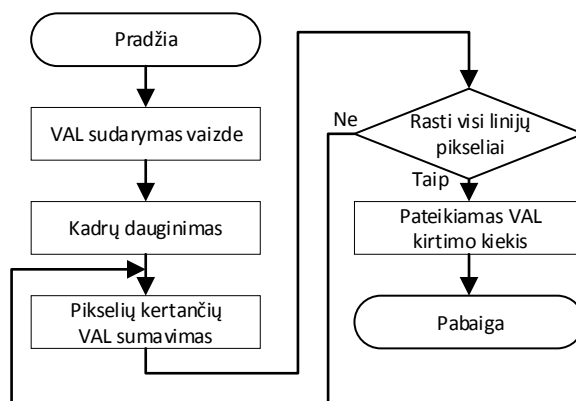
26 pav. Vaizdas po HLF apdorojimo, 14 taškų linija

Apdorojus vaizdą su HLF algoritmu daugiausia išryškėja transporto priemonės, stogo, langų durelių ir apatinio bamperio vietos, kaip ir buvo tikėtasi aukščiau.




27 pav. HLF algoritmas

Kadangi po HLF algoritmo panaudojimo išaugo vykdymo laikas ir vis ta pati transporto priemonė yra apdorojama, kol pravažiuoja pro vaizdo kameros matymo lauką, kuris yra 180° kampas, įvedama, prieš tai aptarta, VAL sistema. Šia sistema sukuriamos nematomos, minimaliai trys, virtualios vertikalios linijos su išdėstymu: viena einanti per centrą, o nuo jos atstumu nuo 5 iki 30 taškų į abi puses sukuriamos dar dvi. Jomis suskaičiuojama, kiek mus dominančių vaizdo taškų kerta šias linijas ir tik tenkinant sąlygas yra atliekamas tolimesnis apdorojimas. VAL sistemos kirtimo algoritmas pateikiamas 28 paveiksle. Bandymų tikslams darbe pasirinkta naudoti šiuos linijų kirtimų reikšmes: centrinė linija – iki 7, kairinė linija – iki 5, dešininė linija – iki 5 reikšmių.



28 pav. VAL algoritmas

Kiekvienam gautam vaizdui yra uždedamas kandidato kontūras iš kurio vėliau bus atliekami bandymai. Tačiau pastebėta, kad kontūras kai kuriais atvejais yra uždedamas ne vien su transporto priemonės vaizdui būdingomis linijomis, bet ir su aplinkos dalimi, todėl sukuriamas papildomas linijų pašalinimo filtras. Šiai funkcijai įgyvendinti panaudojamas centrinis taškas pagal labiausiai nutolusius keturis informatyvių linijų centrus. Taip pat kiekvienai linijai suskaičiuojami jų vidurio taškai. Taip pagal Pitagoro teoremą suskaičiuojami atstumai kiekvienam taškui. Žinant atstumus išvedamas bendras jų vidurkis, o nurodant kiek kartų leidžiama viršyti atstumą tarp taškų surandama tolimiausios linijos, kurios eliminuojamos iš tolimesnio kadrų apdorojimo. To rezultatu pateikiamas tikrasis kandidatas į apmokymo ar klasifikavimo sistemą (žr. 29 pav.). Raudonas taškas – išvestas centras, mėlyni – kiekvienos linijos centrai.



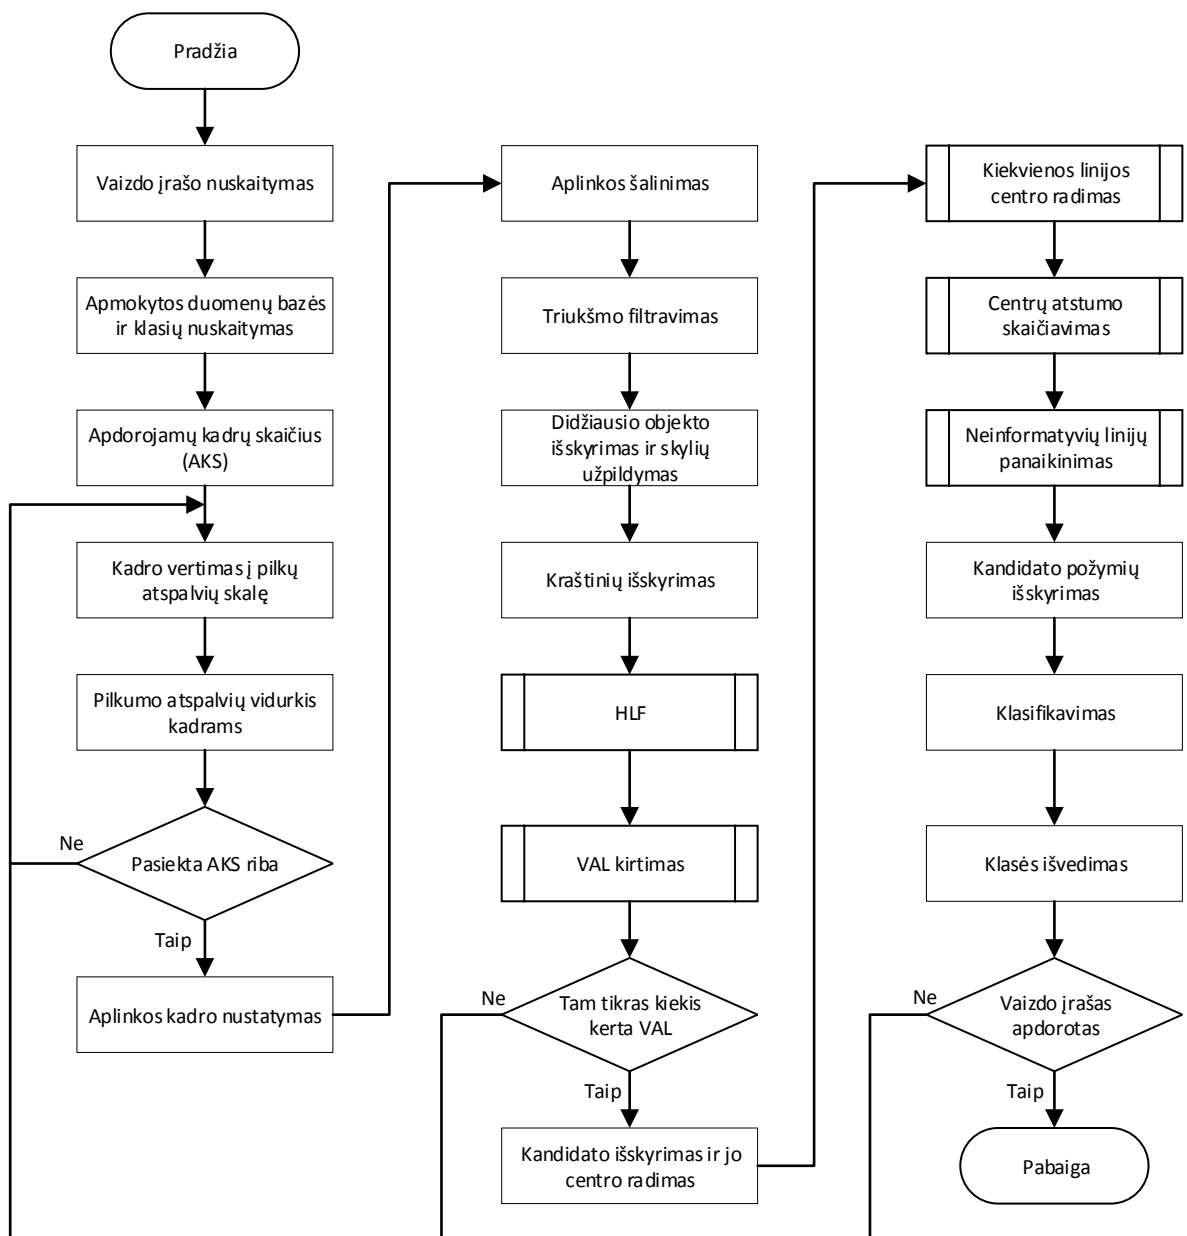
29 pav. Paruoštas galimas kandidatas

Iš kandidato suskaičiuojama minimaliai 10 parametrų, tokių kaip: kontrastas, vidurkis, homogeniškumas, vidutinė kvadratinė reikšmė, standartinis nuokrypis, kurtosis ir t.t. Pagal požymius sudaromos kelios duomenų bazės su skirtingais vaizdų kiekiais. Kiekvienai duomenų bazei priskiriama tam tikra etiketė, reprezentuojanti: lengvąjį automobilį, sunkvežimį, kitas transportas ir vilkikas. Pagal šias duomenų bazes sistemos bandys klasifikuoti aptiktą transportą. Pritaikius klasifikatoriaus sistema atrenka, koks tai buvo transportas (žr. 30 pav.).



30 pav. Išklasifikuota transporto priemonė

Taigi visas bendras judančio transporto klasifikavimo sistemos modelio veikimo algoritmas pateikiamas 31 paveiksle.



31 pav. Sudarytas galutinis sistemos modelio algoritmas

4.5. Apibendrinimas

Pagal sudarytą sistemos algoritmą apdorojant nuotraukas išbandyti keli būdai, kuriais galima išskirti transporto priemones ir joms pritaikyti segmentaciją. Tačiau susidurta su aplinkos kitimo problema, o išskiriant objektą paimamas ne vien jis, o ir didelė dalis aplinkos, kuri nėra informatyvi ir gali įnešti klaidų apmokant sistemą bei klasifikuojant judančias transporto priemones.

Tam išspręsti nuspręsta bandymus daryti su vaizdo įrašais, iš kurių galima stebėti aplinką laikui bėgant. Sėkmingai išskirtam objektui atliktas kraštinių išskyrimas. Iš jų išskiriamos dominančios transporto kraštinės pritaikius HLF. Vaizdas atrenkamas pagal VAL esančius kirtimo taškus. Taip pat atsisakyta neinformatyvių tolimų linijų. Galiausiai gauti kandidatai, iš kurių išskiriama 10 skirtingų parametrų, kuriais apmokoma sistemos duomenų bazė. Pagal ją klasifikuojama ir identifikuojama transporto priemonė. Sukuriamas galutinis sistemos modelio algoritmas.

5. Eksperimentiniai bandymai sudarytai sistemai pagrįsti

Sudarytam sistemos modeliui atliekami eksperimentiniai bandymai, įrodantys sistemos veikimą, geriausių parametrų ir metodikų parinkimą. Bandymai atliekami tinkamai klasifikavimo metodikai nustatyti. Tiriama, iš kokio minimalaus kiekio ir dydžio vaizdų reikėtų sudaryti duomenų bazę. Nustatoma kokie parametrai lemia transporto aptikimą. Atliekamas statistinis duomenų bazės požymių įvertinimas, jos unikalumui ir veikimui pagrįsti. Atlikus bandymus statistiškai išrenkami geriausi parametrai ir metodai, parodantys geriausių sistemos veikimą.

5.1. Klasifikavimo bandymai

Eksperimentiniai bandymai atliekami „MATLAB 2016b“ versijos programine įranga. Pradiniams testavimams atlikti panaudojami du vaizdo įrašai, kai kamera įtaisyta iš šono važiuojamai kelio daliai. Bandymai atliekami panaudojant du klasifikatorius: KNN ir SVM. Šiuo tyrimu siekiama nusakyti, kuris iš klasifikatorių geriau sugeba pateikti teisingą atsakymą apie transportą. Gauti rezultatai pateikiami 4 lentelėje. Tyrimu tikslams panaudota dvi apmokytos duomenų bazės: viena – kai požymiai skaičiuojami iš viso vaizdo, antra – požymiai skaičiuojami iš apkirpto vaizdo, kuris yra tik dominančiame regione.

4 lentelė. Gauti bandymo rezultatai viso vaizdo apmokymu

Transporto klasė	Iš viso transporto	KNN			SVM		
		Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	23	15	6	65	19	2	83
Sunkvežimis	1	1	0	100	1	0	100
Kitas transportas	1	1	0	100	1	0	100
Aplinka	–	3	0		3	0	
Prarastas transportas	–	2			2		

5 lentelė. Gauti rezultatai dominančiu vaizdo regiono apmokymu

Transporto klasė	Iš viso transporto	KNN			SVM		
		Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	23	18	3	78	16	5	70
Sunkvežimis	1	1	0	100	1	0	100
Kitas transportas	1	1	0	100	1	0	100
Aplinka	–	3	0		3	0	
Prarastas transportas	–	2			2		

Iš gautų rezultatų matyti, kad kol vyko apdorojimas buvo prarastos dvi transporto priemonės, tikriausiai dėl to, kad jos tuo metu buvo lenkimo pozicijoje arba atsirado už VAL ribų. Matyti, kad geriausiai identifikuojama apmokus sistemą visu vaizdu ir klasifikuojant SVM algoritmu, kuris leido pasiekti tikslumą nustatant lengvuosius automobilius iki 83 %, nors apmokus sistemą iš apkirpto vaizdo, SVM algoritmas aptiko prasčiausiai – 70 % .

Kadangi bendrai gauta jog SVM tiksliausiai klasifikavo transporto priemones, toliau tiriama kaip klasifikavimas keičiasi sumažinus apmokytų transporto priemonių skaičių duomenų bazėje, kai apmokoma naudojantis tik visu vaizdu. Gauti rezultatai pateikiami 6 lentelėje.

6 lentelė. Apmokymo duomenų bazės vertinimas

Transporto klasė	Iš viso transporto	50 apmokytų vaizdų			30 apmokytų vaizdų		
		Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	23	19	2	83	15	6	65
Sunkvežimis	1	1	0	100	1	0	100
Kitas transportas	1	1	0	100	1	0	100
Aplinka	–	3	0		3	0	
Prarastas transportas	–	2			2		

Iš lentelės matyti, kad esant vos 30 apmokytų vaizdų sistema sugebėjo aptikti beveik 20 % blogiau negu sistema susidedanti iš 50 apmokytų vaizdų.

5.2. Trečio klasifikatoriaus bandymai

Atlikus eksperimentinius bandymus su dviem klasifikatoriais, toliau atliekami bandymai su trečiu. Sudaromas „Naive Bayes“ tipo klasifikatoriaus objekto daugiasluksnis modelis. Į jį paduodama duomenų bazė, ir transporto priemonių klasės. Objekto modelyje atitinkamai duomenys suskirstomi pagal normalųjį skirstinį į lentelę.

Atitinkamai iš kiekvieno vaizdo išskirtas požymių vektorius. Jis kartu su sudarytu klasifikatoriaus šablonu pateikiamas spėjimo funkcijai. Palyginus požymius su skirstinių lentele, vaizdui priskiriama etiketė. Bandymai kartojami du kartus: kai naudojamas pilno dydžio vaizdas ir kai naudojamas tik dominantis vaizdo regionas. Eksperimentas atliekamas tik su penkiasdešimčia apmokytų vaizdų duomenų baze. Gauti „Naive Bayes“ klasifikavimo rezultatai pateikiami 7 lentelėje.

7 lentelė. Gauti trečio klasifikatoriaus rezultatai

Transporto klasė	Iš viso transporto	Visas vaizdas			Dominančio vaizdo regionas		
		Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	23	14	7	61	15	6	65
Sunkvežimis	1	1	0	100	1	0	100
Kitas transportas	1	1	0	100	1	0	100
Aplinka	–	3	0		3	0	
Prarastas transportas	–	2			2		

Iš gautų rezultatų matyti, kad šis klasifikatorius nėra geresnis negu prieš tai naudoti SVM ar KNN metodai, nustatyti transporto priemonei. Siekia net 17 % skirtumas lyginant su SVM.

5.3. Transporto aptikimo vertinimas

Eksperimento metu pastebėta, kad iš 25 transporto priemonių buvo prarastos 2 transporto priemonės. Priimama prielaida, kad jeigu pravažiuojančių objektų būtų 100, tada gali reikšti, kad bus prarandama mažiausiai 8 dominantys objektai.

Norint kuo labiau sumažinti prarandamų objektų, atliekami bandymai pagerinti transporto aptikimą. Bandymams pasirinkta tirti tris vaizdo apdorojimo parametrus: HLF kraštinės ilgį, VAL linijų pozicijas ir slenkstinius pikselių kiekius. HLF kraštinės ilgis padidina arba sumažina aptikto objekto

kraščių, kiekį ir jų minimalų ilgį. Keičiant VAL pozicijas nuo vidurio taško, leidžiami aptikti objektai, esantys ne pačiame viduryje. Slenkstinis pikselių kiekis, kertantis VAL, riboja aplinkos aptikimą.

Bandymui patvirtinti imami papildomi 13 vaizdo įrašų su transportu. Iš jų surandamas transporto priemonių kiekis kiekvienam įrašui. Toliau atliekami bandymai aptikimo tikslumui nustatyti, kai visos VAL linijos yra kertamos judančio transporto tuo pačiu metu. Gauti rezultatai pateikiami 8 lentelėje. Detalesni duomenys pateikiami 1 priede.

8 lentelė. Rezultatai, kertant 3 VAL linijas vienu metu

Parametras	Aptikta	Iš viso	%
14k 10v 111*	89	102	87,3
14k 10v 222	82	102	80,4
14k 5v 111	93	102	91,2
14k 5v 222	83	102	81,4
13k 10v 111	93	102	91,2
13k 10v 222	84	102	82,4
13k 5v 111	97	102	95,1
13k 5v 222	84	102	82,4

* čia 14k – HLF ilgis, 10v – VAL atstumas, 111 – slenkstinis pikselių kiekis

Iš atlikto bandymo rezultatų gauta tai, kad keičiantis parametru dydžiams ir kertant visas VAL vienu metu, buvo aptikta nuo 80,4 % iki 95,1 % transporto. Rezultatas nėra tenkinamas ir toliau atliekami tyrimai, kai kertama bent viena VAL linijų, bet kuriuo metu. Gauti duomenys pateikiami 9 lentelėje.

9 lentelė. Rezultatai, kertant bent 1 iš 3 VAL

Parametras	Aptikta	Iš viso	%
13k 10v 333*	91	102	89,2
13k 10v 222	98	102	96,1
13k 5v 333	89	102	87,3
13k 5v 222	97	102	95,1
14k 10v 333	88	102	86,3
14k 10v 222	98	102	96,1
14k 5v 333	85	102	83,3
14k 5v 222	94	102	92,2
14k 20v 333	90	102	88,2
14k 20v 222	99	102	97,1
14k 15v 333	92	102	90,2
14k 15v 222	100	102	98,0

* čia 13k – HLF ilgis, 10v – VAL atstumas, 333 – slenkstinis pikselių kiekis

Atlikus šį eksperimentą, kai aptinkama kertant bent vieną VAL, gauti rezultatai rodo, kad aptinkama transporto yra nuo 83,3 % iki 98 %. Lyginant su ankstesniu bandymu, aptikimas pagerėjo 3 %, todėl tolimesniems bandymams naudojamas bent vienos VAL kirtimas.

Taip pat bandymų metu surinkti rezultatai statistiškai palyginami, ar aptiktų transporto priemonių vidurkis – μ_1 statistiškai reikšmingai mažesnis, negu vaizdo įrašuose esančio transporto kiekio vidurkiui – μ_2 . Tam išsikeliamos nulinė H_0 ir alternatyvi H_1 hipotezės.

$H_0: \mu_1 = \mu_2$;

$H_1: \mu_1 < \mu_2$;

Hipotezės pagrindžiamos atliekant t-testą su 95 % pasikliovimo lygiu, kai vidurkis yra žinomas $\mu_2 = 8,5$. Skaičiavimams pasitelkiama „Minitab“ programinė įranga. Gauti rezultatai pateikiami 10 lentelėje, kurioje nurodomi kiekvieno parametro transporto aptikimo vidurkis ir p-reikšmė.

10 lentelė. Statistinis aptikimo palyginimas

Parametras	Vidurkis	p-reikšmė
13k 10v 111A	7.750	0.137
13k 10v 222A* ¹	7.000	0.010
13k 5v 111A	8.083	0.296
13k 5v 222A	7.000	0.006
14k 10v 111A	7.417	0.026
14k 10v 222A	6.833	0.005
14k 5v 111A	7.750	0.106
14k 5v 222A	6.917	0.002
13k 10v 333O* ²	7.583	0.051
13k 10v 222O	8.167	0.315
13k 5v 333O	7.417	0.029
13k 5v 222O	8.083	0.269
14k 10v 333O	7.333	0.012
14k 10v 222O	8.167	0.315
14k 5v 333O	7.083	0.002
14k 5v 222O	7.833	0.141
14k 20v 333O	7.500	0.039
14k 20v 222O	8.250	0.359
14k 15v 333O	7.667	0.066
14k 15v 222O	8.333	0.402

*^{1,2} čia 13k – HLF ilgis, 10v – VAL atstumas, 333 – slenkstinis pikselių kiekis, A – loginis IR, O – loginis ARBA

Statistiškai palyginus visus parametrus gauta, kad 11 iš 20 parametrų p-reikšmės yra didesnė negu 0,05 ir priimama H_0 , todėl aptikto transporto vidurkis nėra reikšmingai mažesnis nuo vaizdo įrašuose esančio transporto kiekio vidurkio. Visus vienuolika parametrų galima naudoti sistemoje, o kiti devyni yra atmetami. Kadangi didžiausia p-reikšmė gauta 0,402 tolimesniuose klasifikavimo tyrimuose naudojami šie parametrai: 14 pikselių HLF kraštinės ilgis, 3 VAL su 15 pikselių atstumu nuo centro, kai slenkstis pikselių kiekis bent 2 taškai ir aptinkama bent viena VAL.

5.4. Duomenų bazių praplėtimas ir vertinimas

Turint tinkamus aptikimo parametrus, toliau atliekamas transporto identifikavimo vertinimas. Prieš tai atlikti bandymai parodė, kad esant 10 požymių, transporto priemonės nėra tinkamai suskirstomos į klases. Lengvojo automobilio klasifikavimo atveju, buvo blogai nustatyti 2–7 judantys objektai.

Norint pagerinti identifikuoto transporto priemonių rodiklį duomenų bazės praplečiamos su papildomais šešiais parametrais tokiais, kaip aptikto transporto ilgis, plotis, ilgio ir pločio santykis, aptiktų linijų kiekis transporte, atstumo vidurkis nuo vidurio taško ir HOG vidurkis iš viso vaizdo. Taip pat pridedamos papildomos identifikavimo klasės. Taip sistema gali klasifikuoti į šias grupes: lengvasis automobilis, sunkvežimis, kurio svoris siekia nuo 3,5 iki 7,5 tonų, vilkikas, kurio svoris virš 7,5 tonų ir kitas transportas. Kadangi atsirado papildomos transporto rūšys, apmokytų duomenų bazė taip pat praplečiama po 10 naujos transporto rūšies vaizdo požymių ir atitinkamai padidinamas apmokytų klasių kiekis. Su naujai sudarytomis bazėmis atliekami trijų klasifikatorių eksperimentiniai bandymai, kai imamas pilnas vaizdas, ir kai tik dominantis vaizdo regionas. Gauti rezultatai pateikiami 11 ir 12 lentelėse. Procentinė dalis sudaryta iš gerų ir viso transporto esančių per klasę santykio. Viso transporto kiekio, esančio vaizdo įrašuose lentelė, pateikiama 2 priede. Detalesnės surinktų duomenų lentelės pateikiamos 3 ir 4 priede.

11 lentelė. Klasifikavimo rezultatai, po parametų praplėtimo, imant visą vaizdą

Transporto klasė	Iš viso transporto	Klasifikatorius								
		SVM			KNN			„Naive Bayes“		
		Gerai	Blogai	%	Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	87	83	2	95,4	80	5	91,9	71	14	81,6
Sunkvežimis	14	10	4	71,4	13	1	92,8	7	7	50
Vilkikas	22	22	0	100	20	2	90,9	19	3	86,4
Kitas transportas	2	2	0	100	2	0	100	2	0	
Iš viso	125	117	6	93,6	115	8	92	99	24	79,2
Prarastas transportas		2			2			2		

12 lentelė. Klasifikavimo rezultatai, po parametų praplėtimo, imant dominančio regiono vaizdą

Transporto klasė	Iš viso transporto	Klasifikatorius								
		SVM			KNN			„Naive Bayes“		
		Gerai	Blogai	%	Gerai	Blogai	%	Gerai	Blogai	%
Lengvasis automobilis	87	79	6	90,8	79	6	90,8	57	28	65,5
Sunkvežimis	14	5	9	35,7	11	3	78,6	7	7	50
Vilkikas	22	15	7	68,2	18	4	81,8	16	6	72,7
Kitas transportas	2	2	0	100	2	0	50	2	0	50
Iš viso	125	101	22	80,8	110	13	88	82	36	64,8
Prarastas transportas		2			2			2		

Iš gautų rezultatų akivaizdu, kad geriausiai transporto suskirstymą į klases atlieka SVM klasifikatorius, kai apdorojamas visas vaizdas. Juo ištyrus visus vaizdo įrašus gautas 93,6 % tikslumas. Tačiau atlikus klasifikavimą KNN metodu, gautas tikslumas yra 92 % ir gali būti naudojamas skirstant transportą į numatytas klases.

Kita vertus, blogiausiai nustatyti klases sugebėjo „Naive Bayes“ klasifikatorius, kuris siekė net 79,2 % tikslumą. Taip pat pastebėta, kad imant tik naudingą vaizdo dalį ir ją apdorojus, sistema nesugeba tinkamai suskirstyti transporto į atitinkamas klases ir gaunamas tikslumas atitinka 64,8–88 %. Galima teigti, kad vaizdo dydžio parametrai, kai vaizdas yra iškerpamas daro įtaką požymių išskyrimo ir skaičiavimo metu. Taip nuspręsta tolimesniems tyrimams nebenaudoti kintančių vaizdo dydžių ir atsisakyti trečio – „Naive Bayes“ klasifikatoriaus dėl netikslaus skirstymo į klases.

5.5. Požymių vertinimas

Norint patvirtinti klasifikatorių veiksmingumą, tikslinga vertinti apmokytų duomenų bazių parametrus. Svarbiausia, kad duomenų požymių bazę sudarytų skirtingi požymiai, kurie skirtųsi ne tik tarp tos pačios transporto klasės parametrų bet ir tarp klasių.

Tuo tikslu kiekvienas požymis statistiškai įvertinamas, t.y. ar vieno parametro vidurkis statistiškai lygus kito parametro vidurkiui. Tam išsikeliamos statistinės nulinė H_0 ir alternatyvi H_1 hipotezės pagrindžiančios statistinius skaičiavimus.

$H_0: \mu_x = \mu_y;$

$H_1: \mu_x \neq \mu_y;$

Hipotezės pagrindžiamos atliekant t-testą, tarp dviejų grupių, kai vidurkiai nėra žinomi, su 95 % pasiklovimo lygmeniu. Taip palyginami kiekvienas parametras su kitu imant tik lengvojo automobilio duomenų bazės dalį. Skaičiavimams pasitelkiama „Minitab“ programinė įranga. Gauti rezultatų p-reikšmės pateikiamos 13 lentelėje. Kiekvieno parametro pavadinimas pakeičiamas į „PrX“, dėl lentelės aiškesnės lentelės sudarymo.

13 lentelė. Statistinis lengvojo automobilio požymių įvertinimas

	Pr1	Pr2	Pr3	Pr4	Pr5	Pr6	Pr7	Pr8	Pr9	Pr10	Pr11	Pr12	Pr13	Pr14	Pr15	Pr16
Pr1	–	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Pr2	–	–	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Pr3	–	–	–	0	0	0	0	0	0	0	0	0	0	0	0	0
Pr4	–	–	–	–	0	0	0	0	0	0	0	0	0	0	0	0
Pr5	–	–	–	–	–	0	0	0	0	0	0	0	0	0	0	0
Pr6	–	–	–	–	–	–	0	0,02	0	0	0	0	0	0	0	0
Pr7	–	–	–	–	–	–	–	0	0	0	0	0	0	0	0	0
Pr8	–	–	–	–	–	–	–	–	0	0	0	0	0	0	0	0
Pr9	–	–	–	–	–	–	–	–	–	0	0	0	0	0	0	0
Pr10	–	–	–	–	–	–	–	–	–	–	0	0	0	0	0	0
Pr11	–	–	–	–	–	–	–	–	–	–	–	0	0	0	0	0
Pr12	–	–	–	–	–	–	–	–	–	–	–	–	0	0	0	0

13 lentelės tęsinys

	Pr1	Pr2	Pr3	Pr4	Pr5	Pr6	Pr7	Pr8	Pr9	Pr10	Pr11	Pr12	Pr13	Pr14	Pr15	Pr16
Pr13	–	–	–	–	–	–	–	–	–	–	–	–	–	0	0	0
Pr14	–	–	–	–	–	–	–	–	–	–	–	–	–	–	0,59	0
Pr15	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	0
Pr16	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–

Iš lentelėje pateiktų p-reikšmių matyti, kad dauguma verčių yra lygios ir mažesnės už 0,05, tai reiškia, kad priimama alternatyvi hipotezė. Parametrai yra statistiškai reikšmingi lyginant juos tarpusavyje. Tačiau tik vienoje parametro dalyje gauta, kad parametras yra statistiškai nesiskiriantis. Atsižvelgus į tai, kad dauguma jo dalių yra skirtingi, parametras gali būti naudojamas sistemoje transporto klasifikavimui.

Palyginus požymius tarpusavyje ir nustatius, kad jie yra reikšmingi, toliau vykdomas jų statistinis vertinimas, keičiantis transporto rūšiai. Jeigu parametų vidurkiai bus vienodi, jų teks atsisakyti, nes sistema galimai neteisingai klasifikuos transporto priemones.

Kiekvienos transporto klasės požymiai atitinkamai lyginami ANOVA testu. Taip įvertinama ar klasės parametras yra statistiškai reikšmingas nustatant klases. Pirmiausia išsikeliamos nulinė H_0 ir alternatyvi H_1 hipotezės.

H_0 : $\mu_a = \mu_s = \mu_v = \mu_{kt}$;

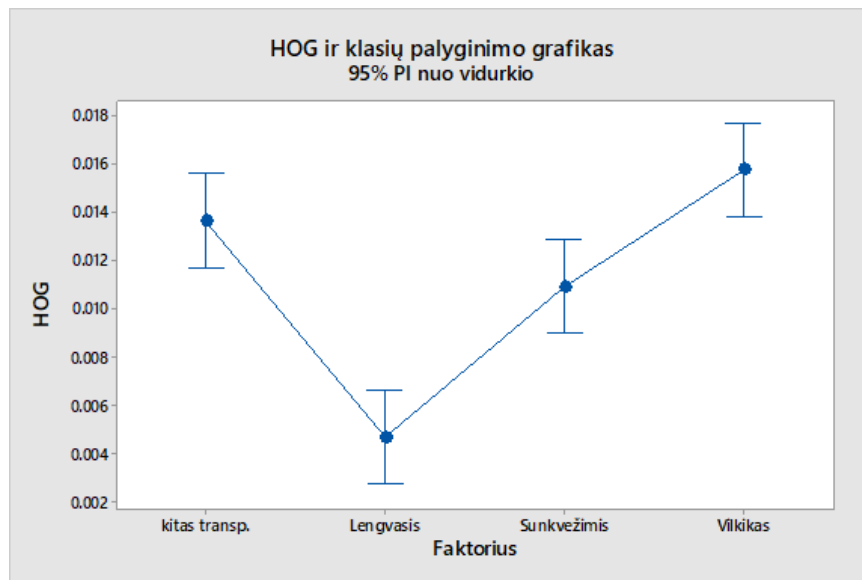
H_1 : $\mu_a \neq \mu_s \neq \mu_v \neq \mu_{kt}$;

čia: μ_a – lengvojo automobilio klasės požymio vidurkis, μ_s – sunkvežimio klasės požymio vidurkis, μ_v – vilkiko klasės požymio vidurkis, μ_{kt} – kito transporto klasės požymio vidurkis.

Atlikus šį testą gauti statistiniai kiekvienos klasės požymių rezultatai pateikiami 14 lentelėje. Taip pat 32 paveiksle atvaizduojama HOG, vieno iš požymių, kitimo grafikas, keičiantis klasėms.

14 lentelė. Statistiniai rezultatai lyginami tarp parametų klasių

	Požymiai					
	Kontrastas	Koreliacija	Energija	Homogeniškumas	Entropija	Vidurkis
p-reikšmė	0	0,001	0,001	0	0	0,001
	St. nuokrypis	Efektinė vertė	Kurtosis	Nelygumai	Ilgis	Plotis
p-reikšmė	0	0	0,001	0	0	0
	I/P santykis	Linijų kiekis	Atstumo vid.	HOG	–	–
p-reikšmė	0,003	0	0	0	–	–



32 pav. HOG parametro statistinis lyginimas tarp klasių

Patikrinus visus požymius statistiškai su 95 % pasiklovimo lygmeniu, gauta, kad visos p-reikšmės yra mažesnės negu 0,05. Tai lemia kad statistiškai visi parametrai kintant klasėms yra statistiškai reikšmingi ir priimama alternatyvi H_1 hipotezė.

Taigi statistinis palyginimas leidžia pagrįsti, kad sudaryta duomenų bazė yra svarbi nustatant klases, tiek tarpusavyje parametru, tiek tarp parametru ir klasių.

5.6. Duomenų bazių tikslumo vertinimas

Nors ankstesni tyrimai parodė, kad duomenų bazė yra statistiškai unikali ir kiekviena transporto klasė priklauso nuo parametru. Tačiau yra pastebėta, kad naudojant mažesni kiekį parametru, t.y. su 10 požymių gautas sistemos tikslumo rezultatas nėra toks tikslus, kaip naudojant 16 požymių duomenų bazę. Tikslumas skiriasi net per 10 %. Nuspręsta atlikti papildomus tyrimus ir nustatyti kiek požymių galima naudoti, kad sistemos tikslumas nebūtų reikšmingai mažesnis ir daugiau požymių skirstyti transporto rūšiai naudoti būtų nebenaudinga.

Tuo tikslu sudaroma duomenų bazė su mažesniu negu 16 požymių duomenų base, surenkami išklasifikuoto transporto rezultatai. Gauti rezultatai statistiškai pagrindžiami lyginant su SVM klasifikatoriaus 16 požymių rezultatu.

Statistinis vertinimas atliekamas naudojantis dviejų bandinių t-testą, su 95 % pasiklovimo lygmeniu, kai imama 15,14 ir 13 parametru duomenų bazės. Išsikeliamos nulinė H_0 ir alternatyvi H_1 hipotezės:

$$H_0: \mu_{16} = \mu_{15,14,13};$$

$$H_1: \mu_{16} \neq \mu_{15,14,13};$$

Gauti statistiniai rezultatai išreikšti p-reikšme pateikiami 15 lentelėje, o gauti klasifikavimo rezultatai pateikiami 5 priede.

15 lentelė. Statistinė lentelė, keičiantis požymių skaičiui

Klasifikatorius	Parametrų kiekis		
	15 parametrų	14 parametrų	13 parametrų
SVM	0,353	0,039	0,016
KNN	0,182	0,058	0,016

Remiantis 15 lentelės duomenimis akivaizdu, kad 15 parametrų p-reikšmės yra didesnės už 0,05, todėl galime priimti nulinę hipotezę ir teigti, kad 15 požymių duomenų bazės rezultatas yra toks statistiškai vienodas. Taigi vertinant dvi duomenų bases, taip pat galima naudoti klasifikavimą iš 15 parametrų.

5.7. Bendras sistemos įvertinimas

Šiuo atveju sistema gali veikti su dviem skirtingais požymių kiekiais ir dvejais klasifikatoriais. Norint nustatyti, kurie iš jų yra tinkamiausi naudojimui, juos tikslinga įvertinti su viso transporto kiekiu. Tuo tikslu statistiškai kiekvienas klasifikatoriaus tikslumo vidurkis $\mu_{16,15}$ pagrindžiamas su viso aptikto transporto kiekio vidurkiu μ . Išsikeliamos statistinės nulinė H_0 ir alternatyvi H_1 hipotezės:

H_0 : $\mu = \mu_{16,15}$;

H_1 : $\mu \neq \mu_{16,15}$;

Gauti statistiniai rezultatai išreikšti p-reikšme pateikiami 16 lentelėje.

16 lentelė. Sistemos statistinis įvertinimas

Klasifikatorius	Parametrų kiekis	
	16 parametrų	15 parametrų
SVM	0,053	0,006
KNN	0,018	0,002

Taigi iš gautų p-reikšmių tik viena reikšmė 0,053 yra didesnė už 0,05, todėl tik šiuo atveju priimama nulinė hipotezė. SVM klasifikavimo sistema su išreikštų 16 transporto požymių nėra reikšmingai skirtinga su bandymo metu viso transporto kiekiu. Sudarytą transporto klasifikavimo sistemą naudinga naudoti su nemažiau 16 požymių ir panaudojant SVM klasifikatorių.

5.8. Rekomendacija

Atlikus eksperimentinius bandymus, galima patvirtinti, kad sudaryta transporto klasifikavimo sistema gali identifikuoti keturias transporto klases. Iš 125 judančių objektų 117 buvo tinkamai išskirti pritaikant SVM metodiką. Tai reiškia, kad esant didesniam pravažiuojančio transporto kiekiui, sistemos tikslumas dar gali nukristi. Tačiau ką daryti norint išsaugoti ar turėti didesnę identifikavimo tikslumą, arba transportą skirstyti į daugiau negu keturias kategorijas, kai transporto matmenys, formos ir kiti parametrai yra panašūs? Tuo tikslu reikėtų keisti požymių skaičių ar net klasifikavimo algoritmą.

Taigi norint turėti tikslesnę ir daugiau kategorijų turinčią sistemą, vietoje mašininio mokymo metodikų, ateityje rekomenduojama, judančio transporto identifikavimui pritaikyti giliojo mokymo neuroninių tinklų algoritmus. Juos pritaikius vaizdo apdorojime tikslumas yra ganėtinai aukštas, galintis siekti virš 95 %. Tokios sistemos įvairiomis metodikomis sugeba atitinkamai įvertinti pikselių

reikšmes. Vidiniuose sluoksniuose iš jų sudaromos tam tikros grupės, iš jų sudaromi vaizdiniai blokai. Iš blokų gaunami požymiai, atitinkantys tam tikrai transporto klasei.

Tačiau reikia žinoti, kad neuroniniams tinklams gali nepakakti šimto ar net tūkstančio skirtingų transporto kategorijų vaizdų, kad sistema veiktų tinkamai. O turint didelius kiekius vaizdų ar net didelį neuroninį tinklą jo apmokymo ir identifikavimo laikas gali būti daug kartų didesnis negu suprojektuotos judančio transporto klasifikavimo sistemos.

5.9. Apibendrinimas

Šioje darbo dalyje atlikti eksperimentiniai bandymai, pagrindžiantys sudarytos transporto klasifikavimo sistemos modelio veikimą. Pradiniai klasifikavimo bandymai atlikti tarp KNN ir SVM mašininio mokymo, kurio metu nustatyta, kad sistema geriausiai klasifikuoja neapkarpytą vaizdą 83 % tikslumu ir esant ne mažiau 50 apmokytų skirtingų vaizdų. Toliau sistema įvertinta su trečiu klasifikatoriumi. Atliktas sistemos transporto aptikimo vertinimas, kurio metu nustatyti geriausi parametrai fiksuoti transportui. Statistiškai įvertinami praplėstos duomenų bazės požymiai, patvirtinamas jų reikšmingumas. Mažinant požymių skaičių nustatytas minimalus leistinas statistiškai reikšmingas požymių skaičius. Statistiškai vienodų požymių tikslumai palyginami su sudaryta sistema ir visu pravažiuojančiu transportu.

Taigi iš visų atliktų tyrimų galima teigti, kad sudarytas sistemos modelis su SVM mašininio algoritmu ir 16 požymių gali tinkamai klasifikuoti transporto priemones į keturias kategorijas. Pateikta rekomendacija tolimesniam projekto patobulinimui.

Išvados

1. Apžvelgti trys transporto priemonių klasifikavimui tinkami būdai: iš vaizdo kamerų gautų vaizdų apdorojimas ir klasifikavimas, magnetiniu jutikliu – AMR metodas bei ultragarsinės sistemos. Kiekvienas iš būdų yra unikalus, dėl metodikų ir sistemos įrengimo vietos, kurios atitinkamai gali būti įrengiamos šalia važiuojamosios dalies ar net pačioje kelio dangoje. Išsikelta mokslinė problema, parametrų ir klasifikavimo metodikoms nustatyti, norint tinkamai aptikti ir suskirstyti transportą į kategorijas.
2. Kiekvienam iš aptartų būdų, aptarti metodai, kuriais identifikuojamos transporto priemonės. Vaizdų apdorojimo metodu transportui pritaikyti skirta daug algoritmų: kraštinių aptikimas, preliminarūs ilgio pločio, greičio, formos, ploto stebėjimai. AMR jutikliu metodu, identifikuojama magnetinio lauko kitimu, energijos kiekiu, transporto matmenimis. Ultragarinių sistemų metodu: transporto ilgį, dydį ir greitį. Galiausiai pasirinkta sudaryti sistemą, skirtą judantį transportą klasifikuoti su vaizdo kameromis dėl mažo aplinkos poveikio ir didelio kiekio identifikacijai skirtų parametrų.
3. Atlikus esančių rinkoje vaizdo sistemų apžvalgą aptartos 3 skirtingos sistemos, kurios pasižymi plačiu 30 metrų matymo lauku. Sistemos yra trimatės ir dvimatės ar su skenavimo funkcijomis, todėl atitinkamai įvertinama transporto ilgis, plotis ir tūris. Transportą geba aptikti 90 % tikslumu, o identifikuoti 95 % tikslumu. Transporto klasifikavimui naudojamos mašininis ir gilusis mokymas.
4. Pasirinktai modeliuoti vaizdo stebėjimo sistemai aptarti galimi identifikavimo parametrai ir jų pasikliaujamumas. Kampų išskyrimo požymiais, priklausomai nuo pasirinktos metodikos galima siekti nuo 88,48 % iki 90,3 % tikslumo. GMM galima siekti tarp 85–95 % identifikavimo tikslumas. SURF galimas iki 93 %, o HOG metodu iki 98 % tikslumas. Aptarti 3 mašininio mokymo algoritmai: SVM, KNN ir „Naive Bayes“. Taip pat patikslinta mokslinė problema.
5. Sukurtas klasifikavimo modelis. Modelis fiksuoja judantį transportą, stebi aplinką ir iš jos išskiria transportą. Informatyvios transporto linijos išskiriamos pritaikant *Canny* kraštinių išskyrimo metodą, VAL, HLF ir kitus filtravimo metodus. Išskirti 10 požymių, kurie lyginami su sudaryta duomenų baze pasitelkus klasifikatorius nustatoma objekto klasė.
6. Pagal sukurta sistemos klasifikavimo modelį sudarytas jo veikimą atvaizduojantis algoritmas. Apimantis nuo vaizdo įrašo nuskaitymo iki konkrečios transporto klasės išvedimo.
7. Atlikti eksperimentiniai bandymai pagrindžia sudarytos sistemos modelio veikimą. Pradinio tyrimo metu ištirti trijų klasifikatorių tikslumai esant 10 požymių duomenų bazėms: SVM – 83 %, KNN – 78 %, „Naive Bayes“ – 65 % tikslumas. Priklausomai nuo apmokytų duomenų bazės vaizdų skaičiaus geriausias tikslumas 83 %, kai imama 50 ir daugiau vaizdų. Statistiškai įvertinus transporto aptikimą, surasti parametrai, leidžiantys nustatyti daugiausia transporto: 14 pikselių HLF, 3 VAL su 15 pikselių atstumu, kai kertama bent viena linija. Praplėtus duomenų bazes iki 16 požymių ir klasių kiekį iki 4, atliktas klasifikavimo tikslumo vertinimas: SVM – 93,6 %, KNN – 92 %, „Naive Bays“ – 79,2 % tikslumas. Statistiškai ištyrus požymius, pastebėta, kad jie tiek tarp klasių, tiek vienas nuo kito yra statistiškai reikšmingai skirtingi, galima teigti, kad duomenų bazė unikalė. Mažinant požymių skaičių pastebėta, kad sistema su 15 požymių statistiškai ($p=0,353$) atitinką sistemą su 16 požymių. Sistema su 16 požymių, SVM klasifikatoriumi tikslumas statistiškai ($p=0,053$) nesiskiria nuo viso transporto. Todėl ištyrus sistemos modelį pastebėta, kad tinkamai sistema gali veikti su 16 požymių duomenų baze, SVM klasifikavimo metodika ir atitinkamais aptikimo parametrais. Bendras sudarytos sistemos tikslumas 93,6 % nuo viso transporto. Pateikta rekomendacija galimam darbo patobulinimui.

Literatūros sąrašas

1. Newswire. Found Out What Are The Leading Causes For Most Car Accidents. 2019. [žiūrėta 2019-12-07]. Prieiga per: <https://markets.businessinsider.com/news/stocks/find-out-what-are-the-leading-causes-for-most-car-accidents-1027930348>
2. GUPTE, S.; MASOUD, O.; MARTIN R. F. K.; PAPANIKOLOPOULOS P. N.; Detection and Classification of Vehicles. [žiūrėta 2019-12-07]. Prieiga per: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.80.4194&rep=rep1&type=pdf>
3. GUPTE. S.; PAPANIKOLOPOULOS. P. N. Algorithms for Vehicle Classification. 2000. [žiūrėta 2019-12-08]. Prieiga per: <https://conservancy.umn.edu/bitstream/handle/11299/696/1/200027.pdf>
4. SARIKAN. S. S.; OZBAYOGLU M. A.; ZILCI O. Automated Vehicle Classification with Image Processing and Computational Intelligence. 2017. [žiūrėta 2019-12-08]. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S1877050917318161>
5. LIU. K.; MATTYUS. G. Fast Multiclass Vehicle Detection on Aerial Images. 2015. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/7122912>
6. CHENG. H-Y.; WENG. C-C.; CHEN. Y-Y.; Vehicle Detection in Aerial Surveillance Using Dynamic Bayesian Networks. 2017. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/6054051>
7. WANG. Y.; BAN. X.; WANG. H.; Wu. D.; WANG. H.; YANG. S.; LIU. S.; Lai. J.; Detection and Classification of Moving Vehicle From Video Using Multiple Spatio-Temporal Features 2019. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/8736962>
8. NG. Y. J.; TAY. H. Y.; Image-based Vehicle Classification System. 2012. [žiūrėta 2019-12-08]. Prieiga per: <https://www.researchgate.net/publication/223130046> Image-based Vehicle Classification System
9. RASHID. U. N.; MITHUN. C. N.; JOY. R. B.; RAHMAN. S. M. Detection And Classification of Vehicles from A Video Using Time-Spatial Image. 2010. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/5700739>
10. MITHUN. C. N.; RASHID. U. N.; RAHMAN. S.M. M. Detection and Classification of Vehicles from Video Using Multiple Time-Spatial Image. 2012. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/6156444>
11. CHOWDHURY. N.; HOWLADER. T.; RAHMAN. S. M. M. Video-Based Tracking of Vehicles Using Multiple Time-Spatial Images. 2016. [žiūrėta 2019-12-08]. Prieiga per: <https://www.researchgate.net/publication/303978698> VideoBased Tracking of Vehicles Using Multiple Time-Spatial Images
12. YAO. Y.; TIAN. B.; WANG F-Y. Coupled Multivehicle Detection and Classification with Prior Objectness Measure. 2017. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/7496893>
13. CHEN. Z.; PEARS. N.; FREAMAN. M.; AUSTIN. J. Road Vehicle Classification using Support Vector Machines. 2009. [žiūrėta 2019-12-08]. Prieiga per: <https://www.researchgate.net/publication/224092629> Road Vehicle Classification using Support Vector Machines

14. GOMMA. A.; ABELWAHAB. M. M.; MOHAMED. A-Z.; MINEMATSU. T.; TANGUCHI. R-I. 2019. [žiūrėta 2019-12-08]. Prieiga per: https://www.researchgate.net/publication/336760546_Robust_Vehicle_Detection_and_Counting_Algorithm_Employing_a_Convolutional_Neural_Network_and_Optical_Flow
15. RAMANATHAN. A.; CHEN. M.; Spatiotemporal Vehicle Tracking, Counting and Classification. 2017. [žiūrėta 2019-12-08]. Prieiga per: <https://ieeexplore-ieee.org.ezproxy.ktu.edu/document/7966754>
16. SIFUENTES. E.; CASAS. O.; PALLAS-ARENY. R. Wireless Magnetic Sensor Node for Vehicle Detection With Optical Wake-Up. 2011. [žiūrėta 2019-12-09]. Prieiga per: https://www.researchgate.net/publication/224209597_Wireless_Magnetic_Sensor_Node_for_Vehicle_Detection_With_Optical_Wake-Up
17. YIU. S. C.; SINEM. C.; BARIS. D.; SUMITRA. G.; CHIN-WOO. T.; PRAVIN. V.; Traffic Measurement and Vehicle Classification with a Single Magnetic Sensor. 2004. [žiūrėta 2019-12-09]. Prieiga per: <https://escholarship.org/uc/item/2gv111tv>
18. TAGHVAEEYAN. S.; RAJAMANI. R. Portable Roadside Sensors for Vehicle Counting, Classification, and Speed Measurement. 2014. [žiūrėta 2019-12-09]. Prieiga per: <https://ieeexplore-ieee.org.ezproxy.ktu.edu/document/6609121>
19. ODAT. E.; SHAMMA. S. J.; CLAUDEL. C. Vehicle Classification and Speed Estimation Using Combined Passive Infrared/Ultrasonic Sensors. 2018. [žiūrėta 2019-12-10]. Prieiga per: <https://ieeexplore-ieee.org.ezproxy.ktu.edu/document/8039243>
20. JO. Y.; JUNG. I. Analysis of Vehicle Detection with WSN-Based Ultrasonic Sensors. 2014. [žiūrėta 2019-12-10]. Prieiga per: https://www.researchgate.net/publication/264539070_Analysis_of_Vehicle_Detection_with_WSN-Based_Ultrasonic_Sensors
21. „ViNotion“ produktai. 2020. [žiūrėta 2020-03-28]. Prieiga per: <https://vinotion.nl/en/products/>
22. „Kapsch TrafficCom“ klasifikavimo produktai. 2020. [žiūrėta 2020-03-29]. Prieiga per: <https://www.kapsch.net/ktc/Portfolio/Products/Video-Sensor-Products/Classification-Products>
23. Kapsch nVDC - Vehicle Detection and Classification Sensor. 2020. [žiūrėta 2020-03-29]. Prieiga per: https://www.ibtta.org/sites/default/files/documents/2015/Dublin/Maitland_Michael.pdf
24. „AutoSense™“. 2020. . [žiūrėta 2020-03-31]. Prieiga per: <http://www.osilaserscan.com/Products/AutoSense/AutoSense-Overview.aspx>
25. „AutoSense“ 618 dokumentacija. [žiūrėta 2020-03-31]. Prieiga per: <http://www.osilaserscan.com/Files/AS618%20Data%20Sheet%20100820a.pdf>
26. „AutoSense“ 825 dokumentacija. [žiūrėta 2020-03-31]. Prieiga per: <http://www.osilaserscan.com/Files/AS825%20data%20sheet%20100803a.pdf>
27. „AutoSense“ 9390 dokumentacija. [žiūrėta 2020-04-01]. Prieiga per: <http://www.osilaserscan.com/Libraries/Documents/AS9390-data-sheet-101010a.sflb.ashx>
28. BILLIONES. R. K. D. C.; BANDALA. A.; SYBINGCO. E.; DADIOS. E.P. Vehicle detection and tracking using corner feature points and artificial neural networks for a vision-based contactless apprehension system. 2017. [žiūrėta 2019-05-15]. Prieiga per: https://www.researchgate.net/publication/322436309_Vehicle_detection_and_tracking_using_corner_feature_points_and_artificial_neural_networks_for_a_vision-based_contactless_apprehension_system

29. SANCHEZ. J.; MONZON. N.; SALGADO. A. An Analysis and Implementation of the Harris Corner Detector. 2018. [žiūrēta 2019-05-15]. Prieiga per: https://www.researchgate.net/publication/328050891_An_Analysis_and_Implementation_of_the_Harris_Corner_Detector
30. Fundamentals of Features and Corners. [žiūrēta 2019-05-15]. Prieiga per: <https://aishack.in/tutorials/harris-corner-detector/>
31. Shi-Tomasi Corner Detector & Good Features to Track. [žiūrēta 2019-05-15]. Prieiga per: https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_feature2d/py_shi_tomasi/py_shi_tomasi.html
32. GANDHI. N.; Harris Corner Detection and Shi-Tomasi Corner Detection. [žiūrēta 2019-05-15]. Prieiga per: <https://medium.com/pixel-wise/detect-those-corners-aba0f034078b>
33. TYAGI. D.; Introduction to FAST (Features from Accelerated Segment Test). [žiūrēta 2019-05-15]. Prieiga per: <https://medium.com/data-breach/introduction-to-fast-features-from-accelerated-segment-test-4ed33dde6d65>
34. MUEGLER. E.; BARTOLOZZI. C.; SCARAMUZZA. D.; Fast Event-based Corner Detection. [žiūrēta 2019-05-15]. Prieiga per: http://rpg.ifi.uzh.ch/docs/BMVC17_Mueggler.pdf
35. FAST Algorithm for Corner Detection. [žiūrēta 2019-05-15]. Prieiga per: https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_feature2d/py_fast/py_fast.html
36. VISWANATHAN. D. G. Features from Accelerated Segment Test (FAST). [žiūrēta 2019-05-15]. Prieiga per: http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/AV1011/AV1FeaturefromAcceleratedSegmentTest.pdf
37. INDRABAYU; BAKTI. R.Y.; ARENI. I.S.; PRAYOGI. A.A. Vehicle detection and tracking using Gaussian Mixture Model and Kalman Filter. [žiūrēta 2019-05-20]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/7892577>
38. JI. Z. SUN. J; Bounded asymmetric Gaussian mixture model with spatial constraint for image segmentation. 2017. [žiūrēta 2019-05-20]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/7949528>
39. HANSA. S.; PANATHAKKAN. A. MANSOORI. S.A. ALAHAMED. H. Automatic Vehicle Detection from Aerial Images using Cascaded Support Vector Machine and Gaussian Mixture Model. 2018. [žiūrēta 2019-05-20]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/8642716>
40. CHUNG-CHANG. W.; HSU. K-J. Vision-based side vehicle detection from a moving vehicle. 2010. [žiūrēta 2019-05-22]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/5551779>
41. CHEN. D-Y.; HSIEH. J-W.; CHEN. L-C.; Symmetrical SURF and Its Applications to Vehicle Detection and Vehicle Make and Model Recognition. 2014. [žiūrēta 2019-05-22]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/6720121>
42. MOMIN B.F.; KUMBHARE. S.M.; Vehicle Detection in Video Surveillance System using Symmetrical SURF. 2015. [žiūrēta 2019-05-22]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/7226055>
43. LI. X.; Guo. X.; A HOG Feature and SVM Based Method for Forward Vehicle Detection with Single Camera. 2013. [žiūrēta 2019-05-27]. Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/6643881>

44. BALLESTEROS. G.; SALGADO. L.; Histograms of oriented gradients for fast on-board vehicle verification. [žiūrēta 2019-05-27]. Prieiga per: http://oa.upm.es/37596/1/INVE_MEM_2014_197870.pdf
45. MITHI. Vehicle Detection with HOG and Linear SVM. 2017. [žiūrēta 2019-05-27]. Prieiga per: <https://medium.com/@mithi/vehicles-tracking-with-hog-and-linear-svm-c9f27eaf521a>
46. ZAKARIA. Y.; MUNIM. H.; GHONEIMA. M.; Modified HOG based on-road vehicle detection method. 2018. [žiūrēta 2019-05-27]. Prieiga per: <https://acadpubl.eu/jsi/2018-118-18/articles/18d/21.pdf>
47. SUNIL. R.; Understanding Support Vector Machine(SVM) algorithm from examples (along with code), 2017, [žiūrēta 2020-11-12]. Prieiga per: <https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/>
48. PISNER. D. A.; SCHNYER. D. M; Machine learning . Methods and Applications to Brain Disorders. Support Vector Machine, 2020, [žiūrēta 2020-11-12]. Prieiga per: <https://www.sciencedirect.com/science/article/pii/B9780128157398000067>
49. Support Vector Machine Algorithm, 2018, [žiūrēta 2020-11-12]. Prieiga per: <https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm>
50. AMITA. G.; MAHAJAN. S.; International Journal for Research in Applied Science & Engineering Technology (IJRASET). Comparison: KNN & SVM Algorithm, 2017 [žiūrēta 2020-11-12]. Prieiga per: <https://www.ijraset.com/files/serve.php?FID=11852>
51. STAVA. S. T.; Introduction to k-Nearest Neighbors: A powerful Machine Learning Algorithm (with implementaton in Python & R), 2018, [žiūrēta 2020-11-13]. Prieiga per: <https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/>
52. GOKTE. S. A.; Most Popular Distance Metrics Used in KNN and When to Use Them, 2020, [žiūrēta 2020-11-13]. Prieiga per: <https://www.kdnuggets.com/2020/11/most-popular-distance-metrics-knn.html>
53. SUNIL. R.; 6 Easy Steps to Learn Naive Bayes Algorithm with codes in Python and R, 2017, [žiūrēta 2020-11-15]. Prieiga per: <https://www.analyticsvidhya.com/blog/2017/09/naive-bayes-explained/>
54. GANDHI. R.; Naive Bayes Classifier, 2018, [žiūrēta 2020-11-15]. Prieiga per: <https://towardsdatascience.com/naive-bayes-classifier-81d512f50a7c>
55. Naive Bayes Classifier Algorithm, 2018, [žiūrēta 2020-11-15]. Prieiga per: <https://www.javatpoint.com/machine-learning-naive-bayes-classifier>

Priedai

1 priedas. Aptikto transporto lentelė nustatant tinkamus aptikimo parametrus

Parametro pavadinimas	Vaizdo įrašo pavadinimas												Iš viso	Iš viso aptikta
	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	V12		
13k 10v 111A	9	6	6	4	6	9	8	8	9	13	7	8	102	93
13k 10v 222A	8	6	6	3	6	9	8	6	9	10	6	7	102	84
13k 5v 111A	9	6	6	4	6	10	8	7	10	14	8	9	102	97
13k 5v 222A	8	6	6	3	6	8	8	7	7	10	7	8	102	84
14k 10v 111A	9	6	6	4	6	9	8	7	9	10	7	8	102	89
14k 10v 222A	8	5	6	3	6	9	8	6	9	9	6	7	102	82
14k 5v 111A	9	6	6	4	6	10	8	7	10	10	8	9	102	93
14k 5v 222A	8	6	6	4	6	8	7	7	7	10	6	8	102	83
13k 10v 333O	10	6	6	4	6	8	8	8	8	10	8	9	102	91
13k 10v 222O	10	6	6	4	6	10	8	8	10	12	8	10	102	98
13k 5v 333O	9	6	6	4	6	8	8	8	8	11	8	7	102	89
13k 5v 222O	9	6	6	4	6	10	8	8	10	12	8	10	102	97
14k 10v 333O	9	6	6	4	6	8	8	7	8	9	8	9	102	88
14k 10v 222O	10	6	6	4	6	10	8	8	10	12	8	10	102	98
14k 5v 333O	9	6	6	4	6	8	8	7	8	8	8	7	102	85
14k 5v 222O	9	6	6	4	6	10	8	7	10	10	8	10	102	94
14k 20v 333O	10	6	6	4	6	8	9	8	8	10	7	8	102	90
14k 20v 222O	10	6	6	4	6	10	9	8	10	12	8	10	102	99
14k 15v 333O	9	6	6	4	6	9	8	8	9	10	8	9	102	92
14k 15v 222O	10	7	6	4	6	10	9	8	10	12	8	10	102	100

2 priedas. Viso transporto kiekis esantis vaizdo įrašuose

Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	5	1	2	2	7	7	8	7	9	6	7	5	16	87
Vilkikas	3	1	2	1	4	2	1		2	2	1	3			22
Sunkvežimis	2	1	3			1	1		1	3	1			1	14
Kitas transportas				1										1	2

3 priedas. Klasifikavimo lentelė po duomenų bazės praplėtimo, kai pilnas vaizdas

SVM																
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso	
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14		
Lengvasis automobilis	5	5	1	2	2	7	7	8	7	7	6	6	5	15	83	
Vilkikas	3	1	2	1	4	2	1		2	2	1	3			22	
Sunkvežimis	1	1	2			1			1	2	1			1	10	
Kitas transportas				1										1	2	
KNN																
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso	
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14		
Lengvasis automobilis	5	4	1	2	2	7	7	8	7	5	6	5	5	16	80	
Vilkikas	3	1	1	1	4	2	1		2	2		3			20	
Sunkvežimis	2	1	3			1			1	3	1			1	13	
Kitas transportas				1										1	2	
„Naive Bayes“																
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso	
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14		
Lengvasis automobilis	4	3	1	1	2	7	5	7	7	6	6	4	5	13	71	
Vilkikas	2	1	2	1	3	2	1		2	2	1	2			19	
Sunkvežimis		1	2			1			1	1	1				7	
Kitas transportas				1										1	2	

4 priedas. Klasifikavimo lentelė po duomenų bazės praplėtimo, kai dominantis vaizdas

SVM															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	4	1	2	2	7	7	8	7	7	6	6	4	13	79
Vilkikas	3	1	2		2	1	1		1	2		2			15
Sunkvežimis	1	1	1							1				1	5
Kitas transportas				1										1	2
KNN															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	4	1	2	2	7	7	8	7	6	6	6	4	14	79
Vilkikas	3	1	1	1	3	2	1		2	1	1	2			18
Sunkvežimis	2	1	2			1			1	3				1	11
Kitas transportas				1										1	2
„Naive Bayes“															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	4	2	1	1	2	5	4	7	5	3	4	3	4	12	57
Vilkikas	2	1	1		3	2	1		2	1	1	2			16
Sunkvežimis	1	1	1			1			1	2					7
Kitas transportas				1										1	2

5 priedas. Klasifikavimo rezultatai, keičiant parametrų kieki

SVM 15 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	5	1	2	2	7	7	8	7	7	6	6	5	16	84
Vilkikas	3	1	2	1	4	2	1		2	2		3			21
Sunkvežimis	1	1	2							1	1				6
Kitas transportas				1										1	2
KNN 15 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	4	1	2	2	7	7	7	7	5	6	5	5	16	79
Vilkikas	3	1	2		4	2	1		2	2		2			19
Sunkvežimis	2	1	2			1			1	3				1	11
Kitas transportas				1										1	2
SVM 14 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	5	1	2	2	7	7	8	7	7	6	6	5	16	84
Vilkikas	3	1	1		3	1	1		1	2		3			16
Sunkvežimis	1	1	1				1			1					5
Kitas transportas				1										1	2
KNN 14 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	4	1	2	2	7	7	7	7	5	6	5	5	16	79
Vilkikas	3	1			3	2	1		2	2		2			16
Sunkvežimis	2	1	2			1			1	3				1	11
Kitas transportas				1										1	2
SVM 13 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	5	1	2	2	7	7	8	7	7	6	6	5	15	83
Vilkikas	3	1	1		3	1	1		1	2		3			16
Sunkvežimis	1	1					1			1					4
Kitas transportas				1										1	2
KNN 13 Parametrų															
Transporto klasė	Vaizdo įrašo pavadinimas														Iš viso
	v1	v2	v3	v4	v5	v6	v7	v8	v9	v10	v11	v12	v13	v14	
Lengvasis automobilis	5	4	1	2	2	7	7	7	7	5	6	5	5	15	78

Vilkikas	3	1	1		3	2	1		2	1		2			16
Sunkvežimis	1	1	2			1			1	3					9
Kitas transportas				1										1	2