

VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
PROGRAMŲ SISTEMŲ STUDIJŲ PROGRAMA

**Vidaus degimo variklių bekontaktis emisijų
prognozavimas pasitelkiant dirbtinių neuroninių
tinklų modelius**

**Contactless emissions prediction of internal combustion engines
using artificial neural network models**

Magistro baigiamasis darbas

Atliko:	Tomas Sirutavičius	(parašas)
Darbo vadovas:	dr. Tadas Žvirblis	(parašas)
Recenzentas:	dr. Valentas Gružauskas	(parašas)

Vilnius – 2025

Santrauka

Šiame darbe nagrinėjamas vidaus degimo variklių bekontaktis emisijų prognozavimas, pasitelkiant dirbtinių neuroninių tinklų modelius, bei statistinius metodus. Atsižvelgiant į augančius emisijų mažinimo reikalavimus ir transporto elektrifikaciją, kyla poreikis efektyvioms emisijų stebėjimo ir prognozavimo technologijoms, ypač pramonės, energetikos ir sunkiojo transporto srityse, kur vidaus degimo varikliai išliks neišvengiami. Tyrimo metu buvo sukurtas ir įrengtas eksperimentinis stendas, kuriame buvo pasitelktas dyzelinis generatorius išmetamųjų dujų kietųjų dalelių skaičiui tirti. Stende buvo sumontuota specializuota matavimo įranga: akselerometrai virpesių matavimui, garso lygio matuoklis, infraraudonųjų spindulių kamera ir išmetamųjų dujų kietųjų dalelių matuoklis. Surinkti eksperimentiniai duomenys buvo apdoroti ir naudoti tyrimui atlikti. Analizei buvo pasirinktas transformerių dirbtinių neuroninių tinklų modelis. Jo efektyvumui palyginti naudotas rekurentinis LSTM modelis ir statistinis ANCOVA modelis. Tyrimo tikslas buvo įvertinti transformerių modelio efektyvumą, prognozuojant emisijų dalelių kiekį bekontakčiu būdu - pasitelkiant variklio virpesių, garso lygmens ir termovizoriaus vaizdų duomenis. Eksperimentų metu išryškėjo, kad transformerių modeliai gali užtikrinti didžiausią prognozavimo tikslumą, pranokdami kitus metodus. Remiantis šia informacija, buvo sukurta atskirų modelių sistema, kuri gebėtų interpretuoti visus eksperimento metu surinktus duomenų tipus atskirai, bei gebėti sujungti prognozes kartu. Apjungtas transformerių modelis pasiekė 96,59% tikslumą, gebėdamas tiksliai nuspėti skirtingų dydžių išmetamųjų dalelių koncentraciją, pralenkdamas LSTM ir ANCOVA, kurie pasiekė 62.34% ir 61.82% tikslumus. Infraraudonųjų spindulių vaizdai mažiausiai prisidėjo prie bendros prognozės ir iš atskirų duomenų tipų parodė mažiausią tikslumą - 86.3%.

Raktiniai žodžiai: transformerių neuroniniai tinklai, rekurentiniai neuroniniai tinklai, dirbtiniai neuroniniai tinklai, emisijų prognozavimas, vidaus degimo varikliai

Summary

This study examines the contactless emission prediction of internal combustion engines using artificial neural network models and statistical methods. Given the increasing requirements for emission reduction and transport electrification, there is a growing need for efficient emission monitoring and forecasting technologies, particularly in the industrial, energy, and heavy transport sectors, where internal combustion engines will remain essential. During the study, an experimental test stand was designed and built, utilizing a diesel generator to analyze the number of particulate emissions. The stand was equipped with specialized measuring instruments, including accelerometers for vibration measurement, a sound level meter, an infrared camera, and a particle analyzer for exhaust emissions. The collected experimental data was processed and used for the study. For analysis, a transformer-based artificial neural network model was selected. To compare its efficiency, a recurrent LSTM model and a statistical ANCOVA model were also tested. The study aimed to evaluate the effectiveness of transformer models in predicting particle emissions in a contactless manner, utilizing engine vibrations, sound levels, and thermal imaging data. Experimental results revealed that transformer models achieved the highest prediction accuracy, outperforming other methods. Based on this information, a modular model system was developed that can independently interpret all types of data collected during the experiment and integrate predictions into a unified forecast. The combined transformer model achieved 96.59% accuracy, successfully predicting varying concentrations of particulate emissions, surpassing LSTM and ANCOVA models, which attained 62.34% and 61.82% accuracy, respectively. Infrared images contributed the least to the overall prediction, demonstrating the lowest accuracy at 86.3% among separate data types.

Keywords: transformer networks, recurrent neural networks, artificial neural networks, emission prediction, internal combustion engines

Turinys

Ivadas	4
1. Vidaus degimo variklių emisijos	6
1.1. Vidaus degimo variklių emisijų sudėtis ir jų poveikis	6
1.2. Tradiciniai emisijų matavimo metodai	7
2. Giliųjų neuroninių tinklų taikymas vidaus degimo variklių emisijų vertinime	10
2.1. Variklių gedimų aptikimas	10
2.2. Emisijų matavimas pasitelkiant neuroninių tinklų modelius	11
3. Gilieji neuroniniai tinklai ir statistiniai metodai	13
3.1. Statistiniai metodai	13
3.2. Laiko eilučių ir signalų apdorojimo metodai naudojant giliuosius neuroninius tinklus ...	15
3.3. Transformaciniai laiko eilutės prognozavimo modeliai	17
4. Vaizdo apdorojimas naudojant konvoliucinius neuroninius tinklus	21
4.1. Spektrogramų generavimas iš IR nuotraukų	21
4.2. Konvoliucinių neuroninių tinklų taikymas spektrogramų ir histogramų analizei	21
5. Eksperimento atlikimas ir metodologija	25
5.1. Stendas	25
5.2. Duomenų apdorojimas ir analizė	28
5.3. Modelių sistema ir apmokymas	32
6. Sukurtos modelių sistemos palyginimas	37
6.1. Modelių palyginimas	37
6.2. Privalumai ir trūkumai	43
Rezultatai ir išvados	44
Literatūra	45
Santrumpos	52
Priedas Nr.1	

sectionPriedas Nr.2

Ivadas

Vidaus degimo varikliai yra vieni iš labiausiai naudojamų variklių transporto priemonėse. Kuriamos naujos technologijos ir gamybos metodai paskatino vidaus degimo variklių tobulėjimą, kuris pasireiškė padidėjusia variklio galia, našumu bei išskiriamomis mažesnėmis ekologinėmis emisijomis ir didesniais energiniais parametrais. Pastaraisiais metais tobulėjant automobilių elektrifikacijai, vis daugiau parduodama elektrinių automobilių [Com23]. Jų eksploatacijos metu išskiriamos emisijos yra lygios nuliui. Be to, Europos Sąjungos direktyvos nurodymu, visi nauji automobiliai su vidaus degimo varikliais, registruojami nuo 2035 metų, turės išskirti 0 kenksmingų emisijų [Age23]. Šie pokyčiai skatina transporto sektoriaus transformaciją, tačiau vidaus degimo variklių emisijų mažinimas išlieka svarbiu tikslu, ypač komerciniuose ir pramoniniuose taikymuose, kur elektrifikacija vis dar yra technologiškai ir ekonomiškai sudėtinga. Keliuose yra dar daug senesnės gamybos automobilių, kurie didina oro taršą. Be to, vidaus degimo varikliai dar ilgai dominuos didelių gabaritų transporto priemonėse ar specializuotuose pramonės įrenginiuose ar elektros generatoriuose. Norint sumažinti šių variklių emisijas, pradėta ieškoti kuro alternatyvų ar kuro priedų, kurie padėtų sumažinti kuro degimo procese išskiriamą taršą [JB20]. Šis procesas yra gana lėtas ir sudėtingas, nes mažiausi pakeitimai gali pakeisti variklio darbo sklandumą, galią ir jo išmetamųjų dujų kiekius bei sudėtį. Vilniaus Gedimino technikos universiteto Mechanikos mokslo institutas atlieka bandymus su komerciniais automobilių varikliais bei industriniais generatoriais, siekiant rasti kuro priedus, kurie sumažintų emisijas ir išlaikytų tas pačias gaunamas energines vertes. Šie bandymai yra atliekami jau keletą metų, kontroliuojamomis sąlygomis, pasitelkiant variklių standus su parengtais matavimo prietaisais, kaip emisijų matuokliai, vaizdo kamera, infraraudonųjų spindulių kamera, virpesių bei garso davikliais, sumontuotais į mikrofoną. Bandymų metu atliekami emisijų, tokių kaip CO₂, NO, NO₂, kiekių matavimai, fiksuojamos variklio skleidžiamos vibracijos, garso slėgis, fiksuojami variklio darbo vaizdai. Visi gauti eksperimentiniai duomenys yra surenkami pasitelkiant specialią programinę įrangą, skaitmenizuojami, apdorojami ir saugomi. Analizuojant šiuos duomenis yra stebima galima koreliacija tarp išskiriamų emisijų ir variklio skleidžiamų vibracijų [ŽVM⁺21]. Kyla klausimas, ar naudojant neuroninių tinklų technologijas galima sukurti modelį, kuris su pakankamu tikslumu gebėtų prognozuoti skirtingų variklių išskiriamas emisijas, remdamasis bekontakčiais variklio veikimo metu surenkamais duomenimis? Pastaruoju metu, dirbtinių neuroninių tinklų technologijos tampa vis populiaresnės. Šių technologijų taikymas neapsiriboja tik vaizdų apdorojimu, atpažinimu, objektų klasifikavimu ar natūralios kalbos analize (LLM) – naujosios neuroninių tinklų technologijos vis dažniau naudojamos sudėtingų fizikinių procesų modeliavimui. To pasekoje, pritraukiama vis daugiau investicijų ir finansavimo tyrimams, kaip šias technologijas patobulinti. Kompiuterinių komponentų tobulėjimas leidžia atlikti vis sudėtingesnius skaičiavimus ir naudoti sudėtingesnius, gilesnius neuroninius tinklus. Transformerių neuroniniai tinklai sulaukia vis daugiau dėmesio dėl gebėjimo apdoroti didelius kiekius duomenų ir yra pritaikomi vis daugiau pramonės bei verslo sričių. Tad atsiranda galimybių šiuos modelius pritaikyti ir tokiam uždaviniui, kaip variklio išmetamųjų dalelių kiekio prognozei. Nauji transformeriais pagrįsti laiko eilutės modeliai, kaip Autoformer [WXW⁺22] atveria naujas galimybes šioje srityje. Tačiau dar nėra aišku, kokią naudą

praktinėse srityse, remiantis tikrais duomenimis, jie atneša, palyginus su jau seniai žinomais ir naudojamais modeliais kaip LSTM ar statistiniais modeliais kaip ANCOVA. Remiantis darbo [SRR23] autorių pateiktais rezultatais, galime pastebėti, jog Autoformer modelis geba pranokti LSTM modelį standartiniuose prognostiniuose uždaviniuose. Todėl atliekant šį tyrimą, šis modelis ir buvo pasirinktas. Autoformer modelio pritaikymas buvo įgyvendintas naudojantis "Python" programavimo kalba, bei "PyTorch" modelių biblioteka. Modelių treniravimui buvo naudojamos optimizavimo bibliotekos, tokios kaip "Adam" ir "Scheduler", siekiant užtikrinti greitą ir efektyvų modelių apsimokymą. Duomenų apdorojimui ir formatavimui buvo sukurta speciali programinė įranga. Eksperimentiniai bandymai buvo atlikti Vilniaus Gedimino technikos universiteto Mechanikos mokslo institute, naudojantis jų turima "Bruel&Kjaer" specializuota įranga, bei dyzeliniu generatoriumi. Sukurtos modelių sistemos apmokymas bei tikslumo įvertinimas buvo atliktas pasitelkiant asmeninį kompiuterį, su "Nvidia RTX 3060m" grafiniu procesoriumi. Atsižvelgiant į šiuos aspektus, šiame darbe bus nagrinėjama, kaip skirtingi neuroninių tinklų modeliai gali būti pritaikomi vidaus degimo variklių emisijų prognozavimui. Šiuo tikslu sukurta ir išbandyta prognostinių modelių sistema, paremta eksperimentiniais, tyrimo metu surinktais duomenimis.

Darbo tikslas: Palyginti transformerių neuroninių tinklų, rekurentinių tinklų ir statistinius modelius, jų taikymo galimybes vidaus degimo variklių emisijų prognozavimui, įvertinant jų efektyvumą ir prognozavimo tikslumą.

Darbo uždaviniai:

1. Atlikti prognostinių mašininio mokymosi modelių literatūros apžvalgą siekiant nustatyti galimas naudoti neuroninių tinklų technologijas laiko eilučių (signalų) bei vaizdo apdorojimo uždaviniuose.
2. Sukurti prognostinių Autoformer transformerių neuroninių tinklų sistemos algoritmo architektūrą, pritaikytą specifiniams eksperimentiniams duomenims.
3. Ištreniruoti sudarytą prognostinių Autoformer transformerių modelių sistemą, pasitelkiant eksperimento metu gautais duomenimis.
4. Ištestuoti sukurta prognostinių transformerių modelių sistemą, naudojant jai nematytus eksperimentinius duomenis.
5. Palyginti gautus rezultatus su LSTM rekurentiniu neuroniniu tinklu ir ANCOVA statistiniu modeliu.
6. Įvertinti sukurtos modelių sistemos rezultatus, nustatyti jos privalumus ir trūkumus, bei parengti apibendrinančias išvadas.

1. Vidaus degimo variklių emisijos

1.1. Vidaus degimo variklių emisijų sudėtis ir jų poveikis

Vidaus degimo variklių kontekste, emisijos tai taršiųjų dalelių patekimas į aplinką variklio darbo metu pro išmetamąjį dujų vamzdį. Tai yra svarbus variklio darbo pašalinis produktas, į kurį taip pat gali įeiti karterio ventiliacijos dujos ar nepanaudoto benzino garavimas. [OKK14]. Variklio skleidžiamų emisijų kiekis priklauso nuo kelių veiksnių [May19]:

- Variklio efektyvumo.
- Variklio kuro tipo.
- Kuro kokybės ir sudėties
- Variklio būklės ir nusidėvėjimo

Kiekvienas iš šių veiksnių gali padidinti ar sumažinti išmetamųjų dujų kiekį. Moderniuose automobiliuose su dyzeliniu varikliu, siekiant sumažinti taršalų kiekį, pasitelkiami ne vien DPF (kietųjų dalelių) filtrai, EGR vožtuvai (skirti pakartotinai cirkuliuoti išmetamąsias dujas atgal į vidaus degimo kamerą), bet ir kuro priedai kaip „AdBlue“. [May19].

Emisijų sudėtis


Vidaus degimo variklių didžiausią dalį išmetamųjų dujų sudaro [AUD00]:

- Azotas N_2 .
- Vandens garai H_2O .
- Anglies dioksidas CO_2 (išskyrus kurus be anglies).

Šios medžiagos savaime nėra toksiškos, tačiau vandens garai ir anglies dioksidas yra šiltnamio efektą sukeliančios dujos, kurios prisideda prie klimato kaitos. Likusioji dalis dujų yra nepageidaujamos, kenksmingos ar toksiškos medžiagos, tokios kaip:

- Anglies monoksidas CO .
- Angliavandeniliai C_xH_y .
- Azoto oksidai NO_x
- Suodžiai

Šios medžiagos susidaro dėl nepilno sudėgimo variklio vidaus degimo kameroje ir temperatūros trūkumo degimo metu arba pertekliaus [AUD00].



1 pav. Dyzelinių variklių emisijų sudėtis [AUD00]

Emisijų poveikis

Vandens garai bei CO_2 dujos prisideda prie šiltnamio efekto kūrimo ir paspartina klimato kaitą. CO_2 dujų išskyrimo galima būtų išvengti naudojant pakaitinius kurus, kurių sudėtyje nėra anglies molekulių, tačiau tokie kurai yra labai brangūs arba gan sudėtingai išgaunami, stabdant juos nuo plataus vartojimo [AUD00].

Azoto oksidai NO_x reaguoja su amoniaku, drėgme ir kitomis medžiagomis, suformuodami azoto rūgšties garus. Garų dalelės gali giliai prasiskverbti į jautrius plaučių audinius ir juos pažeisti, kartais net sukelti mirtį [HLC⁺15]. Azoto oksidų junginių įkvėpimas padidina plaučių vėžio riziką bei gali sukelti arba pabloginti kvėpavimo takų ligas, tokias kaip emfizema ir bronchitas, bei širdies ligas [TKD17].

Anglies monoksidas CO yra viena iš dažniausių mirtinų oro apsinuodijimo priežasčių daugelyje šalių. Šios bespalvės, bekvapės ir beskonės dujos yra labai toksiškos, nes blokuoja deguonies pernešimą organizme. Koncentracijos virš 1000 ppm laikomos itin pavojingomis. Tokios koncentracijos gali susidaryti, kai vidaus degimo varikliai veikia prastai vėdinamose patalpose [Oma02].

1.2. Tradiciniai emisijų matavimo metodai

Išmetamųjų dujų analizatorius

Tai standartinis, industrijoje daug metų naudojamas analizatorius, kuris naudojamas išmatuoti išmetamųjų dujų sudėtį. Tokie matuokliai yra naudojami automobilių techninės apžiūros centruose [Mar22].

PEMS (nešiojamoji emisijų matavimo sistema)

Tai naujasis Europos Komisijos naudojamas emisijų matavimo įrenginys, skirtas nustatyti automobilių EURO standartus. Tai nešiojama sistema, kuri gali būti laikoma automobilio kroviniame skyriuje. Matavimai atliekami automobiliui važiuojant pro nustatytą maršrutą. Taip gaunami duomenys, kurie arčiau atitinka realybę [Mar22].

SEMS (išmanioji emisijų matavimo sistema)


Šis matuoklis taip pat naujai pradėtas naudoti Europos Komisijos. Kadangi PEMS yra trumpalaikis matuoklis, atsirado poreikis ilgalaikių emisijų matavimų duomenims ir kaip jos keičiasi priklausomai nuo temperatūros ir variklio dėvėjimosi. Sistema yra maža, kompaktiška ir lengva [Mar22].

Bekontakčiai metodai matuojant emisijas

Infraraudonųjų spindulių kameros

Šiuo metu Europoje yra palitęs vienas bekontaktis išmetamųjų dujų matavimo būdas, kuris pasitelkia infraraudonųjų spindulių kameras. Strategiškai pastatytas šviesos šaltinis ir infraraudonųjų spindulių kamera geba aptikti automobilių iškiriamas išmetamąsias dujas. Tačiau, toks matavimas nėra tikslus ir dažnai naudojami šalia pastatyti greičio matuokliai, kurie matavimo duomenims suteikia daugiau konteksto ir tikslumo [Mar22].

Taip pat, [JSB⁺18] darbo autoriai nagrinėja karinių dyzelinių transporto priemonių išmetamųjų teršalų termines infraraudonųjų spindulių (IR) charakteristikas esant įvairioms variklio sąlygoms. Šis tyrimas suteikia vertingų įžvalgų apie dyzelinių išmetamųjų dujų šiluminę elgesį ir jų poveikį tiek civilinėms, tiek karinėms reikmėms. Tyrimui atlikti buvo pasitelkta termovizoriaus kamera, bei nešiojamas išmetamųjų dujų matuoklis. Transporto priemonės buvo pastatytos 50 metrų atstumu nuo termovizoriaus, o išmetamųjų dujų matavimai buvo atliekami naudojant dujų analizatorių, tuo pat metu įrašant terminius vaizdo įrašus.



2 pav. Išmetamųjų dujų vaizdas IR kameroje [JSB⁺18]

Tyrimas buvo orientuojamasi į pagrindinių išmetamųjų komponentų, tokių kaip CO, NO_x ir HC koncentracijos ir temperatūros matavimus. Rezultatai parodė, jog transporto priemonei dirbant

laisva eiga, išmetamųjų dujų koncentracija ir temperatūra laikui bėgant rodė minimalų kintamumą. Terminio vaizdo rezultatai rodė mažą išmetamųjų teršalų matomumą dėl žemesnės dujų temperatūros ir koncentracijos. Tačiau varikliui greitėjant buvo pastebėti reikšmingi pokyčiai, dėl aukštesnių išmetamųjų dujų temperatūros. Atlikto tyrimo rezultatai parodė, jog pasitelkus termovizoriaus kameras galima aptikti ir matuoti išmetamąsias dujas, tačiau vien iš termovizoriaus kameros gautų rezultatų, negalima brėžti aiškių išvadų. Šiuos duomenis reikia papildyti kitais matavimais arba juos naudoti, kaip papildomus duomenis kitiems matavimams.

Esamų technologijų apribojimai

Išmetamųjų dujų analizatoriai yra stacionarūs ir gana brangūs įrenginiai. Norint išgauti itin tikslius rezultatus, jie reikalauja daug laiko ir pasiruošimo. Tai sulėtina procesą ir užtrunka daug laiko. Problemų atsiranda daugiau, kai norima matuoti automobilius realiomis sąlygomis. Tada automobilis turi būti statomas ant dinamometro, jog būtų apkrova, tačiau automobilis vis tiek nejudėtų. Ši įranga yra taip pat brangi ir užima daug vietos. Šias problemas sprendžia PEMS matuokliai, tačiau jų tikslumas yra žymiai mažesnis. Negana to, jie yra gan sunkūs, todėl atliekant matavimus judančiame įrenginyje jų svoris daro įtaką matavimo duomenims. Šią problemą sprendžia SEMS matuokliai, tačiau dar mažesnio tikslumo kaina.

2. Giliųjų neuroninių tinklų taikymas vidaus degimo variklių emisijų vertinime

Emisijų matavimo problemoms galima pasitelkti giliųjų neuroninių tinklų technologijas. Tai naujai nagrinėjama pritaikymo sritis, kuri yra sparčiai nagrinėjama. Nors komercinių panaudojimų šioje srityje dar nėra, jau yra atliekami bandymai.

2.1. Variklių gedimų aptikimas


Variklio komponentų gedimų diagnostika yra sudėtinga užduotis. Taip yra dėl sudėtingos vidaus degimo variklių konstrukcijos. Gendant variklio komponentams mažėja variklio našumas ir padidėja priežiūros išlaidos.

Darbo [JP14] autoriai tyrinėjo motociklų variklių gedimus. Gedimų nustatymams jie pasitelkė garso duomenų parametrais, skleidžiamais darbo metu. Surinkti garso vibracijų duomenys buvo apdoroti taip pat pasitelkus greitąją Furjė transformaciją bei trumpalaikę Furjė transformaciją. Patys gedimai buvo klasifikuoti pasitelkiant SVM (atraminių vektorių klasifikatorius) bei sukūrus tiesioginio sklido (feedforward) ir atgalinio sklido (back-propagation) dirbtinių neuroninių tinklų modelį su 6 įvestimis, 1 paslėptu sluoksniu ir 2 išvestimis. Dirbtinių neuroninių tinklų modelis gebėjo aptikti gedimus 98,1% tikslumu, o SVM 99,9% tikslumu.

Tačiau [HTG⁺20] darbo autoriai, tirdami dyzelinių variklių galios, emisijų vibracijų bei kitų parametrų nustatymą gavo kitokius rezultatus. Pasitelkiant daugiasluoksnį perceptroną su tiesioginio sklido ir atgalinio sklido dirbtinių neuroninių tinklų modelį. Kaip ir [JP14] darbe, modelio architektūra išliko panaši - tačiau vietoje 1 paslėpto sluoksnio buvo naudojami 2, o modelis apmokamas pasitelkiant Levenbergo-Markardo algoritmą. Taip pat buvo padidintas apmokymo duomenų kiekis. Testavimo metu, sukurtas modelis pademonstravo 99,95% procentų tikslumą, nuspėjant vibracijų parametrus. Remiantis šiais šaltiniais galime daryti išvadą, jog vibracijų interpretavimo užduotyje, neuroninių tinklų modelis geba pasiekti geresnius rezultatus, nei statistiniai metodai. Tačiau, svarbu turėti pakankamą kiekį duomenų bei optimizuotą apmokymo procesą.

Tyrimo [RCA22] autoriai pristato potencialią gedimų diagnostikos techniką, skirtą nustatyti ir diagnozuoti dyzelinio variklio komponentuose susiformavusius įtrūkimus ir trinties žymes. Variklių vibracijos, skleidžiamas garsas bei emisijų duomenys buvo panaudoti variklio gedimams nustatyti. Šie parametrai buvo analizuojami laiko, dažnio ir laiko–dažnio srityse, naudojant duomenų apdorojimo metodus, tokius kaip greitoji Furjė transformacija (FFT) ir trumpalaikė Furjė transformacija (STFT), tuo pačiu pagrindu kaip [JP14] darbe, jog būtų galima supaprastinti įvesties duomenis ir labiau išryškinti svarbius skirtumus bei detales. Taip pat buvo renkama statistika ir pagrindiniai požymiai, kurie padėtų nustatyti gedimų rimtumą, remiantis gautais duomenimis. Tyrimo metu taip pat buvo sukurtas tiesioginio sklido ir atgalinio sklido dirbtinių neuroninių tinklų modelis su 4 įvestimis, 4 paslėptais sluoksniais ir 4 išvestimis, skirtas prognozuoti ir klasifikuoti variklio komponentuose susiformavusius įtrūkimus bei trinties žymes. Rezultatai parodė, kad FFT ir STFT technikos pagerina variklių diagnostikos rezultatus ir suteikia daug naudingos informacijos diagnostikai atlikti. O sukurti neuroninių tinklų modeliai efektyviai klasifikavo variklio

komponentuose susiformavusius įtrūkimus su 100% tikslumu.



3 pav. Vibracijų stiprumo šuolis lyginant gerą ir nusidevėjusį variklį [RCA22]

Atlikti tyrimai parodė, jog turint nedidelį duomenų kiekį, sprendžiant variklių vibracijų uždavinį, statistiniai metodai gali pralenksti dirbtinių neuroninių tinklų modelius [JP14], tačiau pasitelkus sudėtingesnius modelius, su daugiau paslėptų sluoksnių bei didesnį apmokymo duomenų rinkinį, pasiekiami dar geresni rezultatai [HTG⁺20]. [RCA22] darbas parodo, jog dar didesnis tikslumas gali būti pasiekiamas naudojant dar sudėtingesnę modelį, tačiau prieš tai apdorojant duomenis pasitelkiant Furjė transformacijomis. Parametrų grupavimas yra taip pat svarbi detalė, parodanti, jog jei parametrų kiekis yra gan didelis, juos verta sugrupuoti, sumažinant modelio sudėtingumą ir pagerinant tikslumą.

2.2. Emisijų matavimas pasitelkiant neuroninių tinklų modelius

2018 metais Turkijos mokslininkai tyrė neuroninių tinklų galimybes ir panaudojimo atvejus, vieno cilindro dyzeliniams generatoriams tirti [UC18]. Tyrimo metu buvo sukurtas modelis, kurio įvestis buvo variklio apkrova, kurio mišinio santykis bei variklio sukimosi greitis. Išvesties parametrai buvo kuro suvartojimas, šiluminis efektyvumas emisijų dalelių koncentracija. Gauti rezultatai buvo įvertinti pasitelkiant vidutinės kvadratinės paklaidos (RMSE) skaičiavimais bei ir vidutinės santykinės paklaidos (MRE) skaičiavimais. Gauti rezultatai parodė vidutinę paklaidą išvesties parametrų apie 4%, o vidutinės kvadratinės paklaidos iki $0,964 r^2$. Tyrimas parodė, jog neuroniniai tinklai gali būti sėkmingai naudojami variklių parametrų apskaičiuoti. Nors darbo autoriai teigė, jog paklaidos buvo pakankamai mažos ir gauti rezultatai buvo labai perspektyvūs, panaudojus sudėtingesnę modelį bei skyrus daugiau laiko apmokymams bei optimizacijai, modelio tikslumas galėjo būti ir didesnis. Tai galima pamatyti [JSM⁺09] darbe. Darbo autoriai atliko bandymus didinant paslėptus sluoksnius, nuo 3 iki 9, bei išbandant mokymo algoritmus kaip suskirstytasis konjuguotųjų gradientų metodas (SCG) bei Levenbergo-Marquardto (LM) metodą. Taip pat buvo normalizuoti modelio įvesties parametrai, bei išvesties parametrai. Anot darbo autorių, duomenų normalizavimas padėjo jų sukurtam modeliui veikti tiksliau. Pasitelkus neuroninių tinklų modelį buvo matuojamas kuro suvartojimas, šiluminis efektyvumas, išmetamųjų dujų temperatūra bei kuro ir oro mišinys. Gauti rezultatai parodė modelio vidutinės kvadratinės paklaidos

0.999 r^2 ir vidutinės paklaidos reikšmės 0,01%. Nors [JSM⁺09] darbas buvo atliktas seniau nei [UC18], jis tik parodo, kaip optimizavus modelį, bei apmokymo procesą, galima išgauti žymiai tikslesnius skaičiavimus.

2021 metais atliktas tyrimas [BTS21] nagrinėja amoniako NH_3 kaip kuro priedo poveikį dyzeliniuose varikliuose, naudojant saulėgrąžų biodyzelino kurą. Tyrimo metu matuojamos variklio vibracijų charakteristikos, pasitelkiant akselerometrus, sudėtus trejomis ašimis - X, Y, Z. Amoniakas yra žinomas dėl savo didelio potencialo kuro sektoriuje ir vaidmens mažinant kenksmingas emisijas, todėl yra įdomi alternatyva, nepaisant riboto panaudojimo šiomis dienomis. Darbo autoriai atliko eksperimentus naudodami „Mitsubishi Canter“ „4D31“ dyzelinį variklį. Variklis veikė laisva eiga, be apkrovos, tačiau buvo keičiami variklio sūkliai. NH_3 buvo sumaišytas su saulėgrąžų biodyzelinu. Tyrimo metu tikrintos 3 amoniako koncentracijos kiekiai: 5%, 10% ir 15%. Dirbtinių neuroninių tinklų modelis buvo sukurtas siekiant nustatyti Z ašies vibracijas, naudojant X ašies, Y ašies, laiko ir variklio sūkių duomenis. Sukurtas modelis pasitelkė keletą paslėptų sluoksnių ir prižiūrimo mokymo algoritmą, paremtą vidutinės paklaidos bei vidutinės kvadratinės paklaidos skaičiavimais. Jei modelis nesugebėjo pateikti atitinkamai tikslų išvesties parametru, lyginant su įvesties duomenimis, mokymas buvo kartojamas. Sukurtas giliųjų neuroninių tinklų modelis pasižymėjo dideliu tikslumu prognozuojant eksperimentinius vibracijos duomenis, tikslumo rodikliai buvo 99.206%, 99.675% ir 99.505% atitinkamai 5%, 10% ir 15% NH_3 mišiniams. Nors iš pirmo žvilgsnio, tai atrodo prastesni rezultatai, negu [JSM⁺09] darbe sukurto modelio, tačiau matuojami parametrai buvo sudėtingesni ir sunkiau nuspėjami. Taip pat šiems parametrams didesnę įtaką daro išorės veiksniai, tad rezultatų tikslumo vertinimą galima artimiau vertinti su [UC18] darbo metu sukurtu modeliu.

Atlikti darbai parodo, jog neuroniniai tinklai gali būti sėkmingai panaudoti matuojant įvairius variklių parametrus bei išskiriamus šalutinius produktus. Tačiau modelio tikslumas bei efektyvumas, kaip parodyta darbuose [JSM⁺09] ir [BTS21], priklauso nuo modelio optimizacijų bei jų apmokymų. Taip pat verta pastebėti, jog duomenų normalizavimas gali dar padidinti modelio tikslumą [JSM⁺09]. Tačiau net naudojant paprastus modelius, su nesudėtingais apmokymo algoritmais, pasiekiami neblogi rezultatai [UC18].


3. Gilieji neuroniniai tinklai ir statistiniai metodai

3.1. Statistiniai metodai

Statistiniai metodai yra esminiai įrankiai, naudojami duomenų analizei, interpretacijai bei prognozei. Jie padeda suprasti sudėtingus duomenų rinkinius, nustatyti tendencijas ir sudaryti pagrįstas išvadas. Šie metodai apima įvairias technikas ir modelius, kurie gali būti taikomi emisijų prognozavimo užduočiai. Vieni populiariausių statistinių metodų yra Principinių komponentų regresijos technika (PCR) ir Kovariančių analizė (ANCOVA).

Principinių komponentų regresijos technika (PCR)

Principinių komponentų regresija (PCR) yra populiari technika, naudojama statistiniuose modeliuose siekiant spręsti daugiakolinearumo problemą didelės apimties duomenyse. Principinių komponentų regresija apjungia principinių komponentų analizės techniką (PCA) bei linijinę regresiją, siekiant sumažinti kintamųjų skaičių ir išvengti duomenų pertekliaus [JC16]. Principinių komponentų analizė transformuoja originalius kintamuosius į naują statmenų rinkinį (orthogonals), kuris išlaiko duomenų įvairovę [BW10]. Pasirenkant kelis pirmuosius pagrindinius komponentus, atspindinčius didžiausius skirtumus tarp duomenų jie naudojami kaip įvesties kintamieji linijinėje regresijoje [LKA17]. Tai padeda išspręsti nepriklausomų kintamųjų koreliacijos problemą, nes pagrindiniai komponentai tarpusavyje nekoreliuoja. Nepaisant privalumų, kaip daugiakolinearumo problemos išsprendimas ir gebėjimas naudoti didelį kintamųjų skaičių, ši technika turi ir trūkumų, tokių kaip: sudėtinga pagrindinių komponentų interpretacija bei informacijos praradimas, jei neįtrauki visi pagrindiniai komponentai.




4 pav. Atvejai, kada PCR yra netinkama technika [LKA17]

ANCOVA

Kovariančių analizė (ANCOVA) yra statistinis metodas, kuris susideda iš dispersinės analizės (ANOVA) ir regresijos analizės. Kovariančių analizė yra naudojama siekiant įvertinti pagrindinių veiksnių įtaką priklausomam kintamajam, kartu kontroliuojant lydinčiuosius kintamuosius (covariates). Šis metodas yra naudingas, kai tyrime yra kintamųjų, kurie gali skirtis tarp grupių ir daryti įtaką rezultatams, nes kovariančių analizė leidžia šiuos skirtumus koreguoti ir pašalinti [Kep91]. Nors kovariančių analizė turi daug privalumų, tokių kaip didesnis tyrimo tikslumas ir tikslesnis

duomenų interpretavimas, svarbu atkreipti dėmesį į prielaidas - lydinčiuosius kintamuosius, nes nuo jų gali stipriai kisti rezultatai.

Kovariančių analizė buvo pritaikyta vidaus variklių emisijų prognozavimui pasitelkiant variklio vibracijas. Darbo autoriai [ŽVM⁺21] pritaikė vibracijų duomenis kaip lydinčius kintamuosius prognozuoti vidaus variklio emisijoms. Gauti rezultatai parodė, jog kovariančių analizė didelių tikslumu gebėjo nuspėti emisijas, tačiau tik kai variklis veikė dideliu pajėgumu. Dirbant mažesniu pajėgumu, tikslumas krito.



5 pav. Kovariančių analizės metodo tikslumas nustatant NO_x kiekį [ŽVM⁺21]

Darbe [FRH⁺22] autoriai tiria anglies pluoštų spausdinimą, juos tvirtinant su epoksidine derva. Sukurti maketai yra vertinami, stengiantis nuspėti jų tvirtumą ir kitas savybes pasitelkiant gamavimo laiką, vakuumo stiprumą ir medžiagos storumą kaip įvesties parametrus. Savybės buvo nustatomos keliais būdais - sukuriant dirbtinį neuronų tinklą, sudarytą iš įvesties, kelių paslėptų ir išvesties sluoksnių, dispersinės analizės (ANOVA) skaičiavimais bei pasitelkiant atsako paviršiaus metodiką (RSM). Gauti rezultatai parodė jog pasitelkiant atsako paviršiaus metodiką, buvo pasiektas 91% tikslumas, pasitelkiant ANOVA skaičiavimais - 95%, o pasitelkiant dirbtiniais neuronų tinklais - 97,5%. RSM tikslumas buvo mažesnis dėl matavimo instrumentų paklaidų. Taikant ANOVA metodą pastebėta, jog atliekant skaičiavimus tapo greitai aišku, kurie lydintieji kintamieji darė didžiausią įtaką rezultatams ir žinant šias prielaidas buvo galima manipuluoti rezultatais, tačiau verta paminėti, jog tikslumas išliko vis tiek didelis. Tikėtina, jog dėl šių priežasčių ir darbe [ŽVM⁺21] buvo pasiektas mažas tikslumas dirbant mažesniu pajėgumu. Dirbtinis neuronų tinklas pasiekė geriausią tikslumą ir parodė gebėjimą gauti gerus rezultatus su nestandartiniais maketais. Tai galima priskirti neuronų tinklo gebėjimui ne tiek prisirišti prie tam tikrų lydinčiųjų kintamųjų, ko pasekoje gaunami tikslesni rezultatai, kai parametrai kinta. Šias išvagas patvirtina ir kiti darbai. Tiriant dirbtinių kraujagyslių sienelių buvo atliktas tyrimas, kuris lygino daugiavariosios dispersijos analizės (MANOVA) ir dirbtinio neuronų tinklo - daugiasluoksnio perceptrono (Multilayer perceptron) gebėjimą optimizuoti gamybos procesą - nustatyti gamybos parametrus, kurie paspartintų sienelių gamybą, tikslumą bei kokybę [RRC⁺23]. Gauti rezultatai parodė, jog kai dirbtinis neuroninis tinklas gebėjo nustatyti gamybos parametrus, panašius kaip MANOVA ir galėtų būti pakaitalas MANOVA, kai neatitinkamos statistinės prielaidos. Remiantis darbo rezultatais, galima daryti prielaidą, jog [ŽVM⁺21] rasti netikslumai gali būti išspręsti pasitelkiant giliuosius

neuroninius tinklus, o gauti rezultatai gali būti tikslūs generatoriui dirbant visais pajėgumais.

Sprendžiant pastatų energijos suvartojimo klausimą, buvo taip pat nagrinėjama, ar dirbtinių neuroninių tinklų modelis gebės geriau prognozuojant administracinio pastato šildymo energijos suvartojimą šešiose Maroko klimato zonose negu kovariančių analizės (ANCOVA) modeliai [ARL⁺23]. Rezultatai parodė, jog ANCOVA modeliai pasiekė koreliacijos koeficientą 0.90, tuo tarpu dirbtinis neuroninių tinklų modelis - 0.95. Didesnis tikslumas buvo pasiektas dėl jo gebėjimo apdoroti sudėtingus ryšius tarp kintamųjų ir pateikti tikslesnius rezultatus, negu statistiniai metodai.

Atlikti bandymai parodo, jog įprastai naudojami statistiniai metodai geba gerai prognozuoti duomenis, tačiau jų prisirišimas prie lydinčiųjų kintamųjų bei nestandartinių sąlygų atsiradimo gali paveikti jų tikslumą. Dėl šių priežasčių dirbtiniai neuroniniai tinklai yra gera, moderni alternatyva šių problemų sprendimui, kuri yra atsparesnė nestandartiniais duomenimis, tačiau verta paminėti, jog jų apmokymas ir duomenų paruošimas yra sudėtingesnis, kaip ir reikalaujantis daugiau pačių duomenų, o ir patys modeliai reikalauja optimizavimo pastangų.

3.2. Laiko eilučių ir signalų apdorojimo metodai naudojant giliuosius neuroninius tinklus

Naudojant integruotus giliųjų neuroninių tinklų modelius, tokius kaip LSTM, GRU, Seq2Seq, galima pasiekti reikšmingų rezultatų. Šie modeliai gerai veikia su laiko eilutės duomenimis bei sugeba sėkmingai ir gan tiksliai prognozuoti būsimas reikšmes. Pirminis jų pritaikymas buvo prognozuojant finansinius duomenis, medicininius signalus, gamybos procesų rodiklius ar vibracijas [ZCZ⁺22b].

Vidaus degimo variklių bekontaktis emisijų vertinimas ir optimizavimas yra dar viena sritis, kurioje galima pritaikyti šiuos giliuosius neuroninius tinklus. Tradiciniai metodai, tokie kaip emisijų cheminės sudėties analizė dažnai reikalauja sudėtingos įrangos ir gali būti neefektyvūs arba nepatikimi esant ekstremalioms sąlygoms. Todėl giliųjų neuroninių tinklų modeliai tampa vis populiareni, nes jie gali efektyviai apdoroti didelius duomenų kiekius, atpažinti sudėtingas emisijų pokyčių priklausomybes ir prognozuoti variklių veikimo parametrus be tiesioginio kontakto su išmetamosiomis dujomis.

Rekurentiniai neuroniniai tinklai (RNN) ir jų atmainos


Rekurentiniai neuroniniai tinklai (RNN) yra pravartūs darbui su duomenų sekomis, nes išlaiko informaciją apie ankstesnius laiko momentus. Paprasti tiesiniai neuronų tinklai taip pat „atsimena“ duomenis, tačiau jie atsimena tik tuos, kuriais buvo apmokyti [AW24]. Nors apmokymo metu RNN modeliai mokosi panašiai, jie taip pat išlaiko informaciją apie duomenis, išmokus iš ankstesnių įvesčių, generuodami išvestis. RNN gali būti naudojami kelių tipų modeliuose [Sin24]:

- **Vektorių-sekų (Vector-Sequence) modeliai** - kaip įvestį jie naudoja fiksuoto dydžio vektorius ir sukuria bet kokio dydžio vektorius kaip išvestį.

- **Sekos-vektoriaus (Sequence-Vector Model) modelis** - kaip įvestį jie naudoja bet kokio dydžio vektorių ir sukuria fiksuoto dydžio vektorių kaip išvestį.
- **Sekos į seką (Sequence-to-Sequence) modelis** - tai populiariausias ir dažniausiai naudojamas tipas, kai seka naudojama kaip įvestis ir išvedama kita skirtingo dydžio seka kaip išvestis.


Iš sekos į seką modeliai yra pravartūs užduotims, kaip laiko eilučių prognozavimas, kai reikia numatyti kelis žingsnius į priekį. Sekos į seką modeliai dažnai naudoja auto-enkoderio-auto-dekoderio architektūrą, kuri susideda iš dviejų rekurentinių neuroninių tinklų arba ilgos trumpalaikės atminties modelio. Auto-enkoderis apdoroja įvesties seką ir sukuria vektorių, kuris reprezentuoja visą įvesties seką, o auto-dekoderis šį vektorių generuoti išvesties seką [SVL14]. Tačiau, tokie tradiciniai rekurentiniai neuroniniai tinklai, dėl nykstančių gradientų problemos neišlaiko ilgalaikių priklausomybių [AW24].

Patobulintos RNN versijos, tokios kaip Ilgos trumpalaikės atminties modelis (LSTM) ir Sklendžių rekurentinių vienetų modelis (GRU), padeda dalinai išspręsti šią problemą pasitelkiant sklendes, kurios leidžia suvaldyti ir paskirstyti informacijos srautą ir geriau išlaikyti ilgalaikes priklausomybes. GRU modeliai yra supaprastinta LSTM versija su mažesniu skaičiumi sklendžių, tačiau išlaiko panašų efektyvumą ir reikalauja mažesnių skaičiavimo išlaidų [CvMB⁺14].



6 pav. GRU užmaršties sklendė [CvMB⁺14]

Ilgos trumpalaikės atminties modelis (LSTM) modeliai turi įvesties, užmaršties ir išvesties sklendes, kurios paskirsto informacijos srautą per neuronų tinklą, taip išlaikant informaciją per ilgus laiko tarpus. Tai dalinai išsprendžia nykstančio gradiento problemą, tačiau ne pilnai. Jų atmintis gali išlikti tūkstančius laiko žingsnių, tačiau vėliau vėl atsiranda nykstančio gradiento problema [HS97]. Be to, kaip ir paprasti rekurentiniai neuroniniai tinklai, ilgos trumpalaikės atminties modeliai užtrunka ilga laiką apmokyti. Jų įvestis yra apdorojama vienos sekos, o tai nėra efektyvu, ypač moderniais laikais, naudojant grafinius procesorius (GPU) su daug skaičiavimo branduolių, kurie yra sukurti lygiagrečiams skaičiavimams [AW24].



7 pav. LSTM pasikartojantis modulis [AW24]

3.3. Transformaciniai laiko eilutės prognozavimo modeliai

Pagrindinės rekurentinių neuroninių tinklų problemos yra - nykstančių gradientų ir ilgo apmokymo laiko. Pirmosios transformacinių modelių užuomazgos buvo paminėtos darbe [LPM15]. Transformaciniai modeliai pirmą kartą paminėti darbe [VSP⁺17]. Tai yra pažangūs prognozavimo dirbtinio intelekto modeliai, kurie naudoja transformerių architektūrą laiko eilutėms analizuoti ir prognozuoti. Transformaciniai modeliai buvo pirma sukurti natūralios kalbos analizei, bei apdorojimui, tačiau dėl jų universalumo, juos buvo galima pritaikyti ir kitose srityse. Darbo [VSP⁺17] autoriai, kurie buvo „Google“ darbuotojai, ne vien pristatė transformerių architektūrą, tačiau ir kaip pasitelkiant naujai pristatytą dėmesio mechanizmą, galima šiuos modelius pritaikyti įvairiems poreikiams bei itin dideliems apmokymų duomenims. Pagrindinis šių modelių privalumas nykstančių gradientų bei lygiagretinimo problemų išsprendimas [AW24]. Šių modelių populiarumas auga ir iki šių dienų.

Pagrindiniai transformacinių modelių architektūros elementai:

Dėmesio mechanizmas. Tai yra vienas esminių transformerių architektūros komponentų, kuris leidžia modeliui sutelkti dėmesį į svarbias įvesties duomenų dalis ir atsiriboti nuo mažiau svarbių dalių, taip sumažinant triukšmą ir padidinant tikslumą. Šis mechanizmas tapo itin naudingas apdorojant labai didelius duomenų kiekius ir kuriant didelius natūralios kalbos modelius, nes padeda efektyviai apdoroti ilgas duomenų sekas ir pagerina modelio gebėjimą sujungti ilgalaikius ryšius tarp duomenų [VSP⁺17]. Dėmesio mechanizmas susideda iš 2 pagrindinių dalių:


- Dėmesio sutelkimo mechanizmas (Self-Attention)
- Daugelio dėmesio sutelkimo galvučių mechanizmas (Multi-Head Attention)

Dėmesio sutelkimo mechanizmas. Dėmesio sutelkimo mechanizmas, kaip teigia darbo autoriai, leidžia kiekvienam įvesties sekos elementui (ar tai būtų žodis ar signalas laiko eilutėje) įvertinti savo paties svarbą kitų sekos elementų atžvilgiu. Šis mechanizmas sukuria dėmesio svorių matricas, kurios rodo, kaip stipriai kiekvienas elementas susijęs su kitais. Tai ypač naudinga, kai reikia modeliuoti ilgalaikes priklausomybes ir atpažinti reikšmingus ryšius tarp sekos dalių [Dos21].

Daugelio dėmesio sutelkimo galvučių mechanizmas. Daugelio dėmesio sutelkimo galvučių mechanizmas papildo ir praplečia dėmesio sutelkimo mechanizmo galimybes, leidžiant modeliui turėti keletą „dėmesio sutelkimo galvučių“ (attention heads). Tai leidžia vienu metu, paraleliai, veikti keliems dėmesio sutelkimo mechanizmams. Kiekviena dėmesio sutelkimo galvutė mokosi apie skirtingus priklausomybių aspektus, todėl modelis geba geriau apdoroti sudėtingas ir įvairias duomenų struktūras. Dėl šių priežasčių padidėja modelio lankstumas ir gebėjimas išmokyti įvairius duomenų reprezentacijos aspektus [Her24].

Pozicinis kodavimas. Kadangi transformerių modeliai neturi sekos tvarkos informacijos, jie naudoja specifinį kodavimą pažymėti pozicijas duomenų sekos elementams. Taip elementams

suteikiama pozicinė informacija, kuri leidžia tiksliau ir logiškiau interpretuoti duomenis, bei juos atvaizduoti. Pozicinis kodavimas naudoja sinusoides ir ko-sinusoides funkcijas suteikdamas unikalius vektorius kiekvienai pozicijai duomenų sekoje. Šis mechanizmas suteikia galimybę modeliui atpažinti elementų tvarką sekoje, šokinėti tarp elementų bei teisinga tvarka apdoroti įvesties sekos duomenis [VSP⁺17].



8 pav. Transformacinio modelio architektūra [VSP⁺17]

Dėl savo unikalaus dėmesio sutelkimo mechanizmo, šie modeliai gali būti sėkmingai pritaikyti emisijų prognozavimo uždaviniui ir galimai gebėtų atskirti kelių variklių tipų duomenis, pavyzdžiui - dyzelinio variklio ir benzininio. Toks emisijų prognozavimo modelis galėtų būti nuolat plečiamas ir lengviau panaudojamas tolimesniems tyrimams ar net ir praktikoje. Tradiciškai, laiko-eilutės duomenų analizei, interpretacijai ir prognozei buvo naudojami rekurentiniai neuroniniai tinklai. Tad transformacinių modelių pritaikymas šiai užduočiai yra gan naujas, tačiau turi potencialo atlikti šias užduotis geriau. Tai galima pastebėti ir darbuose, kuriuose yra lyginami šie modeliai. Darbo [ZPK⁺19] autoriai palygino dvikrypčio ilgos trumpalaikės atminties modelio (BLSTM) modelio ir [VSP⁺17] aprašyto transformacinio modelio kalbos atpažinimo užduotyje. Pastebėta, jog BLSTM modelio apmokymas truko ilgiau, buvo mažiau stabilus ir buvo sunku išvengti persimokymo. Tačiau gerai atliko kalbos atpažinimo užduotį. Testuoto transformacinio modelio apmokymas buvo žymiai spartesnis ir stabilesnis. Tačiau siekiant kokybiško apmokymo buvo labai svarbus duomenų normalizavimas.

Žodžių klaidų rodiklis (Word Error Rate (WER))			
Modelis	LibriSpeech (1000h)	Switchboard (300h)	TED-LIUM v2 (200h)
BLSTM	2,56%	6,81%	3,03%
Transformer	2,51%	6.66%	2,81%

1 lentelė. Žodžių klaidų rodiklio rezultatai [ZPK⁺19]

Gauti rezultatai parodė, jog transformacinis modelis pasiekė geresnius rezultatus ir padarė mažiau klaidų. Taip pat pastebėta, jog didinant apmokymų epochų kiekį ir apmokymo duomenų rinkinį, transformacinio modelio tikslumas padidėjo 30%, tuo tarpu BLSTM tik 15%. Darbo rezultatai parodo, jog geresni rezultatai gali būti pasiekiami su transformaciniais modeliais, tačiau svarbu turėti didelį duomenų rinkinį. Šie duomenys buvo gauti kalbos atpažinimo užduotyje ir matomas transformacinių modelių pranašumas. Tačiau kyla klausimas ar šie modeliai išties geresni laiko eilutės uždaviniais spręsti. Darbe "Are Transformers Effective for Time Series Forecasting?" [ZCZ⁺22a] autoriai pateikia pastabas ir bandymus, kurie parodo, jog transformaciniai modeliai prastai geba prognozuoti vertes laiko eilučių uždaviniuose. Autoriai pateikia savo sukurta „DLinear“ LSTM rekurentinį modelį ir lygina jį su transformaciniu laiko eilutės modeliu „Autoformer“ [WXW⁺22]. Abu modeliai buvo apmokyti tais pačiais duomenų rinkiniais ir jų efektyvumas palygintas remiantis vidutine kvadratine paklaida (MSE) ir vidutine absoliučia paklaida (MAE).

Modelis	Traffic		Exchange-Rate		Electricity	
	MSE	MAE	MSE	MAE	MSE	MAE
„DLinear“	0.436	0.296	0.305	0.414	0.169	0.267
„Autoformer“	0.622	0.337	0.509	0.524	0.231	0.338

2 lentelė. „DLinear“ ir „Autoformer“ palyginimas duomenų rinkiniuose [ZCZ⁺22a]

Tačiau, remiantis skiltimi [Hyn06], prognozių spėjimas laiko eilutėse turėtų būti matuojamas naudojantis vidutine absoliučia skalės paklaida (MASE). Toks matavimas atsižvelgia į kelis svarbius parametrus:

- **Skalės invariantiškumas:** Vidutinis absoliutus skalės klaidos rodiklis (MASE) leidžia palyginti prognozes skirtingų dydžių duomenų rinkiniuose.
- **Prognozuojamas elgesys kai $y_t \rightarrow 0$:** MASE išvengia problemų su dalyba iš nulio, skirtingai nei su procentinėmis klaidomis, tokiomis kaip MAPE.
- **Simetrija:** MASE vienodai vertina teigiamas ir neigiamas prognozių klaidas bei vienodai baudžia klaidas didelėse ir mažose prognozėse.
- **Aiškumas:** Vertės didesnės nei vienetą rodo, kad naivus spėjimo metodas yra geresnis nei modelio prognozės.
- **Asimptotinis normalumas:** Dieboldo-Mariano testas parodo, kad MASE statistika artima normaliam paskirstymui, skirtingai nei kiti klaidų matavimo metodai.

Remiantis šiomis pastabomis galime iš naujo įvertinti modelių rezultatus. Tai buvo atlikta straipsnyje [SRR23]. Gauti rezultatai parodo, jog pasitelkus MASE metriką, transformacinis „Autoformer“ modelis generuoja tikslesnes prognozes negu rekurentinis „DLinear“ modelis.

Modelis	Traffic	Exchange-Rate	Electricity
	MASE	MASE	MASE
„DLinear”	0.965	1.690	0.831
„Autoformer”	0.910	1.087	0.751

3 lentelė. „DLinear” ir „Autoformer” palyginimas naudojant MASE [SRR23]

Vertinant rezultatus, matome jog nėra didelio skirtumo tarp transformacinių modelių bei rekurseinių laiko-eilutės uždaviniuose, tačiau tam tikrais atvejais, transformaciniai modeliai geriau ”atsimena” praeities įvykius ir tiksliau pastebi tendencijas. Šį gebėjimą ir nurodo [SRR23] rezultatai. Pasitelkus MASE matavimą, geriau perteikiamas modelio tikslumas prognozuojant tendencijas. Taip pat jie palaiko daugumos parametrų įvestį, kas šiame darbe gali būti labai pravartu.


4. Vaizdo apdorojimas naudojant konvoliucinius neuroninius tinklus

Konvoliuciniai neuroniniai tinklai yra plačiai paplitę vaizdų apdorojimui ir analizavimui. Jie yra ypač veiksmingi dėl savo gebėjimo automatiškai išmokyti ir išskirti svarbius vaizdo požymius, tokius kaip objekto kraštai, tekstūra ar patys objektai. Konvoliuciniai neuroniniai tinklai susideda iš kelių konvoliucinių sluoksnių, kurie naudoja filtrus vaizdų duomenų apdorojimui, taip pat sutelkimo sluoksnius, kurie sumažina vaizdo dydį, tačiau išlaiko svarbius bruožus [LBH15].


4.1. Spektrogramų generavimas iš IR nuotraukų

Spektrogramos yra vizualinės reprezentacijos signalų dažnių per tam tikrą laiką. Jos dažnai naudojamos duomenų analizėje bei vertinant įvairius inžinerinius ir mokslinius duomenis, įskaitant vidaus degimo variklių emisijas. Norint generuoti spektrogramas iš infraraudonųjų spindulių (IR) nuotraukų, būtina naudoti interferometrą, tada konvertuoti signalą į dažnių domeną naudojant Furjė transformaciją. Furjė transformacija paverčia laiko domeno signalus į dažnių komponentus, kurie vėliau gali būti atvaizduoti kaip spektrogramos. Šis procesas leidžia analizuoti signalo dažnių turinį ir aptikti galimus emisijų šaltinius bei modelius [BM21]. Alternatyviai galima naudoti FTIR sistemas, tačiau jos yra brangios ir sunkiai prieinamos.

Tad be specialios įrangos, generuoti spektrogramas yra sudėtingas iššūkis. Tačiau, histogramas galima sugeneruoti ir iš paprastų nuotraukų, ar šiuo atveju - infraraudonųjų spindulių nuotraukų. Tam pasiekti reiktų skaičiuoti nuotraukos kiekvieno pikselio spalvos intensyvumą. Duomenis reprezentuoti dvejomis ašimis, X ir Y. X - ašis atvaizduotų dažnį, o Y ašis atvaizduotų spalvos intensyvumą [AAR23].



9 pav. Emisijų spektrograma [BM21]



10 pav. Nuotraukos histograma [AAR23]

4.2. Konvoliucinių neuroninių tinklų taikymas spektrogramų ir histogramų analizei


Darbo [Pur22] autoriai sėkmingai pritaikė konvoliucinius neuroninius tinklus, muzikos žanro atpažinimui. Kūriniai, atitinkantys žanrus buvo atvaizduoti spektrogramomis. ResNet50 ir VGG16 modeliai buvo apmokyti naudojant tuos pačius apmokymo duomenis ir jų rezultatai palyginti. VGG16 modelis pasiekė 60% tikslumą, o ResNet50 - 40%. Tačiau darbo autorius naudojo

gan mažą apmokymo duomenų rinkinį ir nedidelį kiekį epochų, kas paveikia ResNet50 modelio tikslumą. ResNet50 modelis užtikrintai, dideliu tikslumu atpažino ramius žanrus kaip klasikinę muziką, tačiau nesugebėjo atpažinti tokių žanrų kaip rokas ar sunkusis metalas. Atitinkamai ir šių žanrų spektrogramos buvo pilnesnės pašalinių garsų ir trikdžių. VGG16 pasiekė daug tolygesnius rezultatus. Šias žinias galima pritaikyti ir emisijų analizei. Jei duomenų rinkimo metu galima pastebėti, jog išmetamųjų dujų spektrogramos yra gan aiškos ir tvarkingos, remiantis šio bandymo rezultatais, jų analizei vertėtų naudoti ResNet50 modelį. Tačiau jei jos turės daug triukšmo - VGG16. Panašūs rezultatai gauti ir kitame darbe [YS22], kurio autoriai atliko bandymą tirdami guolių gedimą, konvertuodami gautas vibracijas į spektrogramas, kartu pasitelkę gradiento klasės aktyvavimo žemėlapius (Grad-CAM), kurie leido paaiškinti giliųjų neuroninių tinklų pasirinkimą ir racionalumą jų klasifikavimui. Tyrimo metu buvo palyginti trys modeliai - VGG16, VGG19 ir ResNet50. Gauti rezultatai parodė, jog sėkmingiausias modelis iš visų buvo VGG19, kuris gebėjo atpažinti gedimus 99.92% tikslumu. Remiantis atliktais bandymais, matome, jog tinkamiausi modeliai spektrogramų ir histogramų vertinimo užduotyse yra VGG16, VGG19 bei ResNet modeliai. Tad verta pasigilinti į jos giliau.

VGGNET ir ResNet modeliai

VGGNet


VGGNet yra vienas iš žinomiausių konvoliucinių neuroninių tinklų variantų. Sukurtas Oxfordo universiteto mokslininkų, VGGNet pasižymi paprasta ir gilia architektūra, kurioje naudojami mažo dydžio (3×3) filtrai per kelis konvoliucinius sluoksnius. VGGNet architektūra yra gili, sudaryta iš 16-19 sluoksnių, kas leidžia modeliui atskirti sudėtingus objektų požymius. Ši architektūra taip pat naudoja maksimalaus sutelkimo sluoksnius, kurie sumažina vaizdo dydį, tačiau išlaikant svarbiausius požymius, ir padidina skaičiavimo efektyvumą [TN19].



11 pav. VGGNet architektūra [TN19]

Liekanų neuroninis tinklas (ResNet)

Liekanų neuroninis tinklas (ResNet), sukurtas „Microsoft Research“ mokslininkų, naudoja vadinamąsias liekanų jungtis, kurios leidžia efektyviau mokytis gilius tinklus, išlaikant gradientų stabilumą ir išvengiant nykstančių gradientų problemos. Šios jungtys leidžia sudaryti galias architektūras, turinčias šimtus sluoksnių, kurios geba veikti efektyviai ir tiksliai [KXS⁺16].



12 pav. Liekanų neuroninio tinklo architektūra [Kou23]

Tinklas prasideda su vienu 7x7 konvoliuciniu sluoksniu, kurio žingsnis yra lygus 2, po kurio atliekama rinkinio normalizacija ir pritaikoma dalimis tiesinio vieneto (ReLU) funkcija. Po šios pradinės konvoliucijos sluoksnio vykdoma sutelkimo imant maksimalią reikšmę operacija [HZR⁺15].

Po pradinio konvoliucinio sluoksnio, tinklas yra padalinamas į keturias pagrindines stadijas, kuriose yra kelios liekanų blokų serijos. Pats blokų skaičius skiriasi nuo konkrečios liekanų neuroninio tinklo konfigūracijos. Kiekvienoje stadijoje požymių žemėlapiu sumažinami perpus, o filtrų skaičius yra padvigubinamas, jog būtų išlaikomas pastovus laiko sudėtingumas tarp sluoksnių [HZR⁺15].

Tinklas baigiamas visuotiniu vidutiniu apjungimo sluoksniu, po kurio eina pilnai sujungtų sąryšių sluoksnis. Galiausiai taikoma eksponentinio normalizavimo funkcija, jog būtų gaunamas tikimybinis pasiskirstymas tarp klasių [Kou23].

VGGNet ir ResNet modelių palyginimas

2015 metų „ImageNet“ „ILSVRC2015“ konkurse, buvo palygintas tikslumas VGG16 ir ResNet modelių, naudojant „ImageNet“ duomenų rinkinį. Pagal rezultatus, nugalėjo ResNet152 modelis, parodęs tiksliausius rezultatus.

Modelis	Top-1 err.	Top-5 err.
VGG16	28,07	9,33
ResNet34	24,19	7,40
ResNet50	22,85	6,71
ResNet101	21,75	6,05
ResNet152	21,43	5,71

4 lentelė. ILSVRC2015 konkurso rezultatai [RDS⁺15]

2021 metais atliktas bandymas [MA21] tyrė produktų klasifikavimą pasitelkus konvoliucinius neuroninius tinklus. Palyginimo metu, visi modeliai buvo apmokyti pasitelkus tokį patį duomenų rinkinį ir apmokius modelius po 20 epochų. Tyrimo metu buvo gautuose rezultatuose ResNet50 pasiekė 97,33% tikslumą, VGG16 - 96,33%, o VGG19 - 97,07% tikslumus. Gauti rezultatai patvirtina [RDS⁺15] rezultatus, jog ResNet modeliai geba geriausiai pasirodyti klasifikacijos užduotyse. Tačiau nors klasifikavimo užduotyse ResNet modeliai pasirodo geriausiai, kai šie modeliai yra taikomi kitose praktinėse užduotyse, kai reikia atpažinti smulkias detales ir mažus skirtumus, VGG modeliai pasirodo geriau. Spektrogramų analizės rezultatai darbuose [Pur22], [YS22] parodė aiškų pranašumą VGG modeliams. Taip pat ir 2020 metais atliktas darbas [KA20], kuris tyrė rentgeno nuotraukas Covid-19 pacientų. Tyrimo metu mėginti keli konvoliucinių neuroninių tinklų modeliai Covid-19 pacientų atpažinimui. Tyrime nagrinėti ResNet50, VGG16, VGG19 modeliai, apmokyti tuo pačiu duomenų rinkiniu.

Matavimas	ResNet50	VGG16	VGG19
Tikslumas	97%	99,33%	99,3%
Jautrumas	98,48%	99,38%	100%
Klaidingai neigiami	1,52%	0,72%	0%
Klaidingai teigiami	4,79%	0,62%	1,23%

5 lentelė. Covid-19 pacientų atpažinimo rezultatai [KA20]


Konvoliuciniai neuroniniai tinklai gali būti labai veiksmingi spektrogramų bei histogramų analizei, nes jie geba atskirti ir klasifikuoti sudėtingus požymius, kurie gali būti naudingi diagnozuojant ir vertinant išmetamųjų dujų emisijas. Remiantis konkursuose ir klasifikavimo užduotyse gautais rezultatais [RDS⁺15], [MA21], ResNet modelis parodo didžiausią tikslumą, tačiau reikalauja didelio kiekio duomenų, jog būtų tikslus. Remiantis spektrogramų tyrimo darbų rezultatais [Pur22] [YS22], VGG16 ar VGG19 būtų tinkamas modelis spektrogramų analizei, dėl jo gilios architektūros, kuri leidžia modeliui atskirti smulkias bruožas, kurių yra daug spektrogramose bei histogramose.

5. Eksperimento atlikimas ir metodologija

Tyrimo atlikimui ir modelio sukūrimui buvo reikalingi tokie vidaus degimo variklio duomenys kaip virpesiai, garso lygmuo, termovizoriaus nuotraukos bei veikimo metu išskleistų išmetamųjų dujų dalelių matavimai. Šie duomenys yra sunkiai prieinami ir dažnai atskirai nepublikuojami. Tad jiems gauti buvo kuriamas eksperimentinis stendas su vidaus degimo varikliu ir specializuota matavimo įranga bei atliekami bandymai, kurių metu gauti ir apdoroti variklio virpesių, garso slėgio, garso lygmens bei termovizoriaus vaizdų duomenys. Eksperimentiniai matavimai, kuriuos pasitelkiant būtų galima sukurti, patikrinti ir įvertinti sukurtos programinės įrangos efektyvumą ir tikslumą, buvo atlikti tyrimo metu.

5.1. Stendas

Tyrimui atlikti pasirinktas vidaus degimo variklis - dyzelinis generatorius. Jis sudarė stendo pagrindą, prie kurio ar šalia jo buvo montuojama specializuota testinė įranga. Stendo konfigūracija galima pamatyti 13 pav. 13a pav, numeriu 1 pažymėtas garso lygio matuoklis, numeriu 2 - infraraudonųjų spindulių kamera, 3 - išmetamųjų dujų dalelių matuoklis. 13b pav, 4 - virpesių matuokliai.



13 pav. Eksperimento stendas: (a) Eksperimento metu stende montuoti ir sužymėti matuokliai; (b) „B&K 8341 CCLD“ akselerometrai ir jų ašys; (c) „B&K Machine Diagnostic Toolbox type 9727“ įranga

Svarbu paminėti, jog tarp veikiančio variklio ar jo judančių komponentų, jutiklių bei matuoklių nėra kontakto. Eksperimento stendą sudarė šie prietaisai:

Dyzelinis generatorius ir apkrova

Bandymų metu buvo naudojamas „Kohler SDMO Diesel 4000 C5“ generatorius, kurio pagrindiniai parametrai [SDM16]:

- 1 cilindro, 4 taktų variklis.

- Didžiausia galia - 3,4 kW.
- Pastovi nuolatinė darbinė galia - 2,72 kW.
- Garantuotas garso galios lygis (L_{WA}) - 108 dB(A).
- Garso slėgio lygis 1 m atstumu - 92 dB(A).
- Garso slėgio lygis 7 m atstumu - 78 dB(A).

Generatoriaus apkrovai sukurti buvo pasirinktas elektrinis šildytuvas, gebantis veikti 6 energijos suvartojimo režimais: 0.3 kW, 0.6 kW, 1 kW, 1.3 kW, 1.6 kW, 2 kW. Šiais režimais, taip pat ir laisva eiga, buvo atlikti bandymai.

Garso slėgio ir virpesių matuokliai

Generatoriaus garso slėgio duomenų surinkimui buvo naudojamas "GRAS 46AE" laisvojo lauko "free-field" mikrofonų rinkinys, kurio parametrai [SV25]:

- Dažnių diapazonas nuo 3.15 Hz iki 20 kHz.
- Dinaminis diapazonas nuo 17 dB(A) iki 138 dB.
- Jautrumas - 50 mV/Pa.

Variklio vibracijų matavimai buvo atliekami išilgine (Y) ir skersine (X) kryptimis, keturiuose taškuose, pasitelkiant keturis "Bruel&Kjaer 8341 CCLD" akselerometrų, matomus 13b pav, pažymėtus 4-u numeriu, kurių parametrai [BK09]:

- Dažnių diapazonas nuo 0.3 Hz iki 10 kHz.
- Jautrumas - 10 mV/ms².
- Didžiausias darbinis lygis (peak) - 50 g.
- Likutinis triukšmo lygis nurodytame dažnių diapazone (RMS) $\pm 200 \mu\text{g}$.

Triukšmo ir vibracijų duomenys buvo gaunami naudojant "Bruel&Kjaer Machine Diagnostic Toolbox type 9727", matomas 13c pav. Šis įrankis skirtas analizuoti ir spręsti vibracijos problemas besisukančiose ir stūmoklinėse mašinose, kintančiu greičiu. Sistemą sudaro daugialypis analizatorius (multi-analyzer) "PULSE type 3560", kurio programinėje įrangoje yra "Machine Diagnostics Toolbox Software Bundle Type 7910" sistema, naudota eksperimento metu, išsaugoti ir sisteminti gautus matuoklių duomenis. "PULSE" duomenų kaupimo blokas suteikė 5 kanalus realaus laiko analizei, duomenų įrašymui ir tolesniam jų apdorojimui.

Termovizoriaus kamera

Temperatūros analizė buvo atliekama naudojant "Compact Thermal Camera FLIR C5" termovizorių, kuris matomas 13a pav, nuotraukoje, pažymėtas 2-u numeriu. Šis įrenginys turi [FLI20]:

- 160×120 (19,200 pikselių) termovizorinę kamerą.
- Daugia-spektrinio dinaminio vaizdo sistemą.
- 5 MP vaizdo kamerą.
- Temperatūros matavimą nuo $-20\text{ }^{\circ}\text{C}$ iki $+400\text{ }^{\circ}\text{C}$.
- Jautrumą $< 70\text{ mK}$.
- Tikslumą nuo 0°C iki $100^{\circ}\text{C} \pm 3^{\circ}\text{C}$.

Garso lygio matuoklis

Generatoriaus garso lygiui išmatuoti buvo taikomas Bruel&Kjear 2250 vieno kanalo 1 klasės garso lygio matuoklis ir analizatorius, matomas 13a pav, pažymėtas 1-u numeriu, kuris geba veikti nuo 3 Hz iki 20 kHz plačiajuosčių dažnių diapazone ir nuo 16,6 iki 140 dB(A-weighted) dinaminio diapazono ribose $\pm 1\text{ dB}$ tikslumu [BK21]. Šis prietaisas leido realiuoju laiku analizuoti garsą, garsumo ypatumus bei dokumentuoti matavimus, įrašant matuojamą garsą fiksuotą laiko kiekį.

Emisijų dalelių matuoklis

Emisijų dalelių duomenys buvo renkami naudojant "Cem Instruments Air Particle Counter DT-9880" oro dalelių skaitiklį, matomą 13a pav, pažymėtą 3-iu numeriu. Šis įrenginys matavo dalelių dydžius nuo $0,3\text{ }\mu\text{m}$ iki $10\text{ }\mu\text{m}$, daleles $0,3\text{ }\mu\text{m}$ skaičiuodamas 50% tikslumu, ir daleles, didesnes nei $0,45\text{ }\mu\text{m}$ 100% [CEM19]. Tuo pat metu registruodamas oro drėgmę bei temperatūrą. Integruota kamera leido užfiksuoti vaizdus ir vaizdo įrašus, skirtus peržiūrai kompiuteryje ir tolimesnei analizei.

Eksperimento eiga


Eksperimentas buvo atliekamas pagal planą, kurio metu kiekvienas bandymas yra kartojamas po 6 kartus, kiekvienam iš šilumos generatoriaus galios nustatymų. Matavimai taip pat buvo atlikti ir generatoriui dirbant laisva eiga, neprijungus jokio elektrinio prietaiso. Visi matavimai buvo atliekami tuo pačiu metu - bandymas buvo pradedamas ir įrašomi 10 s virpesių, garso slėgio, triukšmo bei dalelių duomenys. Intervalo gale padaroma termovizoriaus kameros nuotrauka. Gauti duomenys buvo suskirstyti į 4 kategorijas:

- Laiko srities virpesių duomenys.
- Dažnių srities virpesių duomenys.

- Garso lygmens duomenys.
- Infraraudonųjų spindulių nuotraukos.

5.2. Duomenų apdorojimas ir analizė

Kuriant programinę įrangą, ji turėjo gebėti analizuoti ir interpretuoti laiko eilutės duomenis. Šių duomenų apdorojimui, remiantis literatūros apžvalgos rezultatais, buvo pasirinkti laiko eilučių transformerių neuroninių tinklų modeliai, dėl jų pranašesnių rezultatų atliekant panašaus tipo užduotis. Transformerių modelių technologija yra gan nauja ir sparčiai tobulėjanti, tačiau ne visada naujausi modeliai yra pranašesni už senesnius. Taip pat dažnai trūksta informacijos, ar naujai išleisti modeliai yra išties pranašesni, ar geresni tik specifinėje užduotyje, su specialiai atrinktu duomenų rinkiniu. Todėl šiam uždaviniui buvo pasirinktas vienas naujausių, tačiau gerai įvertintas "Autoformer" transformerių modelis, pritaikytas laiko eilučių duomenims apdoroti [WXW⁺22]. Pasitelkiant savo savybę efektyviai užfiksuoti laiko priklausomybės per savianalizės mechanizmus, modelis gali efektyviai apdoroti kintančio ilgumo laiko eilutės duomenis ir pasirinkto laiko intervale rasti paslėptas tendencijas duomenyse. Dėl šių priežasčių jis yra patikimas pasirinkimas laiko eilučių analizei bei gebėjimui nustatyti ilgalaikes priklausomybes [WXW⁺22]. Modelio autokoreliacijos mechanizmas, kuris pakeičia standartinį savianalizės mechanizmą, randamą kituose transformerių modeliuose [WLD⁺23], leidžia modeliui surasti periodines priklausomybes ir nustatyti tendencijas dėmesio mechanizmo sutelkimo metu, taip pasiekiant geresnį tikslumą. "Autoformer" modelis taip pat gali pasinaudoti savo ypatybių mechanizmu, jog atsižvelgtų į kelis kintamuosius vienu metu, prognozuojant rezultatus.




14 pav. Autoformer laiko eilučių modelio architektūra [WXW⁺22]

14-ame pav. pateikta detali "Autoformer" modelio architektūra, kuri buvo naudojama tyrime. Kaip matyti iš 14 pav., modelis remiasi gerai žinomu laiko eilučių analizės metodu, kuris skaido laiko eilučių duomenis į sezoniškumo ir tendencijų-ciklo komponentus. Enkoderis (encoder) pašalina ilgalaikes tendencijas ir sudėtingas ciklines laiko eilučių savybes, naudodamas eilučių skaidymo blokus ir sutelkia dėmesį į tendencijų modeliavimą. Dekoderis (decoder) palaipsniui kaupia informaciją apie tendencijas, kuri išgaunama iš paslėptų kintamųjų. Praeities sezoniškumo informacija išgaunama iš enkoderio ir naudojama dekoderio autokoreliacijos bloke.

Dažnių srities virpesių duomenys

Dažnių srities ir laiko srities duomenys yra funkciškai susiję. Atlikus Furjė transformaciją laiko srities duomenims yra gaunami dažnių srities duomenys, o dažnių srities duomenims atlikus inversinę Furjė transformaciją gaunami laiko srities duomenys [Sch18]. Kadangi pasirinkto modelio "Autoformer" įvesties duomenys yra laiko eilutės, šie dažnių srities virpesių duomenys nebuvo panaudoti modelių sukūrimui, nes atlikus inversinę Furjė transformaciją jie tik pakartotų tuos pačius laiko srities duomenis. Tačiau jie buvo panaudoti netiesiogiai. "Bruel&Kjaer Machine Diagnostic Toolbox type 9727" programinė įranga leidžia analizuoti dažnių srities duomenis, juos paskirstant į 3 centrinės dažnių sritis:

- 1 kHz, 3200 ms ilgio signalus, kurie leido analizuoti virpesius nuo 0 Hz iki 2 kHz, 0.3125 Hz tikslumu.
- 5 kHz, 640 ms ilgio signalus, kurie leido analizuoti virpesius nuo 0 Hz iki 10 kHz, 1.5625 Hz tikslumu.
- 10 kHz, 320 ms ilgio signalus, kurie leido analizuoti virpesius nuo 0 Hz iki 20 kHz, 3.125 Hz tikslumu.




15 pav. Dažnių srities duomenys

Dėl programinės įrangos apribojimų, visų sričių duomenys pateikia po 8192 taškus, tad kuo platesnė dažnių sritis yra analizuojama, tuo didesnis žingsnis naudojamas x ašyje (Hz). 15 pav.

galime pamatyti kiekvienos iš dažnių srities matavimus. Atkreipus dėmesį, galime pastebėti, jog daugiausiai virpesių vyksta nuo 0 Hz iki 2 KHz režyje, kas yra ir būdinga vidaus degimo varikliams. Tad nors ir dažnių srities duomenys nebuvo tiesiogiai panaudoti emisijų dalelių analizės nustatymui, jie padėjo su paprastinti modelį ir sutelkti laiko srities analizę ties 1 kHz srities duomenimis.

Laiko srities virpesių duomenys


Laiko srities virpesių duomenys, kaip ir dažnių srities, buvo gauti pasitelkiant "Briel&Kjaer Machine Diagnostics Toolbox Software Bundle Type 7910" programine įranga. Jos pagalba buvo eksportuojami duomenys, kurie vėliau buvo apdorojami "Python" programinės įrangos aplinkoje. Kiekvienas bandymas, 1 kHz srityje, sudarė po laiko eilutę, kurią sudarė 16384 taškai, Šie duomenys nusako, kaip kintant laikui keitėsi variklio virpesių stiprumas. Taupant darbinę atmintį, eksportuoti programinės įrangos duomenys buvo nuskaitomi, išvaloma pertekline ar nereikalinga informacija ir sugeneruojamas ".csv" dokumentas, kuriame patalpinta visa bandymo laiko eilutės informacija, atlaisvinant modelį ir paruošiant duomenis tolimesniam naudojimui.




16 pav. Laiko eilutės pirmų 1000 taškų virpesių pagreičių duomenys

Garso slėgio duomenys

Garso slėgio duomenys buvo gauti pasitelkiant Bruel&Kjaer 2250 vieno kanalo analizatorių. Po kiekvieno bandymo buvo sugeneruojama detali bandymo garsumo analizė, matoma 17 pav.



17 pav. Garso slėgio duomenys



18 pav. Laiko srities garso slėgio duomenys

Kadangi tai yra dažnių srities duomenys, juos reikėjo transformuoti į laiko srities formatą. Tam atlikti buvo naudojama "Python" programinė įranga ir duomenims atlikta inversinė Furjė transformacija:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{j\omega t} d\omega \quad (1)$$

kur: $f(t)$, yra atkurta laiko domeno funkcija,

$F(\omega)$, yra Furjė transformacija dažnių srityje,

ω , yra Kampinis dažnis,


j , yra įsivaizduojamas vienetasis ($j^2 = -1$),

t , yra laiko kintamasis.

Transformuotus duomenis galima pamatyti 18 pav.

Infraraudonųjų spindulių nuotraukos

Infraraudonųjų spindulių nuotraukos sukėlė daug iššūkių tyrimo metu. Atliekant literatūrinę analizę, vaizdai buvo planuojamas kaip klasifikavimo uždavinys, kuris būtų sprendžiamas pasitelkiant tokius klasifikavimo modelius kaip ResNet50 ar VGG19 ir kurio rezultatas būtų pateikiamas kaip papildoma informacija prognostinio modelio įvesčiai, tačiau jau bandymų metu buvo pastebėta, jog termovizoriaus fiksuojamos nuotraukos negeba užfiksuoti dujų skleidžiamos šilumos terminio vaizdo. Tad pasirinktas sprendimas buvo naudoti metalinį vamzdį (matomą 19a pav.) ir fiksuoti pačio vamzdžio sienelių šilumos pokyčius. Tada nuotrauka yra paverčiama į juodai baltą formatą (matomą 19b pav.). Pasitelkiant literatūrinėje analizėje paminėtą techniką - nuotraukų pavertimą į histogramas, nuotraukų analizės uždavinį galime traktuoti kaip prognostinį uždavinį. Konvertavus nuotrauką į histogramą (matomą 19c pav.) sugeneruojamas spalvos intensyvumo žemėlapis, kurį galima atvaizduoti kaip duomenų masyvą. Interpretuodami šiuos duomenis kaip laiko eilutės duomenis galime pasinaudoti "Autoformer" transformerių modeliu ir jį apmokinus šiais duomenimis prognozuoti emisijų dalelių vertes.




19 pav. IR nuotraukų apdorojimas: (a) IR nuotrauka; (b) Juodai baltą nuotrauka; (c) Nuotraukos histograma

5.3. Modelių sistema ir apmokymas

Modelių sistema

Surinkti duomenys turėjo būti paruošti, suformatuoti ir apdoroti taip, jog atitiktų laiko eilutės transformerių modelio įvesties ir išvesties duomenų formatus. Duomenys, skirti modelio apmokymui, buvo suskirstyti į 3 grupes, nes transformerių modeliai nėra tinkami apdoroti vaizdų apdorojimą tiesioginiu būdu, o norint naudoti keletą įvesties parametrų, šie turi būti vienodo ilgio, formato ir formos. Tačiau vietoje to, jog šie duomenys liktų nepanaudoti, jais pasinaudoti galima ir kitokiu būdu, jog jie prisidėtų ir patikslintų dalelių emisijų prognozes. Dėl šios priežasties, modelio apmokymo metu surinkti duomenys buvo suskirstyti į tris dalis, jog būtų naudojami trijuose skirtinguose modeliuose, kuriuose kiekvienas iš jų prisidėtų prie atskiro "požiūrio" į dalelių emisijų prognozę. Šie modeliai sujungiami, sistemos pabaigoje pridėjus ketvirtą modelį, kurio įvesties parametrai yra kiekvieno iš atskirų modelių prognozės, o išvestis - bendrinė emisijų dalelių prognozė. Sujungus šiuos modelius gaunama programinės įrangos sistema, pavaizduota 20-ame pav., pasižyminti išskirtiniu bruožu - gebėjimu įtraukti ne tik laiko eilučių duomenis, bet ir infraraudonųjų spindulių nuotraukų vaizdus bei garso lygmens analizę.



20 pav. Tyrime naudota transformacinių modelių sistema

Ši modelių sistema yra lanksti ir geba veikti įvairiais būdais. Galima naudoti tik atskirus jos komponentus, galima ir visą sistemą. Atskiri modeliai gali būti pakeičiami kitais ar nesunkiai pridami nauji. Šis sprendimo būdas leido išskaidyti skaičiavimus, o remiantis literatūros analizės atradimais, transformaciniai modeliai naudoja daug kompiuterinių išteklių ir didesni bei gilesni modeliai dažnai pasižymi didesniu tikslumu, tad toks sprendimas leidžia turėti kelis mažesnius, gilesnius modelius.

Modelių apmokymas

Apdorojant duomenų rinkinius iškilo problema tiek dėl duomenų kiekio, tiek dėl persimokymo (overfitting). Modelio įvestis reikalavo, jog kiekvienas laiko eilutės įrašas turėtų tikslią reikšmę – dalelių emisijų vertines reikšmes. Dėl turimos įrangos ribotumo, eksperimento bandymo metu, emisijų dalelių matuoklis išmatuodavo tik po vieną, kiekvieno iš šešių matuojamų dalelių dydžių, skaitinį kiekį. Tačiau jeigu tie patys duomenys būtų kartojami kiekviename laiko eilutės

taške, tikėtina, jog tai paskatintų modelio persimokymą ir sumažintų jo tikslumą. Siekiant išvengti persimokymo, reikšmės buvo atsitiktinai paskirstytos, naudojant normalųjį pasiskirstymą su 1% standartiniu nuokrypiu:

$$f(x; \sigma, \mu) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (2)$$

kur: μ yra vidurkis,

σ yra standartinis nuokrypis,

x yra įvesties reikšmė.

Šis metodas padėjo užtikrinti, jog dalelių emisijų duomenys būtų pakankamai kintantys ir įvairūs, kad modelio mokymo metu būtų išvengta persimokymo. Šis metodas buvo itin aktualus virpesių duomenų analizei, kur kiekviena laiko eilutė turėjo po 16384 taškus.

Tyrimui atlikti buvo apmokyti 4 modeliai, paremti "Autoformer" transformerių laiko eilučių modelio architektūra, kuris pasitelkia laiko eilutės duomenis rezultatams prognozuoti. Kiekvienai iš duomenų grupių: virpesiams, infraraudonųjų spindulių vaizdams, garso lygio matavimams - buvo sukurtas atskiras modelis, su atskirais parametrais. Po to, remiantis jų prognozėmis, apmokytas apjungiantysis modelis, kuris kiekvieno modelio prognozes naudoja kaip įvestį ir sudaro galutinius rezultatus. Kiekvienas modelis buvo apmokomas atsižvelgiant į duomenų rinkinį ir rezultatų tikslumą. Visi modeliai, kiekvienai laiko eilučių serijai buvo apmokomi po 10 epochų, naudojant neigiamą logaritminę tikimybės klaidos funkciją (NLL):

$$\ell(x, y) = L = \{l_1, l_2, \dots, l_N\}^\top, \quad (3)$$

kur: $l_i = -w\{y_i\} \cdot x\{i, y_{ni}\}$, $i = 1, 2, \dots, N$, yra prognozių tenzorius,

y yra etalono tenzorius,

$w\{y_i\}$ yra svoris.

Apmokymai buvo atliekami asmeniniame kompiuteryje, su Nvidia RTX 3060m grafiniu procesoriumi, kuris turi 3840 CUDA branduolius ir 6 GB atminties. Tad tai ir tapo limituojančiu faktoriumi, pasirenkant modelių hiperparametrus. Didinant paslėptų sluoksnių bei dėmesio galvučių kiekį, buvo gaunami geresni rezultatai. Padvigubinus virpesių modelio enkoderio, dekoderio sluoksnius bei dėmesio sutelkimo galvutes, virpesių modelio tikslumas padidėjo 17,64%. Tad optimizuojant modelių konfigūracijas buvo ieškomi hiperparametrai, kurie pilnai išnaudotų visas grafinio procesoriaus galimybes.

Virpesių ir dažnių modelis buvo apmokomas šiais parametrais:

- Laiko eilutės ilgis - 16384.
- Laiko eilučių kiekis - 25 laiko eilutės.
- Parametrų skaičius - 4.

- 6 enkoderio (encoder) ir 6 dekoderio (decoder) sluoksniai.
- 8 enkoderio dėmesio sutelkimo galvutės (attention heads) ir 8 dekoderio dėmesio sutelkimo galvutės.
- 128 paslėpti sluoksniai.

Vaizdų modelis apmokytas šiais parametrais:

- Laiko eilutės ilgis - 256.
- Laiko eilučių kiekis - 25 laiko eilutės.
- Parametrų skaičius - 1.
- 8 enkoderio ir 8 dekoderio sluoksniai.
- 8 enkoderio dėmesio sutelkimo galvutės ir 8 dekoderio dėmesio sutelkimo galvutės.
- 128 paslėpti sluoksniai.

Garso lygio modelis apmokytas šiais parametrais:

- Laiko eilutės ilgis - 33.
- Laiko eilučių kiekis - 25 laiko eilutės.
- Parametrų skaičius - 5.
- 8 enkoderio ir 8 dekoderio sluoksniai.
- 8 enkoderio dėmesio sutelkimo galvutės ir 8 dekoderio dėmesio sutelkimo galvutės.
- 256 paslėpti sluoksniai.

Apjungtas modelis apmokytas šiais parametrais:

- Laiko eilutės ilgis - 100.
- Laiko eilučių kiekis - 25 laiko eilutės.
- Parametrų skaičius - 18.
- 6 enkoderio ir 6 dekoderio sluoksniai.
- 8 enkoderio dėmesio sutelkimo galvutės ir 8 dekoderio dėmesio sutelkimo galvutės.
- 256 paslėpti sluoksniai.

Tikslumo metrikos

Prognozių tikslumas buvo įvertintas naudojant vidutinę absoliučią procentinę paklaidą (MAPE):

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100, \quad (4)$$

kur: N yra bendras duomenų taškų skaičius,
 y_i yra faktinė i -ojo taško duomenų vertė,
 $\hat{y}_i$ yra numatoma i -ojo taško duomenų vertė.

Norint geriau įvertinti, kiek modelis pervertina prognozes, buvo apskaičiuota vidutinė kvadratinė paklaida (RMSE):

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (5)$$

kur: N yra bendras duomenų taškų skaičius,
 y_i yra faktinė i -ojo taško duomenų vertė,
 $\hat{y}_i$ yra numatoma i -ojo taško duomenų vertė.

Palyginimui, taip pat buvo apskaičiuota vidutinė absoliuti klaida (MAE):

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (6)$$

kur: N yra bendras duomenų taškų skaičius,
 y_i yra faktinė i -ojo taško duomenų vertė,
 $\hat{y}_i$ yra numatoma i -ojo taško duomenų vertė.

Tendencijų ir pokyčių įvertinimui buvo naudojama vidutinė absoliuti skalės paklaida (MASE), kuri vienodai vertina teigiamas ir neigiamas prognozių klaidas bei vienodai baudžia klaidas didelėse ir mažose prognozėse.

$$\text{MASE} = \frac{\frac{1}{J} \sum_{j=1}^J |e_j|}{\frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}|}, \quad (7)$$

kur: $e_j = Y_j - F_j$ yra duotojo laikotarpio prognozės paklaida,
 J yra prognozių skaičius,
 Y_j yra faktinė i -ojo taško duomenų vertė,
 F_j yra numatoma i -ojo taško duomenų vertė,
 T yra bendras laiko taškų skaičius.

Nuokrypiams įvertinti ir apskaičiuoti buvo naudojamas imties standartinis nuokrypis:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (8)$$

kur: x_i yra atskirų duomenų taškų reikšmės,
 $\bar{x}$ yra imties vidurkis,
 n yra bendras imties duomenų taškų skaičius.

Tikslumo įvertinimas

Jog galėtume tikslingai įvertinti modelio tikslumą bendrame kontekste, bei galėtume palyginti šios sistemos efektyvumą su tradiciniais metodais, kartu buvo sukurtas statistinis ANCOVA modelis bei rekurentinių neuroninių tinklų modelis LSTM. ANCOVA modelio lygtis gali būti išreikšta taip:

$$C = \beta_0 + \beta_1 x + \beta_2 y + \beta_3 z + \beta_4 q + \sum_{i=1}^k \gamma_i s_i + \epsilon, \quad (9)$$

kur: C yra dalelių skaičius,
 x, y, z, q yra virpesiai, skirtingomis kryptimis,
 s_i yra i -asis dalelės dydis,
 $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4$ yra regresijos koeficientai,
 γ_i yra dalelių dydžių koeficientai,
 ϵ yra paklaidos komponentas.

LSTM modelis apmokytas šiais parametrais:

- Laiko eilutės ilgis - 16384.
- Laiko eilučių kiekis - 25 laiko eilutės.
- Parametrų skaičius - 4.
- 8 sluoksniai.
- 1024 paslėpti sluoksniai.

6. Sukurtos modelių sistemos palyginimas

Modelių testavimas buvo atliktas surinkus visus duomenis ir padalinus juos į 2 dalis. 60% duomenų buvo skirta modelių apmokymams ir validavimui, likusieji 40% buvo skirti atlikti tikslumo matavimams. Tai leido objektyviau įvertinti rezultatus ir gautų modelių rezultatus. Tyrimo metu buvo analizuojami emisijų dalelių kiekiai, kurie buvo paskirstyti į dydžius: 0.3 μm , 0.5 μm , 1 μm , 2.5 μm , 5 μm , ir 10 μm . Dyzelinio generatoriaus apkrova kito nuo laisvos eigos darbo - 0.0 kW iki 2.0 kW. Kiekvienam generatoriaus apkrovos nustatymui, laiko eilutės pabaigoje, kiekvienam iš dalelių dydžių buvo atliekama po 100 prognozių, iš kurių paskaičiuojamas vidurkis galutinei vertei. Tipiniai dalelių matavimai matomi 6 lentelėje.

Dalelių dydis, μm	Apkrovos galia, kW						
	0.0	0.3	0.6	1.0	1.3	1.6	2
0.3	43485	46707	37786	34284	65919	57840	67028
0.5	21474	18759	14845	12065	20179	19699	24566
1.0	4425	3290	2748	1731	3427	3499	4916
2.5	472	412	358	270	428	384	602
5.0	1	0	0	3	3	3	0
10.0	10	9	9	6	1	2	4

6 lentelė. Tipiniai emisijų dalelių kiekių matavimų duomenys

6.1. Modelių palyginimas

Tyrimo metu buvo sukurti 4 modeliai, virpesių, vaizdo, garso lygio ir visų trijų modelių prognozės apjungiantis modelis. Jungiamasis modelis buvo sukurtas kaip sprendimas apjungti atskiras duomenų analizės dalis į rezultatus įtraukiant kiekvieno modelio geriausias savybes atskirai. Tai leido programinei įrangai išlikti atskirtai, lengvai testuojamai ir padalintai atskirais sistemos komponentais. Kartu tai leido atlikti įžvalgas ir iširti, kokio tipo duomenys yra tinkamiausiai ir atneša daugiausiai tikslumo.

Įvertinti transformacinio modelio efektyvumui, virpesių modelio rezultatai buvo palyginti su ANCOVA virpesių modelio rezultatais bei LSTM modelio rezultatais, kurie yra matomi 7 lentelėje.


Modelis	Dalelių dydis, μm	MASE	MAE	RMSE	MAPE (%)
Virpesių	0.3	7.96	4872.38	9003.70	9.00
	0.5	4.37	968.39	1252.24	4.95
	1	6.51	254.64	469.20	7.34
	2.5	8.27	40.62	71.48	9.34
	5	4.21	0.08	0.13	4.78
	10	4.48	0.33	0.59	5.06
LSTM	0.3	43.46	22995.18	23038.34	49.08
	0.5	34.35	6903.67	7004.97	38.77
	1	36.73	1133.37	1168.04	41.28
	2.5	33.07	122.70	631.49	37.36
	5	40.75	1.43	1.65	45.85
	10	54.52	4.95	6.39	61.63
ANCOVA	0.3	33.80	20920.31	24175.84	38.55
	0.5	28.71	6360.56	7666.42	31.74
	1	31.16	1087.25	1232.75	33.82
	2.5	25.11	114.32	124.00	27.65
	5	51.61	1.52	1.90	55.80
	10	39.36	5.90	6.70	41.56

7 lentelė. Transformerių, ANCOVA ir LSTM modelių tikslumo palyginimas

Remiantis gautais rezultatais, galime pastebėti jog transformerių modelis buvo tikslesnis, prognozuojant išmetamųjų dujų dalelių kiekius. ANCOVA modelis pasiekė bendrą 61.82% tikslumą. Toks mažas tikslumas galimas dėl eksperimento metu surinktų duomenų kintamumo. Kadangi eksperimentas buvo atliekamas lauke, dėl įvairių aplinkos veiksnių, duomenys tarp bandymų kito ir tai atsispindi statistinio modelio rezultatuose. LSTM modelis taip pat pasiekė gan žemą tikslumą - 62.34%. Nors modelis reikalauja mažiau skaičiavimo resursų ir dėl to gali būti gilesnis, nei transformerių modelis, dėl didelio eksperimentinių duomenų kiekio išryškėja nykstančių gradientų bei persimokymo problemos. Šie rezultatai parodė transformerių tinklo efektyvumą, išmetamųjų dujų dalelių kiekio prognozės uždavinyje.

Virpesiai

Detalūs virpesių modelio rezultatai yra pateikiami 21-ame pav. Kaip galima pastebėti iš rezultatų, vidutinis modelio tikslumas, apjungus visus bandymo tipus siekė apie 93.36%. Tačiau tik pažvelgus į detalesnius rezultatus galime pastebėti, jog vidurkis nėra itin tinkamas apibūdinti jo tikslumui.




21 pav. Virpesių modelio vidutinė procentinė paklaida (MAPE)

Ties 1.0 kW ir 1.3 kW apkrovos nustatymais, modelis pasiekė mažą procentinę paklaidą, tačiau ties 1.6 kW nustatymais, matomas kritimas prognozių tikslume. Taip pat verta atkreipti dėmesį į atskiras dalelių dydžio prognozes - pastebimas tam tikras nenuoseklumas prognozėse. 0.5 μm ir 5.0 μm dydžių daleles modelis gebėjo prognozuoti sėkmingiau, palyginus su 0.3 μm ir 2.5 μm dydžio dalelėmis, kurių prognozės buvo mažiausiai tikslios. Apart 1.6 kW duomenų, modelis gebėjo surasti ryšius tarp virpesių ir išmetamųjų dujų dalelių skaičiaus, tačiau taip pat galime pastebėti, jog apmokymų eigoje, didesnės galios nustatymo duomenis buvo pateikti mokymo pabaigoje ir atsiranda tam tikras šališkumas šiems duomenims, nes modelis geba juos interpretuoti tiksliau.

Vaizdai

Vaizdų modelio vidutinės absoliučios procentinės paklaidos rezultatai, pateikti 16-ame pav., indikuoja, jog vaizdų modelis, palyginus su virpesių modeliu, pasiekė prastesnį tikslumą, prognozuojant dalelių kiekius. Vidutinis tikslumas siekė apie 86.3%. 1.6 kW prognozės, kaip ir virpesių modelio prognozės, buvo ne tokios tikslios, palyginus su kitais apkrovos nustatymais. Tai, jog šis netikslumas yra pasikartojantis, leidžia daryti prielaidą, jog su šios apkrovos nustatymais yra didesnis bandymo duomenų kintamumas.



22 pav. Vaizdų modelio vidutinė procentinė paklaida (MAPE)


Verta paminėti, jog šis modelis gebėjo atlikti prognozes gan nuosekliai, per visus apkrovos lygmenis. Tai pastebima ir palyginus 1.6 kW apkrovos prognozes su virpesių modeliu. Jos yra nuoseklesnės ir panašesnės į kitas, o netikslumas išskyla ties 2.5 μm ir 5.0 μm dalelių dydžiais. Tačiau bendrame kontekste, vaizdų modelio pasiektas tikslumas yra gan prastas. Prastesni rezultatai yra susiję su bandymo metu gautais vaizdais ir matavimo prietaisų techniniais apribojimais. Kadangi naudota infraraudonųjų spindulių kamera negebėjo aptikti dujų šilumos, bandymų nuotraukų ypatybės remiasi ties bandymo metu naudojamo vamzdžio šiluma. Vėjas ir kiti faktoriai galėjo daryti įtaką jo temperatūrai, o ir temperatūros pokytis vamzdyje galėjo kisti per mažai, jog prasmingos ypatybės išryškėtų, nepaisant pačios kameros paklaidos. 23 pav. galime pastebėti vaizdų ypatybių skirtumus, kai didėjant vamzdžio vidaus temperatūrai proporcingai tamsėja išorės lauko spalva.



23 pav. 0 kw, 1 kw ir 2 kw apkrovos IR vaizdai

Garso lygis

Iš rezultatų, pateiktų 24-ame pav., galime pamatyti, jog garso lygio modelis buvo pats tiksliausias iš atskirų duomenų grupių modelių, prognozuojant dalelių dydžius. Bendras tikslumas siekė 95.89%. Palyginus su virpesių modelio rezultatais, šis modelis pasiekė 2.64% geresnius rezultatus. Įdomus pastebėjimas, jog modeliui itin gerai sekėsi prognozuoti 0.3 μm , 2.5 μm ir 10.0 μm dydžių daleles, kai tuo tarpu, virpesių modeliui sekėsi beveik atvirkščiai. Kaip ir numatyta eksperimento atlikimo metu, skirtingi duomenys, jų kilmė ir informacija, kurią jie atvaizduoja, įneša skirtingą perspektyvą prognozėse.




24 pav. Garso lygio modelio vidutinė procentinė paklaida (MAPE)

Tačiau, kaip ir kituose modeliuose, matomas tikslumo kritimas ties 1.6 kW apkrovos riba. Kadangi įvesties duomenys buvo mažesni, kitaip pasakius įvesties laiko eilutės buvo mažesnės, modelio paslėptų sluoksnių skaičius galėjo būti didesnis, neviršijant laisvos atminties limitų, kas prisidėjo prie modelio tikslumo. Verta pasvarstyti, jog turint spartesnę kompiuterinę įrangą virpesių modelis galėtų parodyti dar geresnius rezultatus jei būtų padidintas modelio sudėtingumas. Duomenyse taip pat matome šališkumą didesnės apkrovos nustatymams, nes (apart 1.6 kW rezultatų) prie šių nustatymų, modelio tikslumas padidėjo. Šis pasikartojimas indikuoja, jog verta pasvarstyti apie geresnį duomenų išmaišymą apmokymų metu.

Apjungtas modelis

Apjungtas modelis remiasi virpesių, vaizdo ir garso lygio modelių rezultatais kaip savo įvestimi ir atlieka vieną, kombinuotą ir apjungtą prognozę, atsižvelgdamas į atskirų modelių rezultatus. Šis modelis ir pasiekė geriausius rezultatus - vidutinis tikslumas siekė 96.59% tikslumą. Detalesni vidutinės procentinės paklaidos matavimai pateikti 25-ame pav.



25 pav. Apjungto modelio vidutinė procentinė paklaida (MAPE)

Kaip matome iš gautų rezultatų, šis modelis atliko nuoseklias prognozes. Žiūrint į atskiras dalelių prognozes, galime pastebėti, jog buvo sėkmingai pasirinkti lydinčiai kintamieji ir surastos esminės ypatybės kiekvieno iš atskirų modelių. Galima pasakyti, jog šis modelis "surado geriausia, ką atskiri modeliai galėjo pasiūlyti". Tačiau verta pasvarstyti, ar vaizdų modelio rezultatai turėtų būti naudojami šiose, apjungtose prognozėse. Kadangi, palyginus su kitais rezultatais, vaizdų modelis pasirodė prasčiau nei kiti, jis galėjo tik iškreipti duomenis ir neatsižvelgus į vaizdų modelio rezultatus, būtų pasiektas dar didesnis tikslumas. Nors ir lyginant su garso lygio modeliu, bendras tikslumas yra didesnis tik 0.73%, jis yra patikimesnis. Matomi mažesni nukrypimai tarp apkrovos nustatymų ir modelis atlieka mažesnius nukrypimus. Tai galima pastebėti 8-oje lentelėje. Atkreipus dėmesį į vidutinę kvadratinę paklaidą (RMSE), matome jog apjungtas modelis pasiekė mažiausią RMSE.

Žvelgiant į MASE metrikas, atrodytų, jog visi modeliai pasirodė prastai. $MASE < 1$ indikuoja gerą prognozę, kuri artima bendrai tendencijai ir yra tikslesnė nei naivus spėjimas, $MASE < 2$

indikuoja, jog tendencija yra gera, tačiau tikslumas nėra labai geras. Tačiau, šiuo atveju, naivus spėjimas - spėjimas jog visos vertės išliks tokios pačios ir yra pats tiksliausias rezultatas, nes visa laiko eilutė atitinka vieną emisijų dalelių matavimą. Dėl šios priežasties, MASE metrikos niekad nebus labai žemos, tai parodo ir pakankamai mažas vidutinės procentinės rodiklis (MAPE). Tad šis matavimas turi būti interpretuotas turint eksperimento specifiką omenyje, tačiau nereiškia, jog šie duomenys neduos jokios naudingos informacijos. Galime pastebėti, jog garso lygmens modelis pasiekė mažiausias MASE metrikas - 1.76 2.5 μm dalelėms ir 1.78 0.3 μm dalelėms. Tačiau taip pat, MASE metrikose, pasižymėjo didžiausiu standartiniu nuokrypiu - 3.71. Tuo tarpu apjungtas modelis pasižymėjo mažiausiu - 0.84. Tai, kaip ir kiti matavimai nurodo gan nuoseklius ir tolygius spėjimus.

Modelis	Dalelių dydis, μm	MASE	MAE	RMSE	MAPE (%)
Virpesių	0.3	7.96	4872.38	9003.70	9.00
	0.5	4.37	968.39	1252.24	4.95
	1	6.51	254.64	469.19	7.34
	2.5	8.27	40.62	71.48	9.34
	5	4.21	0.08	0.13	4.78
	10	4.48	0.33	0.59	5.06
Vaizdų	0.3	8.90	5146.13	6539.07	10.08
	0.5	12.19	2724.32	3248.30	13.70
	1	10.70	389.76	419.30	11.90
	2.5	13.54	68.83	102.83	16.00
	5	15.91	0.14	0.2	18.28
	10	10.96	0.83	1.10	12.26
Garso lygmens	0.3	1.78	1493.35	2980.91	2.55
	0.5	11.39	1790.26	2599.61	8.63
	1	4.73	160.86	245.58	4.74
	2.5	1.76	7.80	9.49	1.77
	5	6.02	0.09	0.14	4.99
	10	2.44	0.13	0.15	1.98
Apjungtas	0.3	2.11	1228.49	1595.69	2.43
	0.5	2.41	539.39	719.49	2.58
	1	3.49	143.29	204.16	3.80
	2.5	4.19	19.52	23.73	4.37
	5	3.83	0.06	0.09	4.37
	10	2.67	0.19	0.29	2.94

8 lentelė. Tikslumo metrikų rezultatai visiems transformerių sistemos modeliams.

6.2. Privalumai ir trūkumai

Remiantis rezultatais verta paminėti pagrindines stiprybes bei silpnybes šio eksperimento ir programinės įrangos sprendimo būdo.

Privalumai

- Dėl duomenų paskirstymo ir išskaidymo, atskiri transformerių modeliai galėjo būti gilesni ir konfigūracijoje naudoti daugiau paslėptų sluoksnių, daugiau enkoderio bei dekoderio sluoksnių. Tai sumažina skaičiavimo resursų poreikius ir leidžia šiems modeliams veikti sparčiau.
- Dėl padalintos ir išskirstytos skaičiavimų apkrovos, šie modeliai gali būti naudojami įprastuose kompiuteriuose.
- Duomenų paskirstymas ir išskaidymas į atskirus modelius leido įvertinti, kurie duomenys yra svarbiausi atliekant prognozes. Išryškėja specifiniai požymiai, kurie geriau ar blogiau atspindi įvairiose duomenų grupėse.
- Išskirstytų modelių sistema yra moduliari, dėl to yra lengviau pakeisti tam tikrus sistemos komponentus, modelius, jų dalis, bei bendrai tobulinti šį sprendimą.
- Išskirstytų modelių sistemos architektūra sukuria daugiau lankstumo taškų ir leidžia veikti keliais konfigūracijos būdais.
- Atskiri modeliai geriau atpažįsta atskirus prognozes elementus, prisidedami prie geresnio bendro rezultato.

Trūkumai

- Atlikus bandymus buvo pastebėta, jog su tais pačiais parametrais, tarp bandymų, rezultatai kinta. Tai gali nutikti dėl kelių faktorių: bandymai buvo atliekami lauke, tad kintančios oro sąlygos galėjo padaryti įtaką rezultatų tikslumui. Taip pat, laboratorijos vieta nulėmė tai, jog rezultatai buvo atliekami netoliese kelio, tad papildomos vibracijos ir garsas galėjo prisidėti prie matavimų kintamumo. Šie faktoriai galėjo daryti įtaką modelių rezultatams ir tikslumui.
- Remiantis rezultatais, matoma tendencija geriau prognozuoti didesnės apkrovos bandymų rezultatus, su kuriais buvo apmokomi modeliai vėliausiai. Tai indikuoja potencialius trūkumus apmokyme, kurie gali būti patobulinti, pasitelkus geresnį duomenų išmaišymą, keičiant modelių konfigūracijos parametrus ar apmokymo strategiją.
- Pasirinkta kelių modelių sistema įneša ne tik savų privalumų, bet ir trūkumų. Kaip ir mikroservisų architektūros sistemose, atsiranda papildomas sudėtingumas valdant atskirus komponentus, kaip modelių eiliškumo koordinavimas.
- Infraraudonųjų spindulių kameros vaizdų analizė nebuvo tokio vertinga, kaip buvo manyta bandymų pradžioje. Prognozės, paremtos vaizdų informacija, palyginus su kitais duomenų šaltiniais, buvo netikslios ir neatnešė naudos.

Rezultatai ir išvados

Pasiekti rezultatai

- Atlikta literatūros apžvalga, kurioje analizuoti įvairūs prognostiniai mašininio mokymosi metodai.
- Sukurta prognostinių Autoformer transformerių neuroninių tinklų sistemos algoritmo architektūra, pritaikyta eksperimento metu gautiems duomenims.
- Išreniruota sukurta Autoformer transformerių modelių sistema, pasitelkiant eksperimento metu gautus duomenis: variklio virpesius, garso lygmens analizes ir infraraudonųjų spindulių kameros vaizdus.
- Ištestuota tyrimo metu sukurta transformerių modelių sistema, pasitelkiant jai dar nematytus eksperimentinius duomenis.
- Palyginti gauti rezultatai su LSTM rekurentiniu neuroniniu tinklu ir ANCOVA statistiniu modeliu, įvertinant jų efektyvumą emisijų prognozavimui.
- Įvertinti sukurtos modelių sistemos rezultatai, nustatyti jos privalumai ir trūkumai, bei parengtos apibendrinančios išvados.

Išvados

- Transformerių modeliai, tokie kaip "Autoformer" gali būti sėkmingai pritaikyti bekontaktiniam emisijų dalelių prognozavimui.
- Padalinant įvesties duomenis pagal duomenų grupes ir sukuriant 3 atskirus modelius - virpesių, vaizdo ir garso lygmens, leido geriau pamatyti ir įvertinti, kurie modeliai tiksliausiai prognozuoja dalelių kiekius.
- Sukurta transformerių modelių sistema buvo efektyvus būdas apibendrinti atskirų trijų modelių prognozes, pasiekdama geriausią vidutinį tikslumą - 96.59%.
- Palyginimas su LSTM rekurentiniu modeliu parodė, jog dėl didelio duomenų kiekio ir poreikio išlaikyti ilgalaikes priklausomybes, LSTM pasiekė tik 62.34% tikslumą, o statistinis ANVOCA modelis – 61.82%.
- Tarp analizuotų duomenų tipų, IR nuotraukų Autoformer modelis parodė prasčiausius rezultatus transformerių modeliuose, pasiekiant vidutinį tikslumą 86.3%.

Literatūra

- [AAR23] M. Avi-Aharon, A. Arbelle ir T. R. Raviv. Differentiable Histogram Loss Functions for Intensity-based Image-to-Image Translation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023. doi: 10.1109/TPAMI.2023.3278287.
- [Age23] European Environment Agency. New registrations of electric vehicles in Europe. <https://www.eea.europa.eu/en/analysis/indicators/new-registrations-of-electric-vehicles?activeAccordion=ecdb3bcf-bbe9-4978-b5cf-0b136399d9f8>, 2023. tikrinta 2024-01-14.
- [ARL⁺23] M. E. Alaoui, M. Rougui, A. Lamrani ir O. Mouhat. Building energy prediction using artificial neural networks and analysis of covariance in the six thermal zones of Morocco. *Materials Today: Proceedings*, 2023. ISSN: 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2023.06.228>. URL: <https://www.sciencedirect.com/science/article/pii/S2214785323036222>.
- [AUD00] AUDI. Motor Vehicle Exhaust Emissions, 2000. URL: http://www.volkspage.net/technik/ssp/ssp/SSP_230.pdf.
- [AW24] U. Ankit ir B. Whitfield. Transformer Neural Networks: A Step-by-Step Breakdown. <https://builtin.com/artificial-intelligence/transformer-neural-network>, 2024.
- [BK09] Brüel ir Kjær. Bruel And Kjar 8341 CCLD specifications. <https://www.bksv.com/de/transducers/vibration/accelerometers/ccld-iepe/8341>, 2009.
- [BK21] Brüel ir Kjær. Bruel And Kjar 2250 specifications. <https://www.bksv.com/media/doc/bp2025.pdf>, 2021.
- [BM21] G. Barouch ir C. Michaël. Fourier Transform Infrared (FTIR) Spectroscopy for Measurements of Vehicle Exhaust Emissions: A Review. *Applied Sciences*, 11(16), 2021. ISSN: 2076-3417. doi: 10.3390/app11167416. URL: <https://www.mdpi.com/2076-3417/11/16/7416>.
- [BTS21] Ö. Büyükdipi, G. Tüccar ir H. S. Soyhan. Experimental investigation and artificial neural networks (ANNs) based prediction of engine vibration of a diesel engine fueled with sunflower biodiesel – NH₃ mixtures, 2021. doi: <https://doi.org/10.1016/j.fuel.2021.121462>. URL: <https://www.sciencedirect.com/science/article/pii/S0016236121013417>.
- [BW10] G. J. Boggy ir P. J. Woolf. A Mechanistic Model of PCR for Accurate Quantification of Quantitative PCR Data. *PLOS ONE*, 5(8):1–7, 2010-08. doi: 10.1371/journal.pone.0012355. URL: <https://doi.org/10.1371/journal.pone.0012355>.
- [CEM19] CEM. Particle Counter User Manual. <https://rapid-tech.com.au/wp-content/uploads/2019/02/DT-9880-User-Manual.pdf>, 2019.

- [Com23] European Commission. Zero emission vehicles: first ‘Fit for 55’ deal will end the sale of new CO₂ emitting cars in Europe by 2035. https://ec.europa.eu/commission/presscorner/detail/en/IP_22_6462, 2023. 38,8 KB, tikrinta 2024-01-14.
- [CvMB⁺14] K. Cho, B. van Merriënboer, D. Bahdanau ir Y. Bengio. On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. <https://arxiv.org/pdf/1409.1259>, 2014. 356 KB, tikrinta 2024-06-14.
- [DHZ⁺23] D. Quanli, L. Hanbin, Z. Zhenjing, S. Yedong, C. Shilong ir M. Zhiwei. A lightweight deep learning-based method for health diagnosis of internal combustion engines on an internet of vehicles platform, 2023. DOI: 10.1177/09544070231198905. URL: https://www.researchgate.net/publication/376462228_A_lightweight_deep_learning-based_method_for_health_diagnosis_of_internal_combustion_engines_on_an_internet_of_vehicles_platform.
- [Dos21] K. Doshi. Transformers Explained Visually (Part 3): Multi-head Attention, deep dive. <https://towardsdatascience.com/transformers-explained-visually-part-3-multi-head-attention-deep-dive-1c1ff1024853>, 2021.
- [FLI20] Teledyne FLIR. Compact Thermal Camera FLIR C5. <https://flir.netx.net/file/asset/27073/original/attachment>, 2020.
- [FRH⁺22] M. M. Francisco, N. M. Roberta, O. L. Heitor ir A. J. Humberto. Prediction of Bending Properties for 3D-Printed Carbon Fibre/Epoxy Composites with Several Processing Parameters Using ANN and Statistical Methods. *Polymers*, 14(17), 2022. ISSN: 2073-4360. DOI: 10.3390/polym14173668. URL: <https://www.mdpi.com/2073-4360/14/17/3668>.
- [GO18] B. Gabriel ir G. Osama. Use of Water Injection Technique to Improve the Combustion Efficiency of the Spark-Ignition Engine: A Model Study, 2018. DOI: 10.12911/22998993/99689. URL: https://www.researchgate.net/publication/329610891_Use_of_Water_Injection_Technique_to_Improve_the_Combustion_Efficiency_of_the_Spark-Ignition_Engine_A_Model_Study.
- [HD05] W. Haifeng ir H. Dejin. Comparison of SVM and LS-SVM for Regression. 1:279–283, 2005. DOI: 10.1109/ICNNB.2005.1614615.
- [Her24] S. Herath. Exploring the Multi-head Attention Sublayer in the Transformer. <https://medium.com/image-processing-with-python/exploring-the-multi-head-attention-sublayer-in-the-transformer-ee1241a128a1>, 2024.
- [Hyn06] R. J. Hyndman. *Another look at measures of forecast accuracy*. FORESIGHT Issue 4, 2006.

- [HLC⁺15] G.B. Hamra, F. Laden, A.J. Cohen, O. Raaschou-Nielsen, M. Brauer ir D. Loomis. Lung Cancer and Exposure to Nitrogen Dioxide and Traffic: A Systematic Review and Meta-Analysis, 2015. DOI: 10.1289/ehp.1408882. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4629738/>.
- [HS97] S. Hochreiter ir J. Schmidhuber. Long Short-Term Memory. *Neural Computation*, 9(8):1735–1780, 1997-11. ISSN: 0899-7667. DOI: 10.1162/neco.1997.9.8.1735. URL: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [HTG⁺20] S. H. Hosseini, A. Taghizadeh-Alisaraei, B. Ghobadian ir A. Abbaszadeh-Mayvan. Artificial neural network modeling of performance, emission, and vibration of a CI engine using alumina nano-catalyst added to diesel-biodiesel blends. *Renewable Energy*, 149:951–961, 2020. ISSN: 0960-1481. DOI: <https://doi.org/10.1016/j.renene.2019.10.080>. URL: <https://www.sciencedirect.com/science/article/pii/S096014811931571X>.
- [HZR⁺15] Kaiming He, Xiangyu Zhang, Shaoqing Ren ir Jian Sun. Deep Residual Learning for Image Recognition. <https://arxiv.org/abs/1512.03385>, 2015.
- [YS22] Y. Youngjun ir J. Seongcheol. Vibration analysis process based on spectrogram using gradient class activation map with selection process of CNN model and feature layer. *Displays*, 2022. DOI: <https://doi.org/10.1016/j.displa.2022.102233>. URL: <https://www.sciencedirect.com/science/article/pii/S01411938222000622>.
- [JB20] M. Jorge ir F. P. Brito. Alternative Fuels for Internal Combustion Engines. *Energies*, 13(16), 2020. ISSN: 1996-1073. DOI: 10.3390/en13164086. URL: <https://www.mdpi.com/1996-1073/13/16/4086>.
- [JC16] I. Jolliffe ir J. Cadima. Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2016. DOI: 10.1098/rsta.2015.0202. URL: https://www.researchgate.net/publication/297661698_Principal_component_analysis_A_review_and_recent_developments.
- [JP14] D.P. Jena ir S.N. Panigrahi. Motor bike piston-bore fault identification from engine noise signature analysis. *Applied Acoustics*, 76:35–47, 2014. ISSN: 0003-682X. DOI: <https://doi.org/10.1016/j.apacoust.2013.07.023>. URL: <https://www.sciencedirect.com/science/article/pii/S0003682X13001746>.
- [JSB⁺18] A. Jain, A. Sharma, S.L. Borana, B. Ravindra ir J.P. Mangalhara. Study and Analysis of Exhaust Emission of Diesel Vehicles using Thermal IR Imagers, 2018. DOI: 10.14429/dsj.68.12701. URL: <https://pdfs.semanticscholar.org/c013/94705d863f722e6a9561b545446f373a26e9.pdf>.

- [JSM⁺09] M. I. Jahirul, R. Saidur, H. H. Masjuki, M. A. Kalam ir M. M. Rashid. Application of Artificial Neural Networks (ANN) for Prediction the Performance of a Dual Fuel Internal Combustion Engine. *HKIE Transactions*, 16(1):14–20, 2009. doi: <https://doi.org/10.1080/1023697X.2009.10668146>. URL: <https://www.tandfonline.com/doi/epdf/10.1080/1023697X.2009.10668146?needAccess=true>.
- [KA20] I. Khan ir N. Aslam. A Deep-Learning-Based Framework for Automated Diagnosis of COVID-19 Using X-ray Images. *Information*, 11:419, 2020-08. doi: [10.3390/info11090419](https://doi.org/10.3390/info11090419).
- [Kep91] G. Keppel. *Design and Analysis: A Researcher's Handbook*. Prentice Hall, 1991. ISBN: 9780132007757. URL: <https://books.google.lt/books?id=BRK2AAAAIAAJ>.
- [KHL⁺98] H. J. Keselman, C. J. Huberty, L. M. Lix, S.n Olejnik ir k.t. Statistical Practices of Educational Researchers: An Analysis of their ANOVA, MANOVA, and ANCOVA Analyses. *Review of Educational Research*, 68(3):350–386, 1998. doi: [10.3102/00346543068003350](https://doi.org/10.3102/00346543068003350). eprint: <https://doi.org/10.3102/00346543068003350>. URL: <https://doi.org/10.3102/00346543068003350>.
- [Kou23] A. Koudiri. Understanding ResNet: A Milestone in Deep Learning and Image Recognition. <https://www.ikomia.ai/blog/mastering-resnet-deep-learning-image-recognition>, 2023. tikrinta 2024-06-15.
- [KXS⁺16] H. Kaiming, Z. Xiangyu, R. Shaoqing ir S. Jian. Deep Residual Learning for Image Recognition. <https://ieeexplore.ieee.org/document/7780459>, 2016. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90). 543 KB, tikrinta 2024-06-14.
- [LBH15] Y. LeCun, Y. Bengio ir G. Hinton. Deep learning. *"Nature"*, 2015-06. doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539). URL: <https://pubmed.ncbi.nlm.nih.gov/26017442/>.
- [LKA17] J. Lever, M. Krzywinski ir N. Altman. Principal component analysis. <https://rdcu.be/dLkFE>, 2017. tikrinta 2024-06-15.
- [LPM15] M. T. Luong, H. Pham ir C. D. Manning. Effective Approaches to Attention-based Neural Machine Translation. <https://arxiv.org/abs/1508.04025>, 2015.
- [MA21] S. Mascarenhas ir M. Agarwal. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. *2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON)*, 2021. doi: [10.1109/CENTCON52345.2021.9687944](https://doi.org/10.1109/CENTCON52345.2021.9687944).
- [May19] A. Mayer. Periodic Emission Inspection of SCR-equipped Cars and Trucks, 2019. URL: http://nanoparticles.ch/archive/2019_Mayer1_PR.pdf.
- [Mar22] M.M. Martinez. How to measure vehicle emissions, 2022. URL: <https://wikis.ec.europa.eu/display/ULEV/How+to+measure+vehicle+emissions>.

- [OKK14] H. Omidvarborna, A. Kumar ir D. Kim. Characterization of particulate matter emitted from transit buses fueled with B20 in idle modes. *Journal of Environmental Chemical Engineering*, 2014. DOI: <https://doi.org/10.1016/j.jece.2014.09.020>. URL: <https://www.sciencedirect.com/science/article/pii/S2213343714002140>.
- [Oma02] Stanley T. Omaye. Metabolic modulation of carbon monoxide toxicity, 2002. DOI: [https://doi.org/10.1016/S0300-483X\(02\)00387-6](https://doi.org/10.1016/S0300-483X(02)00387-6). URL: <https://www.sciencedirect.com/science/article/pii/S0300483X02003876>.
- [Pur22] N. Purnama. Music Genre Recommendations Based on Spectrogram Analysis Using Convolutional Neural Network Algorithm with RESNET-50 and VGG-16 Architecture. *JISA (Jurnal Informatika dan Sains)*, 2022. DOI: <https://doi.org/10.31326/jisa.v5i1.1270>. URL: <http://trilogi.ac.id/journal/ks/index.php/JISA/article/view/1270>.
- [RCA22] S.M. Ramteke, H. Chelladurai ir M. Amarnath. Diagnosis of engine component faults is a challenging task for every researcher due to the complexity involved in the engine operations. 2022. DOI: <https://doi.org/10.1007/s42417-021-00370-2>. URL: <https://link.springer.com/article/10.1007/s42417-021-00370-2#citeas>.
- [RDS⁺15] O. Russakovsky, J. D., H. S., J. Krause, S. Satheesh ir S. Ma. ImageNet Large Scale Visual Recognition Challenge. <https://image-net.org/challenges/LSVRC/2015/results>, 2015. tikrinta 2024-06-15.
- [RRC⁺23] E. Roldán, N. D. Reeves, G. Cooper ir K. Andrews. Towards the ideal vascular implant: Use of machine learning and statistical approaches to optimise manufacturing parameters. *Frontiers in Physics*, 11, 2023. ISSN: 2296-424X. DOI: 10.3389/fphy.2023.1112218. URL: <https://www.frontiersin.org/journals/physics/articles/10.3389/fphy.2023.1112218>.
- [Sch18] Pete Scheidler. Understanding the Basics of Fourier Transforms. <https://blog.endaq.com/fourier-transform-basics>, 2018.
- [SDM16] Kohler SDMO. Kohler SDMO Diesel 4000 specifications. https://portable.kohlerpower.com/en/generating-set-diesel-4000-c5-xml-403_410-1195.html, 2016.
- [Sin24] S. Singh. Types of neural networks: Recurrent Neural Networks. <https://medium.com/@shekhawatsamvardhan/types-of-neural-networks-recurrent-neural-networks-7c43bd73e033>, 2024.
- [SRR23] E. Simhayev, K. Rasul ir N. Rogge. Yes, Transformers are Effective for Time Series Forecasting (+ Autoformer). <https://huggingface.co/blog/autoformer>, 2023.

- [SV25] GRAS Sound ir Vibration. GRAS 46AE specifications. https://www.grasacoustics.com/?eID=1709645390&import_id=140, 2025.
- [SVL14] I. Sutskever, O. Vinyals ir Q. V. Le. Sequence to Sequence Learning with Neural Networks. <https://arxiv.org/abs/1409.3215>, 2014. 373 KB, tikrinta 2024-06-14.
- [TKD17] M.C. Turner, D. Krewski ir W.R. Diver. Ambient Air Pollution and Cancer Mortality in the Cancer Prevention Study II, 2017. DOI: 10.1289/EHP1249. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5783657/>.
- [TN19] B. Timea ir B. Nebojsa. Convolutional Neural Network Layers and Architectures. https://www.researchgate.net/publication/333242381_Convolutional_Neural_Network_Layers_and_Architectures, 2019. DOI: 10.15308/Sinteza-2019-445-451. 942 KB, tikrinta 2024-06-14.
- [UC18] S. Uslu ir M. B. Celik. Prediction of engine emissions and performance with artificial neural networks in a single cylinder diesel engine using diethyl ether. *Engineering Science and Technology, an International Journal*, 21(6):1194–1201, 2018. ISSN: 2215-0986. DOI: <https://doi.org/10.1016/j.jestch.2018.08.017>. URL: <https://www.sciencedirect.com/science/article/pii/S2215098618308085>.
- [VSP⁺17] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser ir I. Polosukhin. Attention Is All You Need. <https://arxiv.org/pdf/1706.03762>, 2017. 382 KB, tikrinta 2024-06-14.
- [WLD⁺23] Xingyu Wang, Hui Liu, Junzhao Du, Zhihan Yang ir Xiyao Dong. CLformer: Locally grouped auto-correlation and convolutional transformer for long-term multivariate time series forecasting. *Engineering Applications of Artificial Intelligence*, 121:106042, 2023. ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2023.106042>. URL: <https://www.sciencedirect.com/science/article/pii/S0952197623002269>.
- [WXW⁺22] H. Wu, J. Xu, J. Wang ir M. Long. Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting. <https://arxiv.org/abs/2106.13008>, 2022.
- [ZCZ⁺22a] A. Zeng, M. Chen, L. Zhang ir Q. Xu. Are Transformers Effective for Time Series Forecasting? <https://arxiv.org/abs/2205.13504>, 2022. eprint: 2205.13504.
- [ZCZ⁺22b] Ailing Zeng, Muxi Chen, Lei Zhang ir Qiang Xu. Are Transformers Effective for Time Series Forecasting? *arXiv preprint arXiv:2205.13504*, 2022.
- [ZPK⁺19] A. Zeyer, P. B. Parnia, I. Kazuki, R. Schlüter ir N. Hermann. A Comparison of Transformer and LSTM Encoder Decoder Models for ASR:8–15, 2019. DOI: 10.1109/ASRU46091.2019.9004025.


- [ŽVM⁺21] T. Žvirblis, D. Vainorius, J. Matijošius, K. Kilikevičienė, A. Rimkus, Á. Bereczky, K. Lukács ir A. Kilikevičius. Engine Vibration Data Increases Prognosis Accuracy on Emission Loads: A Novel Statistical Regressions Algorithm Approach for Vibration Analysis in Time Domain. *Symmetry*, 13(7), 2021. ISSN: 2073-8994. DOI: 10.3390/sym13071234. URL: <https://www.mdpi.com/2073-8994/13/7/1234>.

Santrumpos

- **IR** — *Infrared* (infraraudonieji spinduliai).
- **FFT** — *Fast Fourier Transform* (greitoji Furjė transformacija).
- **STFT** — *Short-Time Fourier Transform* (trumpalaikė Furjė transformacija).
- **SVM** — *Support Vector Machine* (atraminio vektoriaus klasifikatorius).
- **SCG** — *Suskaitytas konjuguotųjų gradientų metodas*.
- **LM** — *Levenbergo-Markardo algoritmas*.
- **GPU** — *Graphics Processing Unit* (grafinis procesorius).
- **NLL** — *Negative Log-Likelihood* (neigiama logaritminės tikimybės klaida).
- **MASE** — *Mean Absolute Scaled Error* (vidutinė absoliuti skalės paklaida).
- **MAE** — *Mean Absolute Error* (vidutinė absoliuti paklaida).
- **RMSE** — *Root Mean Square Error* (vidutinė kvadratinė paklaida).
- **MAPE** — *Mean Absolute Percentage Error* (vidutinė absoliuti procentinė paklaida).
- **PCA** — *Principal Component Analysis* (pagrindinių komponentų analizė).
- **PCR** — *Principal Component Regression* (pagrindinių komponentų regresija).
- **MANOVA** — *Multivariate Analysis of Variance* (daugialypė dispersijos analizė).
- **ANCOVA** — *Analysis of Covariance* (kovariančių analizė).
- **LSTM** — *Long Short-Term Memory* (ilgos trumpalaikės atminties modelis).
- **RNN** — *Recurrent Neural Network* (rekurentinis neuroninis tinklas).
- **GRU** — *Gated Recurrent Unit* (sklendžių rekurentinių vienetų modelis).
- **CNN** — *Convolutional Neural Network* (konvoliucinis neuroninis tinklas).

Priedas Nr. 1


Eksperimento schema



26 pav. Tyrimo metu naudojamos sistemos duomenų schema

Priedas Nr. 2

Emisijų prognozavimo sistemos sekos diagrama



27 pav. Emisijų prognozavimo sistemos sekos diagrama