



VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
INFORMATIKOS INSTITUTAS
KOMPIUTERINIO IR DUOMENŲ MODELIAVIMO KATEDRA

Magistro baigiamasis darbas

**Skirtingų parametrų įtakos elektromobilių energijos
suvartojimui tyrimas**

Atliko:

Artūr Kalčevskij

parašas

Vadovė:

dr. Agnė Brilingaitė

Vilnius
2023

Turinys

Anotacija	3
Summary	4
Ivydas	5
1. Literatūros analizė	8
2. Teoriniai modeliai	11
2.1. Teorinis elektromobilio suvartojamos energijos nustatymo modelis	11
2.2. Kelio tinklo modeliavimas	14
2.2.1. GPS duomenų tikslumo problematika	14
2.2.2. Nuolydžio kampo skaičiavimas	15
2.3. Vairuotojo profilio modelis	16
2.3.1. Greitis	17
2.3.2. Paros laikas	18
2.3.3. Temperatūra	19
2.4. Mašininio mokymosi teorinis panaudojimas	20
2.5. Prognozavimas	20
2.5.1. Prognozuojamas baterijos energijos suvartojimas	20
2.5.2. Dijkstra algoritmas	22
3. Testavimo aplinkos paruošimas ir duomenų rinkimas	24
3.1. Duomenų bazės paruošimas	24
3.2. Mobilioji duomenų rinkimo programėlė <i>evApp</i>	24
3.3. Serverio programinė įranga <i>evProjectServer</i>	26
3.3.1. Segmento kampo duomenys	29
3.3.2. Laiko duomenys	29
3.3.3. Temperatūros duomenys	30
4. Eksperimentai	31
4.1. Žemėlapių segmento nustatymas	31
4.2. Elektromobilio baterijos energijos suvartojimas	32
4.2.1. Pagal segmento kampą	35
4.2.2. Pagal temperatūrą	36
4.2.3. Kelio planavimas	36
4.3. Mašininis mokymasis	37
Išvados ir rekomendacijos	39
Ateities tyrimų gairės	41
Literatūros sąrašas	42

Anotacija

Pasaulyje egzistuoja įvairūs modeliai bei algoritmai, kurie įgalina automobilio nuvažiuojamo atstumo vertinimą bei nustatytus kriterijus atitinkančio maršruto parinkimą, tačiau neretai diskutuojama dėl esamų sprendimų tinkamumo elektromobiliams bei realios galimybės iš anksto nustatyti elektromobilio nuvažiuojamą atstumą. Esami sprendimai neretai yra riboti dėl elektromobilių specifikos nulemtos problematikos, įskaitant poreikį parinkti optimalų energijos prasmę, o ne greičiausią ar trumpiausią kelią. Literatūroje pasigendama individualiais kriterijais ir faktiniais duomenimis paremtų elektromobilio suvartojamos baterijos energijos skaičiavimų bei jų pagrindu paremtų kelio parinkimo sprendimų. Atsižvelgiant į šiuo metu taikomų sprendimų ribotumą, šiam darbui keliamas tikslas nustatyti esminių parametrų įtaką elektromobilio energijos suvartojimui. Išsikeltam tikslui įgyvendinti identifikuojami taikytini kriterijai ir parametrai, susiję su vairuotojo elgsena, elektromobilio savybėmis, kelio geometrija, kelio tinklo apkrova, priklausančia nuo laiko. Darbe pasiūlomi sprendimai – modelis bei algoritmai, kurie leidžia dinamiškai koreguoti bei vertinti vairuotojo profilį ir jo pagrindu prognozuoti elektromobilio suvartojamą energijos kiekį bei pasiūlyti konkrečiam vairuotojui optimalų kelią.

Summary

Investigation of the Different Parameters' Effect on the Energy Consumption of Electric Vehicles

Electric vehicles are becoming increasingly popular, but the main issue on calculation of the energy consumption of an electric vehicle remains relevant. There are various models and algorithms that help to determine consumption of the vehicle, however, their application to an electric vehicle and the real possibility of pre-determining the distance travelled by an electric vehicle and its consumption are discussed. Moreover, it is acknowledged that it is more important to determine the energy-optimal and most economic route for the electric vehicle rather than the fastest or shortest one.

In general, we can talk about two methods for determining the energy consumption of an electric vehicle: algorithms based on general data, physical and technical characteristics of the electric vehicle, and algorithms based on real driving measurements. Real-world driving measurements, capacity of the battery, driving style and driving data, environmental and weather conditions, temperature, road specifics, and other parameters, help to determine more realistic energy consumption data. However, it is noticed that the current literature lacks calculations based on essential criteria and real-world up-to-date data on the consumption of electric vehicle, as well as detailed studies based on it.

Given limitations of the current solutions, the objective of this work is to determine the influence of the key parameters on the energy consumption of an electric vehicle. To achieve this, the applicable key criteria and parameters are identified, practical solutions—algorithms that allow to evaluate the electric vehicle's driver profile and predict the energy consumption of the electric vehicle and propose an optimal path for a specific driver.

The conducted research allows to recommend the electric vehicle driver who wants to drive an electric vehicle as far as possible, to choose an optimal driving style, avoid excessive waste of battery power for sudden acceleration and aggressive driving, that reduce the possible distance travelled. Geographical features of the road, especially road slopes, should also be used for energy saving purposes. When choosing alternative routes, it is recommended to keep in mind that the fastest or shortest road for an electric vehicle does not always mean the optimal one, considering the energy consumption criteria.

Ivadas

Tinkamiausio kelio maršruto planavimas tapo neatsiejama visuomenės kasdienybės dalimi, todėl gausu įvairių modelių, algoritmų ir technologinių sprendimų, tačiau dėl technologinių pokyčių maršruto sudarymo ir kelio parinkimo problematika vis dar aktuali ir reikalauja egzistuojančių sprendimų analizės bei tobulinimo. Pastebima, kad tiriant net ir to paties modelio, techninių charakteristikų ir komplektacijos automobilį gali būti gauti skirtingi rezultatai. Rezultatų neatitikimo priežastys gali būti įvairios, tačiau neretai ši situacija susiklosto dėl skirtingų tyrimo metodų, kurie atsižvelgia į skirtingus kriterijus arba tuos pačius kriterijus įtraukia skirtinga apimtimi.

Kiekviena rinka pasirenka lengvųjų transporto priemonių bandymų procedūras, tačiau pasaulyje vyrauja trys pagrindiniai metodai. Važiavimo ciklą analizei Europoje taikyti NEDC ir WLTP metodai [19, 28], o Amerikoje – EPA (FTP-75) metodas [16]. NEDC (angl. New European Driving Cycle) tyrimas trunka 20 min, automobilis nuvažiuoja 11 km, iš kurių 66% laiko imituoja važiavimą mieste, o 34% laiko užmiestyje, vidutinis greitis yra ~34 km/h. Tačiau šis metodas tinkamesnis palyginimo, o ne matavimo funkcijai atlikti, todėl dėl šio ir kitų tyrimo trūkumų nuo 2017 metų jį pakeitė WLTP (angl. Worldwide Harmonized Light-Duty Vehicles Test Procedure), kurio skaičiavimai paremti bandymu, trunkančiu 30 min, nuvažiuojamas atstumas ~23 km, vidutinis greitis ~46 km/h. Imituojamo važiavimo miesto ir užmiestio proporcijos beveik suvienodintos, padidintas sustojimų mieste skaičius, be to, metodas geba nustatyti elektromobilio galios rezervą. EPA (FTP-75) (angl. EPA Federal Test Procedure) tyrimas, atsižvelgiant į regiono specifiką, orientuotas į važiavimą užmiestyje, nors tyrimo rezultatai panašūs į WLTP, tačiau mažesni ~1,17 karto. Šis metodas laikomas vienu tiksliausiu nuvažiuojamam atstumui apskaičiuoti. Aptartus metodus vienija tai, kad dauguma skaičiavimų atliekami standiniais matavimais, vadovaujamosi iš anksto nustatytais, standartiniais kriterijais ir reikšmėmis, todėl tyrimai iš esmės atspindi tik teorinius rezultatus. Atsižvelgiant į tai, Kinijoje 2019 metais buvo pristatytas Kinijos lengvųjų automobilių bandymo ciklas CLTC-P (angl. China Light-Duty Vehicle Test Cycle For Passenger Car), pagal kurią tyrimas atliekamas remiantis aktualiais eismo analizavimo sistemų duomenimis, todėl pirmosios CLTC-P tyrimo analizės teigia, kad šis metodas gali pateikti rezultatus, artimus realiems [20, 21]. Nors aukščiau aptarti metodai taikomi testuojant tiek vidaus degimo varikliais varomus automobilius, tiek ir elektromobilius, atsižvelgiant į rezultatų netikslumą tradiciniais laikomų automobilių atžvilgiu, ta pačia apimtimi taikant juos ir elektromobiliams, neatsižvelgiant į pastarųjų specifiką, tyrimų rezultatų patikimumas diskutuotinas.

Visose teorijose pripažįstama, kad atitinkamos prognozės bei išvados gali būti daromos remiantis istoriniais, faktiniais duomenimis, prieinamais viešose duomenų bazėse, tačiau įprastai tam reikalingi dideli duomenų kiekiai. Elektromobilių specifika lemia, kad siekiant prognozuoti, pavyzdžiui, elektromobilio energijos suvartojimą gali būti remiamasi tik iš elektromobilių surinktais duomenimis [30]. Tačiau pažymėtina, siekiant gauti tikslesnes prognozes, svarbu vertinti ne bet kokio, o konkretaus elektromobilio modelio, turinčio tas pačias technines savybes, duomenis.

Siekiant tikslesnių rezultatų, praktikoje vis didesnę reikšmę įgyja fizikos žinių bei individualizuotų duomenų pagrindu konstruojami algoritmai bei metodai. Esamų sprendimų tobulinimas bei naujų individualizuotų ir elektromobiliams tinkamų sprendimų kūrimo procesas įgyja vis didesnę pagreitį bei aktualumą tiek dėl natūraliai didėjančio elektromobilių kiekio, tiek dėl poreikio skatinti tarptautines ir nacionalines iniciatyvas įgyvendinti tvaresnius sprendimus, keisti vidaus degimo automobilius elektromobiliais. Pastarąjį dešimtmetį itin skatinamas vidaus degimo varikliais varomų automobilių keitimas automobiliais, varomais elektros energija. Atskirose valstybėse ir regionuose elektromobilių parko plėtros intensyvumas skiriasi. Dalis miestų, keldami ambicingus

tikslus, riboja ar net draudžia vidaus degimo varikliais varomų automobilių eismą atitinkamose teritorijose, įvesdamos mažos taršos zonas (angl. Low Emission Zone), itin mažos taršos zonas (angl. Ultra Low Emission Zone) ar nulinės taršos zonas (angl. Zero Emission Zone).

Vis dar aktualūs nuogaštavimai dėl elektromobilių, kurie didžiąja dalimi susiję su ribota galimybe pakrauti elektromobilio bateriją pagal poreikį, laiko sąnaudomis krovimui bei abejonėmis dėl galimybės nuvažiuoti pageidaujama atstuma. Be to, pastarųjų metų neramumai ir nestabilumas rinkose tiesiogiai įtakoja ir esamus ar potencialius elektromobilių savininkus tiek dėl elektros kainos, tiek ir dėl atsirandančių ribojimų, kaip pavyzdžiui, susijusių su elektromobilių krovimu viešose vietose ar krovimo laiku. Atsižvelgiant į tai, maršrutų parinkimas, kelionės laiko bei baterijos energijos sąnaudų prognozavimas įgijo dar didesnę reikšmę ir svarbą. Galima teigti, kad tolesnė efektyvi elektromobilių parko plėtra didele dalimi priklauso nuo veiksmingų, tinkamų bei patogių maršrutų parinkimo, baterijos energijos sąnaudų prognozavimo algoritmų egzistavimo ir pritaikymo praktikoje.

Esami modeliai ir algoritmai tik iš dalies atliepia esamus iššūkius bei poreikius. Atsižvelgiant į tai, kad elektromobiliams energijos sąnaudų prognozavimas turi esminę reikšmę, turi būti sukurti ir pasiūlyti patikimi sprendimai elektromobilio nuvažiuojamo atstumo prognozavimui ne tik teoriniu, bet ir praktiniu lygmeniu, kurie leistų planuoti maršrutą bei suteiktų pasitikėjimo ir aiškumo dėl galimybės pasiekti kelionės tikslą. Mažiausias elektromobilio baterijos energijos suvartojimas, patiriant maksimalų jo vairavimo komfortą, laikytinas mobilumo elektromobiliu siekiamybe.

Elektromobilio atitinkamam atstumui nuvažiuoti suvartojamos energijos kiekis priklauso nuo daugybės faktorių, ne tik nuo techninių elektrinio variklio ar baterijos savybių, tačiau ir nuo aplinkybių, kaip, pavyzdžiui, kelio atkarpos tipas, nuokalnės ar įkalnės kampas, oro temperatūra ir kitos sąlygos. Nustatant elektromobilio nuvažiuojamą atstumą, nediskutuotiną reikšmę turi vairavimo stilius ir vairuotojo įpročiai, kurių pagrindu konstruojamas vairuotojo profilis.

Egzistuojančių sprendimų ribotumas nesudaro sąlygų įvertinti ir nustatyti elektromobilio energijos suvartojimo atsižvelgiant į esminius, didžiausią įtaką energijos suvartojimui turinčius, parametrus bei individualaus vairuotojo profilį, kas ne tik leistų gauti didesnę praktinę reikšmę turinčius rezultatus, tačiau ir prisidėtų prie proveržio elektromobilių rinkoje.

Šio magistro baigiamojo darbo tikslas – nustatyti skirtingų parametrų įtaką elektromobilių energijos suvartojimui.

Šio darbo tikslui pasiekti keliami uždaviniai:

- 1) sumodeliuoti dinamiškai atsinaujinantį elektromobilio vairuotojo profilį;
- 2) pasiūlyti algoritmus įvertinti elektromobilio vairuotojo profilį bei pateikiamų žemėlapių ir profilio duomenų pagrindu prognozuoti optimalų kelią baterijos energijos suvartojimo aspektu;
- 3) sukurti programinius įrankius, renkančius bei apdorojančius duomenis;
- 4) išbandyti algoritmų veikimą praktikoje bandomųjų važiavimų elektromobiliu metu bei surinkti duomenų aibę;
- 5) įvertinti siūlomų sprendimų tikslumą bei pateikti eksperimentų metu padarytas išvadas.

Darbe identifikuojami esminiai kriterijai, lemiantys elektromobilio suvartojamą baterijos energijos kiekį atstumui nuvažiuoti ir vairuotojo profilį, bei pateikiami sukurti algoritmai, atsižvelgiantys į parametrų konstantas, surinktus duomenis, skaičiavimų rezultatus, o taip pat ir į kintančius

faktinius duomenis, kas leidžia pagal vertinamą vairuotojo profilį parinkti būtent jam optimalų kelią. Darbo metu atliktos analizės ir sukurtų algoritmų pagrindu, siūlomi algoritmų tobulinimo sprendimai, o galimų rezultatų vertinimui pasitelkti ne tik sintetiniai, bet ir realūs, šio darbo tikslui pasiekti sukurta programa *evApp* surinkti duomenys. Atlikus šiame darbe siūlomų sprendimų rezultatų analizę teoriniams skaičiavimams nustatytas minimalus taikytinų kriterijų sąrašas praplėstas pagal realių važiavimų metu nustatytus rezultatus ir trūkumus, atitinkamai peržiūrėti algoritmai, tokiu būdu sumažinta rezultatų paklaida. Tokiu būdu pasiūloma praktikoje pritaikoma priemonė elektromobilio suvartojamos baterijos energijos kiekio atitinkamam atstumui nuvažiuoti nustatymui. Tyrimo metu nustatyta, kaip elektromobilių techninės savybės, geometrinės segmentų savybės bei vairuotojo profilis įtakoja elektromobilio baterijos energijos suvartojimą pageidaujama keliui nuvažiuoti. Algoritmams testuoti ir duomenims rinkti buvo sukurta Android programėlė *evApp*, kuri siunčia duomenis į *evProjectServer* serverinę sistemos dalį, sukurta naudojant C# (.NET 6 core). Darbe buvo naudojamas OpenStreetMap žemėlapis, o duomenims valdyti buvo įdiegta PostgreSQL duomenų bazių valdymo sistema su PostGis plėtiniumi, kelio tinklo geometrijai apibrėžti.

Šio magistro baigiamojo darbo 1 skyriuje pateikiama šiam darbui rengti pasitelktos literatūros ir susijusių darbų analizė, 2 skyriuje aptariamos teorinės formulės ir pristatomi modeliai. Darbo 3 skyrius skirtas aptarti duomenų rinkimą ir apdorojimą, o 4 skyriuje aptariami atlikti eksperimentai ir apibendrinami bandymų metu gauti rezultatai. Paskutiniuosiuose skyriuose apibendrinamos išvados bei pateikiamos rekomendacijos.

Šiame darbe remiamasi mokslo tiriamuoju darbu „Elektromobilio pasiekiamos zonos skaičiavimas“, kuris buvo parengtas antrame magistro studijų semestru. Lyginant su mokslo tiriamuoju darbu, šiame darbe praplėsta susijusių darbų analizė, kelias modeliuojamas kaip segmentų seka, patobulintas prognozuojamas baterijos energijos suvartojimo keliui algoritmas, identifikuoti ir įtraukti papildomi parametrai į koeficiento nustatymo funkciją bei profilio atnaujinimo algoritmą. Rengiant šį darbą buvo pakeista programavimo aplinka, papildomai sukurta programėlė – *evApp* bei serverio programinė įranga – *evProjectServer*. Priešingai nei mokslo tiriamajame darbe, šiame darbe siūlomi algoritmai testuoti ir rezultatai vertinti pagal šiam darbui surinktus realius duomenis.

1. Literatūros analizė

Atsižvelgiant į tai, kad atvirose žemėlapių duomenų bazėse gausu duomenų, kurie yra pakankami grafo konstravimui, t. y., kelio segmentų tinklui sudaryti, susiformavo praktika maršrutus rengti ir kelius parinkti naudojant grafo struktūrą. Klasikinį grafa, nepriklausomai nuo to, ar maršrutas sudaromas vidaus degimo varikliu varomam automobiliui ar elektromobiliui, įprastai sudaro viršūnių sąrašo ir briaunų visumos duomenys [8]. Mokslininkai, atsižvelgdami į maršruto specifiką bei siekdami tikslesnių rezultatų, prie klasikinių grafo reikšmių ir duomenų, pagal poreikį, įtraukia papildomas reikšmes, pavyzdžiui, segmento svorį apibūdinančius kintamuosius, kaip segmento ilgis ir tipas, greičio ribojimai, kampas tarp briaunų, šviesoforų buvimas tarp briaunų galuose, paros laikas, piko ar ne piko metas [29].

Elektromobilio maršrutų planavimui rengiamas grafas gali pasižymėti tuo, jog grafo viršūnių sąrašas sudaromas iš elektromobilio įkrovimo vietų [6, 23] arba briaunoms priskiriamos savybės atsižvelgiant į vairuotojo vairavimo ypatumus ir greitį [7]. Atsižvelgiant į elektromobilio specifiką, nustatant jo pasiekiamą zoną su konkrečiu baterijos lygiu, be klasikinės grafo konstrukcijos papildomai įvedamos ir vertinamos sąnaudų keliui ir sąnaudų suvartojimo funkcijos [8].

Kelio parinkimo algoritmų bei jų modifikacijų šiandieninėje mokslinėje literatūroje gausu, tačiau klasikiniu pavyzdžiu trumpiausiam keliui sudaryti išlieka Dijkstra algoritmas, leidžiantis nustatyti kelio tinklo segmentus, kuriais kelionės tikslas pasiekiamas per trumpiausią laiką [11]. Konkretaus kelio modeliavimui, vadovaujantis gerąja praktika, pasitelkiami ir GPS duomenys [9].

Vienas iš literatūroje pateikiamų praktinę reikšmę turinčių pavyzdžių, kai atsižvelgiant į esamų sprendimų ribotumą, tačiau pasitelkiant formuojamą praktiką bei sprendimus, pasiūloma nauja koncepcija, yra Hibridinio mokymosi metodas (angl. Hybrid Learning). Pastarasis metodas paremtas Dijkstra algoritmo, regresijos ir konvoliucijos modelių sprendimų visuma, kuris įgalina atsitiktines kriterijų reikšmes, taip pat sprendžia vyravusios praktikos taikyti iš anksto nustatytus rodiklius trūkumus. Šis metodas taip pat atkreipia dėmesį į gretimų briaunų priklausomybę nuo sąnaudų, sudaro sąlygas atsižvelgti į apskaičiuotus tarpinius rezultatus, kartu užtikrindamas efektyvų perskaičiavimą kelio nukreipimo atveju [29].

Literatūroje pripažįstama, kad kelias elektromobiliui negali būti parenkamas pagal tuos pačius kriterijus, kaip ir vidaus degimo varikliu varomiems automobiliams, be to, elektromobilių atveju įprastai kalbama ne apie trumpiausią, o baterijos energijos suvartojimo aspektu optimalų [3], mažiausių energijos sąnaudų reikalaujantį kelią [7]. Tačiau pastebima, kad parenkant kelią elektromobiliui neretai pasitelkiamas jau paminėtas Dijkstra algoritmas su atitinkamomis modifikacijomis, pavyzdžiui apjungiamos algoritmo technikos – RangeDijkstra ir daugiasluoksnis Dijkstra. Akademinė bendruomenė atkreipia dėmesį, kad elektromobiliui pritaikytame algoritme energijos elementas negali tiesiog pakeisti įprasto kelionės laiko elemento [8]. Apibendrintai elektromobilių maršrutus galima skirstyti į dvi grupes: nuvažiuojamus be papildomų krovimų ir reikalaujančius tarpinių krovimų. Nepaisant besiplečiančio elektromobilių įkrovimo stotelių tinklo, technologinių greito krovimo galimybių, sprendimai, leidžiantys sumažinti tarpinių krovimų kiekį [22] arba nustatantys tarpinių krovimų trukmę optimaliam laikui kelyje išlaikyti [6, 32] yra itin aktualūs.

Maršruto elektromobiliui parinkimas, suvartojamos elektromobilio baterijos energijos prognozavimas tampa aktualesnis tiek dėl natūraliai didėjančio elektromobilių skaičiaus, tiek ir dėl poreikio prognozuoti bei optimizuoti sąnaudas keliaujant elektromobiliu. Kelio elektromobiliams parinkimo problematika mokslinėje literatūroje neišvengiamai analizuojama atsižvelgiant į baterijos energijos suvartojamumą, dažniausiai atkreipiant dėmesį į tris kriterijus – greitį, atstumą ir apkrovą [23].

Elektromobilio baterijos energijos suvartojimo prognozavimui neretai pasitelkiamas mašininis mokymasis (angl. Machine Learning). Mašininio mokymosi taikymas įvairiose mokslo srityse skirtingais tikslais įtakoja, kad iki šiol nėra visuotinai pripažinto, vieningo mašininio mokymosi apibrėžimo. Mašininis mokymasis gali būti apibrėžiamas kaip dirbtinio intelekto dalis, kompiuterių programavimas, pritaikomas siekiant optimizuoti našumą, pasitelkiant turimus duomenis ar ankstesne patirtimi. Teorijoje pateikiamos skirtingos galimos mašininio mokymosi rūšys, atsižvelgiant į tyrimo objektą, tikslą bei turimus duomenis, vienas aktualiausių ir labiausiai paplitusių vertinimo kriterijų elektromobilių atžvilgiu – baterijos energijos suvartojimas pagal greitį [30].

Surinktų istorinių duomenų pagrindu, pasitelkiant mašininio mokymosi ar kitus metodus literatūroje atliekamos prognozės ir tyrimai įvairiais pjūviais [4, 34]. Šiame darbe taip pat pasitelkiamas tiesinės regresijos mašininio mokymosi metodas, kuris gali pateikti preliminarias prognozes taip pat ir su sąlyginai nedideliu duomenų kiekiu. Tačiau egzistuojančiuose sprendimuose pasigendama strategijų, algoritmų ir tyrimų, orientuotų į individualų elektromobilio baterijos energijos suvartojimą. Įprastai algoritmai rengiami ir prognozės atliekamos pasitelkiant didelius, viešai prieinamus duomenų kiekius [30, 17], tačiau nesant galimybės patikrinti šiuos duomenis, įgyvendinant šiam darbui keliamus uždavinius, šiame darbe remiamasi darbo metu surinktais realiais skirtingų elektromobilių duomenimis, kurie leidžia pasiūlyti literatūroje pasigendamus vairuotojo profiliu ir elektromobilio specifiką paremtus algoritmus, įgalinančius prognozuoti konkretaus elektromobilio suvartojamą energijos kiekį pageidaujama atstumui nuvažiuoti.

Elektromobilio baterijos energijos suvartojimas didele dalimi priklauso nuo vairuotojo nulemtų aplinkybių, pavyzdžiui baterijos pakrovimo įpročių [18], pasirenkamo važiavimo greičio, kuris įtakoja energijos sąnaudas dėl elektromobilį veikiančių jėgų [32]. Tyrimai rodo, jog neproporcingą baterijos energijos suvartojimą gali lemti per didelis, tiek ir per mažas greitis, tuo tarpu optimalus greitis leidžia sumažinti energijos suvartojimo rodiklius bei bendras sąnaudas keliui [23]. Projektuojant algoritmus gali būti atsižvelgiama į eilę su vairuotojo profiliu susijusių rizikų ir pakenkimas, pavyzdžiui, saugus kelias įvertinus eismo įvykių statistiką, reguliavimą bei intensyvumą, oro sąlygas, vairuotojo kompetencijas ir vairavimo įpročius [2]. Sudarant vairuotojo profilį gali būti apdorojami vairavimo tolygumo, greičio viršijimo, kuris kelio parinkimo kontekste gali būti suprantamas kaip kelių eismo taisyklių pažeidimas, tiek ir kaip optimalaus greičio viršijimas, stabdymo ir/ar akseleravimo trukmės, staigių manevrų skaičiaus ir intensyvumas [14], agresyvus stabdymas ir/ar akseleravimas, staigūs posūkiai, persirikiavimas [1] ir kiti duomenys. Vairuotojo profilį lemia ir teigiamais įpročiais pasižyminti vairavimo praktika – optimalaus greičio pasirinkimas, tinkamo atstumo nuo kitų transporto priemonių sraute išlaikymas, o tai prisideda prie didesnio nuvažiuojamo atstumo bei efektyvaus baterijos energijos naudojimo [33].

Išskirtinė elektromobilio savybė – rekuperacija, tačiau kol kas nėra vieningos praktikos bei sutarimo dėl tokios energijos susigrąžinimo į elektromobilio bateriją funkcijos įtraukimo į algoritmus. Dalis mokslininkų teigia, kad rekuperacijos įtaka nėra reikšminga, todėl į ją neatsižvelgia [6], tuo tarpu kiti tam skiria atskirą dėmesį ir pripažįsta, kad energijos susigrąžinimas į elektromobilio bateriją algoritme negali būti laikomas konstanta, todėl nusakoma kaip baterijos lygio viršūnėje funkcija [8]. Šiame darbe siūlomi sprendimai atsižvelgia į elektromobilio rekuperacijos savybę.

Esama darbų, pateikiančių sprendimus nustatyti tikimybinės individualaus elektromobilio pasiekiamas teritorijas žemėlapyje [25], bet šiame darbe pateikiami tikslūs ir aktualūs individualizuoti elektromobilio nuvažiuojamo atstumo ir jam suvartojamos energijos nustatymo sprendimai.

Nepaisant literatūroje pateikiamų vairuotojo profilio sudarymo kriterijų ir sprendimų skaičiavimams gausos, pasigendama elektromobilių specifiką paremtų tyrimų, algoritmų bei išgrynintų kriterijų, kurie turi esminės įtakos prognozuojant elektromobilio nuvažiuojamą atstumą ir jam su-

vartojamą baterijos energijos kiekį, o į kuriuos vertėtų atsižvelgti nebent vertinant vairuotojo vairavimo įpročius ar potencialias rizikas. Šiame darbe pateikiami sprendimai unikalūs dėl išgrynintų kriterijų, turinčių esminės įtakos prognozuojant elektromobilio nuvažiuojamą atstumą ir suvartojamą elektromobilio baterijos energijos kiekį, bei jų įtraukimo į algoritmus. Pateikiami siūlymai dėl praktinio sprendimo apskaičiuoti individualiam vairuotojui reikalingą elektromobilio baterijos energijos kiekį pageidaujama atstumui nuvažiuoti, taigi prognozuojamos realios galimybės pasiekti maršruto tikslą arba atitinkamai planuoti kelionę.

2. Teoriniai modeliai

2.1. Teorinis elektromobilio suvartojamos energijos nustatymo modelis

Teoriniam elektromobilio suvartojamos energijos kiekiui nustatyti svarbu apsibrėžti elektromobilį veikiančias jėgas, kurios susidaro iš atitinkamų apibrėžtų konstantų ir kintamųjų. Teorinis elektromobilio suvartojamos energijos nustatymo modelis paremtas fizikinėmis savybėmis bei objektyviais duomenimis, nurodytais 1 lentelėje.

1 lentelė. Elektromobilio nuvažiuojamam atstumui apskaičiuoti reikalingų savybių lentelė


m	elektromobilio masė/svoris (kg)	
g	kritimo pagreitis ($9,8 \text{ m/s}^2$)	
μ	gumos (padangos) ir asfalto riedėjimo trinties koeficientas, kuris priklauso nuo oro sąlygų:	
	padanga ant sauso asfalto	0,50-0,7
	padanga ant šlapio asfalto (prieš akvaplanavimą)	0,35–0,45
	padanga ant sauso purvo ar žvyro dangos	0,4–0,5
	padanga ant šlapio purvo ar žvyro dangos (prieš akvaplanavimą)	0,3-0,4
	padanga ant lygaus ledo	0,15-0,25
C_x	oro pasipriešinimo koeficientas, kuris pateikiamas kiekvieno elektromobilio techninėje specifikacijoje	
A	priekinis elektromobilio plotas, kuris pateikiamas kiekvieno elektromobilio techninėje specifikacijoje	
ρ	oro tankis ($1,29 \text{ kg/m}^3$ normaliomis sąlygomis)	
ν	elektromobilio greitis (m/s)	
α	kelio nuolydis (kampas)	
B	elektromobilio baterijos talpa (Wh)	
β_{var}	elektros variklio koeficientas, šis parametras yra sąlyginis, kiekvienam elektros varikliui individualus, kuris kartais pateikiamas elektrinio variklio techninėje specifikacijoje	
β_{val}	valdiklių koeficientas, šis parametras yra sąlyginis, kiekvienas veikiantis valdiklis turi individualų elektros suvartojimo rodiklį	
β_{tr}	transmisijos koeficientas, šis parametras yra sąlyginis, kiekvienam elektromobiliui individualus	

Važiuojantį elektromobilį veikia traukos jėga (F_t), kuri traukia elektromobilį, ir pasipriešinimo jėgos, kurios jį stabdo – riedėjimo trinties jėga (F_{tr}) ir oro pasipriešinimo jėga (F_c) (žr. 1 pav.). Traukos jėga yra jėga, kuri veikia elektromobilį ir yra reikalinga jam judėti, ši jėga lygi trinties ir oro pasipriešinimo jėgų sumai (žr. 2.1 formulę).

$$F_t \geq F_{tr} + F_c \quad (2.1)$$

Riedėjimo trinties jėga (žr. 2.2 formulę) yra gumos (padangų) ir asfalto riedėjimo trinties koeficiento, elektromobilio masės ir kritimo pagreičio sandauga.

$$F_{tr} = \mu \cdot m \cdot g \quad (2.2)$$



1 pav. Elektromobilių veikiančios jėgos

Taip pat svarbu atsižvelgti į greičio horizontaliosios ir vertikaliosios dedamąsias. Riedėjimo trinties jėga lygi gumos (padangų) ir asfalto riedėjimo trinties koeficiento, elektromobilio masės, kritimo pagreičio ir segmento nuolydžio kampo kosinuso sandaugos ir elektromobilio masės, kritimo pagreičio ir segmento nuolydžio kampo sinuso sandaugos sumai (žr. 2.3 formulę).

$$F_{tr} = \mu \cdot m \cdot g \cdot \cos \alpha + g \cdot m \cdot \sin \alpha \quad (2.3)$$

Oro pasipriešinimo jėga lygi pusei oro pasipriešinimo koeficiento, priekinio elektromobilio ploto, oro tankio ir greičio, pakelto antruoju laipsniu, sandaugai (žr. 2.4 formulę).

$$F_c = \frac{C_x \cdot A \cdot \rho \cdot v^2}{2} \quad (2.4)$$

Pilna variklio traukos jėga lygi galutinei trinties ir oro pasipriešinimo jėgų sumai (žr. 2.5 formulę).

$$F_t \geq \mu \cdot m \cdot g \cdot \cos \alpha + g \cdot m \cdot \sin \alpha + \frac{C_x \cdot A \cdot \rho \cdot v^2}{2} \quad (2.5)$$

Elektromobilio baterijos talpos skaičiuojamas vatvalandėmis (Wh), todėl turi būti nustatyta galia, kurią reikia suvartoti, kad elektromobilis judėtų. Ši galia lygi veikiančios jėgos ir greičio sandaugai (žr. 2.6 formulę).

$$N = F \cdot v \quad (2.6)$$

Teoriškai būtų galima teigti, kad yra nustatyta variklio galia, kurios pakanka elektromobiliui judėti, tačiau (2.6 formulėje) neatsižvelgta į keletą esminių parametru: variklio efektyvumo koeficientą, valdiklio koeficientą, transmisijos koeficientą (sukimo perdavimo į ratus energija, mechaninis

praradimas). Šiuos parametrus galima sugrupuoti, jų reikšmes sudauginant, į bendrą parametą – bendrą elektromobilio energijos suvartojamumo koeficiento dydį (žr. 2.7 formulę). Kelionės metu šie parametrai įprastai nesikeičia.

$$\beta = \beta_{var} \cdot \beta_{val} \cdot \beta_{tr} \quad (2.7)$$

Nustatant teorinę galią (žr. 2.8 formulę) galima apskaičiuoti, kiek galios reikia elektromobiliui judėti atitinkamu greičiu. Tai yra variklio traukos jėga padauginta iš greičio ir bendro elektromobilio energijos suvartojamumo koeficiento dydžio.

Rezultatų objektyvumui esminę reikšmę turi geografinės kelio segmento savybės – segmento nuolydžio kampas, kuris įtakoja elektromobilio baterijos energijos suvartojimą ir galimybę susigrąžinti energiją (rekuperacija), kai elektromobilis paveiktas traukos jėgos įgauna energiją, kuri surenkama į tą pačią bateriją.

$$N_{var} = (\mu \cdot m \cdot g \cdot \cos \alpha + g \cdot m \cdot \sin \alpha + \frac{Cx \cdot A \cdot \rho \cdot v^2}{2}) \cdot v \cdot \beta \quad (2.8)$$

Žinant baterijos talpą galima nustatyti atstumą, kurį elektromobilis nuvažiuos. Šis atstumas lygus baterijos talpos ir reikalingos galios dalmeniui (žr. 2.9 formulę).

$$S = \frac{B}{N_{var}} \cdot v \quad (2.9)$$

Šiame skyriuje pristatytas teorinio elektromobilio suvartojamos energijos nustatymo modelis naudojamas kaip dedamoji vairuotojo profilio nustatymo algoritme (bus pateikiamas vėlesniuose skyriuose).

2.2. Kelio tinklo modeliavimas

Vadovaujantis vyraujančia praktika, šiame darbe kelio segmentų tinklas modeliuojamas kaip grafas $\mathcal{G} = (V, E)$, kur V yra viršūnių aibė, ir kiekviena $\forall v \in V$ atitinka viršūnę su geografinėmis savybėmis, o E yra briaunų aibė, kurioje kiekviena briauna yra 4-rinkinys $e = (u, v, geo, w) \in E$ ir atitinka kelio segmentą prasidedantį ir pasibaigiantį atitinkamai viršūnėse u ir v , kurios atitinka segmentų jungčių taškus, pavyzdžiui, sankryžas, kelio praplatėjimus, papildomų juostų atsiradimus. Taigi kelias yra apibrėžiamas kaip atitinkamų segmentų seka, kurią atitinka grafo briaunų seka.

1 apibrėžimas. Kelias K yra apibrėžiamas kaip briaunų seka $K = \langle e_1, \dots, e_n \rangle$, kur $\forall e_i, e_{i+1}, i < n : e_i.v = e_{i+1}.u$, o $e_1.u$ ir $e_n.v$ yra atitinkamai kelionės pradžia ir kelionės tikslas.

Šiame darbe briaunos apibrėžimas praplečiamas parametru geo , nes energijos skaičiavimams yra svarbios geografinės segmento savybės, pavyzdžiui, aukščio pokytis arba kelio vingiuotumas. Siekiant apskaičiuoti konkretaus elektromobilio energijos suvartojimą keliaujant segmentu pagal vairuotojo profilį, briaunos svorio w modelis turi būti praplečiamas papildomais parametrais – leistinu greičiu, ilgiu, segmento tipu ir kitais parametrais, įtakojančiais energijos suvartojimą.

2 apibrėžimas. Kelio segmento svoris $w = (t, v, l, \alpha)$ apibrėžiamas kaip segmento tipo t , maksimalaus greičio v , segmento ilgio l ir segmento kampo α parametrų rinkinys, kur $t \in \mathbb{TP}$, $v, l \in \mathbb{R}_{\geq 0}$, o α modeliuoja geometrinį segmento kampą; aibė \mathbb{TP} naudojama visiems įmanomiems segmento tipams nusakyti.

Kelių žemėlapiai pasižymi duomenų nepilnumu. Dalis duomenų gali būti papildyti, tačiau nesant galimybės papildyti nežinomųjų pilna apimtimi, atliekant skaičiavimus trūkstamos reikšmės pasitelkiamos iš prieš tai buvusių segmentų, pavyzdžiui, pasigedus konkretaus segmento duomenų dalies, šie užpildomi vadovaujantis prieš tai buvusio segmento duomenimis, darant prielaidą, kad tie segmentai atitinkamų svorių prasme yra panašūs.

3 apibrėžimas. Segmentus s ir s' laikysime panašiais, $s \cong s'$, jeigu sutampa segmento tipas su jau važiuotu segmento tipu.

2.2.1. GPS duomenų tikslumo problematika

Kelias gali būti modeliuojamas iš anksto nesuplanavus ir neidentifikavus segmentų sekos, atitinkamai vadovaujantis GPS duomenimis, arba vadovaujantis iš anksto suplanuota ir parinkta segmentų seka pagal žemėlapi.

Susijusiuose darbuose ir egzistuojančiose praktikose pripažįstama GPS duomenų tikslumo (angl. GPS Accuracy) problema, kuri analizuojama skirtinguose kontekstuose atskirais pjūviais. Dėl GPS duomenų tikslumo trūkumo praktikoje išimtinai GPS duomenimis paprastai nesiremiama. GPS tikslumo nuokrypis paprastai siejamas su palydovu, kurių pagalba nustatoma padėtis, signalų trikdžiais, šešėliavimu [31], GPS signalo atspindėjimu arba blokavimu, GPS ryšio praradimu, skirtingu duomenų atnaujinimo intensyvumu [13] ir kt.

Atsižvelgiant į GPS duomenų tikslumo problemą, sprendžiant GPS taškų išbarstymo klausimą, tikslesniam objekto buvimo vietos nustatymui ir atvaizdavimui susiformavo praktika naudojamame kelių žemėlapyje pritraukti GPS tašką prie geometriškai artimiausio segmento.

GPS duomenys leidžia nustatyti atstumą bei greitį, koku vairuotojas nuvažiavo atstumą tarp GPS taškų (žr. 1 algoritmą). Atstumo tarp GPS taškų nustatymui taip pat reikalinga priimta

matematinė vidutinė Žemės spindulio (angl. Earth Radius) reikšmė $R = 6,371$ km. Koordinačių ašių Φ ir λ išreiškiamos radianais (žr. 1 algoritmo 1-4 eilutes). Pagal formulę (žr. 1 algoritmo 5-7 eilutes) paskaičiuojamas ortodrominis atstumas. Nustačius atstumą tarp dviejų koordinačių, žinant laiką tam atstumui nuvažiuoti, gali būti nustatomas vidutinis greitis šiam atstumui nuvažiuoti (žr. 1 algoritmo 8 eilutę). Pateiktas skaičiavimas (žr. 1 algoritmą) leidžia nustatyti, kiek vairuotojas nutolo nuo iš anksčiau suplanuoto kelio, ir peržengus tam tikrą atstumo ribą gali būti inicijuota naujo kelio paieška nuo esamo taško.

Svarbu pažymėti, kad pateikiamas skaičiavimas galimas tik tuo atveju, jeigu GPS duomenys būtų idealūs ir neturėtų paklaidų bei nuokrypių. Turint idealius GPS duomenis vartotojas turėtų galimybę susikurti individualų kelių žemėlapi.

1 algoritmas. Atstumo ir greičio tarp taškų skaičiavimas

Ivestis: *Longitude1, Latitude1, DateTime1, Longitude2, Latitude2, DateTime2, R*

Išvestis: l, v

- 1: $\Phi_1 \leftarrow \text{Latitude1} \cdot \Pi/180$
 - 2: $\Phi_2 \leftarrow \text{Latitude2} \cdot \Pi/180$
 - 3: $\Delta\Phi \leftarrow (\text{Latitude2} - \text{Latitude1}) \cdot \Pi/180$
 - 4: $\Delta\lambda \leftarrow (\text{Longitude2} - \text{Longitude1}) \cdot \Pi/180$
 - 5: $a \leftarrow \sin(\Delta\Phi/2) \cdot \sin(\Delta\Phi/2) + \cos(\Phi_1) \cdot \cos(\Phi_2) \cdot \sin(\Delta\lambda/2) \cdot \sin(\Delta\lambda/2)$
 - 6: $c \leftarrow 2 * \text{atan2}(\sqrt{a}, \sqrt{1-a})$
 - 7: $l \leftarrow c \cdot R$
 - 8: $v \leftarrow l / (\text{DateTime2} - \text{DateTime1})$
 - 9: **return** l, v
-

2.2.2. Nuolydžio kampo skaičiavimas

Realūs GPS duomenys pateikia ir aukščio virš jūros lygio reikšmę, todėl turimų GPS duomenų pagrindu gali būti apskaičiuotas kampas tarp dviejų koordinačių. Atsižvelgiant į galimą GPS duomenų netikslumo problematiką, šiame darbe preziumuojama, kad gautų GPS duomenų pagrindu nustatyta aukščio virš jūros lygio reikšmė paklaidos neturi.

Šiame darbe siūlomiems energijos suvartojamumo skaičiavimams (kurie bus aptarti tolesniuose šio darbo skyriuose) reikalingas segmento nuolydžio kampas (žr. 2 algoritmą). Dviejų koordinačių aukščio virš jūros lygio skirtumas yra segmento aukštis. Iš segmento aukščio ir ilgio galima apskaičiuoti segmento kampą, kuris gali būti teigiamas (įkalnė), tiek ir neigiamas (nuokalnė).

2 algoritmas. Nuolydžio kampo skaičiavimas

Ivestis: *FirstAltitude, LastAltitude, SegmentLength*

Išvestis: α

- 1: $h \leftarrow \text{LastAltitude} - \text{FirstAltitude}$
 - 2: $\text{mycalcInRadians} \leftarrow \sin(h/\text{SegmentLength})$
 - 3: $\alpha \leftarrow \text{mycalcInRadians} \cdot 180/\Pi$
 - 4: **return** α
-

2.3. Vairuotojo profilio modelis

Teorinis elektromobilio suvartojamos baterijos energijos nustatymo modelis (žr. 2.1 skyriuje) įgalina atitinkamo elektromobilio suvartojamos energijos kiekio skaičiavimą. Lyginant apskaičiuotą kiekį su konkretaus vairuotojo esant tiems patiems pradiniais duomenimis suvartotu energijos kiekiu nustatoma reikšminga informacija, leidžianti prognozuoti konkrečiam vairuotojui reikalingą baterijos energijos kiekį atitinkamam atstumui nuvažiuoti.

Siekiant sukurti individualaus vairuotojo profilio valdymo algoritmą apibendrintai pasitelkiami dviejų kategorijų duomenys: objektyvūs, nepriklausantys nuo vairuotojo, bei individualūs, faktiniai duomenys, atspindintys vairuotojo vairavimo stilių bei kitus su aplinka susijusius duomenis.

Elektromobilio vairuotojo profilio kintamieji, į kuriuos atsižvelgiama sudarant algoritmą, yra segmento tipas, vairuotojo pasirenkamas ir maksimalus leistinas greitis segmente, bendras nuvažiuotas atstumas atitinkamam segmento tipu, laikas bei temperatūra.

Pažymėtina, kad literatūroje sutinkamas platesnis galimų kintamųjų, siejamų su vairuotoju, sąrašas, kuriuos būtų galima įtraukti į vairuotojo profilio funkciją, tačiau kitų kriterijų įtaka gali būti nežymi arba trumpalaikė, susijusi išimtinai su vienu iš segmentų, todėl perteklinių kintamųjų įtraukimas neleistų optimizuoti skaičiavimų bei galėtų iškreipti rezultatus.

4 apibrėžimas. Vairuotojo profilis apibrėžiamas kaip aibė P , sudaryta iš sudėtinių elementų $p = (t, l, k, ti, te)$, $t \in \mathbb{TP}$, $l \in \mathbb{R}$, $k \in \mathbb{R}$, kur t yra segmento tipas, l yra bendras atstumas tokiam segmento tipe, k – elektromobilio vairuotojo profilio reikšmė, $ti \in \mathbb{T}$ yra laikas, o te yra temperatūra. Šiame darbe parametras k laikomas santykiu tarp teorinio suvartojamo baterijos energijos kiekio ir faktiškai konkretaus elektromobilio vairuotojo suvartojamo baterijos energijos kiekio. Aibės P elementai nuolat atnaujinami vairuotojui keliaujant, pagal kelyje esančius segmentus (jų tipus), laiką ti ir temperatūrą te . Visų vairuotojų profilių aibė yra žymima \mathbb{P} .

Baterijos energija, kuri bus suvartota atitinkamame segmente, apskaičiuojama pagal $e.cost_{(v,\alpha,l)}$ (žr. 2.10 formulę), kuri gaunama iš jau aptartos išsamios teorinės galios apskaičiavimo formulės (žr. 2.8 formulę) ją padauginus iš atstumo ir greičio tame segmente dalmens. Ši formulė gali būti išreikšta kaip funkcija, priklausanti nuo segmento svorio parametrų – greičio v , segmento kampo α (žr. 2 algoritmą), segmento ilgio l . Visi likę parametrai yra pradinės konstantos, kurios nekinta.

$$e.cost_{(v,\alpha,l)} = (\mu \cdot m \cdot g \cdot \cos \alpha + g \cdot m \cdot \sin \alpha + \frac{Cx \cdot A \cdot \rho \cdot v^2}{2}) \cdot v \cdot \beta \cdot \frac{l}{v} \quad (2.10)$$

Siekiant didesnio rezultatų tikslumo, vertėtų vertinti taip pat ir elektromobilio variklio technines savybes, kurios neginčijamai turi įtakos suvartojamam baterijos energijos kiekiui. Elektromobilių variklių sąnaudų ir galios diapazonai yra skirtingi. Optimalus variklių sąnaudų rodiklis (toliau – OVSR) atitinkamame greityje pateikiamas automobilio techninėje specifikacijoje. Energijos suvartojimo aspektu geriausia, kai yra nedidelis, arba nulinis nuokrypis nuo OVSR.

Panaudojant $e.cost_{(v,\alpha,l)}$ gali būti nustatomas tiek teorinis, tiek ir faktinis energijos suvartojamumo rodiklis. Gautų reikšmių dalmuo yra koeficientas – rodiklis, kuris parodo vairuotojo energijos suvartojamumo polinkį segmente. OVSR yra teorinio ir faktinio energijos suvartojamumo dalmuo. Vairuotojo profilio koeficientas lygus vairuotojo energijos suvartojamumo polinkio segmente koeficiento ir elektromobilio OVSR koeficiento reikšmių sandaugai (žr. 2.11 formulę). Šiame darbe OVSR reikšmės sutampa, todėl į šį rodiklį atliekamuose skaičiavimuose nėra neatsižvelgiama, nes atitinkami duomenys nėra viešai prieinami.

$$k_{(v,\alpha,l,v_{ave})} = \frac{e.cost_{(v,\alpha,l)}}{e.cost_{(v_{ave},\alpha,l)}} \cdot \frac{OVSR_v}{OVSR_{v_{ave}}} \quad (2.11)$$

Vairuotojo profilio aibė P yra kintanti, kaip ir jos elementai, jos kitimas priklauso nuo konkretaus vairuotojo bendro nuvažiuoto atstumo atitinkamame segmento tipe, kitimo algoritmas yra aprašytas profilio atnaujinimo algoritme (žr. 3 algoritmą). Algoritmo įvestis v_{ave} yra vidutinis vairuotojo greitis segmente, e yra briauna, P yra vairuotojo profilio p elementų aibė. Jeigu vairuotojas jau važiavo tokiu segmento tipu, tokiu laiku ir tokioje temperatūroje, randamas P aibės atitinkamas elementas p , taip padidinama elemento $p.l$ reikšmė (žr. 3 algoritmo 4 eilutę) ir atnaujinama elemento $p.k$ reikšmė (žr. 3 algoritmo 3 eilutę). Jeigu nerandamas vairuotojo profilio aibėje toks kelio tipas, laikas, temperatūra, tai apskaičiuojamas koeficientas tam segmento tipui, laikui, temperatūrai ir pridedamas naujas elementas aibei P .

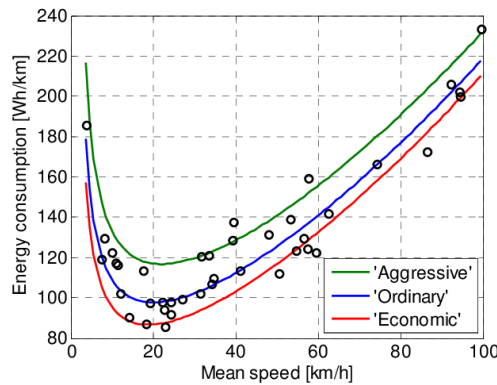
3 algoritmas. Profilio atnaujinimo algoritmas

Įvestis: $v_{ave} \in \mathbb{R}$, $e \in E$ where $e = (u, v, w(t, v, l, \alpha))$, $P \in \mathbb{P}$, $temp \in \mathbb{R}$, $time \in \mathbb{T}$,

- 1: **for all** $p \in P$: $p.te = temp \wedge p.ti = time$ **do**
 - 2: **if** $e.w(t) = p(t)$ **then**
 - 3: $p.k \leftarrow (p.k \cdot p.l + k(v, \alpha, l, v_{ave}) \cdot e.w(l)) / (p.l + e.w(l))$
 - 4: $p.l \leftarrow p.l + e.w(l)$
 - 5: **return**
 - 6: **end if**
 - 7: **end for**
 - 8: $P \leftarrow P \cup (e.w(t), e.w(l), k_{v,\alpha,l,v_{ave}}, time, temp)$
-

2.3.1. Greitis

Elektromobilio vairuotojo pasirinktas greitis turi tiesioginę įtaką galimam nuvažiuoti atstumui, nes kuo greičiau vairuotojas nuvažiuoja tą patį segmentą, tuo daugiau baterijos energijos elektromobilis suvartoja tokiam pat atstumui įveikti. Atitinkamai važiuojant optimaliu greičiu suvartojama sąlyginiai mažiau baterijos energijos. Pateiktos kreivės (žr. 2 pav.) atspindi energijos suvartojimą pagal greitį.



2 pav. Vairuotojo agresyvios vairavimo manieros įtaka energijos sąnaudoms [5]

Vertinant elektromobilių energijos vartojimo veiksnius, vairavimo sąlygas, pagalbinių įrenginių naudojimą, vairuotojo agresyvumą teorijoje pateikiamos analizių kreivės atspindinčios vairuotojo vairavimo manieras, energijos suvartojamumo (angl. Energy Consumption) priklausomybę nuo greičio (angl. Mean Speed) [5]. Kreivės yra parabolės tipo, nes pajudant elektromobilis suvartoja daugiau energijos, nei greičiui palaikyti. Taip pat pažymėtina, kad didžiausią skirtumą energijos suvartojimo aspektu agresyvus važiavimas turi pajudant ir iki pasiekiant ~ 20 km/h greitį, išvysčius didesnę greitį skirtumas tarp energijos suvartojimo nepriklausomai nuo vairuotojo vairavimo manieros mažėja.

Egzistuojančiuose modeliuose, atsižvelgiant į tikslus ir taikomų nuvažiuojamo atstumo nustatymo modelių principus, siūlomos įvairios greičio profilio alternatyvos: maksimalaus leistino greičio, nes šis duomuo yra objektyvus ir įprastai žinomas; turint istorinius duomenis, vidutinis segmentu važiuotas greitis, nepriklausomai nuo to, kada buvo važiuojama atitinkamu segmentu; vidutinis segmentu važiuotas greitis, vertinant važiavimus nustatytu laiku ar periodu; idealusis, atitinkantis realius duomenis [30].

Šiame darbe siūlomas algoritmas (žr. 3 algoritmą) atsižvelgia į maksimalų leistiną bei faktinį – konkretaus vairuotojo pasirinktą greitį. Teorinis ir faktinis energijos suvartojamumo rodikliai nustatomi atsižvelgiant į greitį. Teorinio įverčio atveju atsižvelgiama į maksimalų leistiną greitį, o faktinio – konkretaus vairuotojo pasirinktą greitį, kartu vertinant ir kelio segmento nuolydžio kampo laipsnį. Teorinio energijos rodiklio nustatymo atveju daroma prielaida, kad greitis v yra žinomas segmentui e , $w(v)$ ir tai yra maksimalus tam segmentui leistinas greitis, nes tai objektyvus ir optimalus greitis laiko aspektu, nepaisant to, kad elektromobilis sunaudoja didesnę energijos kiekį, nei važiuojant mažesniu greičiu.

2.3.2. Paros laikas


Paros laikas elektromobilio suvartojamam baterijos energijos kiekiui gali turėti įtakos dėl skirtingų priežasčių, pavyzdžiui, vairuotojo vairavimo stiliaus esant atitinkamam paros laikui dėl fiziologinių ar kitų priežasčių, geresnio ar prastesnio matomumo ir kt., tačiau eismo intensyvumas atitinkamam paros metu, piko ar ne piko metu, turi didžiausią įtaką energijos suvartojamumui.

Didesnis elektromobilio baterijos energijos suvartojimas atitinkamam paros laiku iš esmės įtakojamas dažnesnių sustojimų ir pajudėjimų iš vietos dėl didesnės automobilių koncentracijos bei šviesoforais reguliuojamo eismo [24], ilgesnio laiko važiuojant iki 20 km/h, kai energijos suvartojimas yra didelis (žr. 2 pav.), pastovaus greičio neišlaikymo, papildomo manevravimo ir kt.


Apibendrintai, intensyviausias eismas fiksuojamas darbo dienomis nuo 7 val iki 9 val bei nuo 15 val iki 17 val, mažiausias eismo intensyvumas fiksuojamas darbo dienomis nuo 22 val iki 6 val. Savaitgaliais taip pat galima išskirti intensyvesnio eismo paroje intervalus, tačiau šie nėra tokie žymūs, kaip darbo dienomis, todėl esminės įtakos elektromobilio suvartojamam baterijos energijos kiekiui įprastai neturi (žr. 3 pav.).

Siekiant tikslumo, vertėtų pažymėti, kad skirtingose šalyse ar miestuose, atsižvelgiant į didesnę gyventojų tankumą ar specifinį gyvenimo stilių, aptarti išsaugusio eismo intensyvumo intervalai gali skirtis, be to, vertinant eismo intensyvumą išimtinai vasaros metu, duomenys taip pat gali skirtis, tačiau apibendrintų tendencijų nustatymui ir išvadų pateikimui atsižvelgiama į bendrą principą.

Atlikti moksliniai tyrimai atskleidžia, kad esant intensyviai eismui kelyje elektromobilio baterijos energijos suvartojimas gali padidėti apie 4,5% (žr. 4 pav.).



3 pav. Segmentų pravažiavimų skaičiaus pasiskirstymas skirtingu paros laiku darbo dienomis ir savaitgaliais [30]



4 pav. Vidutinis energijos suvartojimas pagal eismo intensyvumą [15]

2.3.3. Temperatūra

Tyrimai atskleidžia, kad oro temperatūra gali turėti žymios įtakos elektromobilio suvartojamam energijos kiekiui, taigi tiesiogiai lemti galimą nuvažiuoti atstumą. Šaltiniuose pateikiama, kad maksimalus energijos suvartojimas pasiekiamas esant -30°C , o minimalus 23°C [19].

Atsižvelgiant į galimą žymią temperatūros įtaką suvartojamam elektromobilio baterijos energijos kiekiui, į vairuotojo profilio atnaujinimo algoritmą (žr. 3 algoritmą) įtraukta papildoma reikšmė - temperatūra, vertinama realiuoju laiku atitinkamame mieste, kuriame yra vairuojamas elektromobilis.

Pažymėtina, kad temperatūra turi įtakos elektromobilio baterijos energijos praradimui tiek elektromobiliui važiuojant, tiek ir stovint. Priklausomai nuo lauko temperatūros, elektromobilio baterija vidutiniškai praranda nuo 3% iki 8%. Tačiau atsižvelgiant į tai, kad objektyviai įvertinti ir apibendrinti, kiek baterijos energijos prarandama stovint, negalima, į aptariamą baterijos energijos praradimą elektromobiliui stovint, šiame darbe neatsižvelgiama.

2.4. Mašininio mokymosi teorinis panaudojimas

Mašininis mokymasis yra kompleksinis procesas, todėl jo įgalinimui ir rezultatų gavimui svarbu surinkti ir pateikti tinkamus duomenis, nustatyti duomenis, į kuriuos turi būti atsižvelgiama, bei juos prioretizuoti, siekiamų tikslų pasiekimui svarbu parinkti tinkamą mašininio mokymosi metodą bei jį apmokyti.

Šiame darbe modelio apmokymui paduodami automobilio techniniai parametrai, nurodyti 1 lentelėje, teorinio elektromobilio suvartojamos energijos nustatymo modelio pagalba gauti rezultatai bei segmento kampo duomenys (kaip aptarta 2.2.2 dalyje).

Turint didelį duomenų kiekį galima apmokyti modelį ir pasitelkti jį optimizuojant tolesnius skaičiavimus. Šiame darbe taikomas tiesinės regresijos modelis (žr. 2.12), kuris leidžia vieno kintamojo reikšmę prognozuoti atsižvelgiant į kitų kintamųjų reikšmes (žr. 2.13). Apmokytam modeliui pateikiamas pageidaujamas nuvažiuoti segmentas, ir šis pateikia rezultata, kiek teoriškai elektromobilis suvartos baterijos energijos šiam segmentui nuvažiuoti. Tokiu būdu optimizuojami resursai bei laikas rezultatui gauti.

Tiesinės regresijos modelis:

$$mle.cost^{(i)} = a_1 \cdot l^{(i)} + a_2 \cdot \alpha^{(i)} + a_3 \cdot car_{(m,A,B,\beta_{var},\beta_{val},\beta_{tr})}^{(i)} + b \quad (2.12)$$

Tiesinės regresijos funkcija:

$$L_{rege} = \frac{1}{n} \sum_{i=1}^n (e.cost_{(v,\alpha,l)}^{(i)} - mle.cost^{(i)})^2 \quad (2.13)$$

Koeficientų a_1 , a_2 , a_3 , b reikšmių radimas minimizuojant funkciją (žr. 2.13) yra tiesinės regresijos tikslas. car yra elektromobilio sudėtinis parametras, susidedantis iš techninių automobilio reikšmių.

Aptariamo mašininio mokymosi problematika susijusi su jo apmokymu, kuriam būtinas didelis tikslų duomenų kiekis. Nepakankamas ar netikslų duomenų padavimas gali iškreipti prognozes ir rezultatus. Darbo tikslo pasiekimui pirminiai duomenys surinkti ir jų pagrindu skaičiavimai atlikti naudojant anksčiau apibrėžtą teorinio elektromobilio suvartojamos energijos apskaičiavimo formulę.

2.5. Prognozavimas

2.5.1. Prognozuojamas baterijos energijos suvartojimas

Siekiant pasiūlyti algoritmą, kuris nustatytų kelią, kuriuo būtų sunaudojama mažiausiai elektromobilio baterijos energijos, laikytina, kad rekursyvi prognozuojamos baterijos energijos suvartojimo funkcija $PBES : E \times E \times \mathbb{E}^* \times \mathbb{R}^* \times \mathbb{P} \rightarrow \mathbb{E}^* \times \mathbb{R}^*$ gražina kelią nuo pradžios taško iki kelionės tikslo optimalaus energijos naudojimo atžvilgiu, o kartu gražina ir energijos suvartojamųjų aibę (žr. 4 algoritmą), kuri atitinka grafo briaunų (kelio segmentų) seką. Viso keliui $K \in E^*$ suvartojamos energijos kiekio apskaičiavimui reikėtų sudėti gautą energijos suvartojamųjų aibę, keliaujant konkrečiu elektromobiliu, ir naudojant nurodytą vairuotojo profilį. Energijos, suvartojamos segmentui, reikšmė bus neigiama, jei keliaujant segmentu energija ne vartojama, o generuojama dėl kelio savybių (rekuperacija).

Kelias visada talpina pradinę viršūnę, tai lyg atskaitos taškas. Algoritmo įvestis *source* yra pirmojo nustatyto segmento reikšmė, *dest* yra paskutiniojo nustatyto segmento reikšmė, pirmą kartą kviečiant *Patch* ir *co* reikšmės yra tuščios (\perp), tačiau rekursyviai kviečiant kituose lygmenyse, jų

4 algoritmas. Prognozuojamas baterijos energijos suvartojimas keliui

Ivestis: $source, dest, Patch, co, P \in \mathbb{P}$

Išvestis: $Patch \in \mathbb{K}, co \in \mathbb{R} \quad co \leftarrow \perp \in \mathbb{R}$

```
1: Let  $BPatch \leftarrow \perp, Bco \leftarrow \perp$ 
2: if  $Patch = \perp$  then
3:    $co = 0$ 
4: else
5:    $Patch.add(source)$ 
6:   if  $source.v = dest.u$  then
7:     return  $(Patch, co)$ 
8:   else
9:     if  $dest \in E$  then
10:       $Patch.add(dest)$ 
11:       $co.add(dest.cost \cdot P(dest))$ 
12:      return  $Patch, co$ 
13:     else
14:       for  $e \in E$  do
15:         if  $e \notin Patch$  then
16:            $co.add(e.cost \cdot P(e))$ 
17:            $NPatch, Nco \leftarrow PBES_{(e, dest, Patch, co)}$ 
18:           if  $NPatch$  then
19:             if not  $BPatch$  or  $\sum Nco < \sum co$  &  $\sum Nco < \sum Bco$  then
20:                $BPatch \leftarrow NPatch$ 
21:                $Bco \leftarrow Nco$ 
22:             else
23:                $Patch.pop()$ 
24:                $co.pop()$ 
25:               return  $BPatch, Bco$ 
26:             end if
27:           end if
28:         else
29:           return  $Patch, co$ 
30:         end if
31:       end for
32:     end if
33:   end if
34: end if
35: return  $BPatch, Bco$ 
```

reikšmė yra apibrėžta. Jeigu briaunos viršūnė yra tikslas, funkcija grąžina segmentų seką, šiuo atveju tik pradinį segmentą ir jo energijos suvartojamumą $co = 0$. Jeigu viršūnė, kurioje algoritmas turi briauną, su kuria galima pasiekti tikslą, tai grąžina segmentų seką ir energijos suvartojamumo aibę. Jeigu viršūnė neturi briaunų, kuriomis galima pasiekti tikslą, tikrinama kiekviena briauna, jeigu jos atžvilgiu iki šiol nebuvo atlikti skaičiavimai (žr. 4 algoritmo 15 eilutę) nuo suvartojančios mažiausiai energijos, taip daroma prielaida, kad briauna, kuri suvartoja mažiausiai energijos yra tinkamesnė analizuoti toliau. Funkcija yra rekursyvi (žr. 4 algoritmo 17 eilutę), todėl tikrinama briauna tampa įvesties reikšme ir paduodama į tą pačią funkciją, patikrinamos visos briaunos ir palyginama (žr. 4 algoritmo 19 eilutę), ar energijos suvartojamumo prasme pasirinkta briauna yra efektyvesnės pasiekiant tikslą. Jeigu suvartojama mažiau energijos pasiekiant tikslą negu prieš tai pasirinktas geriausias kelias, tai priskiriama $BPatch$ ir Bco kaip geriausias rezultatas, kitu atveju pašalinami paskutiniai elementai: briaunos iš $Patch$ ir reikšmė iš co , bei grąžinamos geriausios reikšmės $BPatch$ ir Bco .

Šiame algoritme atsižvelgiama į vairuotojo profilį ir parenkamas optimalus kelias individualiam elektromobilio vairuotojui pagal jo profilio koeficientą.

2.5.2. Dijkstra algoritmas

5 algoritmas. Klasikinis Dijkstra algoritmas

Įvestis: $\mathcal{G} = (V, E)$, $s \in V$

Išvestis: Optimalus kelias nuo s iki \mathcal{G} viršūnės

```

1: for all  $v \in V$  do
2:    $distance[v] \leftarrow +\infty$   $\triangleright$  Nustatomas atstumas iki visų viršūnių
3:    $previous[v] \leftarrow \perp$   $\triangleright$  Ankstesnė viršūnė nustatoma kaip neapibrėžta
4: end for
5:  $distance[s] \leftarrow 0$ 
6:  $K \leftarrow \emptyset$ 
7:  $Q \leftarrow V$   $\triangleright$   $Q$  priskiriamos visos grafo viršūnės
8: while  $|Q| > 0$  do
9:    $u \leftarrow Extract_{Min}(Q)$   $\triangleright$  Pasirenkama minimalų bendrą svorį turinti viršūnė
10:   $K \leftarrow K \cup \{u\}$ 
11:  for all briauna  $e_{(u,v)}$  išeinanti iš  $u$  do
12:    if  $distance[u] + e_{(u,v)}.w < distance[v]$  then
13:       $distance[v] \leftarrow distance[u] + e_{(u,v)}.w$   $\triangleright$  Briaunos svoris – energijos sunaudojimas
14:       $previous[v] \leftarrow u$ 
15:    end if
16:  end for
17: end while  $\triangleright$  Kol  $Q$  nėra tuščias masyvas
18: return  $K$ 

```

Klasikiniu pavyzdžiu trumpiausiam keliui nustatyti laikomas Dijkstra algoritmas (žr. 5 algoritmą), leidžiantis nustatyti kelio tinklo segmentų seką, kuria kelionės tikslas pasiekiamas per trumpiausią laiką. Šis algoritmas, leidžiantis nustatyti trumpiausią kelią grafe nuo vienos viršūnės iki kitų, yra plačiai taikomas planuojant maršrutus kelių žemėlapiuose, kuriuose kelio segmentai modeliuojami kaip grafo briaunos.

Grafe / žemėlapyje žinomas kiekvienos briaunos / segmento svoris – ilgis. Šio darbo uždavinių įgyvendinimui energijos kiekis, reikalingas segmentui nuvažiuoti laikomas parametru, pagal kurį ieškomas optimalus kelias elektromobiliui.

Vertinant praktiniu pritaikomumo aspektu, Dijkstra algoritmas tinkamiausias, kai visi svoriai yra pastovūs ir nekintantys, tačiau šio darbo kontekste, kiekvienas briaunos svoris kaskart kinta, todėl prieš taikant šį algoritmą būtina paruošti duomenis, t. y., perskaičiuoti visų segmentų svorius, arba, optimizuojant laiką ir resursus, greitesniam duomenų užpildymui pasitelkti mašininį mokymąsi.

Dijkstra algoritmo įvestis yra paruoštas grafas su atitinkamais briaunų svoriais ir s – viršūne, nuo kurios yra skaičiuojami atstumai iki kitų viršūnių.

3. Testavimo aplinkos paruošimas ir duomenų rinkimas

3.1. Duomenų bazės paruošimas

Šiame darbe maršrutų sudarymas, analizė ir parinkimas įgyvendinami naudojant atvirosius žemėlapių duomenis iš OpenStreetMap (OSM) duomenų bazės [26]. Funkcionalumui įgyvendinti ir testams atlikti kelių žemėlapių duomenys buvo importuoti į reliacinę PostgreSQL duomenų bazių valdymo sistemą. Šio darbo tikslais atliekamiems eksperimentams vykdyti buvo importuotas tik Lietuvos kelių žemėlapis, nes atliekant darbą buvo renkami kelionių elektromobiliu Lietuvoje duomenys.

Importuotas žemėlapis turi geometrijos duomenų tipą, šiam duomenų tipui saugoti reikalingas *PostGIS* plėtinys. Geografiniams duomenims naudojama EPSG:4326 (WGS84) projekcija tai yra pasaulinė geodezinė sistema, priimta 1984 metais, naudojama GPS imtuvuose iki šiol. Kai kurios programinės įrangos šį duomenų tipą automatiškai konvertuoja į JSON formatą išsaugant geometrijos atributus.

Nepaisant to, kad pasirinktas turimų duomenų požiūriu gausiausias OSM kelių žemėlapis, jo duomenys nėra pakankami darbo tikslui pasiekti, pavyzdžiui, trūksta maksimalaus leistino greičio bei segmento tipo parametrų. Taip pat importuotas ir konvertuotas į grafą kelių žemėlapis neturėjo unikalios identifikatoriaus, o kai kurioms briaunoms trūko svorio parametrų. Taigi OSM žemėlapis buvo papildytas trūkstamais parametrais, pavyzdžiui, pridėtas naujas atributas unikaliam kiekvieno segmento identifikavimui. Skaičiavimų metu trūkstamos svorio reikšmės parenkamos iš prieš tai buvusio segmento, darant prielaidą, kad tie segmentai atitinkamų svorių prasme panašūs (žr. 3 apibrėžimą).

Teoriniam nuvažiuoto atstumo energijos sunaudojimo ir vairuotojo profilio koeficiento nustatymui reikalingi techniniai automobilių duomenys bei GPS duomenys testavimui. Individualūs techniniai automobilių duomenys (žr. 1 lentelę) buvo paimti iš viešųjų šaltinių [10, 12], o GPS duomenys tyrimams buvo surinkti naudojant šio darbo metu sukurtą mobilią programėlę *evApp*, kuri aprašoma kitame skyriuje.

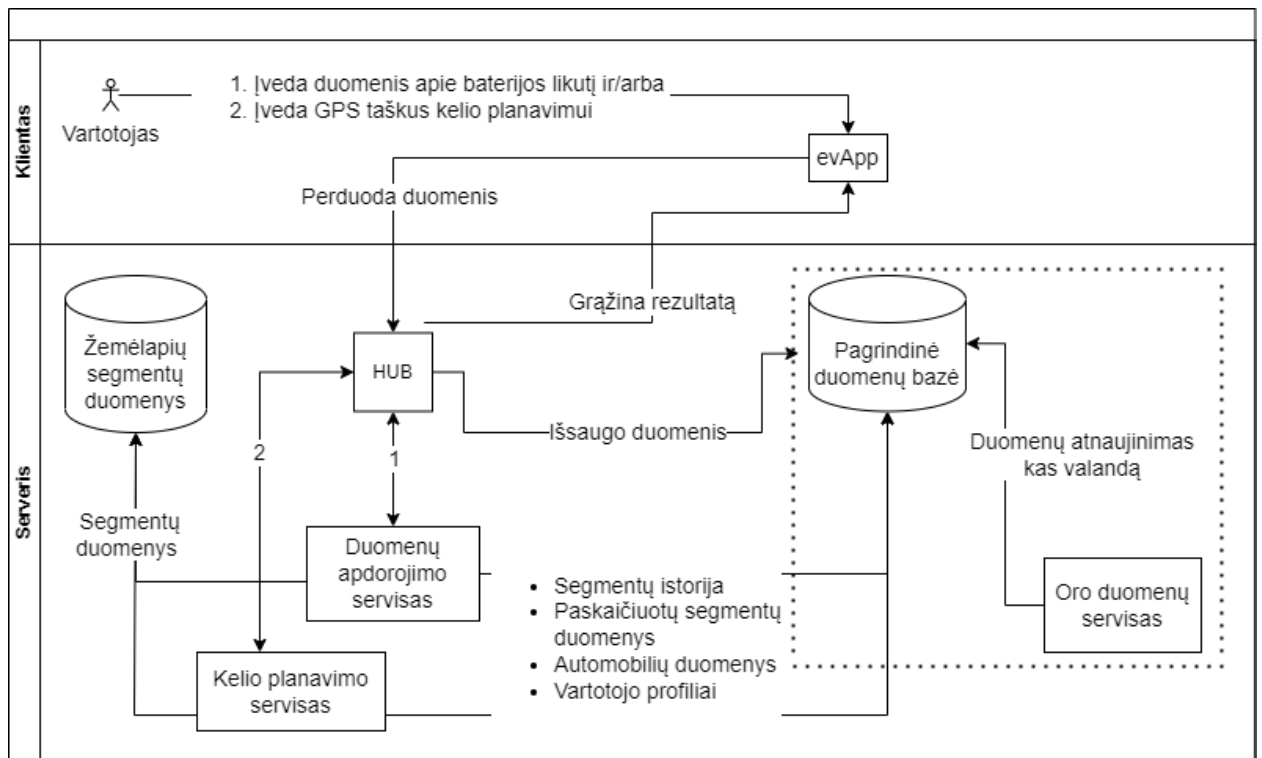
3.2. Mobilioji duomenų rinkimo programėlė *evApp*

Siekiant pademonstruoti šiame darbe siūlomo vartotojo profilio nustatymo algoritmo pritaikymą praktikoje ir patikrinti algoritmo atliekamų skaičiavimų tikslumą, darbo metu buvo sukurta mobilioji Android programėlė *evApp*, įgalinusi duomenų rinkimą kelionių elektromobiliu metu.

Pradinis duomenų rinkimas vykdytas virtualioje aplinkoje. Tačiau atsižvelgiant į virtualioje aplinkoje vykdytų bandomųjų važiavimų metu surinktų sintetinių duomenų ribotumą, siekiant nustatyti šiame darbe siūlomų algoritmų tikslumą ir pritaikomumą praktikoje, tyrimai tęsti realių važiavimų metu surinktų duomenų pagrindu (žr. 5 pav.).

Siekiant surinkti kuo daugiau skirtingų duomenų *evApp* sudaryta galimybė registruotis ir sukurti individualius profilius neribotam vartotojų skaičiui. Registracijos metu pateikiami duomenys: vardas, elektroninio pašto adresas, slaptažodis (pastarasis duomenų bazėje saugomas šifruotu pavidalu). Šiuo metu *evApp* turi 5 aktyvius vartotojus. Sukūrus profilį duomenų bazėje vartotojui yra suteikiamas unikalios identifikavimo numeris. Vartotojai yra identifikuojami pagal registracijos metu nurodytą elektroninio pašto adresą ir slaptažodį.

evApp veikimui užtikrinti papildomai sukurta serverio programinė įranga *evProjectServer* bei PostgreSQL duomenų bazė, kuri aprašoma kitame skyriuje. *evApp* tiesioginės sąsajos su duomenų



5 pav. Supaprastinta duomenų srauto diagrama

baze neturi, visos užklauskos apdorojamos per serverio programinę įrangą. Vartotojo identifikacijai *evApp* siunčia užklauską į serverio programinę įrangą ir ją patvirtinus leidžiama prisijungti prie *evApp*, vairuotojui pateikiami galimi elektromobilio modelio pasirinkimai. Šiuo metu *evApp* leidžia pasirinkti iš trijų elektromobilių tipų: Fiat 500, BMW i3 ir Chevrolet Volt.

Vartotojui patvirtinus baterijos likutinę vertę, išreikštą procentais, prisijungimo prie *evApp* metu užmezgama nepertraukiama sesija. Iš *evApp* gauti vartotojo duomenys duomenų bazėje saugomi pagal atitinkamam vartotojui suteiktą individualų identifikavimo numerį. Duomenys iš *evApp* perduodami ir apdorojami realiuoju laiku. Dėl tinklo trukdžių sesijai nutrūkus, *evApp* nepertraukiamai bando užmegzti naują sesiją su serverio programine įranga tol, kol neužmezgama nauja sesija. Nutrūkus sesijai duomenys kaupiami *evApp*, o užmezgus sesiją visi duomenys perduodami į *evProjectServer*. Kiekviena sesija turi individualų identifikavimo numerį, po nutrūkusios sesijos naujai užmegztai sesijai priskiriamas naujas identifikavimo numeris.

Android operacinės sistemos įrenginio sąsajos su *evApp* metu gaunami GPS modulio duomenys (naudojant Android prieinamas bibliotekas): ilguma, platumas, aukštis virš jūros lygio, greitis ir kita. Surinkti duomenys apdorojami serverio programinėje įrangoje ir saugomi duomenų bazėje. Apdorojus duomenis serverio programinė įranga siunčia informaciją *evApp* apie sunaudotą baterijos energijos kiekį pravažiuotam segmentui.

Siekiant gauti tikslesnius duomenis, *evApp* į Android programinės įrangos programavimo sąsają (angl. Application Programming Interface, API) dėl GPS duomenų atnaujinimo turėtų kreiptis kas 1 sekundę, tačiau dėl taikomų ribojimų duomenų rezultatas nėra pateikiamas pageidaujama dažnumu, todėl algoritme numatyta, kad užklausa naujų duomenų pateikimui siunčiama tik gavus GPS duomenis. Iki šiol *evApp* į serverio programinę įrangą perdavė virš 127 000 GPS taškų.

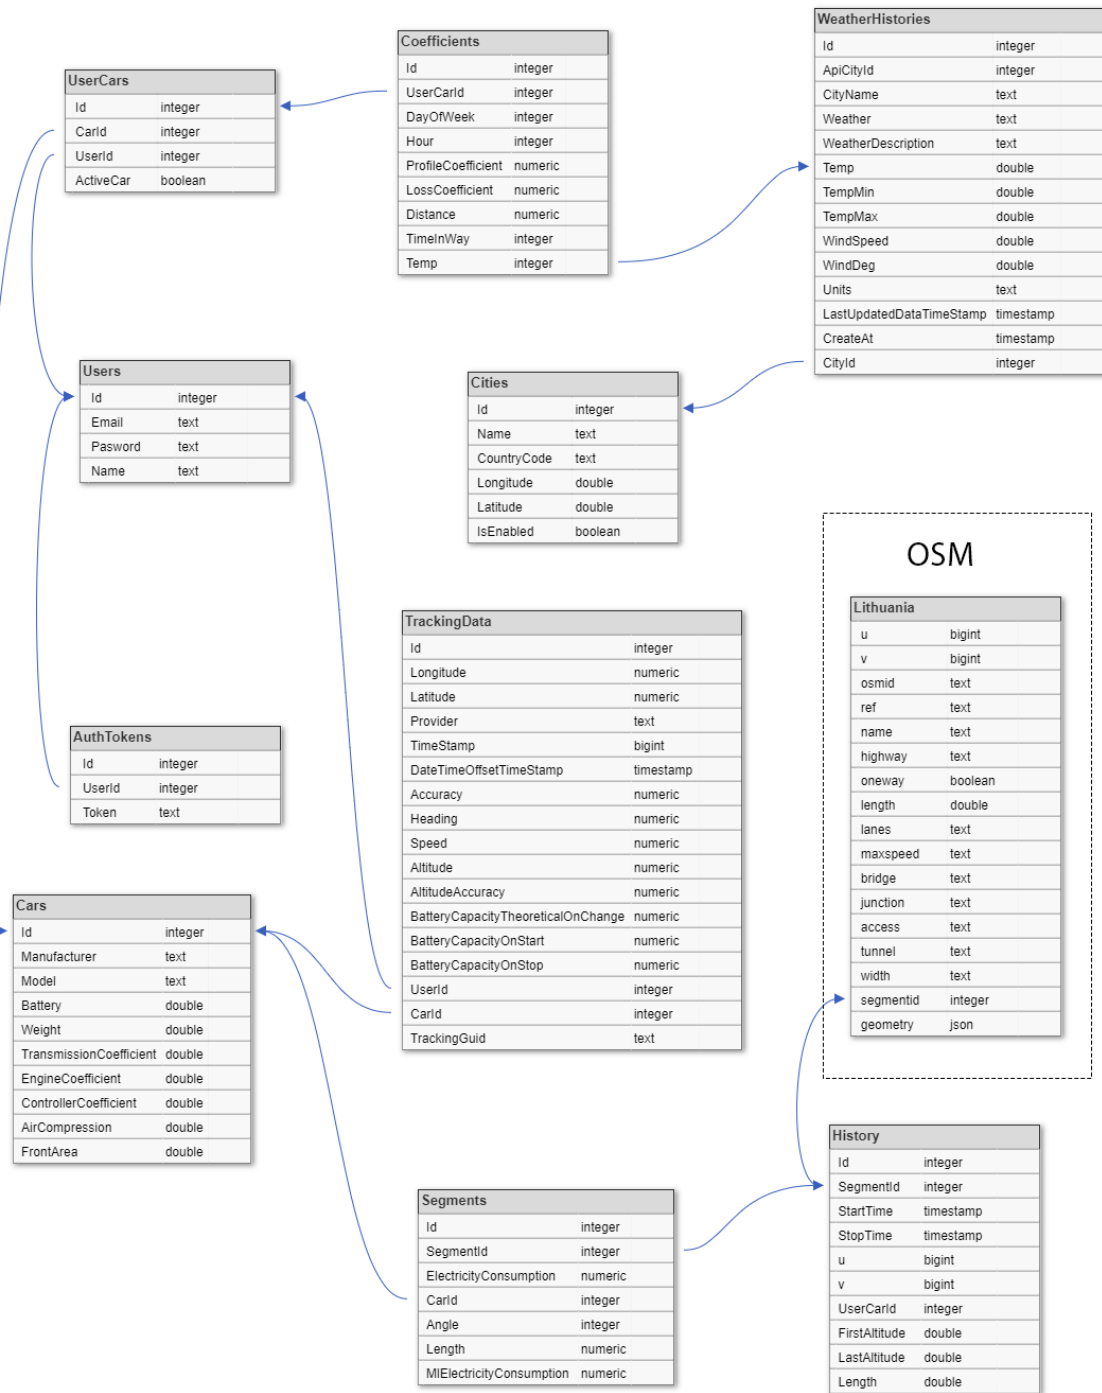
evApp taip pat leidžia nustatyti optimalų kelią energijos suvartojimo aspektu. Vartotojui nurodžius pradžios ir pabaigos GPS taškų koordinatas siunčiama užklausa į serverio programinę įrangą, kuri pagal prognozuojamą baterijos energijos suvartojimą (žr. 4 algoritmą) nustato segmentų seką

ir grąžina ją vartotojui.

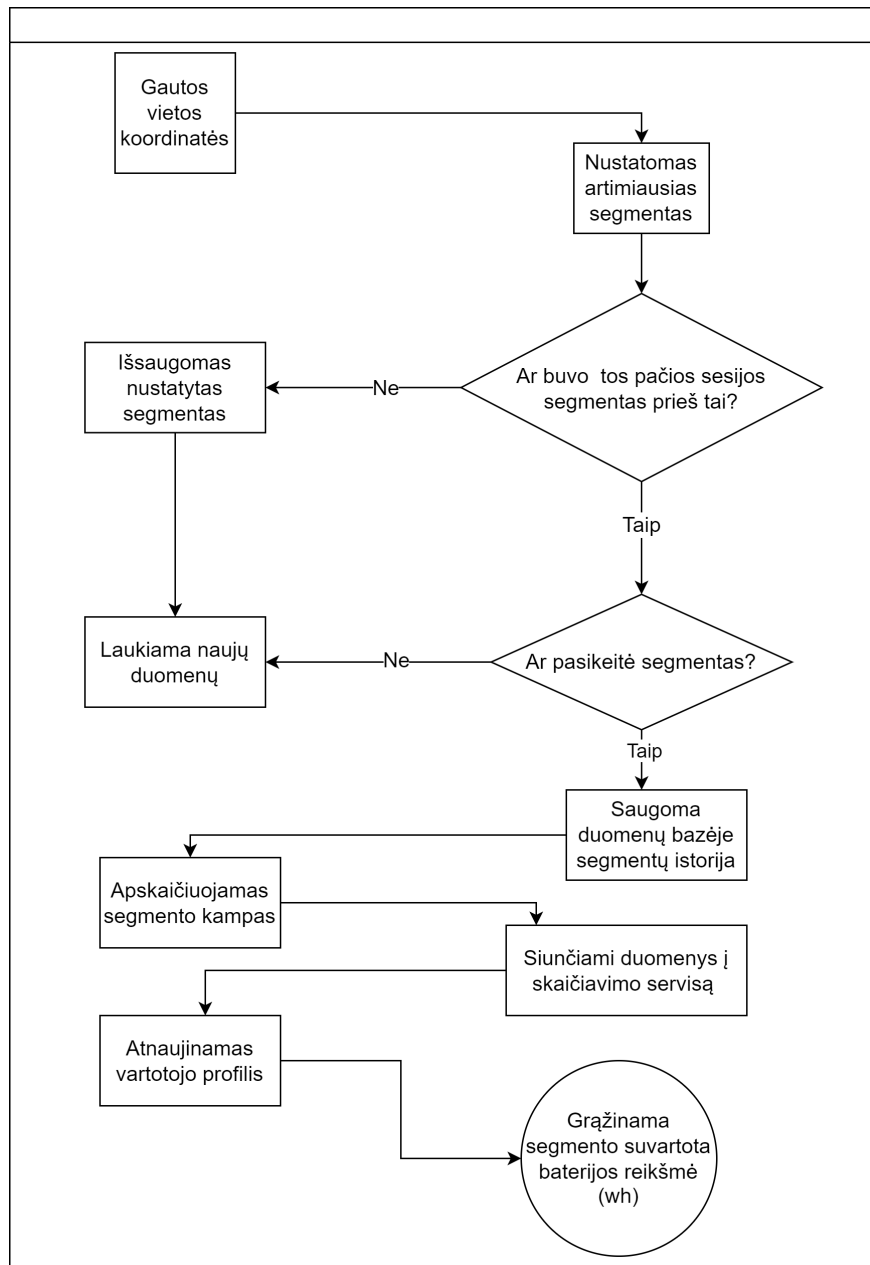
3.3. Serverio programinė įranga *evProjectServer*

Serverio programinė įranga *evProjectServer* yra sukurta tam, kad priimtų iš *evApp* duomenis, atliktų skaičiavimus ir gražintų rezultata į *evApp* (žr. 5 pav.). Šio darbo tikslais taip pat parengta PostgreSQL duomenų bazė (žr. 6 pav.). Atskiroje nuo OSM duomenų bazės nepriklausomoje duomenų bazėje saugomi visi iš *evApp* į serverio programinę įrangą perduoti duomenys, apskaičiuoti vairuotojo profilio koeficientai, pravažiuotų segmentų istorija bei temperatūros duomenys.

Serverio programinė įranga duomenis apdoroja realiuoju metu, pasitelkdama duomenų apdorojimo realiuoju metu servisą (*RealTimeDataAggregationService*) (žr. 7 pav.). Iš vartotojo gautami duomenys, įskaitant vartotojo ID, baterijos reikšmės, GPS duomenys, laiko žymė ir kt., kai nuskaityta atitinkama GPS koordinatė, saugomi *TrackingData* lentelėje. Gavus vartotojo vietos koordinates nustatomas artimiausias segmentas pagal geometrijos artumą. Jeigu tai yra pirmas naujos sesijos segmentas, šis segmentas įsimenamas kaip pradinis, atitinkamai įsimenant tolesniems skaičiavimams reikalingas reikšmes, kaip laikas, aukštis virš jūros lygio, ir laukiama naujų duomenų. Gavus sekančius tos pačios sesijos duomenis ir nustatius, kad segmentas pasikeitė, buvusio segmento reikšmė išsaugoma *History* lentelėje. Jeigu tai tos pačios sesijos tas pats segmentas, laukiama sekančių duomenų. Prieš tai buvusio segmento pabaigos laikas yra naujo segmento pradžios laikas (taip nustatoma, kiek laiko užtrukta buvusiam segmente), prieš tai buvusio segmento aukščio virš jūros lygio reikšmė yra naujo segmento pradžios aukščio virš jūros lygio reikšmė (taip nustatomas segmento kampas). Gautų ir paskaičiuotų duomenų aibė paduodama į suvartojamumo skaičiavimo servisą (*BatteryPowerConsumptionService*). Segmento kampo duomenys ir teorinis segmento suvartojamumas konkrečiam automobiliui saugomi duomenų bazės *Segments* lentelėje. *Segments* lentelėje esantis *SegmentId* sutampa su OSM duomenų bazės *SegmentId*. Pagal gautą rezultatą yra atnaujinamos vartotojo profilio koeficiento reikšmės. Apskaičiuota baterijos energijos suvartojamumo reikšmė grąžinama į *evApp*.



6 pav. PostgreSQL duomenų bazės struktūra



7 pav. Duomenų apdorojimo servisas

3.3.1. Segmento kampo duomenys

Apskaičiuojant kiekvieno segmento energijos suvartojamumą vertinamas segmento kampas. Optimizuojant skaičiavimus, duomenys apie atitinkamo segmento kampo reikšmę saugomi duomenų bazėje, todėl atliekant skaičiavimus tam pačiam ar bet kuriam kitam vartotojui, važiuojančiam segmentu, kurio kampo reikšmė duomenų bazėje jau išsaugota, kampo skaičiavimai pakartotinai neatliekami.


Iki šiol serverio programinėje įrangoje išsaugotos 1 459 segmento kampų reikšmės.

3.3.2. Laiko duomenys

Laiko duomenys šiame darbe suprantami kaip: valandos (paros laikas), savaitės dienos (darbo diena, savaitgalis), laikas, kurį užtruko pravažiuoti atitinkamą segmentą, nes profilio koeficiento reikšmė yra skaičiuojama valandos periodiškumu, atsižvelgiant į paros laiko, dienos, bendro nuvažiuoto atstumo bei laiko, praleisto kelyje atitinkamą valandą, reikšmę.

Serverio programinė įranga nustačiusi, kad atitinkamą dieną ir valandą vairuotojo profilio koeficiento reikšmė nenustatyta, automatiškai kuria naują P aibės elementą. Tuo tarpu jau esant nustatytai vairuotojo profilio koeficiento reikšmei, ji atnaujinama pagal profilio atnaujinimo algoritmą (žr. 3 algoritmą).

Iki šiol serverio programinėje įrangoje išsaugota duomenų apie daugiau nei pravažiuotus 5 000 km (beveik 15 000 segmentų, iš kurių beveik 2 500 yra unikalūs) atitinkamu laiku (žr. 8 pav.).




8 pav. Kilometrai ir valandos

3.3.3. Temperatūros duomenys

Temperatūros duomenys gaunami iš viešai prieinamo šaltinio [27]. Serverio programinė įranga suprogramuota automatiškai gauti temperatūros duomenis ir saugoti juos duomenų bazėje. Esant ribotam užklausų kiekiui, serverio programinė įranga siunčia užklausą dėl duomenų apie temperatūrą atitinkamame mieste atnaujinimo kas valandą, šie duomenys saugomi serverio duomenų bazėje. Surinktų temperatūros duomenų apdorojimui duomenų bazėje buvo iš anksto įvesta informacija apie visus Lietuvos miestus: pavadinimas ir geografinė padėtis. Serverio programinė įranga, gavusi vartotojo GPS duomenis nustato temperatūrą, artimiausią duotajam taškui.

Nustačius, kad vairuotojas jau važiavo tokioje pačioje temperatūroje (temperatūra nustatoma sveikaisiais skaičiais, apvalinant pagal matematikos taisykles) tuo pačiu segmento tipu, tą pačią valandą, atnaujinama koeficiento reikšmė pagal profilio atnaujinimo algoritmą (žr. 3 algoritmą). Jeigu atitinkamai temperatūrai duomenų bazėje profilio koeficiento reikšmė nenumatyta, pridemas naujas koeficiento elementas.

Iki šiol serverio programinėje įrangoje išsaugota duomenų apie beveik pravažiuotą 1 400 km atstumą atitinkamose temperatūrose, iš kurių daugiausia (apie 138 km) esant 14°C ir (apie 133 km) esant -4°C (žr. 9 pav.).



9 pav. Kilometrai ir temperatūra

4. Eksperimentai

4.1. Žemėlapių segmento nustatymas

Eksperimentai vykdyti ir rezultatai analizuoti, naudojant dviejų tipų duomenis: Android emuliacijos pagalba generuojant kelionės duomenis bei realių, faktiškai vykdytų važiavimų metu, renkant duomenis bei testuojant algoritmus. Eksperimentų metų surinktų duomenų atvaizdavimui naudojama QGIS programinė įranga.

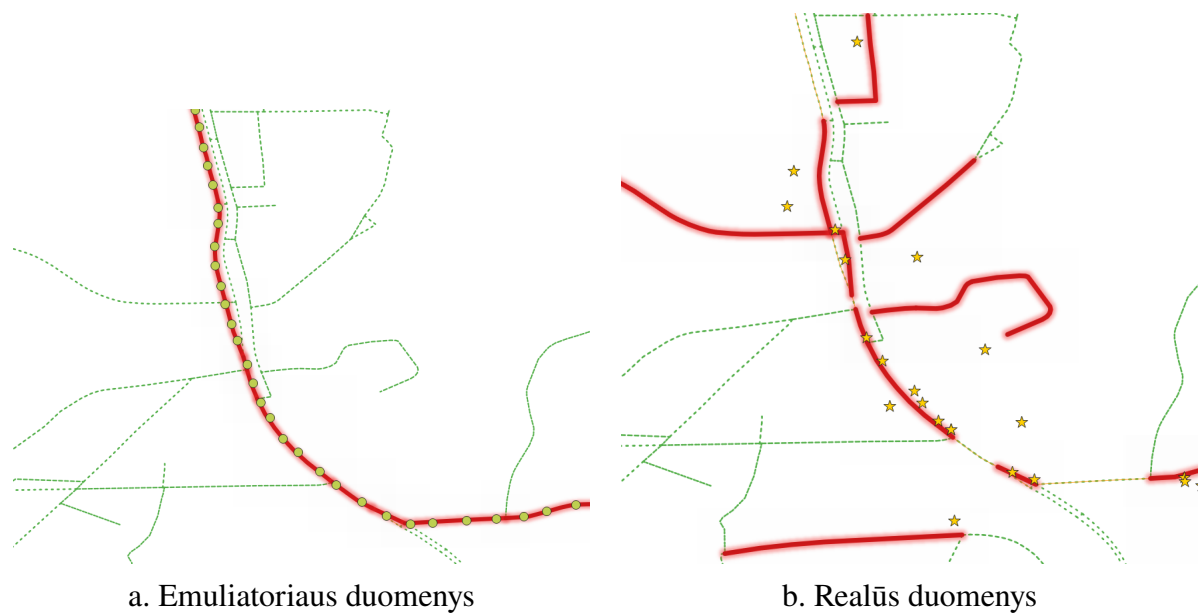
Iki šiol serverio programinėje įrangoje išsaugota duomenų apie 153 faktiškai buvusias keliones ir 47 emuliacijos pagalba vykdytas keliones. Su pirmu elektromobiliu (Fiat 500) fiksuota 90 kelionių, su antru (BMW i3) – 6 kelionės, su trečiu (Chevrolet Volt) - 57 kelionės. Vienas vartotojas su pirmu elektromobiliu turėjo 3 keliones, su trečiu – 43 keliones, o su antru elektromobiliu kelionių nefiksuota; antras vartotojas turėjo 5 keliones su antru elektromobiliu ir 2 keliones su trečiu elektromobiliu, o su pirmu elektromobiliu kelionių nefiksuota; trečias vartotojas su pirmu elektromobiliu turėjo 39 keliones, su antru elektromobiliu – 1 kelionę, o su trečiu elektromobiliu – 4 keliones; ketvirtas vartotojas su pirmu elektromobiliu turėjo 52 keliones, su antru elektromobiliu – 1 kelionę, o su trečiu elektromobiliu – 10 kelionių. Likę du vartotojai kol kas yra testiniai ir buvo skirti kelionėms emuliacijoje.

Nors Android emuliacijos pagalba atliktų važiavimų metu nustatyti GPS taškai neturi GPS tikslumo problemos (žr. 10a pav. – Emuliacijos duomenys), kur taškai simbolizuoja GPS taškus, o raudona linija – važiuotą kelią, tačiau emuliacijos pagalba surinkti duomenys pasižymi kitais trūkumais. Sintetiniai duomenys nepateikia aukščiau virš jūros lygio, šis parametras reikalingas apskaičiuoti kampą (įkalnė, nuokalnė), emuliacijoje nėra galimybės imituoti spūsčių. Taip pat emuliacijoje neatsižvelgiama į nuo vairuotojo priklausančias aplinkybes ir susijusių faktorių įtaką, nevertinamas realus baterijos energijos suvartojimas, iš GPS duomenų sužinomas esamas greitis, jis visada sutampa su maksimaliai leistinu greičiu, taigi virtualioje aplinkoje vairuotojo profilio koeficiento reikšmė nekinta.

Bandomųjų važiavimų realybėje metu gaunami reikalingi duomenys, bet skirtingai nei sintetinių duomenų atveju, susiduriama su GPS tikslumo problema. Android įrenginiai pateikia skirtingo tikslumo GPS duomenis, o GPS duomenų gavimo dažnumas kur kas mažesnis negu virtualioje aplinkoje.

Pirma problema, su kuria susiduria atliekant eksperimentus, tai pirmojo segmento, kuriame yra vartotojo automobilis nustatymas. Pagal duomenų bazių duomenis segmentai, kurie yra kryptiniai, gali turėti tas pačias geometrijas, todėl vien iš GPS koordinačių nustatyti, kuriame iš kryptinių segmentų yra vartotojas, sudėtinga. Šios problematikos nepadėjo išspręsti ir kompasų reikšmių pritraukimas.

Antra problema – kelio tinklo modeliavimas nesuplanavus konkretaus kelio ir neidentifikavus segmentų sekos. Žemėlapių atitikimo (angl. Map Matching) problematika susijusi su gautų geografinių koordinačių suderinimu su loginiu realaus pasaulio modeliu naudojant tam tikrą geografinės informacijos sistemos (angl. GIS - Geographic Information System) formą. Praktikoje naudojame kelių žemėlapyje, realiuoju metu, tai sprendžiama pritraukiant GPS tašką prie geometriškai artimiausio segmento (žr. 10b pav. – Realūs duomenys), kur žvaigždutės simbolizuoja gautus GPS taškus, geltona linija žymi faktiškai važiuotą kelią, raudona storesne linija pažymėtas nustatytas artimiausias segmentas gautiems GPS duomenims. GPS taškų prie geometriškai artimiausio segmento pritraukimo būdu išsprendžiama nuvažiuoto atstumo problematika, nes kiekvieno segmento duomenys yra žinomi, tačiau GPS duomenų netikslumas neleidžia vadovautis išimtinai tik



10 pav. GPS taškų koordinatės ir nustatyti segmentai

geometriškai artimiausiu segmentu, nes gali būti nustatytas segmentas, kuris yra šalia, o ne važiuojamame kelyje. Taigi vertinant nuvažiuotą atstumą ir darant atitinkamas išvadas, svarbu įvertinti galimus GPS duomenų netikslumo nulemtus papildomai įtrauktus segmentus, kurie didina nuvažiuoto atstumo reikšmę.


Nenuoseklus segmentų rinkinio išdėstymas neturint suplanuoto kelio spręstas segmentų parinkimo algoritme numatant, kad sekantis segmentas gali būti tik tas artimiausias segmentas GPS taškui, kurio viršūnės pradžia yra prieš tai nustatyto segmento viršūnės pabaiga, tačiau susidurta su problema, kad parinkus netinkamą GPS taškui artimiausią segmentą (kuriuo faktiškai nebuvo važiuojama), į tinkamą segmentų rinkinį nepatenkama ar patenkama vėlesniuose segmentuose. Ši problema aktualiausia sankryžose ar kituose kelio išsišakojimuose, kur yra keletas galimų važiavimo krypčių. Tokiu būdu iškreipiamas važiuotas kelias, suvartojamos energijos kiekis bei vairuotojo profilio koeficientas. Taigi toks sprendimas negali būti taikomas, o GPS taškų išsibarstymo problema galėtų būti sprendžiama iš anksto planuojant kelią.

4.2. Elektromobilio baterijos energijos suvartojimas

Atlikti eksperimentai patvirtina, kad šiame darbe siūlomi algoritmai yra tinkami ir pritaikomi praktikoje, norint nustatyti, kiek konkretus vartotojas suvartos atitinkamo elektromobilio baterijos energijos keliui nuvažiuoti.


Pakankamas surinktų ir apdorotų duomenų kiekis leidžia tiksliai apskaičiuoti reikalingą elektromobilio baterijos energijos kiekį keliui nuvažiuoti. Atsižvelgiant į realių važiavimų metu surinktų duomenų, naujų bei atnaujintų profilio koeficientų reikšmių kiekį, pateikiami pavyzdinio ketvirtojo vartotojo kelionių pirmuoju elektromobiliu energijos suvartojimo tyrimo rezultatai, kurie atspindi lyginamąją iš *evApp* gautų elektromobilio baterijos energijos likučio bei faktiškai elektromobilio pateiktų baterijos energijos likučio reikšmių kiekvienos kelionės pabaigoje analizę (žr. 11 pav.). Atsižvelgiant į tai, kad kelionės išdėstytos ir numeruojamos eilės tvarka, matyti, kad pradinių kelionių metu esant mažam duomenų kiekiui *evApp* pateikiamos ir faktinės energijos suvartojimo reikšmės turėjo paklaidų, tačiau tolesnių kelionių metu, turint dinamišką vairuotojo profilio algoritimą, tikslinant profilio koeficiento reikšmę tinkamai taikant vartotojo profilio atnaujinimo funkcionalumą,

nuo 39 kelionės paklaidos minimalios arba jų išvis nefiksuota.



11 pav. Ketvirto vartotojo suvartojamumas kelionėse pirmu elektromobiliu

Šio darbo eksperimentų metu surinktų duomenų ir rezultatų žemėlapyje atvaizdavimui naudojama QGIS programinė įranga. Pavyzdyje (žr. 12 pav.) pavaizduotas tinkamai nustatytas ir žemėlapyje atspindėtas faktiškai važiuotas vartotojo kelias, išskyrus dėl GPS duomenų netikslumo papildomai pritrauktus gretimus segmentus. Šio maršruto pabaigoje automobilio nuodytas realus faktinis baterijos energijos likutis: 90%, o *evApp* grąžinta reikšmė 90,8% (žr. 13 pav.). Analizuojamo pavyzdinio važiavimo atveju duomenų bazėje profilio *UserCarID 8* koeficiento reikšmė atitinkamu laiku (10 val, trečiadienis) yra 0.78, surinkta apie 12 km duomenų (žr. 14 pav. ID 338). Taigi aptariamų parametru aspektu surinkta pakankamai duomenų tiksliai vairuotojo profilio koeficiento reikšmei nustatyti.



12 pav. Nustatytas maršrutas, kuriuo važiuota

Vartotojo *UserCarID 8* profilio duomenų analizė patvirtina individualių savybių įtraukimo į vairuotojo profilį svarbą ir įtaką elektromobilio nuvažiuojamam atstumui ir suvartojamos energijos kiekiui. Eksperimentų rezultatai parodo, kad analizuojant tik 10 val konkretaus vairuotojo koeficiento reikšmes skirtingomis savaitės dienomis, esant skirtingai temperatūrai profilio koeficiento

Id	Longitude	Latitude	Provider	DateTimeOffsetTimeStamp	Accuracy	Heading	Speed	Altitude	AltitudeAccuracy	BatteryCapacityTheoreticalOnChange	BatteryCapacityOnStart	BatteryCapacityOnStop	CarId	UserId	TrackingGuid
2	127336	25.32468625	54.72640889	Real	2022-12-21 10:22:02.09+02	6.89501524	27.50246048	21.6	154.8779602	0	10000	10000	0	1	4 26b1f6c5-af6b-4fe1-bc6a-cb9674cb035
332	127666	25.27879908	54.6885373	Real	2022-12-21 10:44:24+02	11.79199982	0	0.478697592	103.0582275	16	9080	10000	9000	1	4 26b1f6c5-af6b-4fe1-bc6a-cb9674cb035

13 pav. Pradinis ir paskutinis GPS taškas

Id	UserCarId	DayOfWeek	Hour	ProfileCoefficient	LossCoeff	Distance	TimeInWay	Temp
339	8	3	10	0.706021816	0	13380.101	1126	-3
346	8	5	10	1.050078764	0	5077.333	769	-2
343	8	4	10	0.841781443	0	8187.67	882	-2
338	8	3	10	0.781372088	0	12197.762	857	-1
349	8	6	10	0.956652092	0	4630.203	451	0
287	8	4	10	1.067532897	0	5320.659	873	7
288	8	4	10	0.913204031	0	2322.997	360	8
283	8	2	10	1.176446094	0	8088.058	1450	9
244	8	1	10	1.124819114	0	5086.333	706	11
236	8	5	10	1.398330255	0	1489.898	32	12
224	8	1	10	0.719581368	0	9590.618	720	12
235	8	5	10	0.744604342	0	11995.609	866	13
210	8	5	10	0.772364385	0	8054.668	596	14
209	8	5	10	0.592040491	0	3719.703	258	15
194	8	6	10	0.510961336	0	1866.688	151	17
164	8	5	10	1.152147771	0	3321.071	479	NULL

14 pav. Vartotojo *UserCarID* 8 profilio duomenys 10 val.

reikšmė svyruoja nuo 0.51 iki 1.40 (žr. 14 pav.). Atsižvelgiant į individualias, nuo vairuotojo priklausančias aplinkybes, vairavimo stilių, važiuojant tuo pačiu automobiliu, tuo pačiu metu (10 val), esant iš esmės tai pačiai temperatūrai (11-12 °C), suvartojamos baterijos energijos kiekis žymiai išauga ir suvartojama daugiau energijos, nei teoriškai reikia atitinkamam segmentui nuvažiuoti (žr. 14 pav. ID 283, 224, 236) – vairuotojo profilio koeficientas 1,12 - 1.40. Pažymėtina, kad nors aptariamieji įrašai tarpusavyje skiriasi nuvažiuotu atstumu apie 3,5 km, tačiau kiti įrašai duomenų bazėje patvirtina, kad iš esmės esant tai pačiai temperatūrai (13-14 °C), to paties vartotojo profilio koeficiento reikšmės yra panašios 0.77 / 0.74, nepaisant, kad įrašai tarpusavyje skiriasi nuvažiuotu atstumu apie 3,9 km. To paties vartotojo *UserCarID* 8 profilio duomenų analizė rodo, kad mažiausiai energijos šis vartotojas suvartoja (profilio koeficiento reikšmė yra 0.39) esant toliau nurodytoms sąlygoms: penktadienis, 11 val, 15 °C (žr. 15 pav.). Pastebėta, kad nustatant to paties vartotojo sunaudojamą baterijos energijos kiekį tame pačiame kelyje, tačiau kitu laiku, žymių nukrypimų taip pat nenustatyta.

Id	UserCarId	DayOfWeek	Hour	ProfileCoefficient	LossCoefficient	Distance	TimeInWay	Temp
211	8	5	11	0.391795035	0	10629.558	527	15

15 pav. Sąlygos, kuriomis vartotojas *UserCarID* 8 suvartoja mažiausiai baterijos energijos

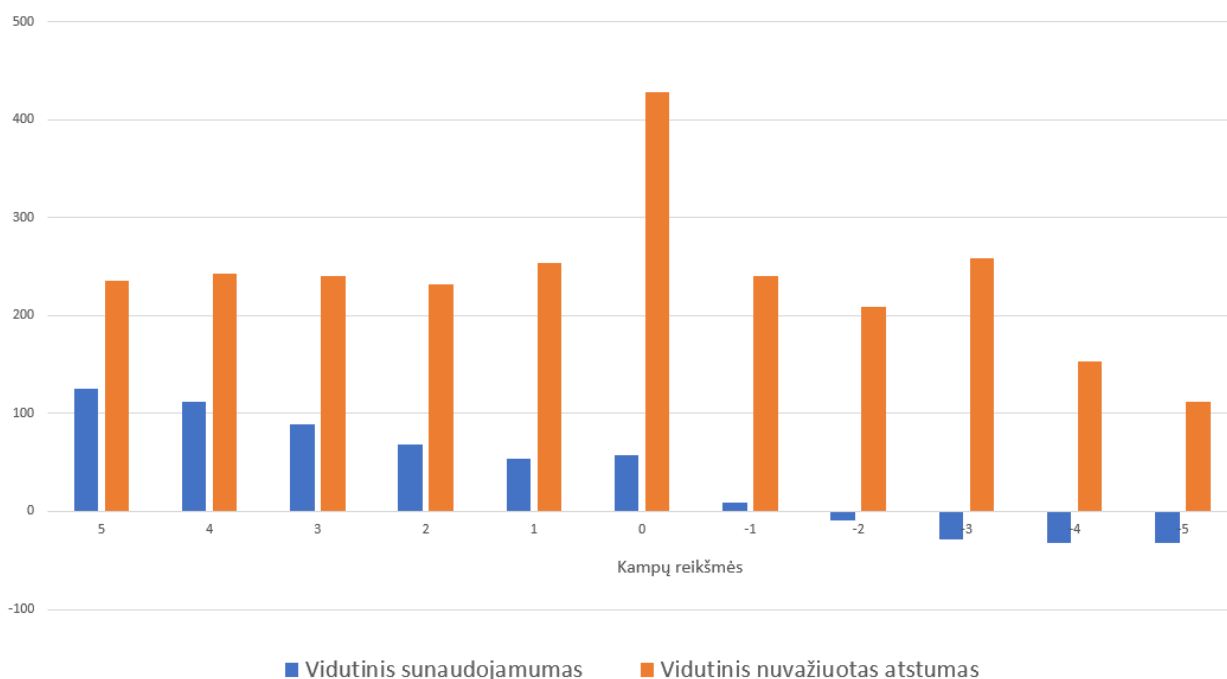
4.2.1. Pagal segmento kampą

Analizuojant surinktus duomenis, pastebėta netikslumų nustatant segmento kampą. Šie netikslumai iš esmės nulemti jau aptartos GPS duomenų netikslumo problematikos.

To paties elektromobilio eksperimentų metu surinktų duomenų pagrindu vertinant segmento kampo įtaką suvartojamam elektromobilio baterijos energijai, nustatyta, kad įkalnei (apie 4°) (segmento ID 134502), kurios ilgis 428 m reikalinga 193W baterijos energijos, o identiško segmento nuokalnei (segmento ID 134032) elektromobilis susigrąžina (rekuperacija) apie 52W baterijos energijos. Tuo tarpu segmentui, kurio geometrinis kampas lygus 0°, tas pats elektromobilis 428 m atstumui nuvažiuoti suvartoja apie 53W.

Analizuojamam elektromobiliui įkalnei (apie 3°) (segmento ID 134661), kurios ilgis 274 m reikalinga 101W baterijos energijos, o identiško segmento nuokalnėje (segmento ID 134664) elektromobilis susigrąžina (rekuperacija) apie 36W baterijos energijos. Segmentui, kurio geometrinis kampas lygus 0°, tas pats elektromobilis 274 m atstumui nuvažiuoti suvartoja apie 34W.

Lyginant tam pačiam elektromobiliui reikalingą elektros energijos kiekį įkalnei (apie 2°) (segmento ID 140055), kurios ilgis 364 m reikalinga 111W baterijos energijos, o atitinkamai priešingos krypties segmento nuokalnėje (segmento ID 127843), kurios ilgis 408 m, elektromobilis susigrąžina (rekuperacija) apie 16W baterijos energijos. Segmentui, kurio geometrinis kampas lygus 0°, tas pats elektromobilis 364–408 m atstumui nuvažiuoti atitinkamai suvartoja apie 40–50 W.



16 pav. Vidutinis suvartojumas pagal segmentų kampus


4.2.2. Pagal temperatūrą

Atlikti eksperimentai patvirtina, kad temperatūra turi įtakos suvartojamos baterijos energijos kiekiui. Esant mažesnei temperatūrai suvartojamos baterijos energijos kiekis tam pačiam atstumui nuvažiuoti didėja eksponentiškai (žr. 18 pav.).

Tačiau kartu atkreiptinas dėmesys, kad surinkti duomenys atskleidžia, kad sudėtingesnės eisimo sąlygos net ir esant žemesnei temperatūrai dėl snygio, plikledžio, prastesnio matomumo ir pan., įtakoja ramesnį vairavimo stilių, mažesnę pasirenkamą greitį bei jo išlaikymą, kas prisideda prie elektromobilio baterijos energijos taupymo (žr. 17 pav.). Eksperimentų rezultatų vertinimo tikslais verta pastebėti, kad duomenys atspindi kelionę elektromobiliu kaskart iš tos pačios uždaros vietos, kur temperatūra žiemą nenukrenta žemiau 6°C, o vasara nepakyla daugiau 23°C. Kartu dėl šio konkretaus elektromobilio individualių techninių savybių, elektromobilio salono šildymo sistema nėra susieta su pagrindine baterija, kurioje sukauptos energijos dėka elektromobilis važiuoja, kondicionieriaus šiame modelyje nėra, todėl skaičiavimai atspindi išimtinai elektromobilio judėjimui suvartojamą baterijos energijos kiekį.

Id	UserCarId	DayOfWeek	Hour	ProfileCoefficient	LossCoefficient	Distance	TimeInWay	Temp
332	8	1	16	0.949796133	0	10121.491	1229	-2

17 pav. Profilio reikšmė prie -2°C



18 pav. Baterijos energijos suvartojimas pagal laiką ir temperatūrą

4.2.3. Kelio planavimas

Darbe siūlomas prognozuojamo baterijos energijos suvartojimo keliui algoritmas (žr. 4 algoritmą) pasiūlo optimalų kelią vairuotojui bei apskaičiuoja šiam keliui nuvažiuoti reikalingą energijos kiekį pagal jo profilio koeficientą.

Atliktų eksperimentų metu nustatyta, kad programėlė *evApp* grąžina siūlomo maršruto segmentų seką pagal pasirinktas maršruto pradžios ir pabaigos taškų koordinatas. Lyginamoji maršruto sudarymo skirtingiems vartotojams analizė patvirtina, kad tam pačiam maršrutui nuvažiuoti, atsižvelgiant į algoritmo dedamųjų reikšmes, prognozuojamas skirtingas energijos kiekis jam nuvažiuoti (žr. 19 pav.). Pavyzdiniai skaičiavimai atspindi, kad tam pačiam atstumui nuvažiuoti, atsižvelgiant į elektromobilio techninius parametrus ir vairuotojo profilį prognozuojamas 76,70W

energijos suvartojamumas pirmam elektromobiliui (žr. 19a pav. – Fiat 500), o trečiam elektromobiliui prognozuojamas 138,55W energijos suvartojamumas (žr. 19b pav. – Chevrolet Volt).

Eksperimentų metu pastebėta, kad svarbu tinkamai pasirinkti pradžios taško koordinatę, nes galima maršruto pradžios segmento nustatymo problematika. Atsižvelgiant į tai, kad prognozuojamas baterijos energijos suvartojimo keliui algoritmas nėra optimizuotas, skaičiavimams reikalinga daug programinės įrangos resursų, be to, keliems vartotojams tuo pat metu pateikus užklausą dėl maršruto sudarymo, skaičiavimai užtrunka. Taigi optimizavimo tikslais maršruto parinkimui galėtų būti pasitelkiamas Dijkstra algoritmas su atitinkamomis korekcijomis, įtraukiant elektromobilio baterijos energijos nustatymo aspektu aktualius parametrus.

Road segments builder				Road segments builder			
StartPoint Lat: 25.25050563 Long: 54.694504		FinishPoint Lat: 25.252217 Long: 54.688299		StartPoint Lat: 25.250563 Long: 54.694504		FinishPoint Lat: 25.252217 Long: 54.688299	
		BUILD ROAD				BUILD ROAD	
SegmentId	Length,(m)	Speed, (km/h)	Cost,(kW)	SegmentId	Length,(m)	Speed, (km/h)	Cost,(kW)
134198	94.402	40	10.3622	134198	94.402	40	18.7182
134592	87.306	40	9.5833	134592	87.306	40	17.3112
134584	93.225	40	10.2330	134584	93.225	40	18.4848
134599	90.175	40	9.8982	134599	90.175	40	17.8800
134612	86.607	40	9.5066	134612	86.607	40	17.1726
134623	97.138	40	10.6625	134623	97.138	40	19.2607
134633	84.774	40	9.3054	134633	84.774	40	16.8091
134634	65.144	40	7.1507	134634	65.144	40	12.9168
Total:			76.7020 W	Total:			138.5532 W

a. Fiat 500

b. Chevrolet Volt

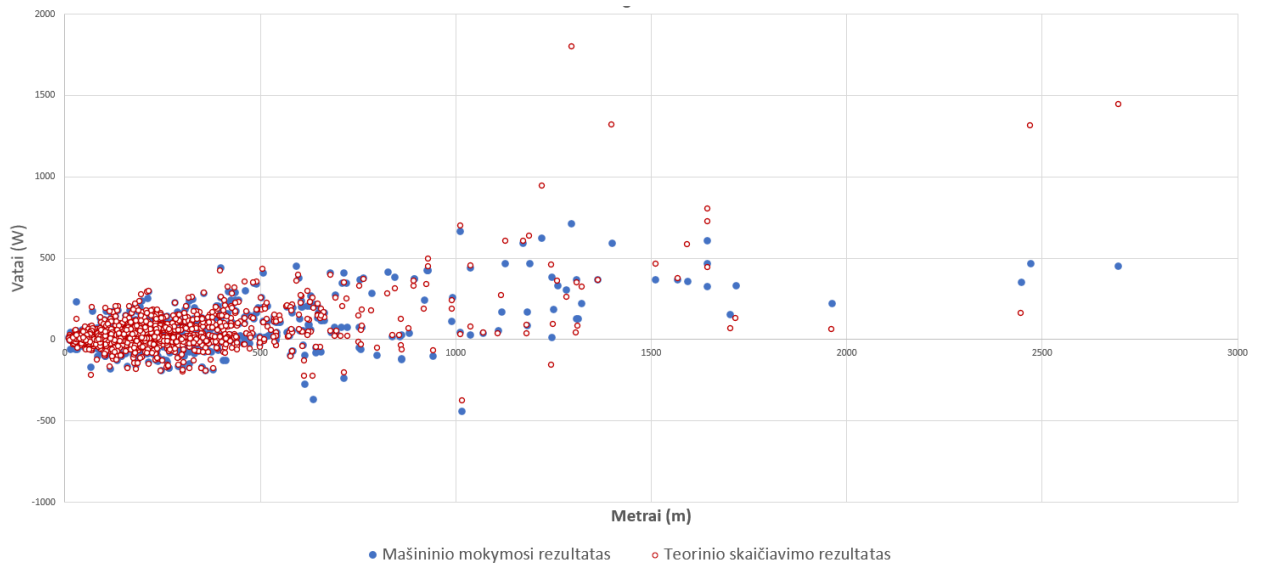
19 pav. Kelio planavimo rezultatai

4.3. Mašininis mokymasis

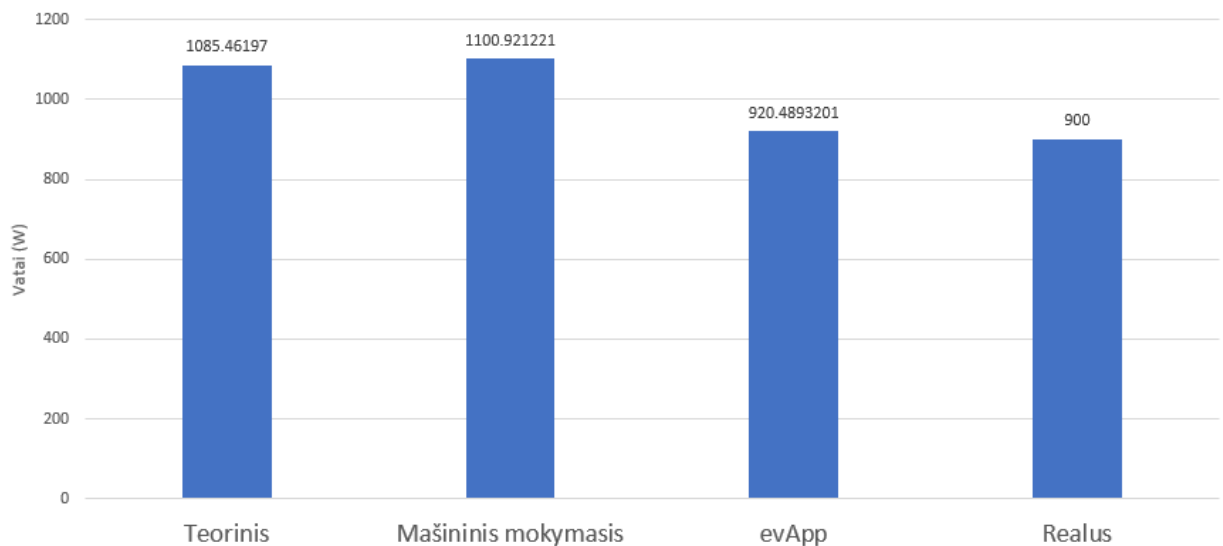
Mašininis mokymasis apmokytas pateikus surinktų teorinių skaičiavimų konkreitiems segmentams duomenų aibę. Serverio programa suprojektuota, kad kiekvieną kartą ją paleidus, vyktų apmokymas.

Pasirinktas mašininio mokymosi tiesinis regresijos modelis. Atsižvelgiant į tai, kad yra daug faktorių kurie lemia energijos suvartojimą, išskirti parametrai, kaip geografinės segmentų savybės – tipas, ilgis, kampas, taip pat laiko parametras bei techniniai transporto priemonės parametrai. Mašininio mokymosi apmokymui pateikta duomenų apie 7 000 segmentų. Mašininio mokymosi testavimui pateikta duomenų apie 2 000 segmentų.

Mašininio mokymosi tiesinės regresijos modelio prognozuojamumas artimiausias teoriniams skaičiavimams, atliekamiems segmentų, kurių ilgis iki 1 000 m. Prognozuojant elektromobilio baterijos energijos suvartojimą segmentui, kurio ilgis viršija 2 000 m, pastebėtas esminis netikslumas prognozuojant kur kas mažesnę suvartojimą, nei nustatytas teorinis (žr. 20 pav.). Aptariami eksperimentų rezultatai leidžia daryti išvadas, kad mašininio mokymosi prognozavimo tikslumas tiesiogiai susijęs su pakankamu skirtingų duomenų pateikimu modelio apmokymui.



20 pav. Mašininio mokymosi ir teorinio modelio nustatytas suvartojamumas segmentui



21 pav. Lyginamoji suvartojamos energijos skaičiavimų analizė

Pateikiamo pavyzdinio nuvažiuoto maršruto ilgis – 8 km, maršrutas nuvažiuotas per 20 min, taigi vidutinis elektromobilio greitis – 24 km/h, lauko temperatūra -2°C , eksperimentas atliktas 10 val, vairuotojo koeficiento reikšmė 0.84. Realus aptariamam maršrutui suvartotas elektromobilio baterijos energijos kiekis – 900W. Lyginamoji skirtingų skaičiavimų ir suvartojamos energijos prognozavimo būdų analizė atspindi (žr. 21 pav.), kad artimiausią skaičiavimą realiam pateikė šiame darbe aptarto vairuotojo profilio atnaujinimo algoritmo pagrindu apskaičiuotas ir *evApp* pateiktas rezultatas (920W). Teorinio elektromobilio suvartojamos energijos nustatymo modelio (1085W) ir mašininio mokymosi (1100W) nustatytas reikalingas elektromobilio baterijos energijos kiekis šiam keliui nuvažiuoti prognozuotas 17-18% didesnis, nei realus energijos suvartojimas, tuo tarpu dinamiškai atsinaujinantis elektromobilio vairuotojo profilis pasižymėjo tik 2% netikslumu. Aptariamasis mašininio mokymosi prognozuojamas energijos suvartojimo netikslumas sietinas su nepakankamu duomenų kiekiu jo apmokymui.

Išvados ir rekomendacijos

Šiuo metu praktikoje dominuojantys metodai, apskaičiuojantys automobilio nuvažiuojamą atstumą, yra skirti tirti automobilius su vidaus degimo varikliais, nes neatsižvelgia į elektromobilių specifiką. Nepaisant literatūroje pateikiamų maršruto pagal numatomą baterijos energijos suvartojimą parinkimo elektromobiliams gausos, dauguma jų remiasi bendraisiais duomenimis, tuo tarpu maršrutų elektromobiliams sudarymui ypatingą reikšmę turi individualūs vairuotojo ir jo turimo elektromobilio duomenys.

Darbe identifiuoti pagrindiniai parametrai, turintys esminės reikšmės elektromobilio energijos suvartojimui: elektromobilio techniniai parametrai, nuolydžio kampas, temperatūra, laikas, greitis, vairuotojo profilis. Darbe pasiūlyti algoritmai, kurie įvertina elektromobilio vairuotojo profilį, pateikiamų duomenų pagrindu prognozuoja optimalų kelią baterijos energijos suvartojimo aspektu bei apskaičiuoja suvartojamą energijos kiekį. Vairuotojo profilio algoritmas yra dinamiškai atnaujinantis po kiekvienos kelionės, didesnis duomenų kiekis užtikrina tikslesnius skaičiavimus bei sudaro sąlygas įvertinti vairuotojo vairavimo įpročius, apskaičiuoti reikalingą elektromobilio baterijos energijos kiekį keliui nuvažiuoti.

Sukurti programiniai įrankiai: Android programėlė *evApp*, serverio programinė įranga *evProjectServer* bei PostgreSQL duomenų bazė leido surinkti bei apdoroti surinktus duomenis, reikalingus vairuotojo profilio įvertinimui ir atnaujinimui, optimalaus kelio pagal vairuotojo profilį parinkimui bei jam nuvažiuoti reikalingos energijos kiekio apskaičiavimui. Sukurti įrankiai gali ir toliau būti naudojami kasdieniams elektromobilio vairuotojo poreikiams.

Siūlomų sprendimų praktiniam pritaikymui įvertinti buvo atlikti eksperimentai, naudojant emuliatorių bei realiai keliaujant elektromobiliais. Tiek bendro profilio koeficiento reikšmių analizė, tiek eksperimentų rezultatai pagal išskirtus parametrus pagrindžia jų įtaką elektromobilio suvartojamam baterijos energijos kiekiui. Eksperimentų rezultatai atskleidžia, kad elektromobilio techniniai parametrai, nuolydžio kampas, temperatūra bei laikas, kurių vairuotojas įtakoti negali, turi įtakos energijos suvartojimo rodikliams, tačiau pastebimą įtaką energijos suvartojimui turi ir vairuotojo profilis ir nuo vairuotojo priklausančios aplinkybės. Surinktų duomenų aibė apie konkretaus vairuotojo profilį leidžia tiksliai nustatyti energijos suvartojamumą nepriklausomai nuo maršruto ilgio ir, ar atitinkamu keliu jau buvo važiuota. Tyrimų rezultatai taip pat leidžia teigti, kad vertinant energijos suvartojimą nustatyti parametrai turi būti vertinami kompleksiskai, pavyzdžiui, net ir esant žemesnei temperatūrai, kuri turėtų įtakoti didesnę energijos suvartojimą, nuo vairuotojo priklausančios aplinkybės, kaip atsargesnis vairavimas, pastovaus greičio palaikymas, mažesnis manevravimas lemia energijos taupymą. Vertinant profilio koeficiento reikšmes nustatyta, kad panašioje temperatūroje, panašiu metu konkretaus vairuotojo profilio koeficientų reikšmės panašios.

Kadangi profilio koeficiento reikšmė skaičiuojama valandos tikslumu, susiduriama su koeficiento reikšmės priskyrimo atitinkamam laikui problema, kai kelionė prasidėjo ir baigėsi skirtingomis valandomis. Programinė įranga priskiria rezultato reikšmę valandai, kurią kelionė baigėsi. Ši problematika galėtų būti sprendžiama susiejant programinę įrangą su automobiliu, automatiškai nuskaitant baterijos statusą. Tokiu būdu koeficiento reikšmė galėtų būti atnaujinama segmento pasikeitimo momentu, todėl nereikėtų vairuotojui fiksuoti baterijos energijos likučio maršruto pabaigoje ir koeficiento reikšmė būtų atnaujinama dar dažniau.

Laiko parametras aktualus prognozuojant optimalų kelią baterijos energijos suvartojimo aspektu. Tuo atveju, jei vairuotojas planuoja maršrutą kitu laiku, nei planuojama kelionė, pavyzdžiui, bus vykstama piko metu, o skaičiavimai atliekami ne piko metu, programinė įranga atsižvelgs į segmento savybes ir profilio reikšmes planavimo laiku. Ši problematika galėtų būti sprendžiama

papildžius *evApp* funkcionalumą ir patikslinus algoritmą, sudarant galimybę nurodyti planuojamą kelionės laiką ar ir kitus parametrus, kaip, pavyzdžiui, temperatūrą.

Atlikti eksperimentiniai mašininio mokymosi prognozavimo rezultatai atskleidžia, kad modelio apmokymui buvo pateikta per mažai duomenų tikslių prognozių pateikimui, todėl skaičiavimų optimizavimo tikslais turėtų būti skirta papildomo dėmesio mašininio mokymosi modelio apmokymui papildomais duomenimis.

Nustatytų duomenų bei rezultatų pagrindu teiktinos rekomendacijos: siekiant elektromobiliu nuvažiuoti kuo didesnę atstumą vairuotojas turėtų pasirinkti optimalų vairavimo stilių, vengti perteklinio baterijos energijos eikvojimo, kurio variklis neišnaudoja, esant galimybei pasirinkti kelionę ne piko metu, įvertinti kelio geografines savybes, ypač nuokalnes, energijos taupymo tikslais. Renkantis iš alternatyvių kelių, atkreipti dėmesį, kad greičiausias ar trumpiausias kelias elektromobiliui ne visuomet yra optimalus energijos suvartojimo atžvilgiu, todėl vertėtų planuoti maršrutą iš anksto.

Ateities tyrimų gairės

Tolimesnis šiame darbe pateikiamų sprendimų tobulinimas galėtų būti siejamas su optimizavimu. Vairuotojo profiliavimui galėtų būti pasitelkiamas mašininis mokymasis. Neturint duomenų apie konkretą vartotoją, tačiau jau turimos profilio aibės pagrindu pagal pirmuosius vartotojo duomenis galėtų būti prognozuojamas jo koeficientas, o dinamiškai atsinaujinančio elektromobilio vairuotojo profilio sprendimo pagalba šis tikslinamas pagal konkretą vartotoją. Siūlomas prognozuojamas energijos suvartojimas keliui galėtų būti optimizuojamas, nes šiuo metu siūlomas sprendimas naudoja daug programinės įrangos resursų.

Mašininio mokymosi pritaikymui praktikoje reikia didelio kiekio duomenų. Jų surinkimui programėlė *evApp* yra paruošta, todėl reikia entuziastų, kurie naudotųsi šiuo sprendimu.

Tikslesniam keliui pagal GPS duomenis ir atitinkamai energijos suvartojimui nustatyti, turėtų būti analizuojamos galimos GPS duomenų tikslumo problemos sprendimo galimybės. Žemėlapių atitikimo problematikos sprendimui galima būtų naudoti egzistuojančius arba siūlant naujus segmentų atitikimo algoritmus.

Tikslesniems energijos suvartojimo skaičiavimams ir techninių klaidų išvengimui elektromobilis galėtų būti susiejamas su programine įranga, kad pati programinė įranga nuskaitytų elektromobilio baterijos informaciją (stovį, pakrovimą, likutį) ir šiuos duomenis panaudoti kaip mašininio mokymosi įvestį. Taip pat turėtų būti įvertintas didesnio išorinių servisų įtraukimo poreikis bei galimybės. Detalesnis duomenų iš skirtingų šaltinių gavimas leistų užtikrinti išsamių ir aktualių duomenų naudojimą, užtikrinant galimybę įvertinti žemėlapių pasikeitimus, net ir laikinus, kaip pavyzdžiui, kelio remonto darbus.

Literatūros sąrašas

- [1] Abdalla Abdelrahman, Hossam S. Hassanein, and Najah AbuAli. Data-driven robust scoring approach for driver profiling applications. In *IEEE Global Communications Conference, GLOBECOM 2018, December 9-13, 2018*, pages 1–6. IEEE, 2018.
- [2] Abdalla Abdelrahman, Hossam S. Hassanein, and Najah Abu Ali. iRouteSafe: Personalized Cloud-Based Route Planning Based on Risk Profiles of Drivers. In *2019 IEEE Globecom Workshops*, pages 1–6. IEEE, 2019.
- [3] Andreas Artmeier, Julian Haselmayr, Martin Leucker, and Martin Sachenbacher. The shortest path problem revisited: Optimal routing for electric vehicles. In Rüdiger Dillmann, Jürgen Beyerer, Uwe D. Hanebeck, and Tanja Schultz, editors, *KI 2010: Advances in Artificial Intelligence*, volume 6359 of *Lecture Notes in Computer Science*, pages 309–316. Springer, 2010.
- [4] Soumia Ayyadi, Mohamed Maaroufi, and Syed Muhammad Arif. Evs charging and discharging model consisted of ev users behaviour. In *2020 5th International Conference on Renewable Energies for Developing Countries (REDEC)*, pages 1–4, 2020.
- [5] Francois Badin, F. Berr, Hedjila Briki, J-C Dabadie, Martin Petit, Sébastien Magand, and E. Condemine. Evaluation of evs energy consumption influencing factors, driving conditions, auxiliaries use, driver’s aggressiveness. *World Electric Vehicle Journal*, 6:112–123, 03 2013.
- [6] Tayebah Bahreini, Nathan Fisher, and Daniel Grosu. An Efficient Algorithm for Routing and Recharging of Electric Vehicles. In Weili Wu and Zhongnan Zhang, editors, *Combinatorial Optimization and Applications*, volume 12577 of *Lecture Notes in Computer Science*, pages 711–726. Springer, 2020.
- [7] John Barco, Andres Guerra, Luis Muñoz, and Nicanor Quijano. Optimal routing and scheduling of charge for electric vehicles: Case study. *CoRR*, abs/1310.0145, 2013.
- [8] Moritz Baum, Valentin Buchhold, Julian Dibbelt, and Dorothea Wagner. Fast computation of isochrones in road networks. *CoRR*, abs/1512.09090, 2015.
- [9] Agnė Brilingaitė and Christian S. Jensen. Enabling routes of road network constrained movements as mobile service context. *Geoinformatica*, 11(1):55–102, 2007.
- [10] carinf.com. carinf.com - car information and technical specifications. <https://www.carinf.com/en.html>, 2022. Žiūrėta: 2022-12-26.
- [11] Edsger W. Dijkstra. A note on two problems in connexion with graphs. *Numerische Mathematik*, 1:269–271, 1959.
- [12] evspecifications.com. EVSpecifications - Electric vehicle specifications, electric car news, EV comparisons. <https://www.evspecifications.com/>, 2022. Žiūrėta: 2022-12-26.
- [13] Mahmoud Ezzat, Mahmoud Sakr, Rania Elgohary, and Mohammed Essam Khalifa. Building road segments and detecting turns from gps tracks. *Journal of Computational Science*, 29:81–93, 2018.

- [14] Peter Händel, Isaac Skog, Johan Wahlström, Farid Bonawiede, Richard Welch, Jens Ohlsson, and Martin Ohlsson. Insurance telematics: Opportunities and challenges with the smartphone solution. *IEEE Intell. Transp. Syst. Mag.*, 6(4):57–70, 2014.
- [15] Tim Jonas, Christopher D. Hunter, and Gretchen A. Macht. Quantifying the impact of traffic on electric vehicle efficiency. *World Electric Vehicle Journal*, 13(1), 2022.
- [16] Charyung Kim, Hyunwoo Lee, Yongsung Park, C. Myung, and S. Park. Study on the criteria for the determination of the road load correlation for automobiles and an analysis of key factors. *Energies*, 9:575, 2016.
- [17] Benjamin Bjerre Krogh, Ove Andersen, and Kristian Torp. Analyzing electric vehicle energy consumption using very large data sets. In Matthias Renz, Cyrus Shahabi, Xiaofang Zhou, and Muhammad Aamir Cheema, editors, *Database Systems for Advanced Applications*, number 9050 in Lecture Notes in Computer Science, pages 471–487. Springer, 2015. DASFAA 2015 : Database Systems for Advanced Applications, DASFAA 2015 ; Conference date: 20-04-2015 Through 23-04-2015.
- [18] Zachary J. Lee, Tongxin Li, and Steven H. Low. Acn-data: Analysis and applications of an open EV charging dataset. In *Proceedings of the Tenth ACM International Conference on Future Energy Systems*, pages 139–149. ACM, 2019.
- [19] Norbert E. Ligterink, Pim van Mensch, and Rob F.A. Cuelenaere. Nedc - wltp comparative testing. Technical report, TNO, 10 2016.
<https://publications.tno.nl/publication/34622355/ZCzWY2/TNO-2016-R11285.pdf>.
- [20] Yu Liu, Kunqi Ma, Hanzhengnan Yu, Jingyuan Li, and Xiaopan An. Influence of test cycles on energy consumption test of electric vehicles. *E3S Web of Conferences*, 241:02004, 01 2021.
- [21] Liu, Yu, Liang, Yongkai, Yu, Hanzhengnan, An, Xiaopan, and Li, Jingyuan. Comparative analysis of china light-duty vehicle test cycle for passenger car and other typical driving cycles. *E3S Web Conf.*, 241:02002, 2021.
- [22] Maximilian Löffler, Guy Desaulniers, Stefan Irnich, and Michael Schneider. Routing electric vehicles with a single recharge per route. *Networks*, 76(2):187–205, 2020.
- [23] Ji Lu, Yuning Chen, Jin-Kao Hao, and Renjie He. The time-dependent electric vehicle routing problem: Model and solution. *Expert Syst. Appl.*, 161:113593, 2020.
- [24] Chengsheng Miao, Haiou Liu, Guoming G. Zhu, and Huiyan Chen. Connectivity-based optimization of vehicle route and speed for improved fuel economy. *Transportation Research Part C: Emerging Technologies*, 91:353–368, 2018.
- [25] Peter Ondruska and Ingmar Posner. Probabilistic attainability maps: Efficiently predicting driver-specific electric vehicle range. *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 1169–1174, 2014.
- [26] OpenStreetMap Foundation. OpenStreetMap. <https://www.openstreetmap.org>, 2022. Žiūrēta: 2022-12-23.

- [27] OpenWeather Ltd. OpenWeatherMap - Online weather service. <https://openweathermap.org/>, 2022. Žiūrėta: 2022-12-26.
- [28] J. Pavlovic, B. Ciuffo, G. Fontaras, V. Valverde, and A. Marotta. How much difference in type-approval co2 emissions from passenger cars in europe can be expected from changing to the new test procedure (nedc vs. wltc)? *Transportation Research Part A: Policy and Practice*, 111:136–147, 2018.
- [29] Simon Aagaard Pedersen, Bin Yang, and Christian S. Jensen. Anytime stochastic routing with hybrid learning. In *Anytime Stochastic Routing with Hybrid Learning*, volume 13, pages 1555–1567. VLDB Endowment, September 2020. 2020 International Conference on Very Large Databases PhD Workshop, VLDB-PhD 2020 ; Conference date: 31-08-2020 Through 04-09-2020.
- [30] Linas Petkevicius, Simonas Saltenis, Alminas Civilis, and Kristian Torp. Probabilistic deep learning for electric-vehicle energy-use prediction. *Symposium on Spatial and Temporal SSTD '21*, page 85–95, 2021.
- [31] Rahmad Sadli, Mohamed Afkir, Abdenour Hadid, Atika Rivenq, and Abdelmalik Taleb-Ahmed. Map-Matching-Based Localization Using Camera and Low-Cost GPS For Lane-Level Accuracy. *Procedia Computer Science*, 198:255–262, 2022.
- [32] Sven Schoenberg and Falko Dressler. Reducing waiting times at charging stations with adaptive electric vehicle route planning. *CoRR*, abs/2102.06503, 2021.
- [33] Daliang Shen, Dominik Karbowski, and Aymeric Rousseau. A minimum principle-based algorithm for energy-efficient eco-driving of electric vehicles in various traffic and road conditions. *IEEE Trans. Intell. Veh.*, 5(4):725–737, 2020.
- [34] Yingqi Xiong, Bin Wang, Chi-Cheng Chu, and Rajit Gadh. Electric vehicle driver clustering using statistical model and machine learning. *2018 IEEE Power and Energy Society General Meeting (PESGM)*, 02 2018.