



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Mikrojudumo priemonių klasifikavimas naudojant magnetinio lauko jutiklius

Baigiamasis magistro projektas

Eidenis Kasperavičius

Projekto autorius

Prof. Dangirutis Navikas

Vadovas

Kaunas, 2026



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Mikrojudumo priemonių klasifikavimas naudojant magnetinio lauko jutiklius

Baigiamasis magistro projektas

Elektronikos inžinerija (6211EX012)

Eidenis Kasperavičius

Projekto autorius

Prof. Dangirutis Navikas

Vadovas

Doc. Mindaugas Knyva

Recenzentas

Kaunas, 2026



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Eidenis Kasperavičius

Mikrojudumo priemonių klasifikavimas naudojant magnetinio lauko jutiklius

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.

Eidenis Kasperavičius

Patvirtinta elektroniniu būdu

Kasperavičius, Eidenis. Mikrojudumo priemonių klasifikavimas naudojant magnetinio lauko jutiklius. Magistro baigiamasis projektas / vadovas prof. Dangirutis Navikas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

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

Reikšminiai žodžiai: mikrojudumo priemonės, transporto srauto parametrai, mašininio mokymosi modeliai.

Kaunas, 2026. 53 p.

Santrauka

Baigiamojo magistro projekto tikslas – ištirti, ar magnetinio lauko jutikliai yra tinkami mikrojudumo priemonių klasifikavimui. Pagrindinė tyrimo dalis atliekama eksperimentiniu būdu surinktus magnetinio lauko iškraipymų parašus klasifikuojant mašininio mokymosi modeliais.

Pirmoje darbo dalyje analizuojami literatūros šaltiniai. Apžvelgiami metodai, kuriuos galima pritaikyti mikrojudumo priemonių parametru įvertinimui. Įvertinami mašininio mokymosi modelių, skirtų klasifikavimui, privalumai ir trūkumai.

Antroje dalyje aprašomas kompiuterinis modeliavimas baigtinių elementų metodu. Nustatomi minimalūs reikalavimai mikrojudumo priemonių parametru įvertinimo sistemoms – įrengimo gylis, gardelės periodas ir diskretizavimo dažnis. Įvertinama magnetinės inklinacijos įtaka įrašytiems mikrojudumo priemonių parašams.

Trečioje dalyje pristatoma mikrojudumo priemonių klasifikavimo metodika. Aptariami duomenų surinkimo ir paruošimo, signalo apdorojimo ir požymių išskyrimo, mašininio mokymosi modelių apmokymo ir validacijos metodai.

Ketvirtoje dalyje analizuojami mašininio mokymosi metodų taikymo mikrojudumo priemonių klasifikavimui rezultatai. Duomenimis pagrindžiamas metodikoje pristatytų žingsnių ir parametru pasirinkimas. Pristatomi bei statistiniais metodais palyginami bendri klasifikavimo rezultatai, detalai analizuojamas geriausių tikslumą pasiekęs modelis.

Kasperavičius Eidenis. Magnetometer-Based Micromobility Vehicle Classification. Master's Final Degree Project / supervisor Prof. Dangirutis Navikas; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

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

Keywords: micromobility, traffic parameters, machine learning models.

Kaunas, 2026. 53 pages.

Summary

The aim of this thesis is to investigate the feasibility of micromobility vehicle classification using magnetic field sensors. The main part of the research focuses on classifying experimentally collected magnetic field signatures using machine learning models.

The first part of the thesis analyzes scientific literature. Methods applicable to the estimation of micromobility vehicle parameters are reviewed, and the advantages and disadvantages of different machine learning models for classification are presented.

The second part describes computer simulations using the finite element method. The necessary requirements for micromobility vehicle parameter estimation systems – installation depth, array spacing and sampling frequency – are established. The influence of magnetic inclination on the recorded signatures of micromobility vehicles is discussed.

The third section presents the methodology for micromobility vehicle classification. Methods for data collection and preparation, signal processing, feature extraction, and the training and validation of machine learning models are described.

The fourth section analyzes the results obtained from applying machine learning models to the classification of micromobility vehicles. Data analysis is used to support the selection of methodological steps and their parameters. General classification results are presented and compared using statistical methods, and the performance of the highest-scoring model is analyzed in detail.

Turinys

Santrumpų ir terminų sąrašas	7
Įvadas.....	8
1. Literatūros apžvalga	9
1.1. Transporto srauto parametrų įvertinimo metodai	9
1.2. Mikrojudumo priemonių klasės.....	14
1.3. Magnetinio lauko parašų apdorojimo ir klasifikavimo metodai.....	14
2. Reikalavimų mikrojudumo priemonių parametrų įvertinimo sistemoms analizė	20
2.1. Pirminiai modeliavimo rezultatai	21
2.2. Geometriniai reikalavimai mikrojudumo priemonių parašų įrašymo sistemai	24
2.3. Dažniniai reikalavimai mikrojudumo priemonių parašų įrašymo sistemai	27
2.4. Magnetinės inklinacijos įtaka magnetinio lauko parašams	29
3. Mikrojudumo priemonių klasifikavimo metodika	30
3.1. Duomenų surinkimas ir paruošimas	30
3.2. Signalų apdorojimas ir požymių išskyrimas.....	33
3.3. Mašininio mokymosi modelių apmokymas ir validacija.....	35
4. Tyrimo rezultatai.....	37
4.1. Duomenų surinkimo ir apdorojimo proceso ir jo parametrų analizė.....	39
4.2. Klasifikavimo modelių rezultatų palyginimas.....	44
4.3. Geriausio klasifikavimo modelio rezultatų analizė	45
4.4. Mikrojudumo priemonių parametrų įvertinimo metodo apribojimai ir tolesnių tyrimų pasiūlymai.....	48
Išvados	49
Literatūros sąrašas	50
Priedai.....	54
1 priedas. Pradinis požymių sąrašas	54

Santrumpų ir terminų sąrašas

Santrumpos:

GBDT – gradientinio medžio stiprinimo modelis (angl. *gradient boosted decision tree*);

KNN – k artimiausių kaimynų modelis (angl. *k-nearest neighbors*);

MP – mikrojudumo priemonė;

MPPĮ – mikrojudumo priemonių parametrų įvertinimas;

MPPIS – mikrojudumo priemonių parametrų įvertinimo sistema;

RF – atsitiktinio miško modelis (angl. *random forest*);

SVM – atraminių vektorių automato modelis (angl. *support vector machine*);

TP – transporto priemonė.

Terminai:

Mikrojudumo priemonė – transporto priemonė, skirta artimo nuotolio susisiekimui, pasiekianti ne didesnę nei 45 km/h maksimalų greitį ir turinti ne didesnę nei 350 kg masę: dviratis, elektrinis paspirtukas, riedlentė ar kt.

Parašas (mikrojudumo priemonės magnetinio lauko iškraipymų parašas) – magnetinio lauko jutikliais užfiksuotas mikrojudumo priemonės sukeltų Žemės magnetinio lauko iškraipymų signalas, turintis laiko ir erdvės ašis.

Sunkioji mikrojudumo priemonė – sunki (virš 35 kg) ir (arba) greita (virš 25 km/h) mikrojudumo priemonė su elektros varikliu.

Tradicinė transporto priemonė – priemonė, skirta krovinių ar keleivių pervežimui važiuojamąja kelio dalimi ir turinti vidaus degimo, elektrinį ar kitokio tipo variklį.

Įvadas

Susisiekimas urbanizuotose teritorijose šiandien patiria permainas, kuriomis sprendžiamos ekologinės ir urbanistinės problemos. Vienas šios transformacijos rezultatų – mikrojudumo priemonės (MP) – lengvos (iki 350 kg svorio) ir lėtos (iki 45 km/h greičio) transporto priemonės [1], skirtos artimo nuotolio susisiekimui, pavyzdžiui, dviračiai, elektriniai paspirtukai ir kt. Jų populiarumas vis auga – didžiausi Europos miestai per metus įrengia beveik 1500 km dviračių takų [2], o Šiaurės Amerikoje kelionių skaičius MP dalijimosi platformose nuo 2022-ųjų iki 2023-ųjų išaugo 20 % [3].

Vis dėlto susisiekimo infrastruktūros planavimas daugelyje miestų yra pritaikytas tik dviračiams, o ne kitiems populiarioms MP rūšims [2]. Viena iš priežasčių – jutikliai, kuriais stebimos tradicinės transporto priemonės (automobiliai, sunkvežimiai, motociklai) nėra pritaikyti stebėti MP, pasižyminčioms mažais matmenimis, dideliu manevringumu, žema prošvaisa ir kitomis savybėmis [4]. Iššūkiai, kylantys renkant naudingą informaciją apie MP srautus, pavyzdžiui, jų skaičių ar pasiskirstymą pagal klasę [4], lemia sudėtingesnę MP infrastruktūros planavimą ir jų vairuotojų bei kitų eismo dalyvių saugumo užtikrinimą.

Šiame darbe tiriamas metodas MP klasifikavimui naudojant perspektyvius, tačiau mikrojudumo temos mokslinėse publikacijose kol kas nenagrinėtus magnetinio lauko jutiklius.

Tyrimo tikslas – sukurti mikrojudumo priemonių klasifikavimo metodą, naudojant magnetinio lauko jutiklius.

Tyrimo uždaviniai:

1. išanalizuoti mikrojudumo priemonių parametrų įvertinimo bei klasifikavimo metodus;
2. nustatyti minimalius reikalavimus mikrojudumo priemonių parametrų įvertinimo sistemoms, naudojančioms magnetinio lauko jutiklius;
3. parengti mikrojudumo priemonių klasifikavimo metodiką;
4. atlikti mašininio mokymosi metodų mikrojudumo priemonių klasifikavimui vertinimą.

Baigiamojo magistro darbo pagrindu publikuotas straipsnis KASPERAVIČIUS, E., et al. Micromobility Vehicle Classification for Smart City Infrastructure Using Magnetic Field Sensor Array. IEEE Access. 2026, vol. 14, 55641-55651. doi: 10.1109/ACCESS.2026.3681387

1. Literatūros apžvalga

Mikrojudumo priemonių svarba urbanistikoje analizuojama keliais skirtingais požiūriais. Tipiniam miesto gyventojui pagrindinė MP paskirtis – pirmo ir paskutinio kilometro (angl. *first-and-last mile*) susisiekimas su pagrindiniais viešojo transporto mazgais. Literatūroje mikrojudumas gali būti apibūdinamas kaip sistema, kuri yra modernių miestų vystymosi dalis, būtina, pavyzdžiui, pereinant prie modelio „išmanusis miestas 2.0“ (angl. *smart city 2.0*) [5]. Strateginio valdymo požiūriu MP – įrankis, kuris leidžia pasiekti tvarią urbanizuotą teritoriją plėtrą ir valdyti didėjančią jų tankį [6, 7].

Nenuostabu, kad vis didesnę reikšmę urbanistikoje turi ir MP parametrų stebėjimas. Pavyzdžiui, „CalmMobility“ urbanistinio planavimo metodikoje didelis dėmesys yra skiriamas *apgalvotam* greičiui ir sekai, kuria įgyvendinami susisiekimo infrastruktūros pokyčiai. Tai – kontrastas pastangoms kuo greičiau užbaigti numatytus darbus, neretai trikdančią įprastą miesto ritmą [8]. Taikant šią metodiką, MP parametrų įvertinimo sistemomis renkami detalūs duomenys, vėliau naudojami priimančiam įgyvendinimo, koregavimo ir stabdymo sprendimus (angl. *go / adjust / stop gates*). Tokiu būdu galima vykdyti bandomuosius projektus, grįstus duomenimis, o prireikus – juos atšaukti [8, 9]. Pagrindinis „CalmMobility“ metodikos tikslas – preciziškas eismo saugumo priemonių įrengimas, kuris leidžia kurti ramesnę ir saugesnę miesto aplinką [6, 8, 9].

Naudingus transporto srauto parametrus galima suskirstyti į kelias grupes, pasitelkiamas planuojant ir mikrojudumo, ir tradicinio transporto infrastruktūrą [10]:

- *apibendrinti transporto srauto parametrai*: transporto priemonių (TP) skaičius per laiko vienetą, srauto tankis, dominuojanti kryptis ir kt.;
- *individualių TP parametrai*: tipas (klasė), ilgis ir kt.;
- *vairuotojų elgesio parametrai*: važiavimo greitis, trajektorija, maršrutas ir kt.

Nepaisant tradicinių TP parametrų įvertinimui taikomų metodų įvairovės, tik nedidelė jų dalis yra tinkami ir efektyvūs MP srauto parametrų įvertinimui.

1.1. Transporto srauto parametrų įvertinimo metodai

Dalis TP srauto parametrų įvertinimo metodų *visiškai* negali būti pritaikomi MP dėl mažų matmenų ir žemos prošvaisos [4]. Tokių metodų pavyzdžiai yra pneumatiniai vamzdeliai ir pjezoelektriniai jutikliai.

Pneumatiniai vamzdeliai yra tiesiami skersai važiuojamosios kelio dalies ant jos paviršiaus. Vamzdelius suspaudžia užvažiuojanti TP, o jų viduje susidaręs papildomas slėgis yra išmatuojamas. Šis matavimo principas lemia, kad tokie vamzdeliai yra tinkami tik TP ašių skaičiavimui (transporto srauto intensyvumo matavimui), bet ne MP klasifikavimui, nes dauguma jų turi dvi ašis ir panašų ilgį. MP srauto parametrams matuoti jie taip pat netinka dėl žemos prošvaisos, lyginant su tradicinėmis TP, ir dėl mažo vairuotojų fizinės apsaugos lygio, kuris yra svarbus kontaktinio matavimo metu [11].

Pjezoelektrines medžiagas naudojančios transporto srauto parametrų įvertinimo metodai yra tinkami TP aptikimui ir ašių skaičiavimui, tačiau sudėtingesniems matavimams (pavyzdžiui, klasifikavimui) neretai reikalauja papildomų jutiklių [12]. Norint pasiekti nominalų sistemos tikslumą dažnai reikia, kad lengvosios TP judėtų pakankamu greičiu, pavyzdžiui, 25 km/h [12], todėl šis metodas netinkamas lengvoms ir sąlyginai lėtoms MP.

Dėl analogiškų prižasčių MP kontekste nepritaikomi ir eksperimentiniai metodai, grįsti, pavyzdžiui, akustiniais jutikliais [13, 14] arba optinėmis skaidulomis [15].

Metodų, skirtų būtent MP parametrų įvertinimui, tyrimų apimtis yra ribota – 2025 metų duomenimis, per paskutinius trejus metus paskelbtų publikacijų skaičius neviršijo dešimties [16]. Visgi, kai kurie metodai, taikomi tradicinėms TP, yra išbandyti ir MP parametrų įvertinimui. Platesnį jų taikymą riboja vidutiniškas tikslumas, kurį lemia maži MP matmenys, mažas metalinių dalių kiekis, didelis manevringumas ir kitos savybės.

Kompiuterinės regos metodai (dažniausiai YOLO modeliai) – pagrindinė mokslinėse publikacijose tiriama priemonė, nes vaizdų apdorojimas yra vienas labiausiai išvystytų metodų ir *tradicinių* TP srauto parametrų įvertinimui. Naudojant šį metodą, skaitmeninės kameros vaizdas yra tiesiogiai arba asinchroniškai perduodamas procesoriui, kuriame konvoliuciniu neuroniniu tinklu vykdomas jo apdorojimas. Kompiuterine rega pasiekiamas, pavyzdžiui, 92 % ir didesnis tikslumas [17], vaizdo kamerų ir duomenų apdorojimo sistemos yra prieinamos komerciškai, tačiau masinio diegimo kaštai gali būti dideli dėl reikalingos tinklo infrastruktūros [14] ir atraminių mechaninių struktūrų [12]. Be to, šio metodo tikslumas priklauso nuo paros laiko, apšvietimo, oro sąlygų [14], aplinkos (gretimos infrastruktūros bei objektų) ir įrengimo standartizavimo [12]. Papildomų iššūkių kelia atitiktis duomenų apsaugos reglamentams [14] bei galimas sukčiavimas naudojant kenkėjiškas įvestis [18].

Vykdam MP aptikimą kompiuterinės regos metodais problemų kelia didelis MP manevringumas ir maži matmenys. Intensyvaus eismo srauto sąlygomis MP gali būti visiškai ar iš dalies užstotos (uždengtos) kitų eismo dalyvių (1 pav.) [19]. Pavyzdžiui, K. Apurv. ir kt. tyrimo [20] metu klasifikuojant 229 nuotraukų rinkinio segmentus į dvi klases („elektrinio paspirtuko vairuotojas“ ir „kita“), pasiektas 91 % tikslumas, tačiau MP vizualinis užstojimas išskirtas kaip svarbus ribojimas.



1 pav. Iš dalies užstotos mikrojudumo priemonės [19]

D. Chen ir kt. [17] atliktas išsamesnis tyrimas įvertino YOLO modelių klasifikavimo tikslumą skirtingoms objektų klasėms. Nustatyta, kad naudotam testavimo duomenų rinkiniui modelis „YOLOv5s“, klasifikuojantis objektus į 11 klasių (žmonės, dviračiai, lengvieji automobiliai, motociklai ir kt.), pasiekė vidutinį 94,6 % tikslumą, tačiau, pavyzdžiui, paspirtukus aptiko tik 60,4 % tikslumu. Tais pačiais metais atliktame K. Sabri ir kt. [19] tyrime aprašytas MP aptikimo tobulinimas


lėmė tik nedidelį rezultatų pagerėjimą – pasiektas 83 % dviračių, 44 % riedlenčių ir 66 % paspirtukų aptikimo tikslumas.

Panašaus lygio alternatyva įprastoms vaizdo kameroms yra infraraudonųjų spindulių kameros, kurios eksperimentų metu naudojamos ir tradicinėms TP, ir MP atpažinti. Pavyzdžiui, B. Stahl ir kt. [11], naudodami tokią kamerą pasiekė 91 % dviračių ir 83 % paspirtukų klasifikavimo tikslumą.

Lidaro ir radaro jutikliai veikia matuodami siunčiamų atitinkamai šviesos ir radijo bangų sklidimo laiką, šioms atspindint nuo kliūtis, o TP atpažinimas atliekamas analizuojant surinktų taškų „debesį“ erdvėje. Apibendrintas objektų aptikimo principas yra panašus į vaizdo kameros duomenų apdorojimą, tačiau radaras pasižymi jautrumu triukšmui iš gretimų elektros perdavimo linijų ir kitų įrenginių [18], o taip pat elektromagnetinį triukšmą kuria pats [13]. Lidaro jutiklius literatūroje jau bandyta pritaikyti MP aptikimui – naudojant duomenų rinkinį su MP ir žmogumi, pasiektas 100 % MP aptikimo tikslumas, tačiau eksperimentas atliktas tik vienoje patalpoje [21]. Tai kelia su tyrimo atkartojamumu susijusių abejonių.

Lidaro ir radaro jutikliai naudojami ir komerciniuose MP aptikimo sprendimuose. Pavyzdžiui, gamintojo „ICOMS“ įrenginys TMA-3B3, naudojamas ir Lietuvoje, turi 24 GHz radaro ir 905 nm bangos ilgio lidaro jutiklius [22]. Jis montuojamas ant stulpo šalia dviračių tako ir skaičiuoja dviračius 97 % tikslumu, tačiau negali MP klasifikuoti ar įvertinti kitų jų parametrų.

Induktyviausias kilpas naudojantys metodai tik neseniai pradėti taikyti MP srauto parametrų įvertinimui. Kai ant kilpos užvažiuoja TP, kurios konstrukcijoje yra laidininkų, juose susidaro sūkurinės srovės, todėl sumažėja kilpos induktyvumas, kurio pokytį galima išmatuoti. Induktyviosios kilpos pasižymi geru rezultatų tikslumu taikant tradicinėms TP, tačiau reikalauja sudėtingo diegimo proceso (dalies viršutinio kelio dangos sluoksnio pašalinimo, kaip pavaizduota **2 pav.**) [11], nuolatinės sistemos priežiūros dėl sunkių TP poveikio ir mechaninių kelio dangos pažeidimų [23], o galimas matavimo rezultatų dviprasmiškumas reikalauja sudėtingų matavimo principų [24]. Atsižvelgus į mažesnius MP matmenis, taip pat svarbus parametras yra ir skersinė skyra, kuri tiesiogiai priklauso nuo kilpų skaičiaus statmena MP judėjimui kryptimi ir yra ribojama kilpos dydžio (santykio signalas-triukšmas).




2 pav. Induktyviųjų kilpų ir pjezoelektrinių juostų įrengimo schema [25]

Sistemą, naudojančią induktyviausias kilpas, 2022-aisiais metais paskelbė kuriantys Valencijos technikos universiteto mokslininkai [10]. Naudojant dvigubą 0,5 m dydžio kilpą, veikiančią 400-800 kHz dažniu, užfiksuojamas induktyvusis MP profilis, apskaičiuojami išvestiniai profilio

parametrai ir įvertinami pačios MP parametrai. Išradimo technologinės parengties lygis – 4 (išradimas patvirtintas laboratorijoje) [10].

Panašų metodą 2024-aisiais savo publikacijoje aprašė ir Indijos technologijos instituto tyrėjai [4]. Pateikta sistema naudoja keturias 100 cm pločio ir 22-92 cm ilgio kilpas, kurių induktyvumas matuojamas 1 MHz dažniu (**3 pav.**). Autorių teigimu, rezultatų patikimumas yra pakankamas (triukšmo įvertis – standartinis nuokrypis – lygus $1 \mu V$, o užfiksuotų signalų amplitudės siekia $100 \mu V$ ir daugiau), tačiau ši sistema taip pat išbandyta tik laboratorinėmis sąlygomis [4].




3 pav. Induktyviųjų kilpų jutiklis mikrojudumo priemonių aptikimui [4]

Induktyviausias kilpas naudoja ir komercinis sprendimas MP skaičiavimui – gamintojo „Eco-Counter“ produktų linija „ZELT“. Šie dviračių skaičiavimo įrenginiai klasifikuoja pravažiuojančias MP 95 % tikslumu, naudodami 13 atskyrimo kriterijų [26]. Nors toks klasifikavimo tikslumas yra tinkamas praktiniam taikymui, tačiau naudojamos tik dvi klasės (dviračių ir elektrinių paspirtukų), todėl praktinė surinktų duomenų nauda gali būti ribota.

Dar viena mokslinių tyrimų kryptis MP parametrų įvertinimo srityje – **aktyviniai metodai**. Pavyzdžiui, A. Lazaro ir kt. publikacijoje [27] aprašomas metodas srauto parametrų įvertinimui, naudojantis atgalinio spinduliavimo (angl. *backscatter*) žymeklį, kurį gali aptikti TP naudojamas radaras. R. Freitas ir kt. [28] kaip MP žymeklį siūlo naudoti išmanųjį telefoną. Aktyviniai metodai turi svarbų trūkumą – norint juos padaryti universalius, reikalingos itin didelio masto teisinio reguliavimo iniciatyvos, kurios silpnai prižiūrimoje MP rinkoje gali būti itin sudėtingos.

Šiame darbe nagrinėjami **magnetinio lauko jutikliai** – literatūroje dar netyrinėtas metodas MP parametrų įvertinimui. Šie jutikliai matuoja žemės magnetinį lauką, kurį iškraipo feromagnetinių medžiagų turinčios TP (**4 pav.**). Magnetinio lauko jutiklių veikimo principas gali būti įvairus: magnetorezistyviniai jutikliai matuoja besikeičiančią permalojaus (nikelio ir geležies lydinio) juostelių varžą, impedansiniai jutikliai matuoja dėl magnetinio lauko besikeičiantį laidininkų impedansą ir t. t.

Naudojant dviejų ašių impedansinį magnetinio lauko jutiklį, pastatytą 66 cm aukštyje 90 cm atstumu nuo tradicinių TP, pasiektas 91,6 % aptikimo tikslumas [29]. Kita sistema, naudojančia magnetinio lauko jutiklį, pasiektas 92-95 % TP skaičiavimo tikslumas [30].



4 pav. Transporto priemonės sukurti žemės magnetinio lauko iškraipymai [31]

Vieno magnetinio lauko jutiklio naudojimas yra itin paprastas, tačiau tokiu būdu negalima patikimai atlikti klasifikavimo, nustatyti judėjimo krypties ir kitų TP parametrų [30]. Kita vertus, naudojant du ar daugiau jutiklių galima įvertinti ir greitį, ir atlikti klasifikavimą. Pavyzdžiui, tokiu metodu pasiektas 87 % klasifikavimo tikslumas, o greitis 90 % atvejų įvertintas su ne didesne nei 7,5 km/h paklaida [32]. Parametrų įvertinimas yra dar tikslesnis atlikus laiko sinchronizavimą tarp atskirų jutiklių, pavyzdžiui, juos sujungus į gardelę. Tokia sistema yra pakankamai tiksli net atlikti TP pakartotiniam identifikavimui – užfiksavus TP magnetinio lauko iškraipymų signalą, kiti tos pačios priemonės signalai iš kandidatų sąrašo atrinkti 90 % tikslumu [33].

Nepaisant to, kad magnetinio lauko jutikliai kol kas nėra naudojami MP aptikimui ir klasifikavimui, dar 2014-aisiais JAV Federalinė greitkelių administracija pažymėjo, kad tokie jutikliai, naudojami poroje (90 cm tarpusavio atstumu 15 cm gylyje), gali aptikti dviratį, esantį 1,2 metro atstumu [25].

Taigi, tik dalis TP parametrų įvertinimui skirtų metodų gali būti fiziškai naudojami ir MP parametrų įvertinimui: induktyviosios kilpos, kompiuterinės regos metodai, lidaro bei radaro ir magnetinio lauko jutikliai (1 lentelė).

1 lentelė. Metodų, kuriuos galima naudoti mikrojūdumo priemonių parametrų įvertinimui, apibendrinimas

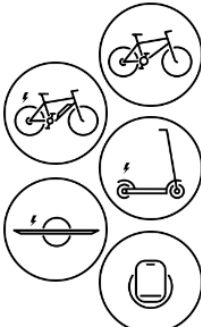
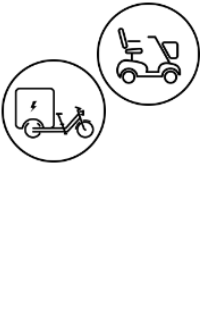
Metodas	Privalumai	Trūkumai
Kontaktinis (pneumatinis, pjezoelektrinis)	Paprastumas, maža kaina, didelis patikimumas	Keliamos saugumo rizikos mikrojūdumo priemonių vairuotojams; netinka mažo svorio, mažu greičiu judančioms MP
Kompiuterinė rega	Nereikalauja fizinio įterpimo į kelio dangą, didelis duomenų detalumas	Mažas MP klasifikavimo tikslumas (pvz., 66%), jautrumas oro sąlygoms ir apšvietimui, vizualiniam užstojimui
Induktyviosios kilpos	Geras SNR ir klasifikavimo tikslumas (pvz., 95% dviem klasėms)	Didelis reikalingas paviršiaus plotas ir sudėtingas diegimas, jautrumas mechaniniams kelio dangos pažeidimams, maža skersinė skyra
Vienas magnetinio lauko jutiklis	Mažas reikalingas paviršiaus plotas, maža kaina, paprastas diegimas	Netinkamas klasifikavimui, važiavimo krypties nustatymui ir kt. parametrų įvertinimui
Magnetinio lauko jutiklių gardelė	Klasifikavimo galimybės, didelė skersinė skyra, mažesnis reikalingas paviršiaus plotas nei induktyviųjų kilpų	Reikalinga sinchronizacija ir sudėtingesni signalų apdorojimo algoritmai nei induktyviosioms kilpoms

Įvertinus savybes, kuriomis MP skiriasi nuo tradicinių TP (manevringumą, mažus matmenis ir kt.), magnetinio lauko jutikliai išsiskiria atsparumu daliniam ar visiškam MP vizualiniam užstojimui, prastoms oro sąlygoms bei apšvietimui, mažesniu nei induktyviųjų kilpų užimamu kelio dangos plotu, geresne skersine skyra bei gerais tradicinių TP parametrų įvertinimo rezultatais.

1.2. Mikrojudumo priemonių klasės

Taikant magnetinio lauko jutiklius, MP parametras¹, kurį įvertinti yra sudėtingiausia – tai MP tipas (klasė), nes klasifikavimo atžvilgiu jis yra netiesinis, lyginant su važiavimo greičiu, kryptimi ar kt. Šio parametro įvertinimą dar labiau apsunkina tai, kad nėra vieningos MP klasifikavimo sistemos.

Pavyzdžiui, „SAE International“ klasifikavimo sistema MP skirsto pagal funkcinius (konstrukcinius) tipus: dviračiai, paspirtukai su sėdyne ir be jos, riedžiai, riedlentės, riedučiai [34]. Į šią klasifikaciją neįtrauktos neelektrinės MP (tradiciniai dviračiai, vaikiški paspirtukai ir kt.). Kita vertus, Tarptautinio transporto forumo (angl. *International Transport Forum*) ataskaitoje pateikiama klasifikavimo sistema įtraukia šias neelektrines MP ir aprašo keturias klases, sudaromas pagal maksimalų greitį ir svorį (5 pav.) [35].

A klasė	B klasė	C klasė	D klasė
neelektrinės arba elektrinės, maksimalus greitis iki 25 km/h		elektrinės, maksimalus greitis 25-45 km/h	
<35 kg (77 lb)	35 – 350 kg (77 – 770 lb)	<35 kg (77 lb)	35 – 350 kg (77 – 770 lb)
			

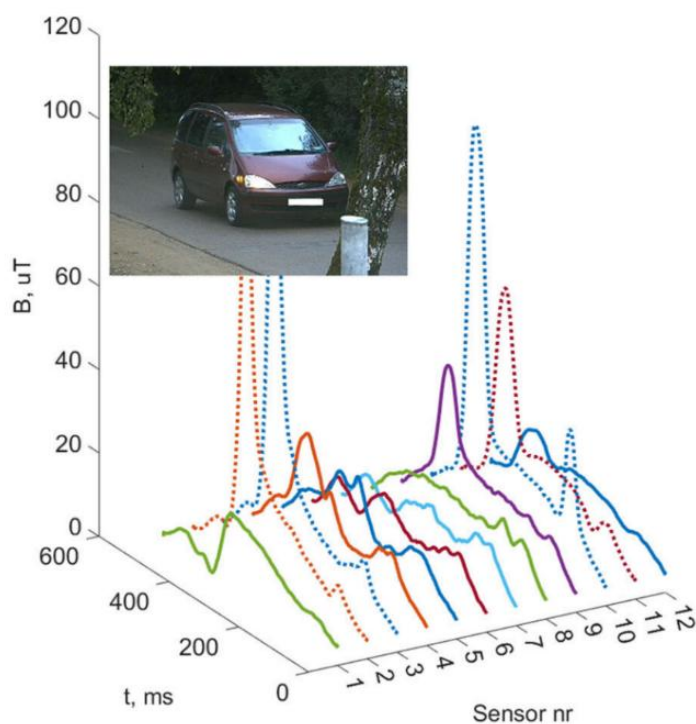
5 pav. Tarptautinio transporto forumo mikrojudumo priemonių klasifikavimo sistema [35]

Taikant klasifikavimo sistemas praktikoje, jos gali būti koreguojamos atsižvelgiant į vietinio MP srauto statistiką. Tai lemia ir teisiniai, ir kultūriniai skirtumai – pavyzdžiui, krovininiai dviračiai, plačiai paplitę Azijos šalyse, beveik nenaudojami Lietuvoje.

1.3. Magnetinio lauko parašų apdoravimo ir klasifikavimo metodai

Naudojant magnetinio lauko jutiklius, įrašomi TP (šiam darbe – ir MP) magnetinio lauko iškraipymų parašai (toliau – parašai). Tai – dviejų matmenų matricos, kurių kiekvienas elementas atitinka vieno jutiklio išmatuotą magnetinio lauko vertę tam tikru laiko momentu (6 pav.).

¹ MP parametrų įvertinimo sistemos atžvilgiu MP klasė yra viena savybių ar parametrų (mašininio mokymosi modelio išvesčių), apibūdinančių priemonę jos užfiksavimo metu.



6 pav. Transporto priemonės magnetinio lauko iškraipymų parašas [36]

Paprasčiausias metodas MP klasifikavimui naudojant šiuos parašus – rankiniu būdu nustatytos taisyklės. Pavyzdžiui, K. Čulik ir kt. [30] klasifikavimą atliko pagal įvertintą magnetinį TP ilgį. Laikyta, kad motociklų ilgis yra iki 2,2 m, keleivinių automobilių – iki 5,5 m, nedidelių sunkvežimių – iki 9,5 m, o didelių sunkvežimių – virš 9,5 m. Deja, tokių taisyklių taikymas nepasiekė didelio tikslumo realaus transporto srauto atveju – kai kurioms TP klasėms klasifikavimo tikslumas nesiekė net 8 %.

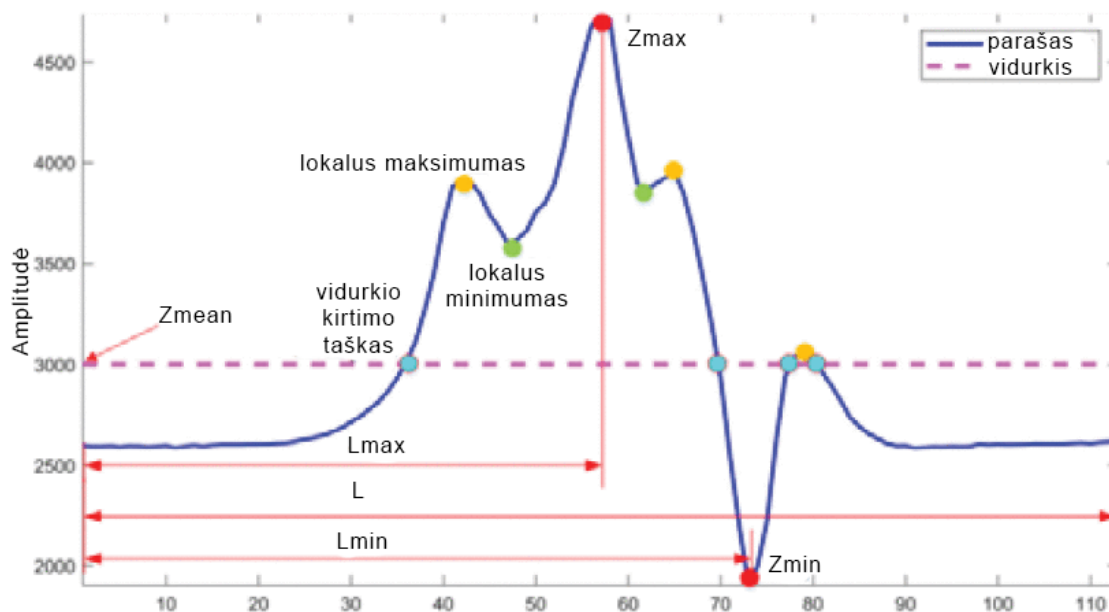
Žinoma, klasifikavimui gali būti naudojama ne viena taisyklė, o jų rinkinys. Pavyzdžiui, S. Keawkamnerd ir kt. [37] tradicinių TP klasifikavimui naudojo tris taisykles (požymius): normalizuotą magnetinio lauko parašo ilgį, vidutinę parašo energiją ir maksimumų skaičių. Šiems požymiams pritaikius hierarchinio medžio modelį su rankiniu būdu parinktomis slenkstinėmis vertėmis, sukurtas algoritmas, kuris pasiekė 80,9 % klasifikavimo tikslumą. Toks modelis tinkamai atliko šią užduotį ir buvo tinkamas itin mažų skaičiavimo pajėgumų mikroprocesoriui, tačiau rankiniu būdu optimizuotas sprendimų medis nėra efektyvus MP klasifikavimui. Šios priemonės pasižymi didesne variacija tarp tos pačios klasės narių, todėl tikėtina, kad pasiekti atitinkamiems rezultatams būtų reikalingas daugiau nei tris požymius turintis medis, kurį optimizuoti rankiniu būdu būtų neefektyvu.

Siekiant sukurti sudėtingesnes klasifikavimo taisykles, pasitelkiamas mašininis mokymasis. Yra žinoma, kad mašininio mokymosi modelių tikslumas ir efektyvumas didėja tik iki tam tikro požymių skaičiaus. Turint per daug požymių, arba kaip modelio įvestį naudojant visą užfiksuotą signalą, klasifikavimo tikslumas mažėja. Taigi, svarbus pirmasis žingsnis naudojant šiuos modelius yra naudingų signalo požymių išskyrimas.

Požymių pasirinkimas itin priklauso nuo modelio taikymo srities. TP klasifikavimą tiriančioje literatūroje išskiriami požymiai, susiję su parašo amplitude (maksimumais, minimumais), jų padėtimi tarpusavyje bei atstumu nuo parašo pradžios ir kt. (**2 lentelė**). Kai kurie požymiai pavaizduoti **7 pav.**

2 lentelė. Transporto priemonių magnetinio lauko parašų klasifikavimo požymių pavyzdžiai

Požymių grupė	Požymiai	Šaltiniai
Amplitudiniai	Skirtumas tarp gretimo maksimumo ir minimumo	[4]
	Globalus maksimumas ir minimumas	[38, 39]
	Lokalių maksimumų ir minimumų amplitudė	[38]
Atstumo	Atstumas tarp maksimumų	[4]
	Parašo ilgis	[40, 38]
	Minimumo, maksimumo ir vidurkio kirtimo taškų atstumas nuo parašo pradžios	[38]
	Maksimumo ir minimumo plotis	[39]
	Globalaus maksimumo ir minimumo santykis	[39]
Kiekybiniai	Maksimumų skaičius	[4, 39]
	Slenkstinį ilgį viršijančių maksimumų skaičius	[40]
	Globalių minimumų (angl. dead zones) skaičius	[4]
Kiti	Vidurkis	[38, 39]
	Standartinis nuokrypis	[38, 39]
	Diferenciniai signalo energijos parametrai	[40]



7 pav. Transporto priemonės magnetinio lauko iškraipymų parašo požymių pavyzdžiai.
Horizontali ašis – signalo atskaitos [38]

Galimų požymių aibė yra per didelė tiesioginiam taikymui net ir atmetus visus požymius, kurie nėra tinkami (neturi prasmės) MP parašams. Iš šios aibės išsirinkti didžiausią įtaką modelio tikslumui turinčius požymius leidžia matmenų mažinimo (angl. *dimensionality reduction*) metodai. Jų sprendžiama problema – duomenų taškų tankio didinimas, pavyzdžiui, 3 matmenų požymių erdvę transformuojant į dviejų matmenų erdvę. Matmenų mažinimo metodų pavyzdžiai yra pagrindinių komponentų analizė (angl. *principal component analysis*, PCA), tiesinė diskriminantinė analizė (angl. *linear discriminant analysis*, LDA), rekursinis požymių atmetimas ir kt. [41]

Požymius išskirti taip pat galima modelio įvesties vektoriaus sudarymo etape pasitelkiant neuroninius tinklus. Pavyzdžiui, naudojant autoenkoderius, pirmasis neuroninis tinklas (enkoderis) įėjimo duomenis koduoja į mažesnę (nurodytų matmenų) požymių erdvę, o antrasis tinklas (dekoderis) iš jos atkuria pradinis duomenis. Apmokius abu tinklus atliekamas testavimas – jeigu skirtumas tarp įėjimo duomenų ir modelio išvesties neviršija nurodytos slenkstinės vertės, kodavimas yra teisingas ir efektyvus. [42]

Bet kuriuo aukščiau aprašytu būdu sudarius požymių erdvę (vektorių), ją galima naudoti kaip mašininio mokymosi modelio įvestį.

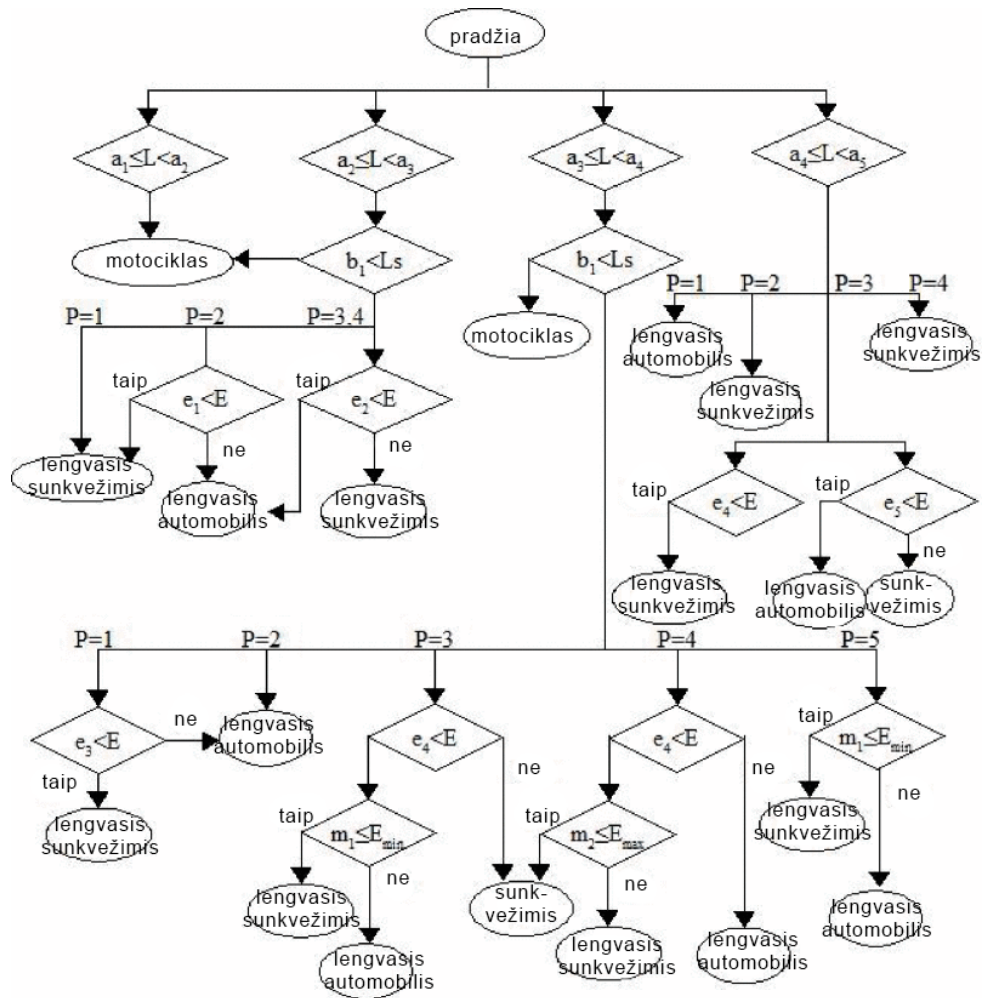
Paprasčiausi mašininio mokymosi modeliai, pavyzdžiui, **Bajeso arba logistinės regresijos**, yra paremti klasikinais statistiniais metodais. Taikant šiuos modelius, atitinkamai remiamasi Bajeso teorema sąlyginėms tikimybėms apskaičiuoti arba kreive, nusakančią duomenų taško tikimybę priklausyti vienai iš dviejų klasių. Šie modeliai nepasiekia didelio tikslumo netiesinių problemų sprendimo metu ir reikalauja, kad požymiai būtų tarpusavyje nepriklausomi, todėl yra netinkami MP parašų apdorojimui.

Sprendimų medžiai (angl. *decision trees*) – tai algoritmai, sudaryti iš sąlygos sakinių (medžio viršūnių), sujungtų algoritmo šakomis. Algoritmas vykdomas nuo medžio šaknies iki galinės viršūnės (lapo), kiekvienai viršūnei priimant po vieną sprendimą. Toks medis gali būti optimizuojamas, pavyzdžiui, naudojant CART (angl. *classification and regression tree*) metodą, kuris kiekvienai viršūnei pagal pasirinktą kriterijų (pavyzdžiui, vidutinį kvadratinį nuokrypį) randa geriausią sąlygą, padalinančią likusius apmokymo duomenis į dvi grupes. [41]

Naudojant sprendimų medžius, galima pasiekti virš 80 % TP parašų klasifikavimo tikslumą [40, 43] (**8 pav.** pateikiamas sprendimų medžio pavyzdys). Šie algoritmai yra greiti, lengvai suprantami, tinkami spręsti netiesinėms problemoms ir, svarbiausia, nereikalauja, kad požymiai būtų nepriklausomi. Sprendimų medžių trūkumai atsiskleidžia naudojant dideles apmokymo duomenų aibes – kyla persimokymo rizika, didėja medžio sudėtingumas ir apmokymo trukmė. [41]

K artimiausių kaimynų (angl. *k-nearest neighbors*, KNN) modelis lygina duomenų panašumą pagal tam tikrą erdvinį kriterijų, pavyzdžiui, euklidinį atstumą. Radius K kaimynų, kurie pagal šį kriterijų yra arčiausiai naujojo duomenų taško, šie balsavimo principu nusprendžia, kurią klasę jam priskirti. Kaip ir sprendimų medžiai, KNN modeliai gali būti naudojami spręsti netiesinėms problemoms, tačiau vykdymas yra lėtas turint didelius duomenų rinkinius, nes atstumo kriterijų įprastu atveju reikia apskaičiuoti kiekvienam žinomam taškui. [41]

Atraminių vektorių automatai (angl. *support vector machines*, SVM) – modeliai, kurie randa arčiausiai klases skiriančios ribos esančius duomenų taškus (atraminius vektorius) ir pagal juos sukonstruoja klases skiriančią hiperplokštumą. Šie modeliai yra atsparūs persimokymui ir tinkami netiesinėms problemoms spręsti, tačiau jiems didelį poveikį turi triukšmas. Naudojant atraminių vektorių automatus galima, pavyzdžiui, pagal magnetinius parašus klasifikuoti lengvuosius automobilius ir sunkvežimius [44]. Naudojant du požymius (dviejų magnetinio lauko jutiklių amplitudžių santykį ir parašo ilgį) S. Taghvaeeyan ir kt. pasiekė 83 % klasifikavimo tikslumą. Y. Feng ir kt. tyrime pat naudotas atraminių vektorių automatas, kurio įvestis yra TP parašo maksimumų skaičius ir vibracijų ilgis [32].



8 pav. Transporto priemonių magnetinio lauko parašų klasifikavimui naudojamas sprendimų medis [40]

Ansamblio modelis – tai aukščiau aprašytų modelių patobulinimas, kurį taikant keli modeliai yra sujungiami į vieną, taip sumažinant atskirų modelių klaidų įtaką rezultatui. Galutinis klasifikavimo sprendimas gali būti priimamas lygaus balsavimo principu arba naudojant svorinius koeficientus. Ansamblio modeliai pasižymi didesniu atsparumu triukšmui ir išskirtims, mažesne persimokymo rizika, tačiau taip pat – ilgesne apmokymo ir vykdymo trukme. [41]

TP parašų klasifikavimui ansamblio modelį naudojo, pavyzdžiui, H. Dong ir kt. [38] – tyrime pasitelktas gradientinio medžio stiprinimo modelis (angl. *gradient boosted decision tree*, GBDT), nuosekliai apmokantis kiekvieną medį pagal gradiento suteikiamą informaciją. Šis modelis pasiekė 80,5 % tikslumą, lyginant su paprastesnio atsitiktinio miško (angl. *random forest*, RF) modelio tikslumu (78,84 %). H. Zhang ir kt. tyrime [45] AdaBoost ansamblio modelis (pagal klaidos dydį keičiantis kiekvieno modelio įtaką galutiniame balsavime) su SVM šerdimi pasiekė 94,6 % skirtingų TP modelių klasifikavimo tikslumą.

Neuroniniai tinklai – mašininio mokymosi modeliai, kurie nereikalauja išankstinio signalo požymių išskyrimo ir kurie yra naudingi taikymo sritims, kuriose požymių išskyrimas yra konceptualiai arba techniškai sudėtingas. Neuroniniai tinklai, sudaryti iš tarpusavyje sujungtų viršūnių (neuronų), išdėstytų keliais sluoksniais, yra tinkami spręsti netiesinėms problemoms ir gali atlikti kelis klasifikavimo procesus vienu metu. Naudojant giliojo mokymosi tinklus – sudarytus iš daugiau nei

trijų neuronų sluoksnių – modelis gali vidiniame sluoksnyje pats susidaryti požymių vektorių. Šio tipo modelių trūkumas – ilga apmokymo trukmė ir sudėtingas modelio logikos interpretavimas. [41]

TP klasifikavimo kontekste skirtingus klasifikavimo modelius lygino H. Li [39] ir H. Zhang [45]. Gauti rezultatai (**3 lentelė**) atskleidė, kad geriausius rezultatus pasiekia ansamblio modeliai. Mažiausią tikslumą pasiekia modeliai, pagrįsti požymių nepriklausomumu (Bajeso ir logistinės regresijos) bei modeliai, skirti tiesinėms problemoms spręsti (neuroninis tinklas, bazinis AdaBoost).

3 lentelė. Mašininio mokymosi modelių, naudojamų TP parašų klasifikavimui, tikslumo palyginimas


Modelis	Tikslumas, %	
	Li ir kt. [39]	Zhang ir kt. [45]
AdaBoost su SVM/RBF šerdimi	-	94,6
RF	-	92
Logistinė regresija	-	90,7
SVM	88,9	91,6
CART	88,9	-
NN	84,7	90,7
AdaBoost	-	84,7
Bajeso	83,1	80,4
Šablono pritaikymas	49,3	-

Tradicinių TP parametrų įvertinimui jau naudojami, tačiau MP parametrų įvertinimui anksčiau nenagrinėti magnetinio lauko jutikliai gali būti taikomi MP klasifikavimui. Atsižvelgiant į darbe naudojamų duomenų tipą – MP magnetinį parašą – signalų apdorojimą galima atlikti taikant mašininio mokymosi modelius. Tinkamiausi šiai problemai spręsti yra ansamblio modeliai, pavyzdžiui, gradientinio medžio stiprinimo arba atsitiktinio miško.

2. Reikalavimų mikrojudumo priemonių parametrų įvertinimo sistemoms analizė


Siekiant MP parametrų įvertinimui sukurti naują metodą, naudojantį magnetinio lauko jutiklius, pirmiausia atlikta jo teorinė analizė. Pasitelkiant kompiuterinį modeliavimą, atliktas šio metodo pagrindimas ir apibrėžti reikalavimai, kurie turėtų būti keliami jį taikančioms mikrojudumo priemonių parametrų įvertinimo sistemoms (MPPIS).

Remiantis literatūros analize žinoma, kad mikrojudumo priemonių klasės yra nehomogeniškos, todėl atliktas bandomasis (orientacinis) modeliavimas, o ne išsamus MP modeliavimas (sumodeliuotų parašų klasifikavimas). Pasirinkus 1.2 skyriuje aprašytas klases reprezentuojančias MP, pagal jų geometriją „Ansys Maxwell“ programine įranga sukurti trimačiai objektai (**9 pav.**) – dviratis, elektrinis paspirtukas be sėdynės ir elektrinis paspirtukas su sėdyne (sunkioji MP).



9 pav. Mikrojudumo priemonių modeliai

Naudotas baigtinių elementų tinklelis sudarytas iš 65 tūkst. elementų $2\text{ m} \times 2\text{ m} \times 0,8\text{ m}$ dydžio erdvėje (**10 pav.**), kurioje vidutinis elemento dydis – 5 cm. Pasirinktas adaptyvus tinklelio sutankinimas, automatiškai sumažinantis elementų dydį srityse, kuriose tiriamo lauko gradientas viršija slenkstinę vertę. Tinklelio tankis rankiniu būdu padidintas erdvės srityje žemiau MP, kuri atitinka galimą jutiklių įrengimo zoną. Paveikslėliuose ši zona pavaizduota pilku stačiakampiu gretasienu.



0 500 $1\text{e}+03$ (mm)


10 pav. Modeliavimui naudoto baigtinių elementų tinklelio pavyzdys

Modeliavimo tikslumas pasirinktas atsižvelgus į baigtinių elementų tinklelio tankį – į modelį įtrauktos pagrindinės MP dalys (ratai, baterijos ir kt.), tačiau neįtrauktos tvirtinimo detalės ir kiti nedideli konstrukciniai elementai. Pavyzdžiui, baterijos vidinė struktūra, atsižvelgus į tipinį celių sujungimą ir naudojamą srovę, modeliuota 15 A srovės kontūru, nukreiptu išilgai paspirtuko ilgosios ašies.


Remiantis MP pavyzdžiais, modelių dalims priskirtos medžiagos (geležis, nikelis, aliuminis, guma), o modeliuojamoje srityje sukurtas 38,5 A/m stiprio vertikalus magnetinis laukas, atitinkantis tipinę vertikalią geomagnetinio lauko komponentę Kaune (t. y., 70 ° magnetinę inklinaciją). Aprašomu MPPĮ metodu išmatuotas horizontalaus magnetinio lauko stipris priklauso nuo sistemos azimuto², todėl horizontaliosios magnetinio lauko komponentės (x ir y jutiklių ašys) į modeliavimą ir metodo kūrimą neįtrauktos.

2.1. Pirminiai modeliavimo rezultatai

Modeliavimo rezultatai patvirtino, kad feromagnetinės MP dalys bei baterijos srovė sukuria magnetinio lauko iškreipimus (**11 pav.**). Remiantis šiais rezultatais, toliau nagrinėjamas elektrinio paspirtuko modelis, vartojant sutartinius su MP susietas kryptis apibūdinančius pavadinimus, pateikiamus 12 pav.



11 pav. Elektrinio paspirtuko modelio iškreiptas magnetinis laukas




12 pav. Sutartinės su mikrojudumo priemone susietos kryptys


² Azimuto įtaka MP parašams analizuojama 2.4 poskyryje

Nustatyta, kad didinant vertikalų atstumą h tarp menamo jutiklio ir kelio dangos paviršiaus, magnetinio lauko iškraipymų (toliau – signalo) amplitudė mažėja. Pavyzdžiui, maksimali amplitudės vertė perpus sumažėjo vertikalų atstumą padidinus nuo 0 mm iki maždaug 40 mm (**13 pav.**).

Signalų amplitudės priklausomybė nuo horizontalaus atstumo d yra sudėtingesnė (**14 pav.**). Pavyzdžiui, elektrinio paspirtuko ratų sukurti magnetinio lauko iškraipymai buvo didžiausi ties MP centru ($d = 0$), tačiau baterijos sukurti iškraipymai didžiausią amplitudę pasiekė 42 mm nuo MP centro – jie yra stipriausi ties atvirais srovės kontūro galais ir silpniausi ties jo centru.

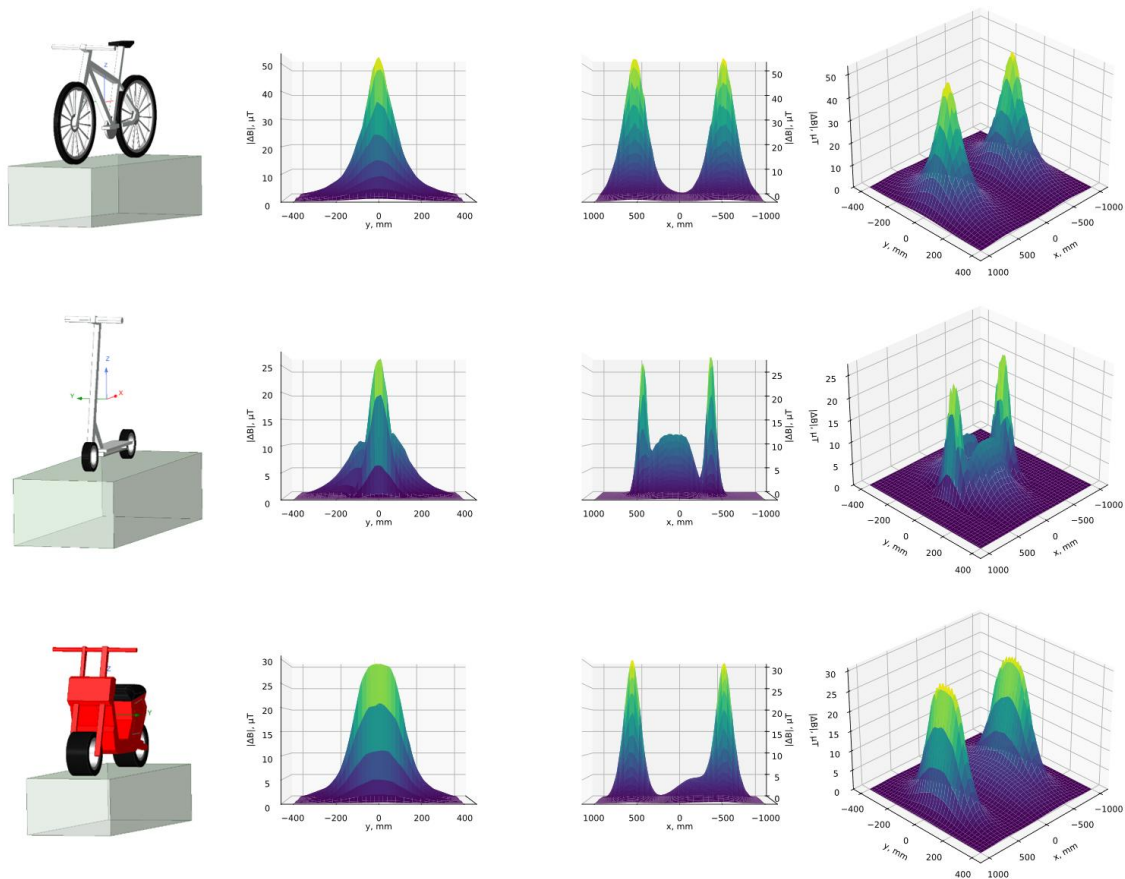


13 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų priklausomybė nuo vertikalus atstumo, kai horizontalus atstumas $d = 40$ mm




14 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų priklausomybė nuo horizontalaus atstumo, kai vertikalus atstumas $h = 15$ mm

Šios priklausomybės įrodo, kad tiriant magnetinio lauko parašus būtina analizuoti visą parašo matricą, o ne tik iš jos išskirtą vektorius. Atlikus visų trijų MP klasių modeliavimą, magnetiniai parašai atvaizduoti trimatėje erdvėje (15 pav.), jutikliui esant $h = 20$ mm vertikaliu atstumu. Signalų amplitudės priklausomybė nuo vertikalus atstumo taip pat pavaizduota **16 pav.**



15 pav. Sumodeliuoti mikrojudumo priemonių parašai ($h = 20$ mm)



16 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų priklausomybė nuo vertikalios atstumo h . Žemiausiame taške ($h = -250$ mm) signalo amplitudė – itin maža

Pagrindiniai pastebėti skirtumai tarp MP klasių buvo šie:

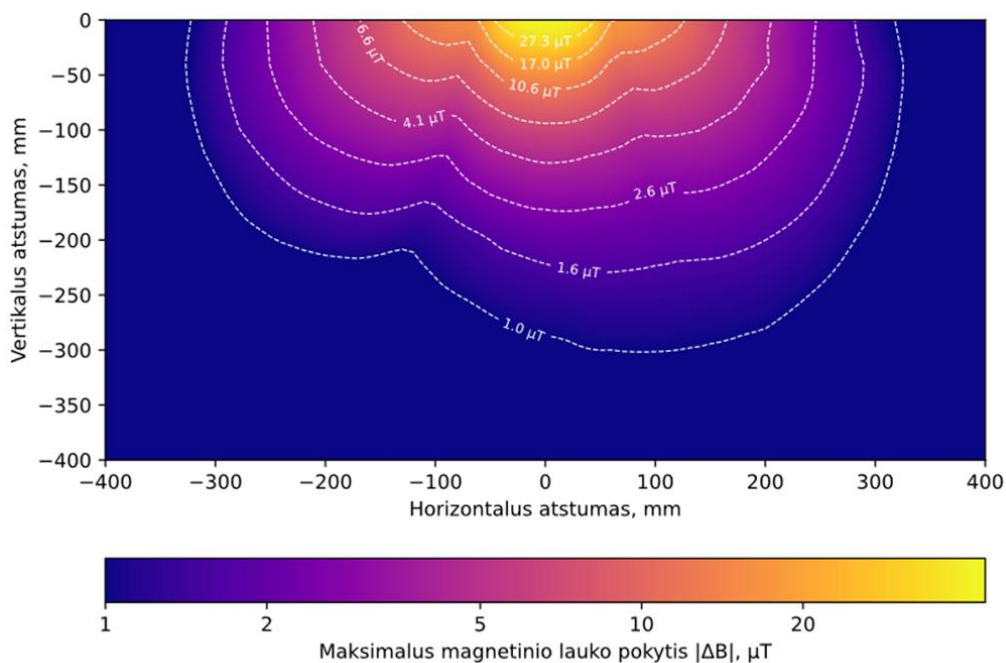
- dviračio paraše aiškiai pastebimi abu jo ratai;
- elektrinio paspirtuko parašas išsiskiria dviem papildomais maksimumais, sukuriama jo baterijos srovės;
- sunkiosios MP parašas yra platesnis, tačiau baterijos srovė jam turi tik nedidelę įtaką.

2.2. Geometriniai reikalavimai mikrojudumo priemonių parašų įrašymo sistemai

Projektuojant MPPIS, vertikalus ir horizontalus atstumas yra aktualūs nepriklausomi geometriniai parametrai, priklausomi nuo įrengimo gylio ir jutiklių gardelės periodo. Dėl šios priežasties magnetinio lauko iškraipymų priklausomybei nuo atstumų d ir h apibendrinti atlikta parašo skerspjūvio analizė.

Taikant tiesinę interpoliaciją, magnetinis laukas iš baigtinių elementų metodo tinklelio perskaičiuotas į pastovaus žingsnio $101 \times 101 \times 81$ taškų matricą. 17 pav. pavaizduotas elektrinio paspirtuko magnetinio lauko iškraipymų skerspjūvis, kuriame kiekvieno taško (galimo jutiklio įrengimo taško) spalva atitinka menamo jutiklio užfiksuotą maksimalią iškraipymų amplitudę per visą MP ilgį. Horizontalus atstumas skerspjūvio grafikuose nurodo didžiausią tiriamos MP centro atstumą iki bet kurio menamos gardelės jutiklio, todėl h , padaugintas iš dviejų, atitinka gardelės periodą. Jutiklių triukšmo lygis, atitinkantis 4 skyriuje aprašyto eksperimento sąlygas, yra $1,5 \mu T$.

Pastebėta, kad paspirtuko erdvinė charakteristika yra nesimetriška (negali būti modeliuojama koncentriniais apskritimais). Taip yra todėl, kad srovės kontūro kuriamo magnetinio lauko kryptis vienoje kontūro pusėje sutampa su ratų sukuriama lauko iškraipymo kryptimi, o kitoje pusėje ji sumažina.



17 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų maksimali amplitudė per visą MP ilgį kiekviename galimame jutiklio įrengimo taške

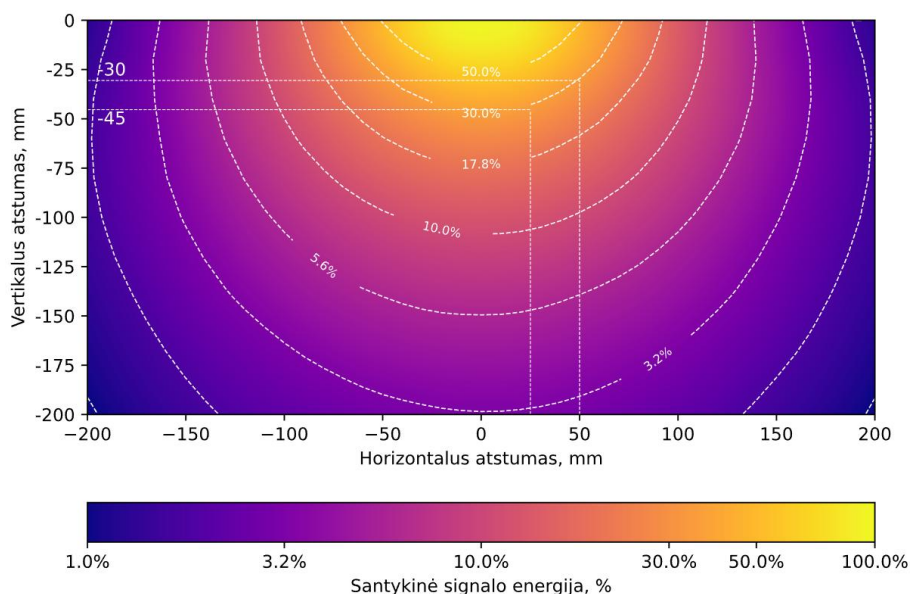
Maksimali iškraipymų amplitudė yra paprasčiausias, tačiau ne pats tinkamiausias parametras iškraipymų amplitudei įvertinti, nes jį taikant atsižvelgiama tik į vieno taško amplitudę. Tinkamesnis parametras – tai signalo energija E , apskaičiuojama pagal formulę

$$E = \int_0^L \Delta B^2(x) dx; \quad (1)$$

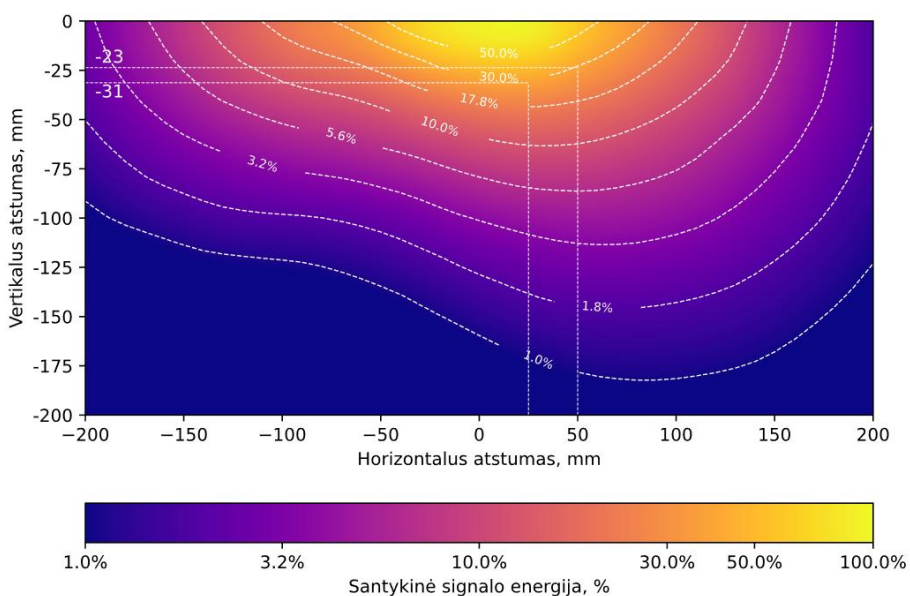
$$E_r(d, h) = \frac{E(d, h)}{E_{max}}; \quad (2)$$

čia ΔB – magnetinio lauko iškraipymų amplitudė atstumu x išilgai MP, integruota per visą MP ilgį. Kiekvieną galimą jutiklio įrengimo tašką atitinkančią energiją padalinus iš maksimalios visame skerspjūvyje užfiksuotos signalo energijos, apskaičiuojama santykinė (normuota) signalo energija E_r .


18 pav. – 20 pav. pateikiami visų trijų MP klasių magnetinio lauko iškraipymų skerspjūviai.



18 pav. Dviračio modelio sukurtų magnetinio lauko iškraipymų santykinė signalo energija



19 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų santykinė signalo energija



20 pav. Sunkiosios mikrojudumo priemonės modelio sukurtų magnetinio lauko iškraipymų santykinė signalo energija

Santykinę signalo energiją galima taikyti kaip signalo kokybės kriterijų, kurio slenkstinė vertė atitinka rekomendacinę ribą MPPĮ metodo taikymui. Tokiu būdu iš signalo energijos diagramų galima nustatyti erdvinės signalo charakteristikas – parašo plotį bei maksimalų galimą gardelės įrenginio gylį. Pastebėta, kad:

- tik lengvųjų MP, kurių baterija yra arti kelio dangos, parašai yra nesimetriški;
- didžiausią parašo plotį turi sunkiosios MP, kurios taip pat turi didžiausius fizinius gabaritus;
- dviračio parašą su fiksuota santykinė signalo energija galima stebėti didesniu vertikaliu atstumu nei paspirtuko parašą su tokia pat energija, nors dviračio parašo plotis yra mažesnis.

Projektuojant MPPIS, signalo kokybės riba priklauso nuo jutiklio triukšmo lygio. Šiame darbe, įvertinus 4 skyriuje aprašytą eksperimentinę sistemą, tokiu parametru pasirinkta 30 % signalo energijos riba (apytiksliai pusė signalo amplitudės), dažnai pateikiama eksperimentuose ir literatūroje. Pavyzdžiui, atsižvelgiant į elektrinio paspirtuko parašo skerspjuvį, jutiklių gardelę, kurios periodas (atstumas tarp jutiklių) yra 100 mm, galima įrengti ne žemiau nei 23 mm po kelio danga. Apibendrinti geometriniai reikalavimai MPPIS pateikiami 4 lentelėje.

4 lentelė. Geometriniai reikalavimai mikrojudumo priemonių parametru įvertinimo sistemoms


Klasė	Maksimalus vertikalus atstumas, mm	
	100 mm gardelės periodas	50 mm gardelės periodas
Dviratis	30	45
Paspirtukas	23	31
Sunkioji MP	62	68

Jei gardelės periodas 50 mm (gardelė yra tanki), maksimalų vertikalų atstumą lemia paspirtuko parašo erdvinė charakteristika, o jei gardelės periodas 100 mm (gardelė – reta), maksimalų vertikalų atstumą lemia siauriausio – dviračio – parašo charakteristika.

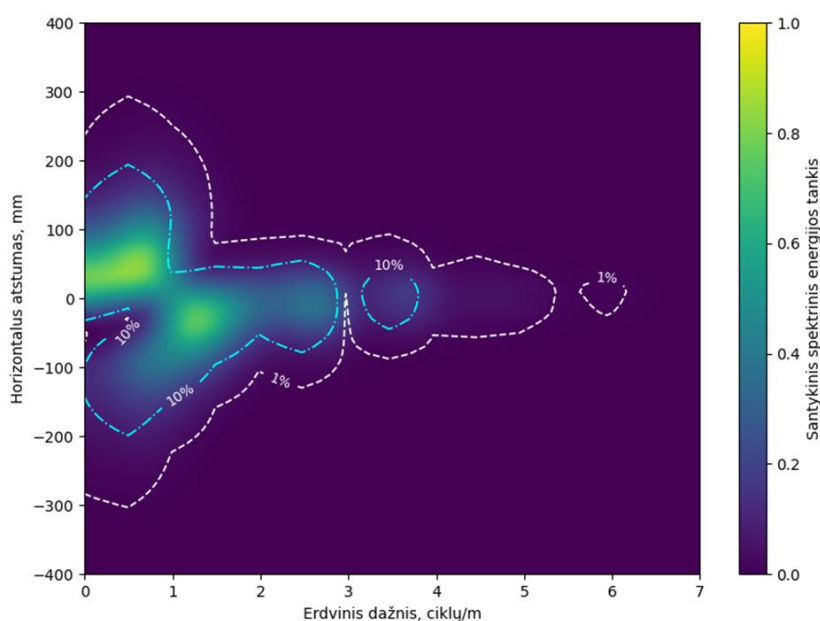
2.3. Dažniniai reikalavimai mikrojudumo priemonių parašų įrašymo sistemai

Geometriniai MPPĮS reikalavimai įvertina dvi kryptis, susijusias su MP (vertikalų ir horizontalų atstumą, žr. 12 pav.), o trečioji kryptis – atstumas išilgai MP – atitinka diskretizavimo periodo arba dažnio reikalavimą.


Pasirinkus $h = 20$ mm vertikalų atstumą, atliktos trijų MP klasių parašų Furjė transformacijos kiekvienai rezultatų matricoje esančiai horizontalaus atstumo vertei. **21 pav.**, **22 pav.** ir **23 pav.** pavaizduoti MP parašų spektrai, kuriuose pastebimos skirtingų dažnių spektrinės dedamosios. Taip pat matoma, kad skirtinguose elektrinio paspirtuko modelio parašo horizontalaus atstumo pjūviuose signalo spektras yra nevienodas.



21 pav. Dviračio modelio sukurtų magnetinio lauko iškraipymų spektras 20 mm vertikaliu atstumu



22 pav. Elektrinio paspirtuko modelio sukurtų magnetinio lauko iškraipymų spektras 20 mm vertikaliu atstumu



23 pav. Sunkiosios mikrojudumo priemonės modelio sukurtų magnetinio lauko iškraipymų spektras 20 mm vertikaliu atstumu

Analizuojant MP parašų spektrus, kaip ir geometrinių parametų atveju, taikomas pasirinktas signalo kokybės kriterijus. Priešingai nei geometrinių parametų atveju, šiame darbe naudojamas ne akumuliacinis kriterijus (pavyzdžiui, suminis spektrinis energijos tankis), bet slenkstinė spektrinio tankio vertė. Toks rodiklis reikalingas, kad būtų tinkamai įvertintos aukšto dažnio dedamosios, kurios, nors ir neturi didelės spektrinės energijos, gali lemti skirtumus tarp MP klasių. Analizuojant aprašomą metodą, diskretizavimo dažniui įvertinti pasirinktos 10% ir 1% spektrinio energijos tankio slenkstinės vertės.

Pateiktose diagramose maksimalaus parašo erdvinio dažnio f_{max} vienetai yra ciklai per metrą, todėl diskretizavimo dažnis f_d apskaičiuotas taikant Naikvisto kriterijų pagal formulę

$$f_d = 2f_{max[Hz]} = 2f_{max[ciklu/s]} \cdot v_{[m/s]}; \quad (3)$$

čia $v = 20 \text{ km/h}$ – maksimalus leistinas mikrojudumo priemonių greitis, reglamentuotas Saugaus eismo automobilių keliais įstatyme [46].

Pavyzdžiui, užfiksuoti paspirtuko parašui, kurio maksimalus erdvinis dažnis taikant 10 % energijos tankio ribą yra 4 ciklai/m, reikalingas diskretizavimo dažnis $f_d = 2 \times 4 \text{ ciklai/m} \times 5,5 \text{ m/s} = 44 \text{ Hz}$. Diskretizavimo dažnio reikalavimų apibendrinimas pateikiamas 5 lentelėje – minimalų diskretizavimo dažnį, nepriklausomai nuo pasirinktos energijos tankio ribos lemia paspirtuko parašo spektras.

5 lentelė. Diskretizavimo dažnio reikalavimai mikrojudumo priemonių parametų įvertinimo sistemoms

Klasė	Minimalus diskretizavimo dažnis, Hz	
	10% energijos tankio riba	1% energijos tankio riba
Dviratis	17	28
Paspirtukas	44	72
Sunkioji MP	28	44


Taigi, remiantis modeliavimo baigtinių elementų metodu rezultatais, galima nustatyti rekomendacijas MPPIS: taikant 30 % santykinės parašo energijos ribą maksimalus gylis po kelio dangą yra 23 mm, jei gardelės periodas yra 100 mm, o minimalus diskretizavimo dažnis yra 72 Hz, jei taikoma 1 % spektrinio energijos tankio riba.

2.4. Magnetinės inklinacijos įtaka magnetinio lauko parašams


Kaip minėta skyriaus pradžioje, įtaką MPPIS turi ir magnetinė inklinacija – kampas tarp magnetinio lauko linijų ir horizontalios plokštumos, kuris priklauso nuo geografinės padėties. Lietuvoje magnetinė inklinacija yra 70° , o ties pusiauju pasiekia minimumą (0°).

Atlikus modeliavimą minimalios magnetinės inklinacijos sąlygomis (**24 pav.** ir **25 pav.**), nustatyta, kad MP parašai skiriasi nuo modeliutų anksčiau šiomis savybėmis:

- *forma* – lauko iškreipimai, sukuriama baterijos srovės, tapo didesni nei sukuriama ratų;
- *amplitude* – ratų iškreipimų amplitudė sumažėjo;
- *erdvinėmis charakteristikomis* – parašo pagrindinė sritis susiaurėjo, tačiau atsirado papildomos šoninės sritys.



24 pav. Sumodeliuotas elektrinio paspirtuko parašas, kai magnetinė inklinacija 0° ir laukas statmenas paspirtuko ilgajai ašiai



25 pav. Sumodeliuotas elektrinio paspirtuko parašas, kai magnetinė inklinacija 0° ir laukas yra išilgai paspirtuko ilgosios ašies

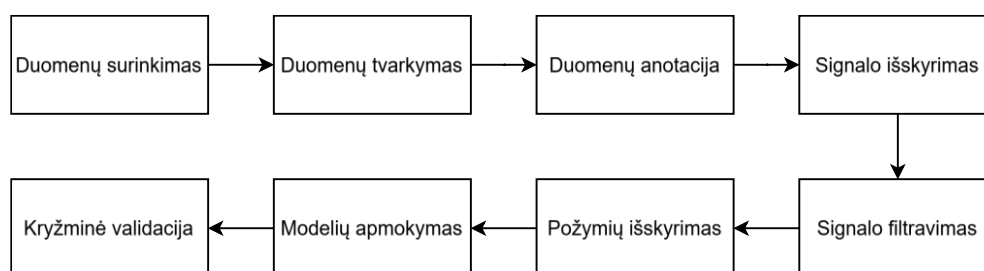
Taip pat pastebėta, kad esant minimaliai magnetinei inklinacijai didesnę reikšmę įgauna užfiksuoto MP parašo priklausomybė nuo važiavimo krypties. Pavyzdžiui, kai magnetinis laukas su nuline inklinacija yra išilgai MP ilgosios ašies, o ne skersai jos, sumodeliuotas parašas skiriasi savo forma ir platesne erdvine charakteristika.

Taigi, siekiant siūlomą MPPI metodą pritaikyti visoms geografinėms vietovėms, reikalingas adaptyvus klasifikavimo algoritmas. Tikėtina, kad problemą spręsti padėtų klasifikavimo kriterijų rinkinys, atsižvelgiantis į MP važiavimo kryptį (MPPIS įrengimo kryptį).

3. Mikrojudumo priemonių klasifikavimo metodika

Siekiant pagrįsti siūlomo MPPĮ metodo veiksmingumą praktinėmis sąlygomis, būtina atlikti kompiuterinio modeliavimo rezultatų validaciją. Dėl šios priežasties suprojektuotas ir atliktas eksperimentas, kuriame naudota MP parašų įrašymo sistema, atitinkanti MPPIS keliamus reikalavimus. Kaip minėta darbo pradžioje, tiriamas vienas MP parametras – klasė, nes jos įvertinimas yra sudėtingesnis nei kitų MP parametru.

Literatūroje aprašomų mašininio mokymosi eksperimentų eiga dažniausiai sudaroma iš duomenų surinkimo, apdorojimo, mašininio mokymosi modelių apmokymo ir validacijos žingsnių [45]. Šiame darbe tokia eiga papildyta žingsniais, būtiniais dėl naudojamų eksperimentinių duomenų, pavyzdžiui, jų tvarkymu, signalo filtravimu ir kryžmine validacija (**26 pav.**).



26 pav. Mikrojudumo priemonių parašų apdorojimo ir klasifikavimo eiga

Eksperimento eigos sudarymas yra iteracinis mokslinio darbo procesas, todėl šiame skyriuje pateikiami *pagrindiniai* MP parašų klasifikavimo eigos principai, kurie yra detaliau pagrindžiami 4 skyriuje.

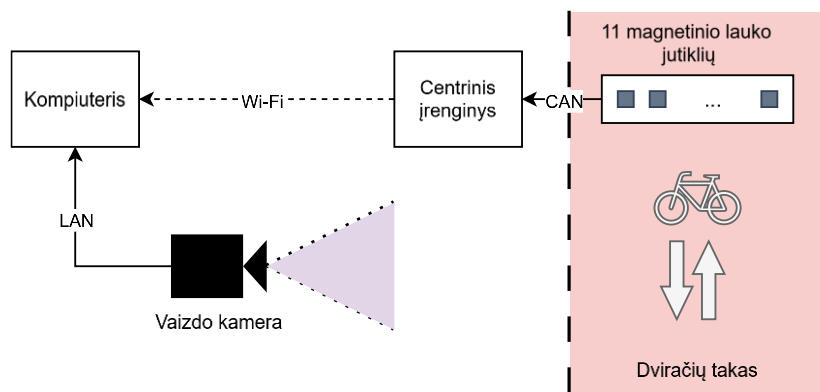
3.1. Duomenų surinkimas ir paruošimas

Pirmasis žingsnis – **duomenų surinkimas** magnetinio lauko jutiklių gardele. Eksperimentinę sistemą MP parašų įrašymui (**27 pav.**) sudarė:

- *magnetinio lauko jutiklių gardelė*, įrengta ant dviračių tako (**28 pav.**) ir sudaryta iš 11 jutiklių, išdėstytų 10 cm tarpusavio atstumu statmenai MP judėjimo kryptims;
- *centrinis įrenginys*, kuris visus jutiklius nuskaitė 500 Hz dažniu per CAN sąsają, nustatė MP magnetinio parašo pradžią bei pabaigą ir išsaugojo parašus atmintyje;
- *kompiuteris*, kuris komunikavo su centriniu įrenginiu Wi-Fi ryšiu, parsisiuntė surinktus MP parašus asinchroniniam apdorojimui ir eksperimento metu fiksavo kameros vaizdą, vėliau naudotą kaip atraminis informacijos šaltinis.

Laikinė sinchronizacija tarp magnetinio lauko jutiklių ir kameros vaizdo pasiekta naudojant viešą NTP serverį.

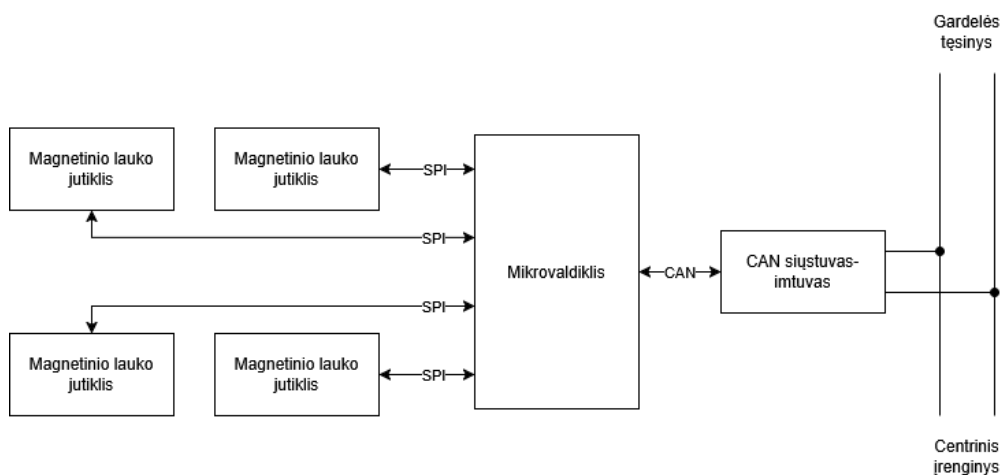
Remiantis ankstesniais tradicinių TP parametru įvertinimo tyrimais, naudota magnetinio lauko jutiklių gardelė, sudaryta iš magnetinio lauko jutiklių grupių (**29 pav.**). Kiekvienoje šių grupių yra iki 4 jutiklių, esančių ant vienos spausdintinio montažo plokštės. Mikrovaldiklis, nuskaitęs matavimų duomenis, juos perduoda CAN sąsaja.



27 pav. Duomenų surinkimo sistemos schema



28 pav. Duomenų surinkimo sistema (kairėje) ir jutiklių gardelė (dešinėje), naudota eksperimento metu




29 pav. Struktūrinė magnetinio lauko jutiklių gardelės dalies schema

Atsižvelgus į ankstesnius magnetinio lauko jutiklių gardelių taikymus [33, 36], nustatytas MP parašų fiksavimo algoritmas.

1. Kiekvienu gardelės jutikliu nuolatos matuojant magnetinę indukciją, kaupiamas 0,1 sekundės trukmės išankstinių duomenų masyvas (angl. *prebuffer*).
2. Bet kuriam jutikliui užfiksavus vertę, moduliui viršijančią 4,38 μT (300 santykinų vienetų; slenkstis pasirinktas remiantis ankstesniais TP klasifikavimo eksperimentais), pradedamas MP parašo įrašymas.
3. Duomenys kaupiami tol, kol nors vieno jutiklio išmatuota magnetinė indukcija viršija šią slenkstinę vertę.
4. Visų jutiklių išmatuotoms vertėms nukritus žemiau slenkstinės vertės, kaupiamas papildomas 1 sekundės trukmės duomenų masyvas (angl. *postbuffer*); jei slenkstinė vertė šio intervalo metu yra viršijama, kartojami 3 ir 4 žingsniai.
5. MP parašo įrašymas sustabdomas, tačiau parašas nesaugomas, jei jo ilgis viršija 4 sekundes.

Duomenų masyvų dydžiai kartu su magnetinio lauko jutiklių nuskaitymo dažniu (diskretizavimo dažniu) pasirinkti atsižvelgus į laisvos mikrovaldiklio atminties dydį bei ankstesnius TP klasifikavimo eksperimentus. Diskretizavimo dažnis – daugiau nei 5 kartus didesnis už minimalų MPPIS rekomenduojamą diskretizavimo dažnį, kad būtų galima įvertinti šio reikalavimo adekvatumą realiomis sąlygomis.

Įrašyto MP parašo pavyzdys pateikiamas **30 pav.** Didžiausią amplitudę užfiksavusio (toliau – centrinio) jutiklio signalas pavaizduotas tamsiai mėlyna spalva, jam gretimų jutiklių – šviesiai mėlyna spalva, o signalo pradžia, pabaiga bei slenkstinė vertė (naudojama 2 ir 3 algoritmo žingsniuose) – oranžine spalva.



30 pav. Mikrojudumo priemonės parašo fiksavimo pradžios ir pabaigos kriterijai

Po MP parašų surinkimo atliktas **duomenų tvarkymas ir anotacija** – atmesti neteisingai įrašyti parašai, sistemos užfiksautos ne mikrojudumo priemonės ir atlikta rankinė įrašų anotacija (žymėjimas), reikalinga modelių išvestims validuoti.

Ir anotacijos metu, ir naudojant mašininio mokymosi modelius naudota klasifikavimo sistema, parengta atsižvelgus į „SAE International“ rekomendacijas [34] ir vietinio MP eismo statistiką. MP skirstytos į tris klases, pateikiamas **6** lentelėje.

6 lentelė. Tyrime naudotos mikrojudumo priemonių klasės

Klasė	Apibūdinimas	Įtrauktos transporto priemonės
Dviračiai	Lengvos (< 35 kg) transporto priemonės be elektros variklių	Dviračiai
Elektriniai paspirtukai	Lengvos (< 35 kg) lėtos (< 25 km/h) transporto priemonės su elektros varikliais	Asmeniniai ir dalijimosi platformų elektriniai paspirtukai be sėdynės
Sunkiosios mikrojudumo priemonės	Sunkios (> 35 kg) ir (arba) greitos (> 25 km/h) mikrojudumo priemonės su elektros varikliais	Lengvieji ir sunkieji elektriniai dviračiai; asmeniniai ir dalijimosi platformų elektriniai paspirtukai su sėdyne

Eksperimentinės sistemos naudojimo rezultatas – MP parašai, susieti su vaizdo kameros įrašais, kuriuos kartu galima naudoti klasifikavimui ir validacijai.

3.2. Signalų apdorojimas ir požymių išskyrimas

Paruošus duomenų rinkinį, kiekvienam užfiksuotam MP parašui atliktas **signalų išskyrimas**, t. y., atrinktas centrinis jutiklis, turintis didžiausią absoliutaus maksimumo vertę per visą parašo ilgį

$$c = \arg \max_j \left(\max_i (|z_{ij}|) \right), \quad (4)$$

čia z_{ij} – magnetinio lauko vertė, užfiksuota jutiklio j laiko momentu i . Centrinio jutiklio išskyrimas reikalingas, nes didelė dalis signalo požymių, toliau aprašytų šiame skyriuje, turi teorijoje apibrėžtą prasmę vienmatei signalo matricai (vektoriui).

Kaip minėta ankstesniame skyriuje, MPPIS įrengimo kryptis (azimutas) turi įtakos įrašytiems MP parašams. Dėl šios priežasties naudojama magnetinio lauko z ašis (B_z), o ne lauko modulis.

Centrinio jutiklio **signalų filtravimas** atliktas Butterworth'o žemų dažnių filtru, pasirinktu dėl gero kompromiso tarp plokščios pralaidos juostos ir stačios pereinamosios charakteristikos, lyginant su kitais filtrų tipais. Filtru ribinis dažnis optimizuotas eksperimentiniu būdu – ištyrus, kaip nuo jo priklauso klasifikavimo tikslumas (plačiau – šio skyriaus pabaigoje ir 4 skyriuje).

Požymių išskyrimas pradėtas aprašius 35 požymius, pateikiamus 1 priede – ir originalius, ir pateiktus literatūroje. Daugumai požymių, išskyrus skerspjuvio požymius, naudotas centrinio jutiklio signalas. Eliminacija atlikta rekursiniu metodu.

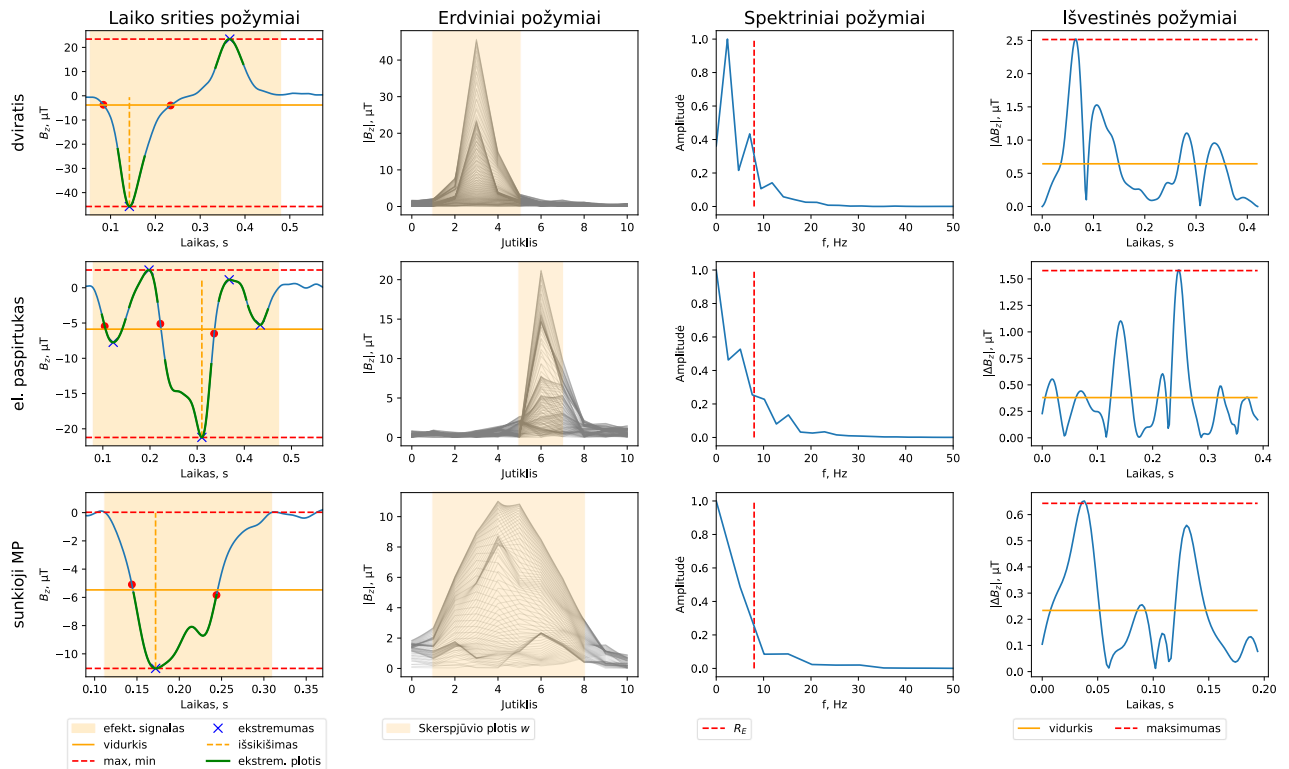
1. Apmokymui ir validacijai naudojant N požymių, nustatytas klasifikavimo tikslumas ir kiekvieno požymio svarba³ (angl. *importance*).
2. Iš požymių sąrašo pašalintas mažiausią svarbą turintis požymis.
3. 1 ir 2 žingsniai kartoti, kol sąrašė liko 1 požymis.

Šiuo rekursiniu metodu ištyrus klasifikavimo tikslumo priklausomybę nuo požymių skaičiaus, galutinis naudojamų požymių sąrašas sudarytas nustatius ribą, virš kurios klasifikavimo tikslumas nustoja reikšmingai didėti. 14-os požymių, išlikusių po rekursinio atrenkamojo proceso, apibendrinimas pateikiamas 7 lentelėje, o iliustracijos – 31 pav.

³ Klasifikavimo požymių svarba apibrėžiama šio skyriaus pabaigoje

7 lentelė. Mikrojudumo priemonių parašų klasifikavimo požymių apibendrinimas

	Požymio pavadinimas	Komentaras
1	Ekstremumų skaičius [4, 39]	Lokalių ekstremumų skaičius
2	Vidutinis atstumas tarp ekstremumų [4]	-
3	Vidutinis ekstremumų plotis [39]	-
4	Vidutinis ekstremumų išsikišimas (angl. <i>prominence</i>) [4]	-
5	Efektinis signalo ilgis l_e	Plačiausio intervalo, kuriame nors viena signalo atskaita yra virš 2,3 μT (slenkstinė vertė, 1,5 karto didesnė nei jutiklių triukšmo lygis), ilgis, išplėstas iki artimiausios nulinės atskaitos
6	Išplėstinis maksimumo plotis	Intervalo nuo maksimumo iki artimiausių nulinių atskaitų abiejomis kryptimis ilgis
7	Efektinio signalo standartinis nuokrypis [38, 39]	-
8	Globalaus minimumo padėtis [38]	Normalizuota pagal formulę $p_{min} = \frac{\arg \min(z)}{l_e}$, čia $\arg \min(z)$ – minimumo atskaitos atstumas (indeksas) nuo efektinio signalo pradžios
9	Pirmojo lokalaus minimumo padėtis	Žr. 8 eilutę
10	Pirmojo efektinio signalo vidurkio kirtimo padėtis [38]	Žr. 8 eilutę
11	Skerspjūvio plotis w	Plačiausio nepertraukiamo jutiklių intervalo, kuriame maksimalios atskaitos $z_{i,j}$ laiko momentu i visų jutiklių atskaitos viršija 2.3 μT (ta pati slenkstinė vertė, kaip 2 punkte), ilgis (jutiklių skaičius)
12	Žemo ir aukšto dažnio spektrinių dedamųjų energijos santykis R_E	$R_E = \frac{\sum_{f=0}^{f_{th}} Z[f] ^2}{\sum_{f=f_{th}}^{f_s/2} Z[f] ^2}$, čia $Z[f]$ – spektrinės dedamosios amplitudė ties dažniu f , $f_{th} = 8 \text{ Hz}$ – eksperimentiniu būdu pasirinkta riba tarp žemo ir aukšto dažnio dedamųjų, o $f_s = 500 \text{ Hz}$ – diskretizavimo dažnis
13	Svorio indeksas R_W	$R_W = w_{spatial} \cdot l_e \cdot z_{max} $
14	Amplitudės ir variacijos santykis R_{av}	$R_{av} = \frac{z_{max} - z_{min}}{\frac{1}{N-1} \sum_{n=0}^{N-2} z[n+1] - z[n] }$, čia N – atskaitų skaičius



31 pav. Mikrojudumo priemonės parašo požymių pavyzdžiai

Aprašyti požymiai leidžia įvertinti pagrindinius vizualiai pastebimus skirtumus tarp MP klasių (maksimumų skaičių, parašo plotį ir kt.), subtilesnius skirtumus (santykinę minimumo padėtį, variaciją ar kt.) ir sudėtingus rodiklius, kuriuos sudėtinga pastebėti vizualiai (santykius ir indeksus).

3.3. Mašininio mokymosi modelių apmokymas ir validacija

Išskirti požymiai naudoti mašininio mokymosi **modeliams apmokyti**. Pasirinkti 6 modeliai, aprašyti analizuotoje literatūroje ir reprezentuojantys skirtingų tipų mašininio mokymosi algoritmus:

- logistinės regresijos modelis;
- Bajeso modelis;
- k artimiausių kaimynų modelis (angl. *k-nearest neighbors*, KNN);
- atraminių vektorių automato modelis (angl. *support vector machine*, SVM);
- atsitiktinio miško modelis (angl. *random forest*, RF);
- gradientinio medžio stiprinimo modelis (angl. *gradient boosted decision trees*, GBDT).

Taikant šiuos modelius, MP klasifikavimo tikslumas įvertintas naudojant 10-ies grupių **kryžminę validaciją** (angl. *10-fold cross validation*), kurios metu turimi duomenys suskirstyti į grupes (8 lentelė). Validaciją kartojant k kartų, kiekvieną jų $k-1$ grupės naudotos modeliui apmokyti, o viena, skirtinga kiekvienai iteracijai, naudota validacijai.

Kryžminė validacija užtikrina, kad visi turimi duomenys yra įvertinami modelio validacijos metu, tačiau nei vienas įrašas (MP parašas) nėra naudojamas validuoti tam pačiam modeliui, kuriam apmokyti buvo naudotas. Tai padidina tyrimo rezultatų patikimumą, lyginant su vienos apmokymo ir vienos validacijos duomenų grupės naudojimu. Kryžminės validacijos tikslumo paaiškinimas pateikiamas 9 lentelėje – tai yra modelio teisingai klasifikuotų įrašų skaičiaus ir visų įrašų skaičiaus santykis.

8 lentelė. 10-ies grupių kryžminės validacijos metu naudojamos duomenų grupės

Iteracija	Duomenų grupė				
	1	2	3	...	10
1	validacija	mokymas	mokymas	...	mokymas
2	mokymas	validacija	mokymas	...	mokymas
3	mokymas	mokymas	validacija	...	mokymas
...	mokymas
10	mokymas	mokymas	mokymas	mokymas	validacija

9 lentelė. Klasifikavimo modelio tikslumą apibūdinantys parametrai

Tikroji klasė	Modelio priskirta klasė		
	Dviratis	El. paspirtukas	Sunkioji MP
Dviratis	n_1	n_2	n_3
El. paspirtukas	n_4	n_5	n_6
Sunkioji MP	n_7	n_8	n_9

$$\text{Jautrumas dviračių klasei} = \frac{n_1}{n_1+n_2+n_3}$$

$$\text{Preciziškumas dviračių klasei} = \frac{n_1}{n_1+n_4+n_7}$$

$$\text{Tikslumas} = \frac{n_1+n_5+n_9}{\sum n}$$

Be bendro modelio tikslumo, lentelėje taip pat apibrėžti specifiniai, su kiekviena klase susiję rodikliai – jautrumas ir preciziškumas. Pavyzdyje, kuriame analizuojama dviračių klasė, idealus (artimas vienetui) jautrumas nurodo modelio gebėjimą priskirti dviračių klasę *visiems* pateiktiems dviračių parašams, o preciziškumas – gebėjimą priskirti dviračių klasę *tik šios klasės* parašams.

Aprašyta MP parašų klasifikavimo metodika leidžia pagrįsti siūlomo MPPĮ metodo veiksmingumą. Duomenų surinkimas eksperimentine sistema leidžia įvertinti atlikto kompiuterinio modeliavimo adekvatumą realiomis sąlygomis. Mašininio mokymosi modelių bei jiems pateikiamų signalo požymių įvairovė sudaro sąlygas palyginti tradicinių TP parametrų įvertinimo algoritmų pritaikomumą MP klasifikavimui. Taikomi tikslumo įvertinimo metodai bei parametrai leidžia užtikrinti tyrimo rezultatų patikimumą.

4. Tyrimo rezultatai

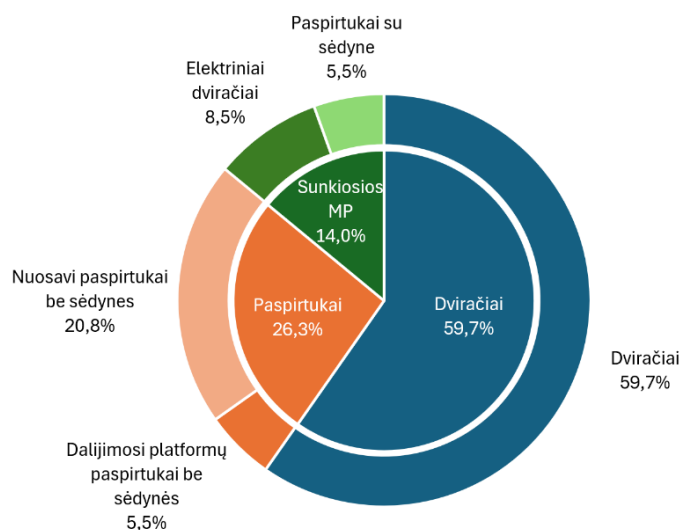
Atliktus **duomenų surinkimą**, įrašyti 554 MP parašai, kurių statistika pateikiama **10** lentelėje. Bendras MP eismo srauto tankis, įtraukus ir naudotus tyrimui, ir atmestus parašus, buvo apskaičiuotas 15 minučių intervalais ir siekė nuo 20 iki 76 MP per valandą (vidutiniškai 31 MP per valandą).

10 lentelė. Surinktų mikrojudumo priemonių parašų statistika

Klasė	Atmesta		Naudota tyrimui	Viso
	Jungtiniuose parašuose	Netinkamai įrašyta		
Dviračiai	64	192	141	397
El. paspirtukai	5	43	62	110
Sunkiosios MP	-	7	33	40
Kita	-	7	-	7

Duomenų tvarkymo ir anotacijos metu atmesti ir tyrimui nenaudoti parašai, kuriuos sudarė kelios MP, nes šių parašų analizė reikalauja papildomų, į darbą neįtrauktų eksperimentų. Taip pat atmesti netinkamai įrašyti parašai, pavyzdžiui, MP, apvažiuojančių gardelę arba važiuojančių dviračių taku už jo ribų, nes tinkamas parašo užfiksavimas nėra tiriamas metodo parametras. Jo užtikrinimui gali būti įrengiamos transporto infrastruktūros priemonės (tvorelės, borteliai ir kt.) arba MPPIS gali būti montuojamos po kelio danga. Kiti atmesti parašai priklauso neįgaliųjų vežimėliams, žoliapjovėms ir kt.

Didžiąją dalį tyrimui naudotų parašų – 59,7 % (**32 pav.**) sudarė dviračių parašai, o mažiausiai užfiksuota sunkiųjų MP parašų – 14 %. Tai reiškia, kad įrašų skaičiaus pasiskirstymas pagal klasę nėra lygus, tačiau atitinka realaus MP eismo sąlygas.



32 pav. Mikrojudumo priemonių pasiskirstymas pagal klasę realaus eismo sąlygomis


Lyginant eksperimentiškai užfiksuotus MP parašus su modeliavimo rezultatais (**33 pav.**), pastebėti tik nedideli skirtumai: eksperimentiniuose parašuose fiksuota mažesnė signalo amplitudė (priklausanti nuo konkrečios MP konstrukcijos), didesnis triukšmas, o matavimai atlikti mažesne

horizontalaus atstumo skyra. Šis rezultatas leidžia įsitikinti, kad kompiuterinis modeliavimas buvo atliktas teisingai.







Mikrojudumo priemonė



Sumodeliuotas parašas

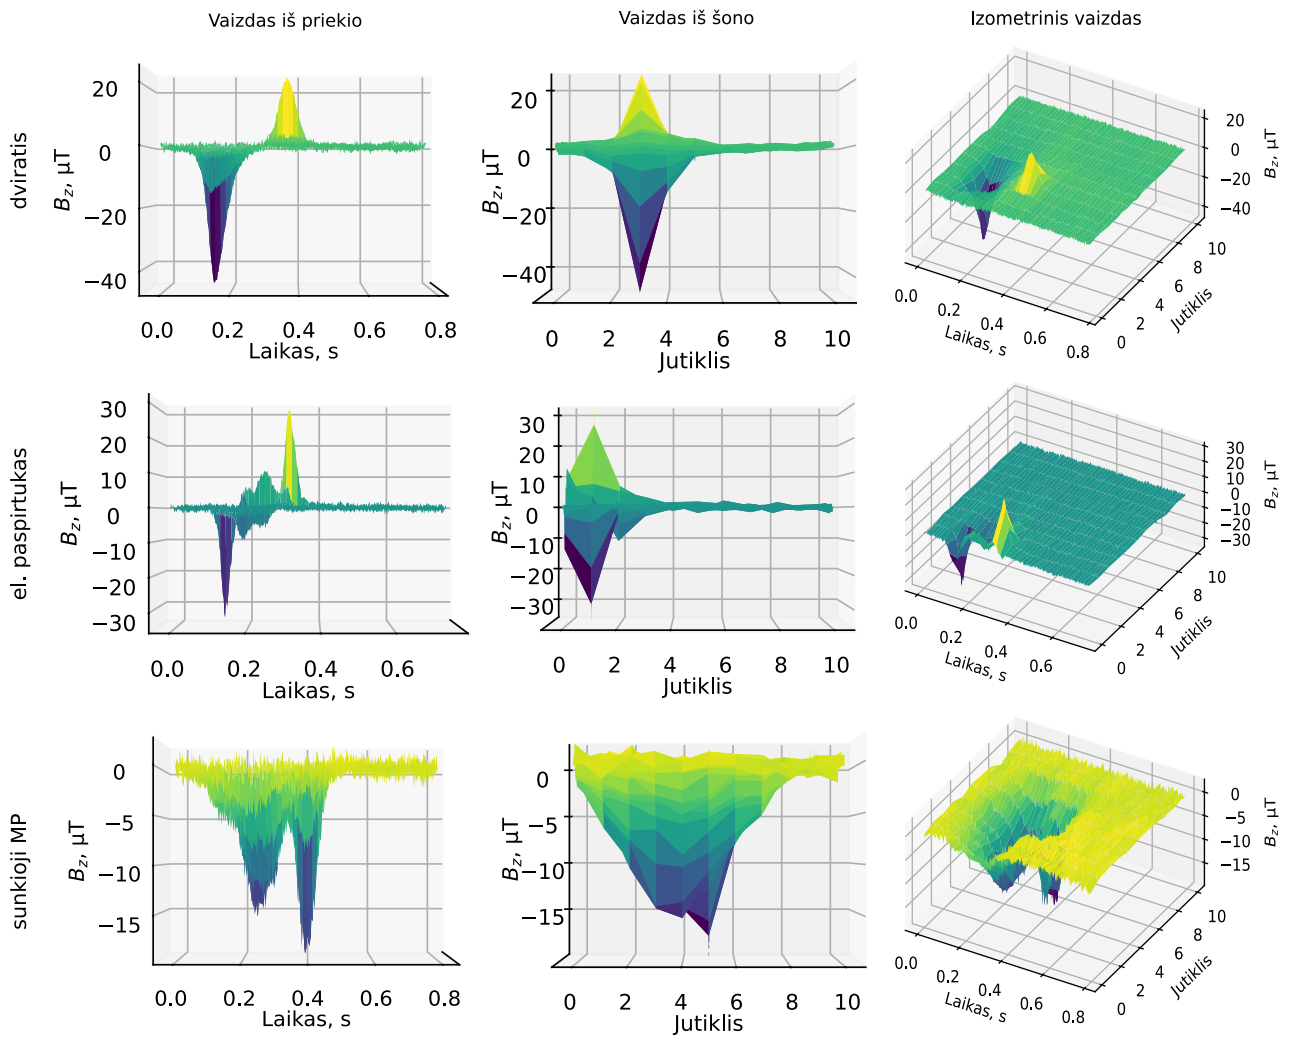


Užfiksuotas parašas



33 pav. Sumodeliuoti ir užfiksuoti mikrojudumo priemonių parašai

Daugiau užfiksuotų MP parašų pavyzdžių pateikiama 34 pav. – pagrindiniai skirtumai tarp MP klasių yra susiję su parašo pločiu (sunkiosios MP parašo plotis yra didžiausias) ir papildomais maksimumais. Pavyzdžiui, vienas skirtumų tarp paspirtuko ir dviračio parašų – pastebimi atitinkamai 3 ir 2 maksimumai. Sudarant pradinį požymių sąrašą dėmesys pirmiausia atkreiptas į tokius akivaizdžius skirtumus, o kiti (pavyzdžiui, sudėtiniai) požymiai pridėti papildomai.



34 pav. Skirtingų klasių mikrojudumo priemonių parašų pavyzdžiai

Nors skirtumai pastebimi ir tarp tos pačios MP klasės parašų (pavyzdžiui, kai kuriuose dviračių klasės parašuose užfiksuoti pedalo, esančio žemiausioje padėtyje, sukuriama magnetinio lauko iškreipimai), tačiau pagrindiniai skiriamieji bruožai bei statistinė analizė (realizuota naudojant mašininio mokymosi modelius) leidžia MPPĮ metodui panaudoti reikšmingus požymius, o kitus – atmesti.

4.1. Duomenų surinkimo ir apdorojimo proceso ir jo parametrų analizė


Nepaisant to, kad neteisingai įrašyti parašai buvo atmesti ir tyrime nenaudoti, jie gali būti reikšmingi bandomiesiems MPPĮS taikymams, kuriuose nenaudojama infrastruktūra, užtikrinanti teisingą MP parašų įrašymą. Dėl šios priežasties įvertinti tiksliausio modelio⁴ klasifikavimo rezultatai, pasiekti įtraukus šiuos parašus.

Nustatyta, kad dalis parašų gali būti klasifikuojami teisingai, net jei jie buvo įrašyti netinkamai. Apmokymo duomenų rinkinį sudarius ir iš teisingai, ir iš neteisingai įrašytų parašų, kryžminės validacijos tikslumas sumažėjo sąlyginai nedaug – 6,3 procentinio punkto (35 pav.).

⁴ Modelių tikslumas lyginamas toliau šiame skyriuje

Kita vertus, siekiant maksimalaus galimo MPPIS tikslumo, į apmokymo duomenų rinkinį tokie parašai gali būti neįtraukiami, o tik užfiksuojami sistemos naudojimo metu (šio tyrimo metu – įtraukti į testavimo duomenų rinkinį). Netinkamai įrašytus parašus pašalinus iš apmokymo, tačiau naudojant testavimui, klasifikavimo tikslumas sumažėjo daugiau – 12,5 procentinio punkto.


Šis rezultatas gali būti pasitelktas vertinant, ar konkretaus MPPIS įrengimo atveju (naudojant konkrečią transporto infrastruktūros planavimo metodiką) yra reikalingos teisingą parašų įrašymą užtikrinančios fizinės priemonės.



35 pav. Neteisingai įrašytų parašų įtaka klasifikavimo tikslumui

Neteisingai įrašytų parašų įtraukimas į apmokymo duomenų rinkinį turėjo didesnę įtaką elektrinių paspirtukų klasei, kurią sudarė mažiau įrašų, nei dviračių klasei. Galimas paaiškinimas – neteisingai įrašytuose parašuose buvo prarasti triukšmui jautrūs signalo požymiai, todėl modelis dažniau spėjo pagrindinę klasę – dviračius. Sunkiųjų MP klasifikavimo tikslumas šioje tyrimo dalyje nenagrinėtas, nes jų parašų, įrašytų neteisingai, absoliučiu skaičiumi užfiksuota kur kas mažiau nei kitų klasių.


Visų tyrime naudotų parašų centrinio signalo išskyrimui naudota z ašis, kurios matavimams įtakos neturi MPPIS azimutas. Tai patvirtina ir eksperimento rezultatai (**36 pav.**) – klasifikavimo tikslumas naudojant z ašies duomenis buvo geresnis nei visų kitų ašių ar modulio, nepriklausomai nuo to, pagal kurios ašies duomenis buvo išskirtas centrinis jutiklis.



36 pav. Klasifikavimo tikslumo priklausomybė nuo naudojamos magnetinio lauko jutiklio ašies


Analizuojant ašies pasirinkimo įtaką specifiniam kiekvienos klasės tikslumui (37 pav.), nustatyta, kad didžiausią įtaką jis turėjo sunkiųjų MP klasei. Analogiškai rezultatams, gautiems įtraukus neteisingai įrašytus parašus, magnetinio lauko modulio naudojimas lėmė vidutiniškus, o x ar y ašių – prasčiausius rezultatus.

Šis pastebėjimas leidžia MPPIS supaprastinti – beveik tris kartus sumažinti saugomų duomenų kiekį (vienos ašies duomenys vietoje trijų), sistemos konfigūracijai naudojamų parametru skaičių ir palengvinti parašų vizualizaciją.



37 pav. Specifinio kiekvienos klasės tikslumo priklausomybė nuo naudojamos magnetinio lauko jutiklių ašies

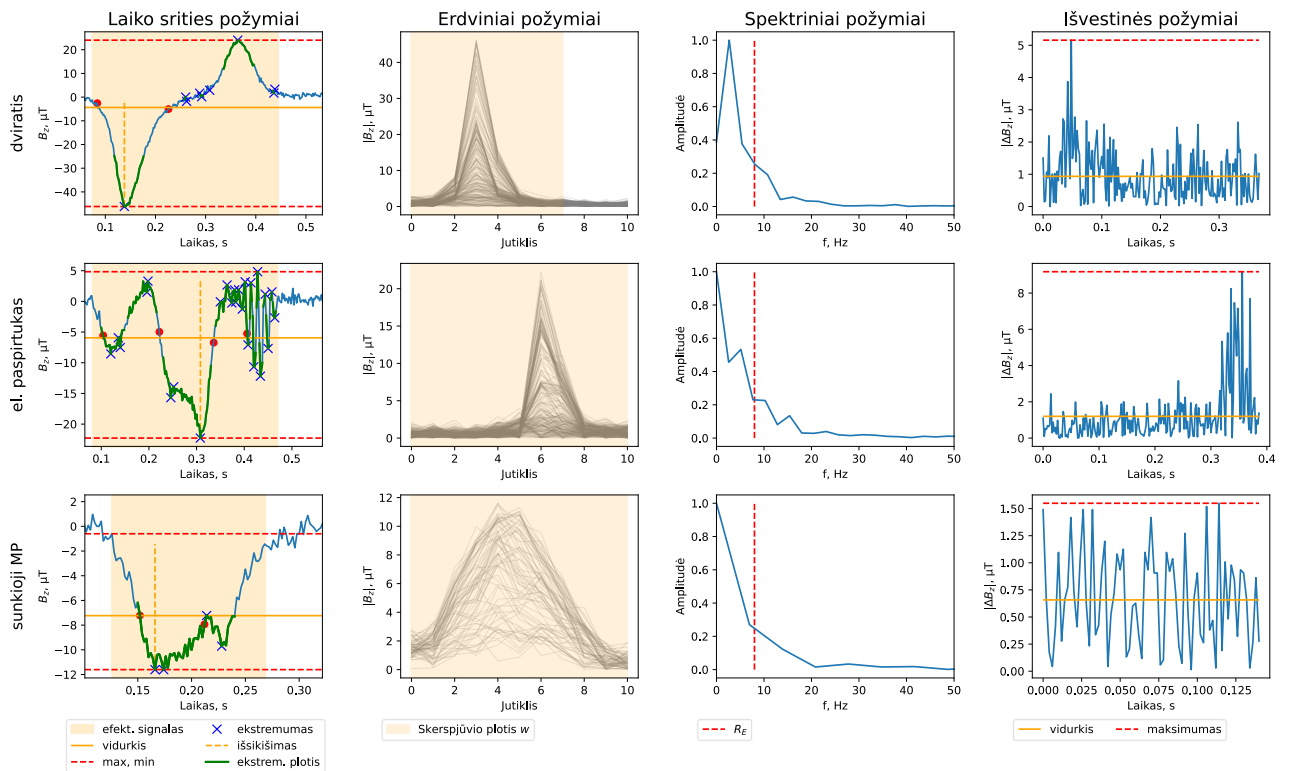
Siekiant padidinti išskirtų požymių kokybę, atliktas **signalo filtravimas** žemų dažnių filtru. Geriausias kryžminės validacijos tikslumas pasiektas naudojant filtrą su ribiniu dažniu $f_c = 30$ Hz (38 pav.), o naudojant per žemą (< 10 Hz) arba per aukštą (> 150 Hz) ribinį dažnį, gautas rezultatas buvo prastesnis nei filtro nenaudojant. Tai gan tiksliai atitinka modeliavimo rezultatus – remiantis jais, maksimalus reikšmingas signale esantis dažnis yra 36 Hz.



38 pav. Kryžminės validacijos tikslumo priklausomybė nuo žemų dažnių filtro ribinio dažnio. Nuspalvinta sritis – standartinis nuokrypis


Žemų dažnių filtro svarba taip pat pastebima 39 pav., kuriame pateikiami prastos kokybės požymių pavyzdžiai. Lyginant su metodikoje pateikiamais aukštesnės kokybės požymių pavyzdžiais (31 pav.), čia pastebimi skirtumai (pavyzdžiui, ekstremumų skaičius), kurie gali lemti neteisingą MP parašo klasifikavimą.

Praktikoje naudojamos MPPIS filtravimas gali būti atliekamas naudojant išorinius komponentus arba pačiuose jutikliuose įdiegtus algoritmus, taip sumažinant reikalingus mikrovaldiklio skaičiavimo pajėgumus, komunikacijos sąsajomis perduodamų ir atmintyje saugomų duomenų kiekį, sistemos taktinį dažnį, suvartojamą energiją ir komponentų kaštus.



39 pav. Požymių, apskaičiuotų nenaudojant žemų dažnių filtro, pavyzdžiai


Metodologijoje aprašytas galutinis klasifikavimo požymių sąrašas sudarytas remiantis tikslumo kreive, pateikta 40 pav. Maksimalus tikslumas prieš nusistovėjimą pasiektas naudojant 14 požymių iš 35 – papildomų požymių pridėjimas viršijus šią ribą nepagerino klasifikavimo tikslumo, tačiau sumažino modelio stabilumą. Tyrimo metu nestabilus modelis gali sumažinti pristatomų rezultatų patikimumą, o praktinio taikymo metu – lemti kintantį bendrą sistemos tikslumą.



40 pav. Gradientinio medžio stiprinimo modelio klasifikavimo tikslumo priklausomybė nuo požymių skaičiaus. Nuspalvinta sritis – kryžminės validacijos tikslumo standartinis nuokrypis

Du iš šių atrinktų požymių turėjo didesnę svarbą (angl. *importance*) modelio spėjimams nei likę (**41 pav.**) – žemo ir aukšto dažnio dedamųjų santykis (19 % svarba) bei skerspjūvio plotis (12 % svarba). Pirmasis požymis patvirtina, kad sunkiųjų MP parašai, kaip pastebėta ir modeliavimo metu, turi skirtingą aukšto ir žemo dažnio dedamųjų santykį nei likusios dvi klasės, o antrasis – kad skiriasi jų parašo plotis. Likusių požymių svarba tolygiai mažėjo iki 3,5%.

Kiekvienas į modelio įvesties vektorių įtrauktas požymis didina mikrovaldiklio atliekamų skaičiavimų trukmę, modelio parametrų skaičių ir t. t., todėl siekiant efektyvaus sistemos veikimo reikia naudoti ne daugiau požymių, nei būtina.



41 pav. Gradientinio medžio stiprinimo modelio požymių svarba

Maksimalus MP parašų klasifikavimo tikslumas šiame darbe pasiektas duomenų apdorojimo ir klasifikavimo proceso metu taikant visus aptartus žingsnius ir parametrus – neteisingai įrašytų parašų atmetimą, z ašies išskyrimą, signalo filtravimą bei didžiausią svarbą turinčių požymių išskyrimą.

4.2. Klasifikavimo modelių rezultatų palyginimas

Atlikus **modelių apmokymą ir kryžminę validaciją**, gauti rezultatai, pateikiami 11 lentelėje. Visų modelių vidutinis tikslumas buvo panašus (0,7 – 0,82), tačiau standartinis tikslumo nuokrypis kito 2,5 karto (0,04 – 0,11). Tai reiškia, kad naudojant bet kurį modelį teoriškai galima pasiekti panašius klasifikavimo rezultatus, tačiau kai kurie modeliai yra stabilesni (patikimesni) už kitus.

Modeliai, kurių algoritmai yra pagrįsti požymių nepriklausomumo prielaida (logistinės regresijos, Bajeso) turėjo mažesnę tikslumą nei sudėtingesni modeliai (RF, KNN, GBDT). Tai įrodo, kad sprendžiama netiesinė klasifikavimo problema.

Siekiant įvertinti klasifikavimo modelių veiksmingumą, jų tikslumas lygintas su atramine statistine reikšme (angl. *baseline*), t. y., tikslumu, kuris būtų pasiektas visuomet įrašui priskiriant dviračių klasę, sudarančią didžiausią duomenų dalį. Tokio paprastojo statistinio modelio tikslumas yra 60 %, o klasių pasiskirstymą atitinkančio statistinio modelio tikslumas yra 45 %. Atliktas vienos imties *t* testas, lyginantis modelio tikslumą su 60 % statistine riba, įrodė, kad visi analizuoti modeliai yra naudingi – jų *p* reikšmė yra mažesnė nei $\alpha = 0,05$.

11 lentelė. Klasifikavimo modelių kryžminės validacijos rezultatai


Modelis	Tikslumas ± std. nuokrypis	Tikslumo pasikliautinis intervalas (95%)	Lygių klasių preciziškumas	Lygių klasių atkartojamumas	Lygių klasių F1	<i>t</i> testo <i>p</i> reikšmė*	McNemar'o <i>p</i> reikšmė**
GBDT	0.82 ± 0.04	0.80-0.84	0.80	0.76	0.78	3.1·10 ⁻⁸	-
RF	0.79 ± 0.07	0.75-0.83	0.75	0.70	0.72	1.3·10 ⁻⁵	0.19
SVM (su RBF šerdimi)	0.78 ± 0.08	0.73-0.83	0.70	0.75	0.71	5.6·10 ⁻⁵	0.02
KNN (k=5)	0.76 ± 0.05	0.73-0.79	0.71	0.67	0.69	3.2·10 ⁻⁶	0.04
Bajeso	0.71 ± 0.07	0.67-0.75	0.63	0.65	0.64	8.0·10 ⁻⁴	5.4·10 ⁻⁴
Logistinės regresijos	0.70 ± 0.11	0.63-0.77	0.66	0.73	0.68	0.018	1.8·10 ⁻⁴
Atraminė statistinė reikšmė	0.60	-	-	-	-	-	-

* *p* reikšmės, gautos *t* testu lyginant kiekvieno modelio rezultatus su paprastojo statistinio modelio tikslumu.

** *p* reikšmės, gautos McNemar'o testu lyginant kiekvieno modelio rezultatus su GBDT rezultatais.

Geriausiu tikslumu pasižymėjo GBDT modelis, kurio tikslumas buvo 0,82 ± 0,04. Kadangi šiame darbe atliekamas bandomasis tyrimas (angl. *pilot study*), toks rezultatas yra teigiamas ir įrodo MPPĮ metodo tinkamumą. Kita vertus, galutinės MPPIS kūrimas reikalautų papildomų tyrimų ir modelio tobulinimo.

Naudojant GBDT modelį, didžiausiu specifiniu tikslumu pasižymėjo dviračių klasė (**42 pav.**) – jos preciziškumas buvo 0,83, o jautrumas 0,89; mažesnis tikslumas – elektrinių paspirtukų klasės, kurios preciziškumas 0,83 ir jautrumas 0,76; sudėtingiausias klasifikavimas – sunkioji MP klasės, kurios preciziškumas 0,75 ir jautrumas 0,64. Jei kiekviena klasė turėtų vienodą svorį duomenų rinkinyje, klasifikavimo tikslumas (angl. *macro-average F1*) būtų 0,78. Toks rodiklis nėra reikšmingas praktiniam taikymui, jei MP eismas yra panašus į stebėtą šio tyrimo metu, tačiau jis gali būti naudingas siekiant tarpusavyje palyginti skirtingas MPPĮS ar jas naudojančių tyrimų rezultatus.



42 pav. Trijų geriausio tikslumo modelių klasifikavimo matrica

Kiti du geriausiu tikslumu pasižymėję modeliai (RF ir SVM) pasiekė panašų *bendrą* tikslumo lygį, tačiau skirtingą *specifinį* (atskirų klasių) tikslumą. Atlikus McNemar'o testą, lyginantį dviejų modelių teisingų ir neteisingų klasifikavimo rezultatų aibes, nustatyta, kad beveik visų modelių rezultatai reikšmingai ($p < 0,05$) skyrėsi nuo geriausio modelio – GBDT – rezultatų. Vienintelė išimtis – RF modelis, pagal tikslumą esantis antroje vietoje.


Aptarti skirtumai reiškia, kad modelio pasirinkimas priklauso ne tik nuo bendro tikslumo (kuris, kaip jau minėta, yra panašus visiems modeliams), tačiau ir nuo to, kurių klasių specifiniam tikslumui skiriamas prioritetas. Pavyzdžiui, RF modelis prasčiau atpažino sunkiąsias MP (tikslumas 0,45); SVM modelis šios klasės tikslumą pagerino nuo 0,64 iki 0,73, tačiau kitų klasių tikslumas, lyginant su GBDT modeliu, sumažėjo. Tai reiškia, kad stebint bendrą MP pasiskirstymą reikėtų naudoti GBDT modelį, o skaičiuojant sunkiąsias MP (pavyzdžiui, planuojant įrengti greičio mažinimo priemones) – SVM modelį.

4.3. Geriausio klasifikavimo modelio rezultatų analizė

Geriausio modelio – GBDT – rezultatai buvo išanalizuoti detaliau. Nagrinėjant mokymosi kreivę (**43 pav.**), vaizduojančią mokymosi tikslumo augimą didinant naudotų įrašų skaičių, pastebėta, kad įsisotinimas pasiektas naudojant 25 % mokymosi duomenų. Tai indikuoja persimokymą, kylantį, nes GBDT modelis įsiminė ribotos apimties ($N = 236$) duomenų rinkinį.

Nepaisant to, atliekamas tyrimas yra prasmingas, nes kryžminės validacijos tikslumas, nustatytas naudojant apmokymo metu modelio nematytus duomenis, yra aukštas (virš 80 %) ir didėjantis, taigi, modelis gali klasifikuoti ir anksčiau nematytus MP parašus. Persimokymas šiuo atveju įspėja tik apie mažą duomenų rinkinio dydį, o ne fundamentinį modelio trūkumą. Tai patvirtina ir paprastesnių

modelių (turinčių mažesnę persimokymo riziką) rezultatai – jais nebuvo pasiektas geresnis kryžminės validacijos tikslumas.



43 pav. Gradientinio medžio stiprinimo modelio klasifikavimo tikslumo priklausomybė nuo apmokymo imties dydžio (mokymosi kreivė). Nuspalvintos sritys – standartinis nuokrypis

Pagrindinis būdas tobulinti modelio gebėjimą apibendrinti MP parašų savybes – įrašų skaičiaus, ypač sunkiųjų MP klasės, didinimas. Remiantis duomenimis, iš kurių sudaryta mokymosi kreivė, įvertinta, kad sunkiųjų MP parašų klasifikavimo jautrumas nusistovėtų ties 70 % turint apytiksliai 1000 parašų duomenų rinkinį (išlaikant klasių proporcijas), o bendras tikslumas – ties 88 % turint apytiksliai 500 parašų.

Šis įvertinimas atitinka rekomendacijas, pateikiamas mokslinėse publikacijose – pavyzdžiui, MacNell ir kt. [47] teigimu, efektyviam GBDT modelių taikymui reikalingi 20-30 įrašų kiekvienam naudojamam požymiui. Be to, tikėtina, kad papildomų sunkiųjų MP įrašų įtraukimas į duomenų rinkinį leistų aprašyti didesniu informatyvumu pasižyminčius signalo požymius. Tai dar pagerintų bendrus klasifikavimo rezultatus. Tikslumas, reikalingas praktiniam (komerciniam) sistemos taikymui gali siekti 90 – 95 % [26].

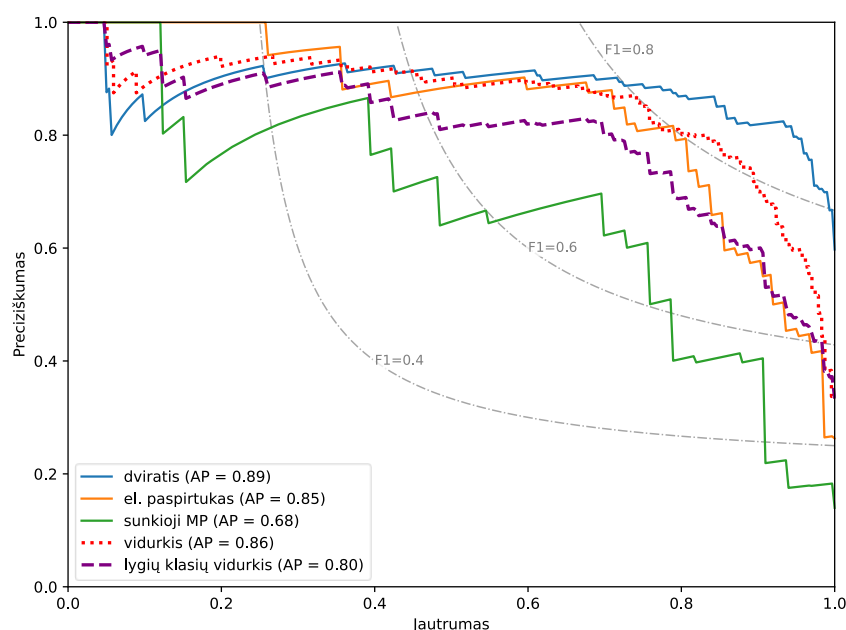
Alternatyva papildomų įrašų rinkimui – duomenų rinkinio augmentacijos (angl. *dataset augmentation*) metodai. Kaip jau minėta, turimas duomenų rinkinys yra nesubalansuotas (jame sunkiųjų MP parašų yra mažiau nei kitų klasių parašų), todėl augmentacijos metodais siekta suvienodinti klasių proporcijas.

Vienas iš tokių metodų – papildomų sunkiųjų MP parašų sukūrimas naudojant signalo inversiją. Tai lėmė tik nedidelį tikslumo padidėjimą (nuo 0,82 iki 0,84), tačiau standartinį nuokrypį padidino beveik 40 % (iki 0,06). Galima tokių rezultatų priežastis – visi tyrime naudoti požymiai, išskyrus du, yra simetriniai. Dėl šios savybės signalo inversija reikšmingai nepadidino sunkiųjų MP klasės parašų kintamumo. Klasifikuojant įrašus, panašius į esančius mokymosi rinkinyje, pasiektas tikslumo padidėjimas, tačiau taip pat – didesnė priklausomybė nuo kryžminės validacijos grupės sandaros. Taigi, taikant šį metodą modelio rezultatai buvo pagerinti tik šiek tiek, tačiau jų patikimumas sumažėjo.

Kiti augmentacijos būdai yra, pavyzdžiui, didesnio svorio suteikimas elektrinių paspirtukų ir sunkiųjų MP klasėms arba dviračių klasės įrašų skaičiaus sumažinimas. Šie metodai lėmė rezultatus, panašius į pasiektus SVM modeliu – didesnis sunkiųjų MP klasės svoris padidino specifinį tikslumą iki 0,77, tačiau sumažino bendrą tikslumą ir padidino standartinę nuokrypį analogiškai signalo inversijai.

Nors augmentacijos (dirbtinių duomenų įtraukimo) metodai klasifikavimo tikslumo nepagerino, tikrojo sunkiųjų MP parašų skaičiaus padidinimas turėtų būti veiksmingas, nes validacijos tikslumo kreivė nepasiekė nusistovėjimo. Tai leidžia teigti, kad yra tikslinga atlikti tolesnius tyrimus, susijusius su aprašomu MPPĮ metodu.

Visų tyrime naudotų modelių hiperparametrai optimizuoti tinklelio paieškos (angl. *grid search*) metodu, kuris atlieka modelio apmokymą ir validaciją su visomis nurodytų parametru verčių kombinacijomis. Optimizavimo rezultatais galima įsitikinti, pavyzdžiui, nagrinėjant preciziškumo-jautrumo kreives (angl. *precision-recall curves*), pateiktas 44 pav.

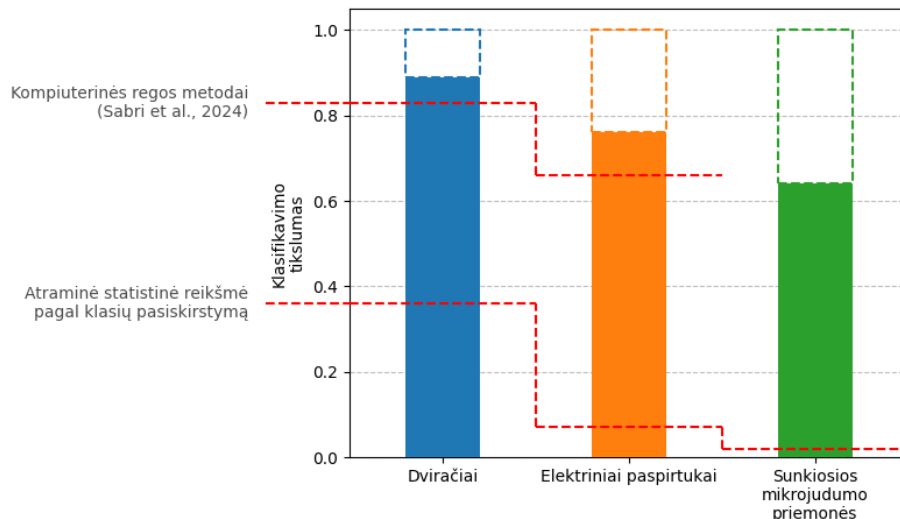


44 pav. Gradientinio medžio stiprinimo modelio preciziškumo-jautrumo kreivės

Paeiliui bandant skirtingas galimas pasirinkimų medžio viršūnių slenkstines vertes (kiekvienas kreivės taškas atitinka vieną galimą slenkstinę vertę), pasiekiamas norimas modelio preciziškumas ir jautrumas. Kuriam rodikliui skiriamas prioritetas, priklauso nuo konkretaus taikymo – pavyzdžiui, jei kaupiant statistiką svarbu praleisti kuo mažiau sunkiųjų MP, pasirenkama slenkstinė vertė, atitinkanti didelį šios klasės jautrumą.

Pastebėta, kad su beveik visomis slenkstinėmis vertėmis geriausiu rezultatu pasižymėjo dviračių klasė – rezultatai analogiškai anksčiau nagrinėtoms klasifikavimo matricoms. Geriausias klasifikavimo rezultatas, esantis arčiausiai taško (1, 1), atitinka F1 rodiklį (arba, šiuo atveju, ir tikslumą), nagrinėtą pateiktose matricose – 0,82.

Pasiekti rezultatai palyginti su atraminėmis tikslumo vertėmis – kompiuterinės regos metodų ir statistinio spėjimo rezultatais (45 pav.). Remiantis jais, galima teigti, kad siūlomas MPPĮ metodas yra ne tik naudingas (pasiekia geresnį tikslumą nei paprastas statistinis modelis), tačiau ir pagerina rezultatus, pasiekiamus naudojant šiuo metu populiariausius kompiuterinės regos metodus.



45 pav. Klasifikavimo magnetinio lauko jutikliais ir kitais metodais tikslumas

Įvertinus magnetinio lauko jutiklių privalumus (atsparumą aplinkos sąlygoms, vizualiniam užstojimui ir t. t.), galima teigti, kad šis MPPĮ metodas pasižymi neišvystytu potencialu, o papildomi tyrimai šia tema prisidėtų prie mikrojudumo vystymo išmaniuosiuose miestuose.

4.4. Mikrojudumo priemonių parametru įvertinimo metodo apribojimai ir tolesnių tyrimų pasiūlymai

Aprašomas MPPĮ metodas neturi ribojimų, apsunkinančių daugelio kitų technologijų taikymą (pavyzdžiui, nėra jautrus pėstiesiems, apšvietimui ir kt.), tačiau turi specifinių apribojimų.

Vienas svarbiausių apribojimų – šiuo metodu negalima aptikti MP be metalinių ar magnetinių dalių, pavyzdžiui, vaikiškų paspirtukų ar riedučių. Tokios priemonės nesudaro didelės eismo srauto dalies – šio tyrimo metu jos sudarė mažiau nei 1 % viso MP srauto. Kitas apribojimas – negalima garantuoti MPPĮS veikimo itin intensyvaus eismo sąlygomis, jei atstumas tarp MP išlaikomas mažesnis nei 10 cm – gali kilti sunkumų atskiriant individualius MP parašus. Metodas taip pat neužtikrina teisingų rezultatų anomalaus elgesio atveju, pavyzdžiui, važiuojant dviračiu ant vieno rato.

Tolimesni tyrimai šioje srityje galėtų būti skirti didesnės apimties duomenų rinkinio sudarymui, siekiant pagerinti jo reprezentatyvumą ir lygų klasių pasiskirstymą. Taip pat šiame tyrime nenagrinėtas sudėtinių MP parašų skaidymas į atskirų MP parašus. Šis žingsnis gali būti realizuotas naudojant, pavyzdžiui, neuroninius tinklus MP skaičiaus įvertinimui ir parašo segmentacijai, arba maišytų šaltinių atskyrimo (angl. *mix source separation*) metodus. Taip pat svarbu sukurti metodą parašų, užfiksuotų MP judant įstrižai jutiklių gardelės, „ištiesinimui“. Šiam metodui galima naudoti MP ašies įvertinimo ir sukamosios transformacijos algoritmus, arba jutiklių duomenų suliejimo (angl. *sensor fusion*) algoritmus su adaptyviais slenksčiais.

Prieš MPPĮS taikant praktikoje, verta skirti dėmesį tyrimams, susijusiems su jų optimizavimu naudojimui transporto infrastruktūroje: tinkamų diegimo, priežiūros procedūrų sudarymui, sistemos architektūros parengimui masiniam naudojimui (angl. *scalability*) bei integracijai į išmaniųjų miestų sistemas.

Išvados

1. Magnetinio lauko jutiklių naudojimas mikrojudumo priemonių parametrų įvertinti išsiskiria atsparumu mikrojudumo priemonių vizualiniam užstojimui, oro sąlygoms ir apšvietimui, pasižymi paprastu diegimu ir priežiūra bei gera skersine skyra. Šiais jutikliais užfiksuoti mikrojudumo priemonių magnetinio lauko iškraipymų parašai gali būti apdorojami naudojant mašininio mokymosi modelius. Sudėtingiausiai įvertinamo mikrojudumo priemonės parametro – klasės – nustatymui tinkamiausi yra ansamblio modeliai, pavyzdžiui, gradientinio medžio stiprinimo arba atsitiktinio miško, kurių įvestims naudojami matmenų mažinimo metodais atrinkti parašų požymiai.
2. Atlikus kompiuterinį modeliavimą, parengti minimalūs reikalavimai mikrojudumo priemonių parametrų įvertinimo sistemoms, naudojančioms magnetinio lauko jutiklius: maksimalus jutiklių gardelės įrengimo gylis po kelio danga yra 23 mm, jei gardelės periodas yra 100 mm, arba 31 mm, jei gardelės periodas yra 50 mm; minimalus diskretizavimo dažnis, taikant 1 % spektrinio energijos tankio ribą, yra 72 Hz.
3. Nustatyta, kad mikrojudumo priemonių parašų apdorojimas priklauso nuo geografinės padėties – šiame tyrime nagrinėtos 70° magnetinės inklinacijos sąlygos, o metodo pritaikymas visoms geografinėms vietovėms reikalautų adaptyvaus klasifikavimo algoritmo.
4. Atlikus eksperimentus, parinkti optimalūs mikrojudumo priemonių klasifikavimo metodikos žingsniai bei parametrai: duomenų surinkimas naudojant magnetinio lauko jutiklių gardelę, neteisingai įrašytų parašų atmetimas, anotacija, z ašies centrinio jutiklio signalo išskyrimas iš parašo matricos, filtravimas 30 Hz ribinio dažnio žemų dažnių filtru, 14-os požymių išskyrimas (svarbiausi – žemo ir aukšto dažnio dedamųjų santykis ir skerspjūvio plotis), modelių apmokymas bei 10-ies grupių kryžminė validacija.
5. Mašininio mokymosi modelių vertinimas įrodė, kad magnetinio lauko jutikliai gali būti taikomi mikrojudumo priemonėms klasifikuoti. Geriausius rezultatus galima pasiekti naudojant gradientinio medžio stiprinimo bei atsitiktinio miško modelius, tiksliausiai klasifikuojančius dviračius (89 %), prasčiau – paspirtukus (76 %), o blogiausiai – sunkiąsias mikrojudumo priemones (64 %). Prasčiausi rezultatai – modelių, pagrįstų požymių nepriklausomumo prielaida (McNemar'o testo, kuriuo palyginti modeliai, $p < 0,05$).
6. Atlikus tyrimą nustatyta, kad magnetinio lauko jutiklių taikymas mikrojudumo priemonių parametrų įvertinimui yra veiksmingas (t testo, lyginančio su atramine statistine verte, $p < 0,05$) ir pranašesnis nei šiai užduočiai naudojamų kompiuterinės regos metodų – pasiektas bendras klasifikavimo tikslumas yra 82 %.

Literatūros sąrašas

1. ABDULJABBAR, R. L., S. LIYANAGE, H. DIA. The role of micro-mobility in shaping sustainable cities: A systematic literature review. *Transportation Research Part D: Transport and Environment*, 92, 2021, 102734. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S1361920921000389>.
2. HOSSEIN SABBAGHIAN, M., D. LLOPIS-CASTELLÓ, A. GARCÍA. A Safe Infrastructure for Micromobility: The Current State of Knowledge. *Sustainability*, 15, 2023, 13, 10140. Prieiga per internetą: <https://www.mdpi.com/2071-1050/15/13/10140>.
3. NACTO. Shared Micromobility Report: 2023. Ataskaita. 2024. Prieiga per internetą: <https://nacto.org/publication/shared-micromobility-report-2023/> [žiūrėta 2025-10-07].
4. RAJAN, T. P., B. GEORGE. An Inductive Loop Detector for Personal Transporters in Urban Cycle Lanes. Iš: *IECON 2024 - 50th Annual Conference of the IEEE Industrial Electronics Society*, 1–6. IEEE, 2024. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/10905280>.
5. CREUTZIG, F. From smart city to digital urban commons: Institutional considerations for governing shared mobility data. *Environmental Research: Infrastructure and Sustainability*, 1, 2021, 2, 025004. Prieiga per internetą: <https://doi.org/10.1088/2634-4505/ac0a4e>.
6. FONG, B., A. C. M. FONG, G. Y. HONG. Sustainable Micromobility Management in Smart Cities. *Trans. Intell. Transport. Sys.*, 24, 2023, 12, 15890–15896. Prieiga per internetą: <https://doi.org/10.1109/TITS.2023.3292377>.
7. DIAS, G. J. C., P. RIBEIRO, E. ARSENIO. Micromobility: a systematic literature review on the measurement of its environmental, social, and economic impacts on urban sustainability. Iš: *European Transport Conference*. Association for European Transport, 2021. Prieiga per internetą: <https://hdl.handle.net/1822/78533>.
8. TUROŃ, K. Sustainable Urban Mobility Transitions—From Policy Uncertainty to the CalmMobility Paradigm. *Smart Cities*, 8, 2025, 5, 164. Prieiga per internetą: <https://www.mdpi.com/2624-6511/8/5/164>.
9. FOLCO, P., L. GAUVIN, M. TIZZONI, M. SZELL. Data-driven micromobility network planning for demand and safety. *Environment and Planning B: Urban Analytics and City Science*, 50, 2023, 8, 2087–2102. DOI: 10.1177/23998083221135611.
10. MARTÍNEZ MILLANA, A. Personal Mobility Vehicle monitoring system. 2022. Prieiga per internetą: <https://www.itaca.upv.es/innovation-old/results-and-technology-offer/personal-mobility-vehicle-monitoring-system/> [žiūrėta 2025-05-15].
11. STAHL, B., J. APFELBECK, R. LANGE. Classification of Micromobility Vehicles in Thermal-Infrared Images Based on Combined Image and Contour Features Using Neuromorphic Processing. *Applied Sciences*, 13, 2023, 6, 3795. Prieiga per internetą: <https://www.mdpi.com/2076-3417/13/6/3795>.
12. GONZÁLEZ, B., F. J. JIMÉNEZ, J. DE FRUTOS. A Virtual Instrument for Road Vehicle Classification Based on Piezoelectric Transducers. *Sensors*, 20, 2020, 16, 4597. Prieiga per internetą: <https://www.mdpi.com/1424-8220/20/16/4597>.
13. SZWOCH, G., J. KOTUS. Acoustic Detector of Road Vehicles Based on Sound Intensity. *Sensors*, 21, 2021, 23, 7781. Prieiga per internetą: <https://www.mdpi.com/1424-8220/21/23/7781>.
14. CHIANG, C.-Y., M. JABER, K. K. CHAI, J. LOO. Distributed Acoustic Sensor Systems for Vehicle Detection and Classification. *IEEE Access*, 11, 2023, 31293–31303. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/10078155>.
15. FRNIAK, M., M. MARKOVIC, P. KAMENCAY, J. DUBOVAN, M. BENCO, M. DADO. Vehicle Classification Based on FBG Sensor Arrays Using Neural Networks. *Sensors*, 20, 2020, 16, 4472. Prieiga per internetą: <https://www.mdpi.com/1424-8220/20/16/4472>.

16. HASSANIN, M., M. A. ALSHEIKH, C. C. N. KUHN, D. HERATH, D. T. HOANG, I. RADWAN. Towards Autonomous Riding: A Review of Perception, Planning, and Control in Intelligent Two-Wheelers. Preprintas. arXiv, 2025. Prieiga per internetą: <http://arxiv.org/abs/2507.11852> [žiūrėta 2026-03-04].
17. CHEN, D., A. HOSSEINI, A. SMITH, A. F. NIKKHAH, A. HEYDARIAN, O. SHOGLI, B. CAMPBELL. Performance Evaluation of Real-Time Object Detection for Electric Scooters. Preprintas. arXiv, 2024. Prieiga per internetą: <http://arxiv.org/abs/2405.03039> [žiūrėta 2025-05-15].
18. SLIWA, B., N. PIATKOWSKI, C. WIETFELD. The Channel as a Traffic Sensor: Vehicle Detection and Classification Based on Radio Fingerprinting. *IEEE Internet of Things Journal*, 7, 2020, 8, 7392–7406. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/9046237>.
19. SABRI, K., C. DJILALI, G.-A. BILODEAU, N. SAUNIER, W. BOUACHIR. Detection of Micromobility Vehicles in Urban Traffic Videos. Preprintas. arXiv, 2024. Prieiga per internetą: <http://arxiv.org/abs/2402.18503> [žiūrėta 2025-05-15].
20. APURV, K., R. TIAN, R. SHERONY. Detection of E-scooter Riders in Naturalistic Scenes. Preprintas. arXiv, 2021. Prieiga per internetą: <http://arxiv.org/abs/2111.14060> [žiūrėta 2026-03-04].
21. KUDO, T., K. AZUMA, R. SHINKUMA, G. TROVATO. Edge system with multi-LIDAR sensor network for tracking micro-mobility vehicles. Iš: *2023 IEEE 20th Consumer Communications & Networking Conference (CCNC)*. 983–984. IEEE, 2023. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/10059769>.
22. ICOMS DETECTIONS S.A. TMA-3B3. *Icoms Detections*. Svetainė. Prieiga per internetą: <https://www.icomsdetections.com/project/tma-3b3-en/> [žiūrėta 2025-05-15].
23. BEYER, P. Non-intrusive detection, the way forward. Iš: *Southern African Transport Conference*. 2015. Prieiga per internetą: <http://hdl.handle.net/2263/57785>.
24. MARSZALEK, Z., K. DUDA. Multifrequency Vector Measurement System for Reliable Vehicle Magnetic Profile Assessment. *Sensors*, 20, 2020, 17, 4933. Prieiga per internetą: <https://www.mdpi.com/1424-8220/20/17/4933>.
25. FEDERAL HIGHWAY ADMINISTRATION. Office of Highway Policy Information - Policy. 2014. Prieiga per internetą: <https://www.fhwa.dot.gov/policyinformation/pubs/vdstits2007/04pt2.cfm> [žiūrėta 2025-05-15].
26. ECO-COUNTER. ZELT Evo - The world's most trusted bike counter. *Eco-Counter*. Prieiga per internetą: <https://www.eco-counter.com/solutions/counting-solutions/urban-zelt> [žiūrėta 2025-10-13].
27. LAZARO, A., M. LAZARO, R. VILLARINO, D. GIRBAU. Smart Spread Spectrum Modulated Tags for Detection of Vulnerable Road Users with Automotive Radar. *Sensors*, 23, 2023, 5, 2730. Prieiga per internetą: <https://www.mdpi.com/1424-8220/23/5/2730>.
28. FREITAS, R., M. J. NICOLAU, A. COSTA. Detection and positioning of vulnerable road users in vehicular networks. Iš: *2024 International Wireless Communications and Mobile Computing (IWCMC)*. 0842–0848. 2024. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/10592547>.
29. YAO, R., T. UCHIYAMA. Analysis of Magnetic Signatures for Vehicle Detection Using Dual-Axis Magneto-Impedance Sensors. *IEEE Sensors Journal*, 24, 2024, 6, 8721–8730. Prieiga per internetą: <https://ieeexplore.ieee.org/document/10325222>.
30. ČULÍK, K., V. ŠTEFANCOVÁ, K. HRUDKAY. Application of Wireless Magnetic Sensors in the Urban Environment and Their Accuracy Verification. *Sensors*, 23, 2023, 12, 5740. Prieiga per internetą: <https://www.mdpi.com/1424-8220/23/12/5740>.

31. BALID, W., H. TAFISH, H. H. REFAI. Intelligent Vehicle Counting and Classification Sensor for Real-Time Traffic Surveillance. *IEEE Transactions on Intelligent Transportation Systems*, 19, 2018, 6, 1784–1794. Prieiga per internetą: <https://ieeexplore.ieee.org/document/8026566/>.
32. FENG, Y., G. MAO, B. CHEN, C. LI, Y. HUI, Z. XU, J. CHEN. MagMonitor: Vehicle Speed Estimation and Vehicle Classification Through A Magnetic Sensor. *IEEE Transactions on Intelligent Transportation Systems*, 23, 2022, 2, 1311–1322. Prieiga per internetą: <https://ieeexplore.ieee.org/document/9210166/?arnumber=9210166>.
33. BALAMUTAS, J., D. NAVIKAS, V. MARKEVIČIUS, M. ČEPĖNAS, A. VALINEVIČIUS, M. ŽILYS, M. PRAUZEK, J. KONECNY, Z. LI, D. ANDRIUKAITIS. Vehicle Re-Identification Based on Multiple Magnetic Signatures Features Evaluation. *IEEE Access*, 12, 2024, 102606–102618. Prieiga per internetą: <https://ieeexplore.ieee.org/document/10609373>.
34. SAE INTERNATIONAL. J3194_202502, *Taxonomy and Classification of Powered Micromobility Vehicles*. Prieiga per internetą: https://www.sae.org/standards/j3194_202502-taxonomy-classification-powered-micromobility-vehicles [žiūrėta 2025-10-13].
35. SANTACREU, A., G. YANNIS, O. de S. LEON, P. CRIST. *Safe Micromobility*. Ataskaita. International Transport Forum, 2020. Prieiga per internetą: <https://www.itf-oecd.org/safe-micromobility> [žiūrėta 2025-10-07].
36. BALAMUTAS, J., D. NAVIKAS, V. MARKEVIČIUS, M. ČEPĖNAS, A. VALINEVIČIUS, M. ŽILYS, M. FRIVALDSKY, Z. LI, D. ANDRIUKAITIS. Passing Vehicle Road Occupancy Detection Using the Magnetic Sensor Array. *IEEE Access*, 11, 2023, 50984–50993. Prieiga per internetą: <https://ieeexplore.ieee.org/document/10130572>.
37. KEAWKAMNERD, S., J. CHINRUNGRUENG, C. JARUCHART. Vehicle Classification with low computation magnetic sensor. Iš: *2008 8th International Conference on ITS Telecommunications*. 164–169. 2008. Prieiga per internetą: <https://ieeexplore.ieee.org/document/4740249> [žiūrėta 2025-10-14].
38. DONG, H., X. WANG, C. ZHANG, R. HE, L. JIA, Y. QIN. Improved Robust Vehicle Detection and Identification Based on Single Magnetic Sensor. *IEEE Access*, 6, 2018, 5247–5255. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/8252690>.
39. LI, H., H. DONG, L. JIA, M. REN. Vehicle classification with single multi-functional magnetic sensor and optimal MNS-based CART. *Measurement*, 55, 2014, 142–152. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S0263224114001869>.
40. KAEWKAMNERD, S., J. CHINRUNGRUENG, R. PONGTHORNSERI, S. DUMNIN. Vehicle classification based on magnetic sensor signal. Iš: *The 2010 IEEE International Conference on Information and Automation*. 935–939. 2010. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/5512140>.
41. ALNUAIMI, A. F. A. H., T. H. K. ALBALDAWI. An overview of machine learning classification techniques. *BIO Web of Conferences*, 97, 2024, 00133. Prieiga per internetą: <https://www.bio-conferences.org/10.1051/bioconf/20249700133>.
42. CHANDANA, M. H., G. DORASANAMMA, S. KIRAN, A. A. KUMAR. A Review on Feature Extraction Techniques using Machine Learning. *Macaw International Journal of Advanced Research in Computer Science and Engineering*, 10, 2024, 1, 57–63. Prieiga per internetą: <https://www.macawpublications.com/Journals/index.php/MIJARCSE/article/view/53>.
43. BALAMUTAS, J., M. AMBRAZIŪNAS, D. NAVIKAS, V. MARKEVIČIUS, M. ČEPĖNAS, A. VALINEVIČIUS, M. ŽILYS, D. ANDRIUKAITIS. Method for Accelerometer and Magnetometer Based Vehicle Classification. Iš: *2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*. 2289–2294. 2023. Prieiga per internetą: <https://ieeexplore.ieee.org/abstract/document/10422711>.
44. TAGHVAAEYAN, S., R. RAJAMANI. Portable Roadside Sensors for Vehicle Counting, Classification, and Speed Measurement. *IEEE Transactions on Intelligent Transportation*

- Systems*, 15, 2014, 1, 73–83. Prieiga per internetą: <https://ieeexplore.ieee.org/document/6609121>.
45. ZHANG, H., W. ZHOU, G. LIU, Z. WANG, Z. QIAN. Fine-Grained Vehicle Make and Model Recognition Framework Based on Magnetic Fingerprint. *IEEE Transactions on Intelligent Transportation Systems*, 25, 2024, 8, 8460–8472. Prieiga per internetą: <https://ieeexplore.ieee.org/document/10481527>.
46. LIETUVOS RESPUBLIKOS SEIMAS. *Saugaus eismo automobilių keliais įstatymo Nr. VIII-2043 2, 10 ir 25 straipsnių pakeitimo ir įstatymo papildymo 17 straipsniu įstatymas*. 2023. Prieiga per internetą: <https://e-seimas.lrs.lt/rs/legalact/TAD/c0ea772009eb11eeb489c7d891071d0a/> [žiūrėta 2025-12-02].
47. MACNELL, N., L. FEINSTEIN, J. WILKERSON, P. M. SALO, S. A. MOLSBERRY, M. B. FESSLER, P. S. THORNE, A. A. MOTSINGER-REIF, D. C. ZELDIN. Implementing machine learning methods with complex survey data: Lessons learned on the impacts of accounting sampling weights in gradient boosting. *PLOS ONE*, 18, 2023, 1, e0280387. Prieiga per internetą: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0280387>.

Priedai

1 priedas. Pradinis požymių sąrašas

Nr.	Požymio pavadinimas	Komentaras
1	Efektinis signalo ilgis	Plačiausio intervalo, kuriame nors viena signalo atskaita yra virš $2,3 \mu\text{T}$ (slenkstinė vertė, 1,5 karto didesnė nei jutiklių triukšmo lygis), ilgis, išplėstas iki artimiausių nulinių atskaitų
2	Atstumas tarp ekstremumų	Vidutinis atstumas tarp ekstremumų
3	Ekstremumo plotis	Vidutinis ekstremumo plotis
4	Išsikišimas	Vidutinis ekstremumo išsikišimas virš artimiausio priešingo ženklo ekstremumo
5	Maksimumas	Signalų globalus maksimumas
6	Maksimumo ir minimumo santykis	Signalų globalaus maksimumo ir globalaus minimumo santykis
7	Vidurkis	Efektinio signalo vidurkis
8	„Rimties zonų“ skaičius	Nepertraukiamų efektinio signalo intervalų, kuriuose signalas neviršija slenkstinės ribos, skaičius
9	Vidurkio kirtimų skaičius	Vidurkio kirtimų skaičius
10	Ekstremumų skaičius	Lokalų ekstremumų skaičius
11	Nulio kirtimų skaičius	Nulio kirtimų skaičius
12	„Plačių“ ekstremumų skaičius	Ekstremumų, kurių plotis viršija slenkstinę vertę, skaičius
13	Maksimumo padėtis	Globalaus maksimumo padėtis, normalizuota efektinio signalo ilgiui
14	1-ojo vidurkio kirtimo padėtis	1-ojo vidurkio kirtimo padėtis, normalizuota efektinio signalo ilgiui
15	2-ojo vidurkio kirtimo padėtis	2-ojo vidurkio kirtimo padėtis, normalizuota efektinio signalo ilgiui
16	Minimumo padėtis	Globalaus minimumo padėtis, normalizuota efektinio signalo ilgiui
17	1-ojo ekstremumo padėtis	1-ojo lokalaus ekstremumo padėtis, normalizuota efektinio signalo ilgiui
18	2-ojo ekstremumo padėtis	2-ojo lokalaus ekstremumo padėtis, normalizuota efektinio signalo ilgiui
19	3-ojo ekstremumo padėtis	1-ojo lokalaus ekstremumo padėtis, normalizuota efektinio signalo ilgiui
20	Standartinis nuokrypis	Signalų standartinis nuokrypis
21	Simetrija	Pirmosios signalo pusės integralo ir viso signalo integralo santykis
22	Paskutinio ketvirčio standartinis nuokrypis	Efektinio signalo paskutinio ketvirčio standartinis nuokrypis
23	Išplėstinis ekstremumo plotis	Globalaus maksimumo plotis, išplėstas iki artimiausių nulinių atskaitų
24	Skerspjūvio plotis	Plačiausio nepertraukiamo jutiklių intervalo, kuriame maksimalios atskaitos $z_{i,j}$ laiko momentu i visų jutiklių atskaitos viršija $2,3 \mu\text{T}$, ilgis (jutiklių skaičius)
25	Žemo ir aukšto dažnio dedamųjų santykis	Santykis tarp spektrinių dedamųjų sumos žemiau ir aukščiau 8 Hz

26	Amplitudinis santykis	Globalaus maksimumo ir minimumo santykis
27	Išvestinės santykis	Maksimalios ir minimalios signalo išvestinės verčių santykis
28	Amplitudės ir variacijos santykis	$R_{av} = \frac{z_{max}-z_{min}}{\frac{1}{N-1} \sum_{n=0}^{N-2} z[n+1]-z[n] }$, čia N – atskaitų skaičius
29	Svorio indeksas	$R_w = w_{spatial} \cdot l_e \cdot z_{max} $
30	Skerspjūvio pločio ir amplitudinio santykio sandauga	Skerspjūvio pločio w ir signalo amplitudinio santykio sandauga
31	Ekstremumų ir nulio kirtimų skaičiaus santykis	Signalų lokalių ekstremumų skaičiaus ir nulio kirtimų skaičiaus santykis
32	Pėdsakas	Skerspjūvio pločio ir efektinio signalo ilgio sandauga
33	Išvestinės minimumas	Signalų išvestinės minimali vertė
34	Išvestinės maksimumas	Signalų išvestinės maksimali vertė
35	Išvestinės vidurkis	Signalų išvestinės verčių vidurkis