

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Vinício de Araújo Matos

**Análise e Modelagem das Emissões Instantâneas
de CO₂ em Veículos de Combustão Interna por
meio de Dados OBD-II e Redes Neurais
Artificiais**

João Pessoa
2025

Vinício de Araújo Matos

Análise e Modelagem das Emissões Instantâneas de CO₂ em Veículos de Combustão Interna por meio de Dados OBD-II e Redes Neurais Artificiais

Trabalho final de Mestrado apresentado ao
Programa de Pós Graduação em Engenharia
Elétrica da Universidade Federal da Paraíba
como exigência para a obtenção do título de
Mestre em Engenharia Elétrica.

Universidade Federal da Paraíba

Centro de Energias Alternativas e Renováveis

Programa de Pós Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Juan Moises Maurício Villanueva

Coorientador: Prof. Dr. Cicero da Rocha Souto

João Pessoa

2025

UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA – PPGE

A Comissão Examinadora, abaixo assinada, aprova a Dissertação

**ANÁLISE E MODELAGEM DAS EMISSÕES INSTANTÂNEAS DE CO₂ EM
VEÍCULOS DE COMBUSTÃO INTERNA POR MEIO DE DADOS OBD-II E REDES
NEURAIS ARTIFICIAIS**

Elaborada por

VINÍCIO DE ARAÚJO MATOS

como requisito parcial para obtenção do grau de
Mestre em Engenharia Elétrica.

COMISSÃO EXAMINADORA

 Documento assinado digitalmente
JUAN MOISES MAURICIO VILLANUEVA
Data: 22/12/2025 20:41:40-0300
Verifique em <https://validar.iti.gov.br>

PROF. DR. JUAN MOISES MAURICIO VILLANUEVA
Orientador – UFPB

 Documento assinado digitalmente
CICERO DA ROCHA SOUTO
Data: 22/12/2025 20:12:53-0300
Verifique em <https://validar.iti.gov.br>

PROF. DR. CÍCERO DA ROCHA SOUTO
Coorientador – UFPB

 Documento assinado digitalmente
EULER CASSIO TAVARES DE MACEDO
Data: 22/12/2025 17:32:09-0300
Verifique em <https://validar.iti.gov.br>

PROF. DR. EULER CASSIO TAVARES DE MACÊDO
Examinador Interno – UFPB

 Documento assinado digitalmente
RAIMUNDO CARLOS SILVÉRIO FREIRE
Data: 11/12/2025 13:19:51-0300
Verifique em <https://validar.iti.gov.br>

PROF. DR. CARLOS RAIMUNDO SILVÉRIO FREIRE
Examinador Externo – UFCG

RESUMO

Este trabalho desenvolve uma metodologia para avaliar e modelar as emissões veiculares de dióxido de carbono (CO_2) por meio de dados coletados via interface OBD-II, integrando análise automotiva com técnicas de redes neurais artificiais. O objetivo geral é comparar o comportamento de emissões de veículos de combustão interna com veículos elétricos em condições reais de uso. Os dados relevantes de operação (velocidade, aceleração, fluxo de ar, etc.) foram coletados diretamente dos veículos através do OBD-II e posteriormente analisados de forma exploratória para identificar padrões e correlações (como a forte relação entre carga do motor e geração de CO_2). Modelos preditivos do tipo *Multi-Layer Perceptron* (MLP) e *Long Short-Term Memory* (LSTM) foram então treinados para estimar as emissões instantâneas de CO_2 . O modelo LSTM apresentou melhor desempenho, atingindo erro médio percentual absoluto (MAPE) em torno de 5%, significativamente superior ao MLP (MAPE 16%). A análise comparativa indica que veículos elétricos eliminam as emissões diretas durante o uso, mas seu impacto total de CO_2 depende da matriz elétrica e das emissões na fabricação. Conclui-se que a abordagem proposta - combinando dados OBD-II e redes neurais - é eficaz para estimar emissões em tempo real, podendo complementar as estimativas padronizadas.

Palavras-chave: Emissões veiculares; Veículos elétricos; Dióxido de carbono; On-Board Diagnostics; Redes neurais artificiais; Emissões Veiculares; Veículos Elétricos; Dióxido de Carbono (CO_2) ; *On-Board Diagnostics* (OBD); Eficiência Energética.

ABSTRACT

This study develops a methodology to evaluate and model vehicle carbon dioxide (CO₂) emissions using data collected via the OBD-II interface, integrating detailed automotive analysis with artificial neural network techniques. The overall goal is to compare the emission behavior of internal combustion engine vehicles with electric vehicles under real operating conditions. Relevant operational data (speed, throttle position, air flow, etc.) were gathered directly from vehicles through OBD-II and then explored to identify patterns and correlations (such as the strong relationship between engine load and CO₂ generation). Predictive models using *Multi-Layer Perceptron* (MLP) and *Long Short-Term Memory* (LSTM) neural networks were trained to estimate instantaneous CO₂ emissions. The LSTM model achieved the best performance with a mean absolute percentage error (MAPE) of around 5%, significantly outperforming the MLP (MAPE 16%). The comparative analysis indicates that electric vehicles eliminate direct emissions during use, but their total CO₂ impact depends on the electrical grid mix and manufacturing emissions. In conclusion, the proposed approach - combining OBD-II data and neural networks - proved effective for real-time emission estimation and can complement standardized lab-based estimates.

Keywords: Vehicle emissions; Electric vehicles; Carbon dioxide; On-board diagnostics; Artificial neural networks; Vehicle emissions; Electric vehicles; CO₂; OBD; Energy efficiency.

LISTA DE ILUSTRAÇÕES

Figura 1 – Crescimento da Produção Automotiva Mundial (Organisation Internationale des Constructeurs d’Automobiles, 2024).	22
Figura 2 – Licenciamentos de Veículos no Brasil - Série Histórica (ANFAVEA, 2025).	23
Figura 3 – Vendas de Veículos Eletrificados na China - 2011 a 2021 (International Energy Agency, 2024b).	24
Figura 4 – Contribuição de Poluentes por Tipo de Veículo - Em porcentagem (%). (WU et al., 2023)	25
Figura 5 – Distribuição da matriz elétrica por região e sua contribuição para as emissões de CO ₂	30
Figura 6 – Pinagem do conector OBD-II (CS Selectronics, 2024).	36
Figura 7 – MLP com duas camadas ocultas. Fonte: (FLECK et al., 2016).	40
Figura 8 – LSTM - Fonte: (BARBOSA et al., 2021)	41
Figura 9 – Monte Carlo Dropout - Fonte: (LIMA, 2022)	42
Figura 10 – Dispositivo <i>ELM Electronics - 327</i> (ELM327) utilizado na coleta de dados (Elm Electronics Inc., 2017).	45
Figura 11 – Aplicativo <i>Torque Pro</i> utilizado para leitura e registro dos dados (HAWKINS, 2025).	46
Figura 12 – <i>Integrated Development Environment</i> (IDE) e linguagem de programação usadas na análise de dados.	48
Figura 13 – Arquitetura usada para processamento dos dados.	49
Figura 14 – Matriz de Correlação.	52
Figura 15 – Correlação entre Carga do Motor e CO ₂	54
Figura 16 – Valores reais de Medição - Onix.	55
Figura 17 – Valores reais de Medição - Fastback.	55
Figura 18 – Desvio Padrão - Onix.	56
Figura 19 – Desvio Padrão - Fastback.	56
Figura 20 – Fluxograma do procedimento de execução para combinações de hiperparâmetros.	58
Figura 21 – Fluxograma geral do procedimento experimental.	59
Figura 22 – Primeira Etapa de Treinamento - MAPE por Número de Neurônios.	60
Figura 23 – Primeira Etapa de Treinamento - MAPE por Taxa de Aprendizagem.	61
Figura 24 – Primeira Etapa de Treinamento - MAPE por Quantidade de Camadas.	62
Figura 25 – Primeira Etapa de Treinamento - MAPE por Épocas.	62
Figura 26 – Segunda Etapa de Treinamento - MAPE por Taxa de Dropout.	64
Figura 27 – Segunda Etapa de Treinamento - MAPE por Parâmetro T.	64

Figura 28 – Dispersão entre valores reais e previstos de gCO_2 para a rede LSTM com MCD.	66
Figura 29 – Top 5% Amostras com menor variabilidade (menor incerteza) - Monte Carlo Dropout.	67
Figura 30 – Top 5% Amostras com maior variabilidade (maior incerteza) - Monte Carlo Dropout.	67

LISTA DE TABELAS

Tabela 1 – Resumo das Revisões Bibliográficas	20
Tabela 2 – Relação entre fase PROCONVE (Brasil) e Europa.	26
Tabela 3 – CO ₂ por litro de combustível (IEEP, 2010; INNOVATEMOTORS, 2014; HILL et al., 2012).	29
Tabela 4 – Emissões de CO ₂ por tipo de combustível na geração de eletricidade. .	30
Tabela 5 – Emissões de CO ₂ na Produção de Veículos (kg por veículo)	31
Tabela 6 – Densidade energética (δ) conforme NBR 7024, seção 6.8.3.	33
Tabela 7 – Estrutura de uma mensagem CAN	35
Tabela 8 – Estrutura de Identificadores no <i>Controller Area Network</i> (CAN) Estendido (SAE J1939)	36
Tabela 9 – Serviços/Modos definidos pela norma SAE J1979	37
Tabela 10 – Exemplos de PIDs do Serviço 01	38
Tabela 11 – Parâmetros do <i>Monte Carlo Dropout</i>	43
Tabela 12 – Exemplos de <i>PIDs</i> definidos por norma SAE	47
Tabela 13 – Especificações técnicas do veículo Onix.	47
Tabela 14 – Especificações técnicas do veículo Fastback.	48
Tabela 15 – Distribuição de tempo e amostras por veículo	51
Tabela 16 – Estatísticas descritivas dos parâmetros registrados	51
Tabela 17 – Parâmetros coletados via OBD	53
Tabela 18 – Descrição dos parâmetros utilizados na equação do cálculo de CO ₂ . . .	54
Tabela 19 – Resumo dos valores do PBE, média e desvio padrão	56
Tabela 20 – Valores de hiperparâmetros testados no modelo LSTM e MLP	58
Tabela 21 – Resumo da primeira etapa de treinamentos.	63
Tabela 22 – Melhores configurações e resultados dos modelos	65
Tabela 23 – Métricas de Desempenho para as melhores Configurações de Redes Neurais	65
Tabela 24 – Métricas de Avaliação do Modelo	66

LISTA DE SIGLAS

ABS *Anti-lock Braking System*

AFR *Air-Fuel Ratio*

ANFAVEA Associação Nacional dos Fabricantes de Veículos Automotores

BEVs Veículos Elétricos a Bateria

CAN *Controller Area Network*

CO Monóxido de Carbono

CO₂ Dióxido de Carbono

COV Composto Orgânico Volátil

CRC *Cyclic Redundancy Check*

DTC *Diagnostic Trouble Code*

ECU *Electronic Control Unit*

ELM327 *ELM Electronics - 327*

ESP *Electronic Stability Program*

H₂O *Água*

HC Hidrocarbonetos

IA Inteligência Artificial

IDE *Integrated Development Environment*

INMETRO Instituto Nacional de Metrologia, Qualidade e Tecnologia

ISO *International Organization for Standardization*

LSTM *Long Short-Term Memory*

LSTMs *Long Short-Term Memory*

MCD *Monte Carlo Dropout*

MLP *Multi-Layer Perceptron*

MP Material Particulado

MP₁₀ Material Particulado com até 10 mm de diâmetro

MP_{2,5} Material Particulado com até 2,5 mm de diâmetro

N₂ *Nitrogênio*

NBR Norma Técnica Brasileira

NO_x Óxido de Nitrogênio

OBD *On-Board Diagnostics*

PBE Programa Brasileiro de Etiquetagem

PHEV Veículos Híbridos Elétricos *Plug-in*

PID *Parameter ID*

PROCONVE Programa de Controle da Poluição do Ar por Veículos Automotores

RNA Rede Neural Artificial

RNAs Redes Neurais Artificiais

RNN Rede Neural Recorrente

RNNs Redes Neurais Recorrentes

SAE *Society of Automotive Engineers*

SoC *State of Charge*

VCI Veículos de Combustão Interna

VEs Veículos Elétricos

VHs Veículos Híbridos

SUMÁRIO

	Lista de tabelas	8
1	INTRODUÇÃO	13
1.1	Pertinência e motivação do trabalho	13
1.2	Contribuições	14
1.3	A importância da Medição Instantânea de CO ₂	15
1.4	Objetivo Geral	15
1.5	Objetivo Específico	16
1.6	Estrutura e organização do trabalho	16
2	REVISÃO BIBLIOGRÁFICA	17
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	Crescimento da Frota de Veículos	21
3.1.1	Panorama Mundial	21
3.1.2	Evolução da Frota no Brasil	22
3.1.3	A chegada dos VEs	23
3.2	As Emissões Geradas pelos Veículos	24
3.2.1	Emissões de Veículos a Combustão	24
3.2.2	Impacto das Emissões no Brasil	25
3.2.3	Mecanismos de Redução de Emissões Veiculares	26
3.2.4	A Relevância do Etanol	27
3.2.5	Métricas de Quantificação de Emissões Veiculares	27
3.2.6	Programa Brasileiro de Etiquetagem	28
3.2.7	A relevância do Dióxido de Carbono - CO ₂	28
3.2.8	Relação entre energia elétrica e CO ₂	29
3.2.9	Emissões de CO ₂ durante a Produção de Veículos	31
3.3	Normas Técnicas Brasileiras (NBR) relevantes	31
3.3.1	NBR 7024-2017 - Autonomia de Combustível em Veículos a Combustão	31
3.3.2	NBR 7024-2017 - Consumo Energético em Veículos a Combustão	32
3.3.3	NBR 17142 - Consumo Energético em Veículos Elétricos	33
3.4	Aquisição e Análise de Dados Veiculares	34
3.4.1	ISO 11898 - Rede CAN Automotiva	34
3.4.2	SAE J1939 e SAE J1979 - Padronização OBD	36
3.4.3	Parâmetros Coletáveis a partir do OBD	36
3.5	Aprendizado de Máquina	38

3.5.1	Uso do Aprendizado de Máquina na Estimação de CO ₂	38
3.5.2	A relação entre Equações Físicas e Aprendizado de Máquina	38
3.5.3	Redes Neurais	39
3.5.4	Perceptron Multicamadas - MLP (<i>Multi-Layer Perceptron</i>)	39
3.5.5	Memória de Curto e Longo Prazo - LSTM (<i>Long Short-Term Memory</i>) .	40
3.5.6	Análise de Incertezas - <i>Monte Carlo Dropout</i>	42
3.5.7	Métricas de Avaliação de Modelos	43
3.6	Justificativa da Escolha dos Algoritmos	44
4	MATERIAIS E MÉTODOS	45
4.1	Materiais	45
4.1.1	Veículos Utilizados para a Análise	47
4.2	Métodos	48
4.2.1	Coleta e tratamento de Dados	48
4.2.2	Análise dos Dados	49
5	RESULTADOS	51
5.1	Coletas de Dados Realizadas	51
5.1.1	Parâmetros Coletados - OBD	53
5.1.2	Parâmetro Calculado - Emissão de CO ₂	53
5.2	Análise Exploratória dos Dados	54
5.3	Treinamento de Redes Neurais Artificiais	57
5.3.1	Primeira Etapa de Treinamentos	60
5.3.1.1	Análise de Desempenho por Quantidade de Neurônios	60
5.3.1.2	Análise de Desempenho por Taxa de Aprendizagem	61
5.3.1.3	Análise de Desempenho por Configuração de Camadas	61
5.3.1.4	Análise de Desempenho por Épocas	62
5.3.1.5	Resumo da primeira etapa de treinamentos	63
5.3.2	Segunda Etapa de Treinamentos	63
5.3.2.1	Análise de Desempenho por Taxa de Desativação	63
5.3.2.2	Análise de Desempenho por Amostras de Inferência	64
5.3.2.3	Redes Neurais com Melhores Resultados	65
5.3.2.4	Análise individual da Rede Neural	65
5.3.2.5	Análise das Incertezas via <i>Monte Carlo Dropout</i>	67
6	CONCLUSÃO	68
6.1	Limitações do Estudo	68
6.2	Trabalhos Futuros	69
	REFERÊNCIAS	70

1 INTRODUÇÃO

1.1 PERTINÊNCIA E MOTIVAÇÃO DO TRABALHO

A crescente urbanização e a busca por cidades mais inteligentes têm sido uma prioridade global, especialmente em regiões como a Europa e os Estados Unidos. A densificação dos centros urbanos, aliada a preocupações ambientais e de sustentabilidade, tem desafiado os sistemas de transporte já sobrecarregados. A previsão das Nações Unidas de que a população mundial atingirá 9,8 bilhões até 2050, com quase todo esse crescimento ocorrendo em áreas urbanas, destaca a necessidade urgente de soluções inovadoras para a mobilidade urbana (FARID et al., 2022).

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2023), a frota de veículos no Brasil ultrapassou 119 milhões de unidades em 2023, refletindo um crescimento significativo nos últimos anos. Esse aumento acentua o impacto ambiental causado pelos veículos a combustão, que ainda representam a maior parte da frota nacional e são os principais responsáveis pelas emissões de CO₂ e outros poluentes no Brasil e no mundo.

Embora tecnologias mais limpas, como os veículos híbridos e elétricos, estejam ganhando espaço, a quantidade de Veículos Elétricos (VEs) no Brasil permanece pouco representativa em relação ao total da frota nacional e mundial (SANGUESA et al., 2021). Isso implica que, apesar das iniciativas de transição para tecnologias sustentáveis, as emissões oriundas dos Veículos de Combustão Interna (VCI) continuam sendo a principal fonte de gases de efeito estufa no setor de transporte. Adicionalmente, os benefícios dos VEs no contexto de redução de emissões podem ser limitados em países onde a geração de eletricidade ainda é baseada em combustíveis fósseis, reduzindo o impacto líquido dessas tecnologias ao longo do ciclo de vida dos veículos (STASINOPOULOS N. SHIWAKOTI, 2016). Em países com matrizes energéticas de alta emissão, como em alguns cenários nos Estados Unidos, VEs e híbridos apresentam vantagens claras em termos de emissões ao longo do ciclo de vida (LIEUTENANT et al., 2022).

Especificamente na frota leve, as emissões do setor de transporte representam uma fonte importante de gases de efeito estufa no Brasil e no mundo, com os veículos a combustão sendo ainda os principais responsáveis pelas emissões de CO₂ e outros poluentes (U.S. Department of Energy, 2024; International Energy Agency, 2024a). (CHOMA et al., 2021) apontou que o setor de transporte foi responsável por cerca de 28% das emissões de gases de efeito estufa em 2018, com dois terços dessas emissões originadas de veículos de passeio leves.

Como consequência, a poluição atmosférica gerada pelo setor de transporte representa uma das principais fontes de degradação ambiental e risco para a saúde pública, com impactos diretos e indiretos significativos. Estima-se que, mundialmente, aproximadamente 4,2 milhões de mortes prematuras ao ano estejam associadas à exposição a poluentes atmosféricos, como o Material Particulado (MP) e Óxido de Nitrogênio (NO_x), liberados em grande parte por veículos de combustão interna (World Health Organization, 2018). O Brasil, com uma frota crescente e predominantemente composta por veículos a combustão, enfrenta desafios críticos de qualidade do ar, particularmente em áreas urbanas, onde os efeitos nocivos da poluição têm se intensificado com o tempo. Estudos demonstram que a exposição contínua a esses poluentes contribui para o aumento de doenças respiratórias, cardiovasculares e outras condições crônicas, gerando uma demanda urgente por soluções de mitigação (GOUVEIA; JUNGER, 2018; JUNGER; LEON, 2019).

Dada a relevância do problema, é essencial explorar alternativas que reduzam as emissões oriundas do setor de transporte, especialmente no contexto brasileiro, onde iniciativas como a eletrificação da frota ainda se encontram em estágios iniciais. Este trabalho, portanto, faz uso de dados automotivos para o monitoramento e análise dos impactos das emissões no setor de transporte. A adoção de tecnologias de menor emissão é um caminho promissor para reduzir as concentrações de poluentes nas regiões urbanas e, conseqüentemente, os impactos adversos na saúde pública e no meio ambiente (JUNGER; LEON, 2019).

1.2 CONTRIBUIÇÕES

O presente estudo justifica-se pela necessidade urgente de adotar medidas que contribuam para a sustentabilidade do setor de transporte e para a redução dos custos sociais e econômicos decorrentes dos efeitos da poluição atmosférica. Como contribuição, este estudo incorpora o uso de ferramentas baseadas em Inteligência Artificial (IA) para correlacionar as emissões com variáveis ambientais e operacionais. Dessa forma, o trabalho visa facilitar o monitoramento de emissões veiculares por meio da integração de dispositivos como o *ELM Electronics - 327* (ELM327) para coleta de dados em tempo real. Além disso, a análise desses dados utilizando linguagens de programação, como *Python*, e bibliotecas especializadas permite o desenvolvimento de modelos preditivos baseados em Inteligência Artificial. Esses modelos são capazes de correlacionar variáveis operacionais, como fluxo de massa de ar e consumo energético, com as emissões de CO_2 . Adicionalmente, este estudo visa possibilitar a criação de uma plataforma integrada de coleta e análise de dados veiculares, utilizando dispositivos de diagnóstico embarcados OBD e protocolos padronizados, como *Controller Area Network* (CAN) e normas *Society of Automotive Engineers* (SAE).

1.3 A IMPORTÂNCIA DA MEDIÇÃO INSTANTÂNEA DE CO₂

A medição instantânea de emissões de CO₂, em contraste com o valor total acumulado entre dois pontos de um trajeto, permite caracterizar a dinâmica real do processo de combustão e dos hábitos de condução. Valores instantâneos revelam picos e padrões de emissão associados a eventos específicos (acelerações bruscas, subidas íngremes, tráfego intenso), possibilitando identificar comportamentos ocultos que seriam mascarados por um somatório global. Essa granularidade viabiliza a inferência do perfil do condutor e o monitoramento de conformidade com práticas de *eco-driving*, além de fornecer insumos para calibrar estratégias de controle embarcadas.

Ao integrar a leitura instantânea às unidades eletrônicas dos veículos, abre-se a possibilidade de parametrizar limites máximos de emissão em tempo real, modulando torque, injeção e estratégias de transmissão de modo a prevenir ultrapassagens de limiares críticos. Por fim, dados instantâneos alimentam modelos preditivos e diagnósticos preventivos, permitindo intervenções direcionadas a trechos ou condições específicas do percurso e oferecendo maior eficácia do que ajustes baseados apenas no valor total de emissões entre os pontos A e B.

1.4 OBJETIVO GERAL

O presente trabalho objetiva desenvolver uma metodologia para avaliar e modelar as emissões de CO₂ veicular a partir de dados obtidos pela interface OBD, empregando técnicas de redes neurais artificiais. A finalidade é utilizar técnicas de Inteligência Artificial para realizar estimativas das emissões de CO₂ com base em parâmetros de condução, como velocidade, aceleração e outros dados coletados do veículo, buscando capturar padrões e relações que métodos tradicionais baseados apenas em equações podem não ser capazes de identificar.

Em síntese, este trabalho caracteriza-se como uma análise comparativa de abordagens para modelagem das emissões veiculares. Busca-se confrontar o desempenho de duas metodologias baseadas em Inteligência Artificial - nomeadamente, arquiteturas de redes neurais artificiais do tipo *Multi-Layer Perceptron* (MLP) e *Long Short-Term Memory* (LSTM) - na estimativa das emissões instantâneas de CO₂ a partir de dados *on-board*. Assim, o propósito central é identificar qual dessas abordagens fornece maior acurácia preditiva e melhor adequação à dinâmica real de condução. Importante destacar que não se trata de uma comparação direta entre diferentes veículos em termos absolutos de emissões, nem de uma verificação primária de conformidade com normas ambientais. Ainda que resultados obtidos sejam pontualmente comparados a valores de referência normativos para fins de contextualização, o foco principal reside na avaliação comparativa das técnicas

de modelagem e predição desenvolvidas no estudo.

1.5 OBJETIVO ESPECÍFICO

Para atingir o objetivo geral proposto, definiram-se os seguintes objetivos específicos:

- Realização de análise exploratória dos dados coletados, identificando padrões e correlações entre o estilo de condução e as emissões de CO₂.
- Desenvolver modelos preditivos usando Redes Neurais Artificiais capazes de estimar as emissões instantâneas de CO₂ com base nos parâmetros monitorados via OBD, utilizando dois tipos de arquiteturas de rede.
- Ajustar e validar os modelos de IA desenvolvidos, conduzindo experimentos de treinamento com diferentes configurações (número de neurônios, camadas, taxa de aprendizagem, etc.) e avaliando o desempenho de cada modelo por meio de métricas de erro (MAE, MAPE, RMSE, coeficiente R^2 , entre outras).
- Selecionar a configuração ótima e verificar sua capacidade preditiva e então executar uma segunda fase de treinamentos.
- Após a segunda fase de treinamento, avaliar o desempenho do modelo selecionado em relação a um conjunto de dados de teste, utilizando as métricas previamente já utilizadas.

1.6 ESTRUTURA E ORGANIZAÇÃO DO TRABALHO

Além deste capítulo introdutório, o trabalho está composto por mais 4 capítulos, descritos a seguir:

- Capítulo 2: este capítulo abordará a fundamentação teórica e conceitos utilizados para o desenvolvimento deste trabalho.
- Capítulo 3: este capítulo apresenta a metodologia empregada na concepção e evolução desta pesquisa. Serão apresentadas informações acerca dos algoritmos e técnicas adotadas, além de abranger as etapas de pré-processamento que foram desenvolvidas.
- Capítulo 4: nesta seção são apresentados em detalhes os resultados obtidos por meio das técnicas e algoritmos empregados na metodologia.
- Capítulo 5: finalmente, neste capítulo, as conclusões deste estudo são delineadas, sintetizando os resultados alcançados e propondo aprimoramentos para o desenvolvimento de trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são tratados os principais conceitos e bases teóricas que sustentam este trabalho. Serão abordados temas como o crescimento da frota veicular, as emissões atmosféricas associadas, os avanços em normas técnicas e as ferramentas tecnológicas utilizadas para coleta e análise de dados. Além disso, serão discutidos os principais padrões internacionais e nacionais que regulam a emissão de poluentes e consumo energético, destacando como essas regulamentações influenciam o desenvolvimento de tecnologias automotivas mais limpas e sustentáveis.

Em (NTZIACHRISTOS et al., 2014), foi desenvolvido um estudo comparativo entre o consumo de combustível em uso real e os valores de homologação para 924 veículos de passeio (611 a gasolina, 313 a diesel) na Europa. Entre os principais resultados estão que o consumo médio em uso real foi 11% maior que o homologado para carros a gasolina e 16% maior para carros a diesel. Para veículos registrados em 2012 na faixa de 90-100 gCO₂/km, o desvio chegou a ser superior a 60%. Os autores identificaram que resistências veiculares irrealistas usadas na homologação são uma das principais razões para essa diferença. Foi desenvolvido um modelo linear simplificado para prever o consumo em uso real com base em dados publicamente disponíveis, utilizando o consumo medido na homologação, a massa e a cilindrada do motor. Embora o estudo forneça informações valiosas sobre as discrepâncias entre consumo real e homologado, ele se baseia em dados coletados de várias fontes europeias, o que pode limitar sua aplicabilidade global. Além disso, o modelo simplificado proposto pode não capturar todas as variáveis que influenciam o consumo real de combustível, como condições de tráfego e estilo de direção.

Um estudo conduzido por (PRATI et al., 2021) investigou o impacto de estilos de condução no consumo de combustível e emissões de CO₂ utilizando um veículo híbrido *plug-in*. Foram realizados testes em condições reais de condução em áreas urbanas, rurais e rodovias, avaliando parâmetros como emissões de Monóxido de Carbono (CO), CO₂, e NO_x, além do consumo energético do motor elétrico. Os resultados demonstraram que a condução em modo híbrido com bateria carregada reduziu significativamente as emissões de CO₂ e o consumo de combustível, enquanto picos de emissões de CO e NO_x foram observados durante acelerações bruscas em trechos de rodovia. O estudo também destacou que o modo de condução puramente elétrico é capaz de eliminar emissões em trajetos urbanos com inclinações acentuadas. Apesar disso, variáveis como o estado de carga da bateria e o uso do ar-condicionado impactaram negativamente a eficiência energética do veículo. Estes resultados enfatizam a importância de um estilo de condução otimizado para reduzir emissões e melhorar a eficiência do veículo em diferentes cenários de condução.

(PRATI et al., 2021).

Um estudo liderado por (STRANDGREN et al., 2020) propôs um conceito inovador de espectrômetro de imagem compacto baseado no espaço para esse fim. Com uma resolução espacial de $50 \times 50 \text{ m}^2$, o instrumento foi projetado para identificar emissões de CO_2 de fontes localizadas, como usinas de energia de médio porte, que são responsáveis por uma parcela significativa das emissões globais. O trabalho demonstrou que o conceito do instrumento é capaz de detectar emissões de CO_2 com precisão, mesmo em cenários desafiadores. Simulações indicaram que ele pode alcançar um erro de ruído de apenas 1,1 ppm na estimativa da concentração média de CO_2 no ar seco. Um resultado importante foi a simulação da capacidade do instrumento de observar CO_2 de usinas individuais (instalações de médio porte que operam de forma isolada) em áreas urbanas. Segundo o estudo, é possível detectar emissões de fontes com taxas anuais de até 0,3 Mt de CO_2 , o que evidencia o potencial para monitorar fontes menores de emissão. Embora o foco do trabalho seja a detecção de fontes localizadas/pontuais (como usinas de médio porte), os resultados são relevantes para esta dissertação por evidenciar requisitos de sensoriamento, incerteza e detectabilidade necessários para quantificar emissões de CO_2 em ambientes complexos, inclusive urbanos.

Em (ENSSLEN et al., 2017), foi realizado um estudo que avaliou as emissões de CO_2 geradas por veículos elétricos em um cenário de frota de deslocamento França-Alemanha. O estudo monitorou o consumo de eletricidade em tempo real durante a condução e o carregamento de veículos, totalizando 38 365 km percorridos e 639 eventos de carregamento registrados. Os dados foram combinados com a matriz de geração elétrica nacional de cada país, com resolução horária, para determinar a intensidade de emissões de CO_2 . O trabalho destacou que estratégias inteligentes de carregamento podem reduzir significativamente as emissões relacionadas a veículos elétricos, especialmente em países como a França, onde a intensidade de carbono da eletricidade é muito menor em comparação à Alemanha. Apesar dos resultados promissores, o estudo ressalta a importância de expandir redes de energia limpa para maximizar os benefícios dos veículos elétricos na mitigação de emissões (ENSSLEN et al., 2017).

No estudo conduzido por (ZIÓŁKOWSKI et al., 2021), a previsão do consumo de combustível foi realizada exclusivamente por meio de um perceptron multicamada (MLP) com arquitetura 22-10-3, utilizando 22 variáveis técnicas de uma base de dados contendo 1 750 veículos. O treinamento da RNA empregou validação cruzada e ajuste de hiperparâmetros, e o desempenho foi avaliado pelas métricas MSE, RMSE, MAPE, coeficiente de correlação de Pearson e coeficiente de determinação (R^2) no conjunto de teste. Os resultados revelaram altos valores de r (aprox. 0,93) e R^2 (acima de 0,86), demonstrando a capacidade da MLP em capturar interações não lineares entre variáveis técnicas do veículo.

Os autores destacam que as RNAs apresentam maior flexibilidade para lidar com padrões complexos em dados veiculares reais em comparação com modelos lineares reportados na literatura, recomendando o incremento do volume e da diversidade de dados, bem como o refinamento das arquiteturas de MLP, para aumentar ainda mais a precisão preditiva. Segundo o autor, futuros trabalhos podem explorar arquiteturas mais profundas, regularização avançada e integração de dados de sensores em tempo real para otimizar estimativas de emissões de CO₂.

A partir desta revisão bibliográfica, podem ser destacadas diversas oportunidades e desafios no monitoramento de emissões de CO₂ em veículos leves. Os estudos analisados sugerem abordagens variadas, desde o uso de modelos lineares simplificados e algoritmos baseados em dados públicos até a implementação de instrumentos inovadores e estratégias inteligentes de carregamento para veículos elétricos. Além disso, as metodologias discutidas reforçam o potencial de técnicas avançadas, como inteligência artificial e sistemas embarcados, bem como o uso de interfaces amplamente difundidas, como OBD e CAN, para coleta de dados. Apesar dos avanços, a complexidade do problema e a diversidade de fatores envolvidos apontam para a necessidade de maior integração entre tecnologias de ponta, infraestrutura energética limpa e políticas públicas eficazes, de modo a otimizar o monitoramento e a redução de emissões. Apresenta-se de forma resumida na Tabela 1 os principais achados e limitações dos estudos revisados, destacando a relevância de cada abordagem para o contexto atual de monitoramento de emissões veiculares.

Tabela 1 – Resumo das Revisões Bibliográficas

Autor	Síntese e Objetivos	Limitações
(NTZIACHRISTOS et al., 2014)	Comparou o consumo real e homologado na Europa e desenvolveu um modelo linear preditivo, identificando desvios médios de 11% (gasolina) e 16% (diesel) - com casos extremos chegando a 60%.	Uso de resistências veiculares irrealistas e modelo simplificado sem considerar variáveis como tráfego e estilo de condução.
(ENSSLEN et al., 2017)	Monitorou as emissões de CO ₂ em veículos elétricos integrando consumo real com matrizes de geração elétrica, evidenciando redução de emissões via estratégias inteligentes de carregamento e diferenças na intensidade de carbono entre países.	Necessidade de expansão das redes de energia limpa para ampliar os benefícios do monitoramento.
(STRANDGREN et al., 2020)	Desenvolveu por simulação um espectrômetro de imagem compacto para monitoramento de CO ₂ , atingindo erro médio de 1,1 ppm e demonstrando viabilidade para detectar pequenas emissões industriais.	Baixa resolução espectral, interferência de aerossóis/nuvens e alto custo de implementação em larga escala.
(PRATI et al., 2021)	Investigou o impacto dos estilos de condução nas emissões de CO ₂ , demonstrando que o modo híbrido reduz emissões e consumo energético, e evidenciou a eficácia do modo elétrico em trajetos urbanos.	Picos de emissões de CO e NO _x em acelerações bruscas e influência negativa do estado da bateria e uso do ar-condicionado.
(ZIÓŁKOWSKI et al., 2021)	Aplicou redes neurais MLP 22-10-3 e MLP 20-10-3 treinadas com 1 750 registros técnicos de veículos (2010-2020), avaliadas por MSE, RMSE, MAPE, coeficientes de Pearson (0,93-0,95) e de determinação ($R^2 > 0,98$), além de análise de sensibilidade das variáveis de entrada.	Base de dados restrita a parâmetros declarados em testes padronizados (NEDC, WLTP); ausência de validação em situações reais de condução; necessidade de ampliação e atualização contínua da base de dados.

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos teóricos que embasam este trabalho. Nele são discutidos o crescimento da frota de veículos, o impacto ambiental das emissões e as normas técnicas que orientam sua mensuração. Por fim, abordam-se os principais protocolos de comunicação automotiva utilizados para aquisição e análise de dados.

3.1 CRESCIMENTO DA FROTA DE VEÍCULOS

3.1.1 PANORAMA MUNDIAL

Nas últimas décadas, a indústria automotiva global passou por uma transformação estrutural significativa. Evidenciam-se na Figura 1, construída com base em dados da OICA (Organisation Internationale des Constructeurs d'Automobiles, 2024), a evolução da produção mundial de veículos entre 1999 e 2024, segmentada por grandes regiões.

Durante esse período, observa-se uma mudança marcante na distribuição geográfica da produção. A Ásia, destacada em vermelho no gráfico, assume papel de liderança desde o início dos anos 2010, ultrapassando de forma constante América do Norte e Europa em volume anual produzido. Este crescimento asiático reflete especialmente o avanço de países como China, Índia e Coreia do Sul no setor automotivo.

Em contrapartida, a produção na América do Norte e Europa apresenta relativa estabilidade, com variações discretas ao longo dos anos, enquanto a América do Sul mantém participação modesta, porém consistente.

O pico global de produção ocorreu em 2017, com posterior declínio acentuado em 2020, efeito da pandemia da COVID-19, seguido de uma recuperação parcial nos anos subsequentes.




Figura 1 – Crescimento da Produção Automotiva Mundial (Organisation Internationale des Constructeurs d'Automobiles, 2024).

3.1.2 EVOLUÇÃO DA FROTA NO BRASIL

Especificamente no Brasil, nas últimas décadas o país vem se consolidando como um dos principais produtores e consumidores de veículos. Segundo a Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA), em 2007, o setor automotivo brasileiro registrou uma produção de 2,46 milhões de unidades, um aumento de 28% em relação a 2006, o que representou o melhor desempenho da indústria até então (NETO; PIRES, 2011), conforme exibido na Figura 2.



Figura 2 – Licenciamentos de Veículos no Brasil - Série Histórica (ANFAVEA, 2025).

Esse crescimento colocou o Brasil como o sexto maior fabricante de veículos do mundo em 2007, ultrapassando países tradicionais na indústria automotiva, como a França e a Espanha (NETO; PIRES, 2011). Esse avanço foi, possivelmente, impulsionado por uma combinação de fatores, incluindo a entrada de novas empresas, o desenvolvimento de novos modelos e os avanços tecnológicos. Em conclusão, os dados da ANFAVEA demonstram um crescimento expressivo no setor automotivo brasileiro, posicionando o país como um importante *player* no mercado global.

3.1.3 A CHEGADA DOS VES

Com o aumento da conscientização ambiental e a busca por alternativas sustentáveis, os VEs têm ganhado espaço significativo no mercado global. O crescimento nas vendas tem sido impulsionado por avanços tecnológicos em baterias, que reduziram os custos e aumentaram a autonomia dos veículos, além de políticas governamentais de incentivo à eletrificação do transporte (SRDIC; LUKIC, 2018).

Observa-se na Figura 3 o crescimento contínuo da produção de veículos eletrificados na China entre 2010 e 2023, com destaque para a predominância dos Veículos Elétricos a Bateria (BEVs) em relação aos Veículos Híbridos Elétricos *Plug-in* (PHEV). Em 2023, a produção de BEVs ultrapassou 20 milhões de unidades, enquanto os PHEV alcançaram a marca de 8,5 milhões, refletindo uma expansão acelerada da eletromobilidade no país.




Figura 3 – Vendas de Veículos Eletrificados na China - 2011 a 2021 (International Energy Agency, 2024b).

No Brasil, a transição para VEs ainda enfrenta desafios como o alto custo dos veículos e a falta de infraestrutura de recarga. Apesar disso, o país já conta com uma base industrial significativa e tem explorado tecnologias de transição, como os Veículos Híbridos (VHs) que utilizam biocombustíveis, o que representa um potencial único para o desenvolvimento da eletromobilidade nacional (YAMAMURA et al., 2022). Além disso, iniciativas governamentais e incentivos fiscais têm sido discutidos para reduzir a carga tributária dos VEs e fomentar investimentos na infraestrutura de carregamento (RUOSO; RIBEIRO, 2022).

3.2 AS EMISSÕES GERADAS PELOS VEÍCULOS

3.2.1 EMISSÕES DE VEÍCULOS A COMBUSTÃO

A frota de veículos automotivos é uma das principais fontes de emissões de poluentes atmosféricos. Diversos estudos destacam como o aumento do número de veículos está correlacionado com a maior liberação de compostos nocivos, como NO_x , CO e partículas finas, compostas essencialmente por Material Particulado com até 2,5 μm de diâmetro ($\text{MP}_{2,5}$) e Material Particulado com até 10 μm de diâmetro (MP_{10}). Estudos específicos mediram emissões de Composto Orgânico Volátil (COV) em ambientes urbanos e estacionamentos subterrâneos, constatando que as emissões de veículos são responsáveis por altas concentrações de COV, especialmente em áreas com grande volume de tráfego, durante horários de pico (WU et al., 2023). Outro estudo sobre a cidade de São Paulo revelou que

a expansão da frota de veículos, incentivada por políticas de crédito facilitado e redução de impostos sobre combustíveis, aumentou a poluição do ar na região metropolitana, reduzindo a eficácia de medidas de controle de emissões previamente implementadas (TESTA, 2015). Além disso, estudos que utilizam modelos preditivos apontam que parâmetros internos dos veículos, como a rotação do motor e a velocidade, estão diretamente relacionados à quantidade de CO₂ emitido. Essas correlações foram validadas com sensores de diagnóstico embarcados, que permitem estimativas precisas das emissões com base no comportamento do veículo (MALDONADO et al., 2018). Conforme ilustrado pela Figura 4, a contribuição de diferentes tipos de veículos (gasolina, diesel e gás natural comprimido) para a emissão de diversos poluentes, como CO, NO_x, COV e MP, varia significativamente.

Contribuição de Poluentes por tipo de Combustível.




Figura 4 – Contribuição de Poluentes por Tipo de Veículo - Em porcentagem (%). (WU et al., 2023)

Veículos a gasolina são responsáveis pela maior parte das emissões de CO e COV, enquanto veículos a diesel predominam nas emissões de NO_x e partículas finas.

3.2.2 IMPACTO DAS EMISSÕES NO BRASIL

Para reduzir os impactos das emissões no Brasil, o governo instituiu em 1986 o Programa de Controle da Poluição do Ar por Veículos Automotores (PROCONVE). Esse programa estabelece etapas progressivas de controle de emissões para veículos leves e pesados, impondo limites mais restritivos para poluentes. Desde sua criação, o PROCONVE contribuiu para uma significativa redução emissões ao longo de suas atualizações, como a fase P7 para veículos pesados, que exigiu uma queda de 96,3% nas emissões de partículas

em comparação às fases iniciais (BENTO; VINHA; PRIETO, 2015). O PROCONVE foi inspirado nas normas de emissões veiculares adotadas na Europa, conhecidas como padrões Euro. Embora as diretrizes europeias e brasileiras compartilhem o objetivo de reduzir a poluição, a evolução dos seus estágios segue cronogramas distintos. No caso de veículos **pesados**, a nomenclatura europeia utiliza **Euro VI** (algarismos romanos), enquanto **Euro 6** é usualmente empregado para veículos leves. Assim, a Tabela 2 apresenta uma **correlação regulatória** entre as fases do PROCONVE (pesados) e os padrões europeus equivalentes. Ressalta-se que a fase **P8** define o requisito **mínimo obrigatório** para **novos veículos** no Brasil (cronograma: 2022 para novos modelos e 2023 para os demais), mas não impede que veículos já atendam antecipadamente a esse patamar tecnológico, o que explica a existência de ônibus e caminhões com especificação Euro VI em circulação antes do marco de 2023.

Tabela 2 – Relação entre fase PROCONVE (Brasil) e Europa.

Fase Proconve	Fase Euro	Gases					Vigência	Resolução Conama/Ibama
		g/kW/h				ppm		
		CO	HC	N _{ox}	MP	Enxofre		
P1	—	14	4	18	—	—	1989 a 1993	18/1986
P2	Euro 0	11	2	14,40	0,6	3000 a 10000	1994 a 1995	8/1993
P3	Euro I	5	1	9	0,40 ou 0,70 ²	3000 a 10000	1996 a 1999	8/1993
P4	Euro II	4	1	7	0,15	3000 a 10000	2000 a 2005	8/1993
P5	Euro III	2	1	5	0,10 ou 0,13 ³	500 a 2000	2006 a 2008	315/2002
P6	Euro IV	2	0	4	0,02	50	2009 a 2011	315/2002
P7	Euro V	2	0	2	0,02	10	2012 a 2022	403/2008
P8	Euro VI	1	0	1	0,01	10	01/2022 (novos modelos) e 01/2023 (demais)	490/2018

Nota: A fase P8 estabelece a exigência mínima para novos veículos; é facultado o atendimento antecipado.

3.2.3 MECANISMOS DE REDUÇÃO DE EMISSÕES VEICULARES

Atualmente, os veículos automotores contam com diversos mecanismos físicos e tecnológicos para reduzir a emissão de poluentes na fonte. Dentre os principais dispositivos de controle destacam-se os conversores catalíticos de três vias (catalisadores), responsáveis por converter CO, Hidrocarbonetos (HC) e NO_x em compostos menos nocivos (como CO₂, Água (H₂O) e Nitrogênio (N₂)). Adicionalmente, estratégias como a recirculação dos gases de exaustão e o aprimoramento do controle eletrônico de combustão (injeção eletrônica multiponto, ignição controlada, etc.) contribuem para minimizar a formação de poluentes durante a operação do motor. Tais avanços, somados à melhoria na qualidade dos combustíveis (por exemplo, teores reduzidos de enxofre na gasolina e no diesel, além do uso de biocombustíveis), resultaram em veículos modernos significativamente menos poluentes em comparação aos de décadas passadas.

Em paralelo às inovações técnicas, instrumentos regulatórios têm desempenhado papel crucial no controle de emissões veiculares. Programas governamentais como o PROCONVE no Brasil - em sintonia com os padrões internacionais, a exemplo das sucessivas normas Euro europeias - impõem limites cada vez mais rígidos para a emissão de NO_x, CO, HC e materiais particulados, obrigando os fabricantes a incorporarem as tecnologias de mitigação supracitadas para atender à legislação. De igual modo, iniciativas de eficiência energética e rotulagem, como o Programa Brasileiro de Etiquetagem (PBE) coordenado pelo Inmetro, avaliam e classificam os veículos conforme seu consumo de combustível e emissões de CO₂, incentivando a competição do mercado por veículos mais limpos. Essa combinação de exigências

legais e desenvolvimento tecnológico direciona a indústria automotiva rumo a veículos de menor impacto ambiental, ao mesmo tempo em que oferece aos consumidores informações transparentes para escolhas mais sustentáveis.

3.2.4 A RELEVÂNCIA DO ETANOL

O Brasil destaca-se mundialmente pelo uso extensivo do etanol como combustível veicular, o que o torna componente fundamental da matriz energética de transporte no país. Desde as iniciativas do Programa Nacional do Álcool (Proálcool) nas décadas de 1970-80 até a popularização dos veículos *flex fuel* a partir de meados dos anos 2000, o etanol (derivado principalmente da cana-de-açúcar) consolidou-se como uma alternativa renovável à gasolina, contribuindo para a redução das emissões líquidas de CO₂. Isso ocorre porque a combustão do etanol tende a emitir menores quantidades de poluentes.

Apesar da importância do etanol no contexto brasileiro, este estudo focou-se exclusivamente em veículos de combustão interna operando com gasolina. Essa delimitação de escopo deve-se à restrição dos veículos disponíveis para análise que, apesar de serem veículos *flex fuel*, os seus proprietários usam exclusivamente gasolina, por opção pessoal. Com isso, busca-se manter a consistência metodológica e evitar a introdução de variáveis extra (como o percentual de etanol).

3.2.5 MÉTRICAS DE QUANTIFICAÇÃO DE EMISSÕES VEICULARES

Em estudos de poluição veicular, diversas métricas são empregadas para quantificar as emissões geradas pelos automóveis. Nos ensaios padronizados de laboratório - como aqueles realizados para certificação em programas tipo PROCONVE e PBE - é usual expressar-se a emissão de poluentes em termos de massa por distância percorrida, tipicamente em gramas por quilômetro (g/km). Esse índice representa a quantidade média de determinado poluente emitida a cada quilômetro durante um ciclo de condução específico, permitindo comparar veículos distintos sob condições controladas.

Por outro lado, em medições dinâmicas e em tempo real, seja em campo ou em ambiente de teste, frequentemente utiliza-se a taxa de emissão em função do tempo - por exemplo, gramas por segundo (g/s) - o que fornece o perfil instantâneo de geração de poluentes ao longo do trajeto. Há também a possibilidade de expressar-se a poluição em termos de concentração nos gases de escape, medida em unidades como partes por milhão (ppm) (para compostos gasosos como CO, NO_x, HC) ou em miligramas por metro cúbico (mg/m³) no caso de material particulado. Essas concentrações, quando combinadas com o fluxo volumétrico de exaustão, permitem calcular a massa total emitida e são úteis para correlação com padrões de qualidade do ar e limites regulamentares.

Dentre os diversos poluentes veiculares, este trabalho teve como foco o dióxido de carbono CO₂, dado seu papel central nas mudanças climáticas e a disponibilidade de métodos indiretos para estimá-lo via dados veiculares. A opção por centrar a análise no CO₂ justifica-se por esse gás ser o principal responsável pelo efeito estufa entre os produtos da combustão veicular, além de apresentar relação direta com a eficiência energética do veículo. Os valores instantâneos de CO₂ coletados podem ser integrados ao longo de um percurso para se obter uma emissão total e também convertidos em métricas médias (como g/km) para comparação com os dados oficiais de consumo e emissão informados pelos fabricantes. Cabe salientar que outros poluentes tradicionais (a exemplo de NO_x e material particulado) não foram medidos diretamente neste estudo devido a limitações dos sensores disponíveis e ao escopo delimitado - que privilegiou o CO₂ -, embora sua quantificação exija, em geral, instrumentação específica e metodologias distintas da empregada aqui.

3.2.6 PROGRAMA BRASILEIRO DE ETIQUETAGEM

O PBE é um programa coordenado pelo Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMETRO) e tem como objetivo o fornecimento de informações sobre a eficiência energética de diversos produtos, incluindo veículos automotores. No contexto automotivo, o PBE permite que consumidores comparem modelos com base no consumo de combustível e emissões de CO₂, incentivando escolhas mais eficientes. Os veículos são classificados em categorias que variam de "A" (mais eficiente) a "E" (menos eficiente), com base em testes padronizados conduzidos pelo INMETRO. Além disso, o PBE considera a emissão de gases do efeito estufa como um critério adicional para a avaliação dos automóveis.

Embora o PBE seja uma ferramenta útil para avaliar a eficiência energética dos veículos, os testes realizados para a etiquetagem são conduzidos em condições padronizadas de laboratório, que podem não refletir com precisão o consumo de combustível e as emissões em condições reais de uso. Fatores como o tipo de trajeto (urbano ou rodoviário), estilo de condução, carga transportada e condições climáticas podem influenciar significativamente o desempenho do veículo em comparação aos valores divulgados. Em países como os Estados Unidos e a União Europeia, há metodologias de monitoramento complementar, como o uso de ciclos de teste mais rigorosos, medições de emissões em condições reais de condução e auditorias regulares para verificar a conformidade dos modelos comercializados com os resultados dos testes laboratoriais.

No Brasil, apesar do avanço com o PBE, a ausência de um monitoramento sistemático das emissões em condições reais pode gerar discrepâncias entre os valores divulgados e aqueles observados pelos consumidores no uso cotidiano dos veículos. A implementação do PBE complementa o PROCONVE, pois incentiva fabricantes a adotarem tecnologias mais limpas e eficientes para atender tanto às exigências regulatórias quanto às demandas do mercado por veículos de menor consumo, entretanto, a sua capacidade de refletir a realidade do uso dos veículos ainda é limitada.

3.2.7 A RELEVÂNCIA DO DIÓXIDO DE CARBONO - CO₂

Um dos principais poluentes emitidos por veículos é o CO₂, o qual tem grande importância ambiental. Diferente de outros poluentes, como NO_x e MP, o CO₂ não contribui diretamente para problemas de saúde respiratória, mas exerce um papel crítico no aquecimento global devido ao seu efeito estufa (WALLINGTON et al., 2022; WINKLER et al., 2018). O acúmulo de CO₂ na atmosfera aumenta a retenção de calor, alterando padrões climáticos globais e exacerbando eventos climáticos extremos. A formação do CO₂ durante a combustão de hidrocarbonetos ocorre através da reação química básica descrita na (3.1):



Em que o combustível (C_xH_y) reage com o oxigênio (O₂), liberando CO₂ e água (H₂O).

Nota-se que a emissão de CO₂ é diretamente ligada à quantidade de combustível consumida. Observa-se também que para diferentes tipos de combustíveis, a quantidade de CO₂ emitida depende da quantidade de carbono presente em cada unidade de combustível. Por exemplo, combustíveis fósseis como gasolina e diesel possuem altas concentrações de carbono, o que resulta em maior geração de CO₂ em comparação a combustíveis com menos carbono. Estudos mostram que o aumento no consumo de combustíveis fósseis está fortemente correlacionado com a elevação das emissões de CO₂ em diversos países (ISLAM, 2020; ASLAM et al., 2022). Em paralelo, tem-se o conceito de relação ar-combustível, do inglês *Air-Fuel Ratio* (AFR). É correlacionada na Tabela 3 a quantidade de CO₂ gerada por litro de combustível consumido, de acordo com o combustível utilizado, além da AFR e Densidade (ρ).

Tabela 3 – CO₂ por litro de combustível (IEEP, 2010; INNOVATEMOTORS, 2014; HILL et al., 2012).

Combustível	FE - CO ₂ [g/L]	AFR	Densidade (ρ) [g/L]
Gasolina	2310	14,7	737
Diesel	2660	14,6	850
Etanol	1510	9	789

Observa-se que combustíveis como gasolina e diesel produzem maiores quantidades de CO₂ devido às suas cadeias de carbono longas e alta densidade energética. O gás natural, embora também seja fóssil, emite menos CO₂ que gasolina e diesel, pois possui uma proporção maior de hidrogênio em relação ao carbono (LU, 2017). Já os biocombustíveis podem ter emissões neutras de CO₂, desde que o CO₂ liberado seja reabsorvido no cultivo das plantas utilizadas em sua produção.

3.2.8 RELAÇÃO ENTRE ENERGIA ELÉTRICA E CO₂

Embora os veículos elétricos VEs sejam amplamente promovidos como uma solução sustentável para reduzir emissões de carbono, eles não são completamente livres de emissões indiretas de CO₂. Isso ocorre porque a energia elétrica utilizada para carregar os veículos é, muitas vezes, gerada a partir de fontes que produzem gases de efeito estufa, como carvão e gás natural. Assim, a matriz elétrica de cada região desempenha um papel crítico na determinação do impacto ambiental dos VEs.

Estudos mostram que o impacto de carbono dos VEs varia significativamente dependendo da proporção de fontes renováveis e fósseis na matriz elétrica. Por exemplo, países com matrizes baseadas em carvão tendem a ter emissões mais altas associadas ao uso de VEs, enquanto regiões que utilizam energia renovável conseguem reduzir essas emissões de forma significativa (MäRTZ; PLÖTZ; JOCHEM, 2021).

Uma pesquisa sobre o gerenciamento da pegada de carbono dos VEs indicou que otimizar os horários de carregamento para coincidir com períodos de menor intensidade de carbono na geração elétrica pode reduzir significativamente as emissões de CO₂ associadas ao carregamento de VEs (LIU et al., 2024). Além disso, modelos preditivos sugerem que, sem uma rápida descarbonização da geração elétrica, os benefícios ambientais dos VEs podem ser comprometidos. Por exemplo, um estudo no Reino Unido mostrou que, mesmo com o aumento da proporção de veículos elétricos, a dependência de combustíveis fósseis na matriz elétrica pode dificultar o alcance das metas de emissões líquidas zero (LOGAN; NELSON; HASTINGS, 2022).

Apresenta-se na Figura 5 (Energy Institute, 2024) a composição da matriz elétrica de diferentes regiões globais, destacando as proporções de fontes como carvão, gás, hidroeleticidade, energia nuclear, renováveis e óleo.




Figura 5 – Distribuição da matriz elétrica por região e sua contribuição para as emissões de CO₂.

Observa-se que o impacto ambiental dos veículos elétricos depende fortemente da matriz energética de cada região. Por exemplo, na China, onde o carvão representa 61% da geração de eletricidade, as emissões associadas ao uso de veículos elétricos são significativamente mais altas. Em contraste, o Brasil destaca-se com uma matriz predominantemente limpa, devido à alta participação de fontes hidroelétricas (60%), reduzindo o impacto ambiental dos VEs. Este contraste demonstra a importância de acelerar a transição para fontes de energia renovável globalmente, especialmente em regiões dependentes de combustíveis fósseis, para maximizar os benefícios ambientais dos veículos elétricos.

É importante compreender que, após analisar a matriz elétrica de cada região em termos de porcentagens de fontes de energia, é igualmente essencial considerar as emissões específicas de CO₂ associadas a cada tipo de geração elétrica. São representados na Tabela 4 os valores de emissões totais de CO₂ (em gCO₂/kWh) por tipo de combustível utilizado na geração de eletricidade.

Tabela 4 – Emissões de CO₂ por tipo de combustível na geração de eletricidade.

Combustível	Total Emissões (gCO ₂ /kWh)
Gás Natural	690,55
Óleo Combustível	707,13
Nuclear (UO ₂)	17,80
Carvão	916,12
Eólica	6,75
Hidráulica	4,33
Biomassa	68,72

Observa-se que fontes renováveis, como eólica e hidráulica, possuem os menores índices de emissão de CO₂, enquanto combustíveis fósseis, como carvão e óleo, lideram em termos de impacto ambiental.

Essa análise é crucial para calcular as emissões indiretas de CO₂ provenientes do uso de VEs em diferentes regiões globais (Energy Institute, 2024). Com esses dados, é possível determinar que a composição da matriz elétrica de um país, aliada à eficiência de emissões de cada fonte, define a verdadeira pegada de carbono dos VEs. Por exemplo, mesmo regiões com maior dependência de fontes renováveis podem ainda ter impactos significativos caso haja contribuição de fontes com altas emissões. Assim, essa integração entre matriz elétrica e eficiência por fonte deve ser considerada ao avaliar o impacto ambiental dos VEs.

3.2.9 EMISSÕES DE CO₂ DURANTE A PRODUÇÃO DE VEÍCULOS

A produção de veículos, tanto os convencionais de combustão interna quanto os elétricos VEs, gera emissões significativas de CO₂. Esses impactos ambientais estão associados à fabricação dos diversos componentes do veículo, incluindo carroceria, chassi, sistemas de transmissão e, no caso dos VEs, baterias de íon-lítio, que representam uma das maiores fontes de emissões. Conforme destacado na Tabela 5, os VEs apresentam emissões mais altas na fase de produção quando comparados aos VCI. Por exemplo, as emissões totais da produção de um VCI alcançam 9172,5 kg de CO₂, enquanto os VEs geram 14642,5 kg de CO₂. Esse aumento é amplamente atribuído à fabricação das baterias, que requerem processos industriais intensivos em energia e materiais raros.

Apesar dessas emissões iniciais mais altas, os VEs podem compensar esse impacto ao longo do ciclo de vida, especialmente em regiões onde a matriz elétrica utiliza predominantemente fontes renováveis de energia.

Tabela 5 – Emissões de CO₂ na Produção de Veículos (kg por veículo)

Componente	VCI	VEs
Carroceria (incl. interior e exterior)	2767,9	4393,5
Chassi (sem bateria)	1684,7	2665,5
Sistema de transmissão	2092,5	145,6
Motor de tração	-	1179,1
Controlador eletrônico	-	1010,2
Baterias de chumbo-ácido	24,5	15,1
Baterias de íon-lítio	-	2788,8
Fluidos	230,2	98,3
Pneus	677,1	677,1
Montagem do veículo	1064,1	1064,1
Total	9172,5	14642,5

Fonte: Adaptado de (QIAO; ZHAO; LIU, 2017).

3.3 NORMAS TÉCNICAS BRASILEIRAS (NBR) RELEVANTES

3.3.1 NBR 7024-2017 - AUTONOMIA DE COMBUSTÍVEL EM VEÍCULOS A COMBUSTÃO

A Norma Técnica Brasileira (NBR) 7024 especifica métodos para medir o consumo de combustível de veículos automotores leves. A norma define três métodos principais para a quantificação do consumo

de combustível:

1. **Método Volumétrico:** Esse método mede diretamente o volume de combustível consumido em litros por 100 km. A quantidade de CO₂ pode ser estimada a partir do volume de combustível consumido e da composição química do combustível (presença de carbono), utilizando fatores de emissão específicos para cada tipo de combustível, conforme representado na Equação (3.2):

$$C = \frac{V [1 + \alpha(T_0 - T)]}{D} \times 100 \quad (3.2)$$

Em que:

- C é o consumo de combustível, em L/100 km;
 - V é o volume do combustível consumido, em litros;
 - D é a distância efetiva percorrida, em quilômetros;
 - α é o coeficiente de dilatação volumétrica do combustível. Para gasolina, gasolina com álcool e álcool hidratado, $\alpha = 0,001/^{\circ}\text{C}$;
 - T_0 é a temperatura de referência (20°C);
 - T é a temperatura do combustível, em graus Celsius.
2. **Método Gravimétrico:** Consiste na medição da massa do combustível consumido em gramas. A partir dessa massa e considerando a densidade e a proporção de carbono do combustível, é possível calcular a quantidade de CO₂ emitida por quilômetro percorrido, conforme representado na Equação (3.3):

$$C = \frac{M}{D \times d} \times 100 \quad (3.3)$$

Em que:

- C é o consumo de combustível, em L/100 km;
 - M é a massa do combustível consumido, em gramas;
 - D é a distância efetiva percorrida, em quilômetros;
 - d é a massa específica do combustível, em quilogramas por metro cúbico, a 20°C.
3. **Método de Balanço de Carbono:** O método por balanço de carbono calcula o consumo de combustível a partir das massas de diferentes componentes do gás de escapamento, como HC e CO, emitidos pelo veículo. Este método não será abordado neste trabalho devido à sua alta complexidade, pois requer a medição de múltiplos componentes adicionais.

3.3.2 NBR 7024-2017 - CONSUMO ENERGÉTICO EM VEÍCULOS A COMBUSTÃO

A seção 6.8 da NBR 7024 menciona a Equação (3.4), especificando o cálculo de consumo energético para veículos a combustão:

$$CE = \frac{\delta}{A} \quad (3.4)$$

Em que:

- CE : Consumo energético (MJ/km);
- δ : Densidade energética do combustível, conforme Tabela 6 (MJ/L);

- A : Autonomia (km/L).
- Nota: A autonomia, comumente medida em km, é expressa em km/L na norma NBR 7024:2017.

Com auxílio da Tabela 6, descrita na seção 6.8.3 da NBR 7024, é possível correlacionar as densidades energéticas para diversos combustíveis:

Tabela 6 – Densidade energética (δ) conforme NBR 7024, seção 6.8.3.

Combustível	Densidade energética (δ) (MJ/L)
Gasolina	31,65
Gasool A22	28,99
Etanol	20,09
Diesel	35,65
GNV	35,24

Conforme descrito na NBR 7024, capítulo 6, existe a necessidade de se considerar aferição em ciclo urbano e ciclo estrada. Deste modo, tem-se a Equação (3.5):

$$CE_{\text{combinado}} = 0,55 \times CE_{\text{urbano}} + 0,45 \times CE_{\text{estrada}} \quad (3.5)$$

Em que:

- $CE_{\text{combinado}}$: Consumo energético combinado (MJ/km);
- CE_{urbano} : Consumo energético (Equação 3.4) em ciclo urbano (MJ/km);
- CE_{estrada} : Consumo energético (Equação 3.4) em ciclo de estrada (MJ/km).

O ciclo urbano é definido como trajeto urbano com trânsito moderado e o ciclo estrada é considerado trânsito livre, conforme capítulo 6.8 da norma NBR 7024:2017.

3.3.3 NBR 17142 - CONSUMO ENERGÉTICO EM VEÍCULOS ELÉTRICOS

Segundo a NBR 17142, tem-se o consumo de Energia para Corrente Contínua (CE_{dc}) definido por:

$$CE_{dc} = \frac{E_{dc}}{D} \quad (3.6)$$

Em que:

- CE_{dc} : Consumo de energia de descarga em corrente contínua (Wh/km);
- E_{dc} : Energia de descarga medida em cada ciclo (Wh);
- D : Distância percorrida em cada ciclo (km).

Eficiência da bateria:

$$\eta = \frac{E_{\text{útil}}}{E_{\text{entrada}}} \quad (3.7)$$

Em que:

- η : Eficiência da Bateria;
- $E_{\text{útil}}$: Energia útil disponível pela bateria, após um ciclo completo de Recarga.

- E_{entrada} : Energia usada para executar um ciclo completo de Recarga (0% até 100%);

Por fim, a energia consumida em corrente alternada é determinada utilizando-se o fator η e o CE_{dc} :

$$CE_{ac} = \eta \times CE_{dc} \quad (3.8)$$

Em que:

- CE_{ac} : Consumo de energia em corrente alternada (Wh/km);
- η : Eficiência da Bateria (conforme Equação 3.7).

Convertendo para MJ/km:

$$CE = CE_{ac} \times 0,0036 \quad (3.9)$$

Em que:

- CE : Consumo energético (MJ/km);

Vale ressaltar que as medições de consumo energético devem ser realizadas considerando o conceito de circuito combinado, que determina 55% do consumo em ciclo urbano e 45% em ciclo rodoviário:

$$CE_{\text{combinado}} = 0,55 \times CE_{\text{urbano}} + 0,45 \times CE_{\text{estrada}} \quad (3.10)$$

Em que:

- $CE_{\text{combinado}}$: Consumo energético combinado (MJ/km);
- CE_{urbano} : Consumo energético em ciclo urbano (MJ/km);
- CE_{estrada} : Consumo energético em ciclo de estrada (MJ/km).

3.4 AQUISIÇÃO E ANÁLISE DE DADOS VEICULARES

3.4.1 ISO 11898 - REDE CAN AUTOMOTIVA

A Rede CAN é amplamente utilizada na comunicação entre *Electronic Control Unit* (ECU) em veículos modernos. Esse protocolo foi projetado para permitir a troca eficiente e confiável de informações dentro do sistema veicular. Ele apresenta baixa latência e alta tolerância a falhas, sendo crucial para funções de segurança e controle em tempo real (WAGNER; SCHILDT; POEHLN, 2016). A CAN é fundamental para a operação de diversos sistemas veiculares, como sistemas de frenagem *Anti-lock Braking System* (ABS), controle de estabilidade *Electronic Stability Program* (ESP) e gerenciamento de motor. Além disso, sua flexibilidade permite integração com ferramentas de diagnóstico por meio da interface OBD, facilitando a manutenção e análise de desempenho (ZHANG et al., 2021).

O protocolo CAN se baseia em arquitetura de barramento. Nessa configuração, todas as ECUs estão conectadas a um mesmo barramento físico, permitindo a comunicação entre elas sem a necessidade de um dispositivo central. As mensagens CAN são transmitidas de forma serial e utilizam um protocolo de detecção de erros chamado *Cyclic Redundancy Check* (CRC), garantindo alta integridade dos dados transmitidos. Cada mensagem CAN contém:

Tabela 7 – Estrutura de uma mensagem CAN

Campo	Descrição
Identificador	Define a prioridade da mensagem, com valores mais baixos indicando maior prioridade.
Campo de Dados	Transporta a informação útil, com até 8 bytes.
CRC	Utilizado para verificar a integridade da mensagem.
Campo de Controle	Contém informações sobre o comprimento do campo de dados.

A comunicação no barramento ocorre de maneira *broadcast*, ou seja, todas as ECUs conectadas recebem as mensagens transmitidas. No entanto, cada ECU decide se processará ou ignorará a mensagem com base no identificador, funcionando em dois modos principais (ativo ou passivo). Outras funcionalidades relevantes da rede CAN são a respeito da garantia da robustez na detecção e correção de erros. Os principais mecanismos incluem:

- **Detecção de Erro de Sobrecarga:** Identifica falhas quando o barramento está sobrecarregado.
- **Detecção de Erro de Bit:** Verifica se o bit transmitido é diferente do recebido.
- **CRC:** Garante a integridade dos dados.

Se um erro é detectado, a mensagem é descartada e retransmitida, garantindo confiabilidade mesmo em ambientes adversos (TEO et al., 2021).

A norma *International Organization for Standardization* (ISO) 11898 abrange a especificação da comunicação em redes CAN, dividindo-se em múltiplas partes para descrever diferentes camadas do protocolo. A primeira parte, ISO 11898-1, define o protocolo da camada de enlace de dados e a sinalização física. Ela especifica:

- **Subcamadas de Controle de Acesso ao Meio e Controle de Enlace Lógico.**
- **Formatos de quadros**, incluindo quadros de dados e de erro.
- **Mecanismos de detecção de erro**, como CRC e monitoramento de erros na linha.

A segunda parte, ISO 11898-2, especifica a **Unidade de Acesso ao Meio** de alta velocidade, suportando elevadas taxas de transmissão. Ela inclui:

- **Níveis de tensão diferencial** entre as linhas CAN High e CAN Low, representando os estados dominante e recessivo.
- **Requisitos elétricos**, como resistências internas, capacitâncias e especificações de cabo, minimizando reflexões e interferências.
- **Topologias de rede**, recomendando uma estrutura linear para reduzir ondas refletidas nos cabos, com valores específicos de impedância e resistências de terminação (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, 2003).

Partes adicionais, como a ISO 11898-3, abordam a interface de médio suporte tolerante a falhas, enquanto a ISO 11898-4 introduz comunicação baseada em eventos temporais para aplicações críticas.

3.4.2 SAE J1939 E SAE J1979 - PADRONIZAÇÃO OBD

As normas SAE J1939 e SAE J1979 são fundamentais para a padronização de sistemas OBD em diferentes categorias de veículos. A SAE J1939 é amplamente utilizada em veículos comerciais pesados e implementações industriais, enquanto a SAE J1979 é aplicada a veículos de passeio. Ambas as normas definem a utilização de barramento CAN no formato estendido, com identificadores de 29 bits, para transmitir mensagens de diagnóstico e controle veicular (SAE International, 2017). A estrutura completa é representada na Tabela 8.

Tabela 8 – Estrutura de Identificadores no CAN Estendido (SAE J1939)

Campo	Bits	Descrição
Prioridade (P)	3	Define urgência
Página Estendida (EDP)	1	Expansão futura
Página de Dados (DP)	1	Organização de parâmetros
Formato do PDU (PF)	8	Tipo de mensagem
Campo Específico do PDU	8	Endereço ou extensão
Endereço de Origem (SA)	8	Identificação do transmissor

A interface física segue o padrão de conectores de 16 pinos especificado pela SAE J1962, garantindo a compatibilidade entre equipamentos de diferentes fabricantes. O conector é projetado para facilitar o acesso ao diagnóstico e à manutenção do veículo, conforme Figura 6:




Figura 6 – Pinagem do conector OBD-II (CS Selectronics, 2024).

3.4.3 PARÂMETROS COLETÁVEIS A PARTIR DO OBD

A aquisição de dados veiculares a partir do protocolo OBD é viabilizada pela utilização de *Parameter ID* (PID), os quais representam códigos padronizados que permitem acessar informações específicas dos subsistemas veiculares. O padrão mais amplamente utilizado para PID em veículos de combustão interna é definido pela norma SAE J1979, que especifica códigos para dados como velocidade, rotação

do motor e consumo de combustível (SAIBANNAVAR; MATH; KULKARNI, 2021). Essa padronização facilita a interoperabilidade entre diferentes fabricantes e sistemas de diagnóstico, promovendo eficiência nas manutenções e monitoramento. Para VEs, porém, não há um padrão universalmente adotado. Estudos indicam que os fabricantes frequentemente utilizam códigos proprietários para parâmetros como o *State of Charge* (SoC) da bateria e temperaturas de células, dificultando a unificação dos processos de diagnóstico (RAMAI et al., 2022; TSENG et al., 2016). A necessidade de padronização para VEs é destacada como uma prioridade, dado o crescimento da frota elétrica (MENGI, 2017).

Além dos PID, os *Diagnostic Trouble Code* (DTC) desempenham um papel crítico na identificação de falhas. Enquanto a SAE J2012 define os DTCs para veículos a combustão, o suporte para VEs é limitado, refletindo a ausência de normas específicas para a complexidade de sistemas elétricos (SAIBANNAVAR; MATH; KULKARNI, 2021). No contexto de veículos elétricos, a coleta de dados inclui parâmetros adicionais como eficiência de carregamento e estados de saúde das baterias. O desafio reside em desenvolver um padrão unificado que inclua esses aspectos, promovendo a consistência e acessibilidade nos diagnósticos (RAMAI et al., 2022).

Os serviços ou modos definidos pela norma SAE J1979 estruturam a comunicação entre o ECU do veículo e os dispositivos de diagnóstico, utilizando mensagens em formato hexadecimal. São apresentados na Tabela 9 os serviços mais comuns, descritos com seus códigos hexadecimais e respectivas funcionalidades.

Tabela 9 – Serviços/Modos definidos pela norma SAE J1979

Service/Mode (hex)	Descrição
01	Mostrar dados atuais
02	Mostrar quadro de congelamento (<i>freeze frame</i>)
03	Exibir códigos de falhas armazenados (DTC)
04	Limpar códigos de falhas (DTC) e valores armazenados
05	Resultados de testes, monitoramento de sensores de oxigênio (não CAN)
06	Resultados de testes de outros sistemas/componentes (monitoramento de sensores de oxigênio para veículos CAN)
07	Exibir códigos de falhas pendentes (detectados no ciclo de direção atual ou anterior)
08	Controlar a operação de um componente/sistema embarcado
09	Solicitar informações do veículo
0A	Códigos de falhas permanentes (DTC) (códigos apagados)

Os modos utilizam comunicação hexadecimal, com mensagens compostas por um identificador de serviço e dados complementares. Por exemplo, ao solicitar dados atuais (modo 01), um dispositivo envia o código hexadecimal do serviço seguido de um PID específico. O serviço 01 é amplamente utilizado para monitorar dados em tempo real, como velocidade, carga do motor e temperatura. Cada parâmetro é identificado por um PID e os valores são retornados em formato hexadecimal, que devem ser decodificados

para valores compreensíveis. Observam-se, na Tabela 10, alguns exemplos de PIDs disponíveis no serviço 01.

Tabela 10 – Exemplos de PIDs do Serviço 01

PID (hex)	Descrição	Unidade
0C	Rotação do motor	RPM
0D	Velocidade do veículo	km/h
04	Carga calculada do motor	%
05	Temperatura do líquido de arrefecimento	°C
0B	Pressão absoluta do coletor (<i>Manifold Absolute Pressure Sensor</i>)	kPa
10	Fluxo de massa de ar (<i>Mass Air Flow Sensor</i>)	g/s

Cada PID é associado a um conjunto de dados específicos. Por exemplo, para o PID 0C, a mensagem retorna dois bytes que representam a rotação do motor. O valor real é calculado dividindo o número hexadecimal obtido por 4, conforme especificado pela norma SAE. Essas informações exemplificam como a leitura e decodificação dos dados no OBD são realizadas, destacando a importância da padronização para diagnósticos precisos e eficientes.

3.5 APRENDIZADO DE MÁQUINA

3.5.1 USO DO APRENDIZADO DE MÁQUINA NA ESTIMAÇÃO DE CO₂

A estimação das emissões de dióxido de carbono CO₂ em veículos é uma tarefa complexa, com múltiplos fatores influenciando os resultados, como tipo de combustível, estilo de condução, topografia e condições climáticas. Métodos tradicionais baseados em modelos físicos ou estatísticos muitas vezes falham em capturar essas complexidades.

O Aprendizado de Máquina, por outro lado, permite construir modelos baseados em dados reais, oferecendo maior precisão preditiva ao considerar múltiplas variáveis simultaneamente e suas interações não lineares.

3.5.2 A RELAÇÃO ENTRE EQUAÇÕES FÍSICAS E APRENDIZADO DE MÁQUINA

A principal diferença entre equações tradicionais e modelos de aprendizado de máquina está na forma como são desenvolvidos e aplicados. Equações tradicionais são construídas a partir de leis físicas e empíricas, com parâmetros fixos. Elas geralmente assumem condições ideais ou lineares, o que limita sua acurácia no mundo real.

Por outro lado, algoritmos como redes neurais profundas obtêm desempenho superior na previsão de emissões veiculares em comparação com métodos convencionais, especialmente quando utilizados com

dados de alta frequência ou de sensores embarcados (WRIGHT et al., 2024)(ULUSSEVER et al., 2023). Modelos de aprendizado de máquina conseguem aprender padrões complexos e se adaptar a diferentes condições sem a necessidade de hipóteses rígidas (QIAO et al., 2024). Estudos comparativos mostram que aprendizado de máquina apresenta maior capacidade preditiva, especialmente em cenários com grande volume de dados e múltiplas variáveis de entrada (NATARAJAN et al., 2023).

3.5.3 REDES NEURAIS

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, amplamente utilizados em tarefas de previsão e classificação. No contexto automotivo, as RNAs vêm sendo empregadas para estimar emissões de CO₂ com alta precisão, considerando múltiplas variáveis como velocidade, carga do motor, tipo de combustível e condições ambientais (CHEN; YE; HUANG, 2018; LI; SUN, 2021).

Diferentemente de outros modelos de aprendizado de máquina, como as árvores de decisão, que funcionam com regras sequenciais, as RNAs utilizam camadas de nós interconectados (neurônios) que processam os dados de entrada por meio de funções de ativação. O aprendizado ocorre a partir do ajuste dos pesos das conexões, com base no erro entre a previsão do modelo e o valor real, usando algoritmos como retropropagação. As RNAs apresentam excelente capacidade de modelar relações não lineares e de capturar padrões complexos nos dados.

Portanto, optou-se neste trabalho pelo uso de Redes Neurais Artificiais justamente por essas vantagens em relação a métodos estatísticos tradicionais, visto que tais redes capturam relações complexas nos dados sem exigir os pressupostos simplificadores que modelos clássicos demandam.

Segundo (CHEN; YE; HUANG, 2018), modelos como *Backpropagation Neural Network* e *Generalized Regression Neural Network* superam métodos estatísticos tradicionais na estimativa de fluxos de CO₂ em diversas aplicações ambientais. Em escalas urbanas, RNAs também foram usadas com sucesso para prever emissões de carbono em cidades (LI; SUN, 2021).

As configurações das RNAs são cruciais para o desempenho do modelo e incluem:

- **Arquitetura:** composta por camadas de entrada, ocultas e de saída.
- **Funções de ativação:** ReLU, sigmoid, ou tanh são comuns.
- **Hiperparâmetros:** número de camadas, número de neurônios, taxa de aprendizado.
- **Validação cruzada:** usada para evitar *overfitting*.

3.5.4 PERCEPTRON MULTICAMADAS - MLP (*MULTI-LAYER PERCEPTRON*)

O MLP é um tipo específico de Rede Neural Artificial (RNA) que se destaca por sua arquitetura em camadas bem definidas e totalmente conectadas, sendo amplamente utilizado para tarefas de regressão e classificação. Em aplicações automotivas, o MLP tem mostrado grande eficácia na previsão de emissões de CO₂, especialmente quando há disponibilidade de dados complexos e multidimensionais (MEHR-MOHAMMADI; GHAEMI, 2023).

A principal diferença entre um MLP e outras RNAs está na estrutura: o MLP é composto por ao menos três camadas — uma de entrada, uma ou mais camadas ocultas, e uma de saída — com

todos os neurônios interligados entre as camadas adjacentes. Essa conectividade completa permite que o modelo capture relações altamente não lineares nos dados. Além disso, o MLP utiliza funções de ativação não lineares, como ReLU, sigmoid ou tanh, para transformar os dados nas camadas ocultas, e aplica algoritmos de otimização para ajustar os pesos com base no erro de previsão. Algoritmos MLP oferecem boa capacidade de generalização em cenários com muitas variáveis correlacionadas. Quando comparado a outras RNAs, sua principal vantagem está na simplicidade da implementação e na eficácia em dados estruturados, como os extraídos de sensores veiculares via OBD.

As principais configurações de um MLP incluem:

- **Número de camadas ocultas:** indica o número de camadas internas (ocultas).
- **Número de neurônios por camada:** definido conforme a complexidade dos dados.
- **Função de ativação:** ReLU, sigmoide e tanh fazem o mesmo papel (introduzir não linearidade), mas a ReLU é mais comum por treinar mais rápido e funcionar melhor em redes profundas; já sigmoide/tanh “saturam” nas extremidades e tendem a aprender mais devagar.
- **Algoritmo de otimização:** como Adam, SGD ou RMSProp.
- **Técnicas de regularização:** como *dropout* e *early stopping*, para evitar *overfitting* (quando o modelo “decora” os dados de treino e piora em dados novos), geralmente por excesso de complexidade e poucos dados ou mesmo ruído.




Figura 7 – MLP com duas camadas ocultas. Fonte: (FLECK et al., 2016).

3.5.5 MEMÓRIA DE CURTO E LONGO PRAZO - LSTM (*LONG SHORT-TERM MEMORY*)

As *Long Short-Term Memory* (LSTMs) são um tipo avançado de RNA, projetadas para lidar com dados sequenciais e temporais. Inspiradas Redes Neurais Recorrentes (RNNs), as LSTMs foram criadas para superar a dificuldade das Rede Neural Recorrente (RNN) em aprender dependências de longo prazo, devido ao problema do “desvanecimento do gradiente”. Uma característica distintiva das LSTMs é a presença de três portas fundamentais em cada neurônio: a porta de entrada (*input gate*), a porta de saída (*output gate*) e a porta de esquecimento (*forget gate*), conforme Figura 8.




Figura 8 – LSTM - Fonte: (BARBOSA et al., 2021)

Enquanto o MLP trabalha com entradas independentes e possui estrutura de camadas fixas, as LSTMs incorporam uma célula de memória que permite reter e esquecer informações ao longo do tempo, ajustando-se dinamicamente ao comportamento histórico dos dados. Isso é especialmente útil no contexto automotivo, onde fatores como velocidade, aceleração, condições ambientais e estilo de direção variam continuamente ao longo do tempo (ZHANG et al., 2018).

As LSTMs superam modelos tradicionais e mesmo outras RNAs em tarefas de previsão de emissões de poluentes como CO_2 , principalmente quando há grande variabilidade nos dados (HU et al., 2024). Modelos híbridos, como *Wavelet-LSTM*, foram desenvolvidos para lidar com séries temporais ruidosas, mostrando ganhos em precisão sobre modelos estatísticos convencionais (ZHANG et al., 2018). Além disso, otimizações como o uso de algoritmos genéticos ou *Particle Swarm Optimization* melhoram ainda mais a performance das LSTMs em tarefas de predição de emissões (HU et al., 2024).

Assim como outras RNAs, as LSTMs utilizam funções de ativação não lineares e aprendizado por retropropagação, mas se destacam por sua estrutura interna de portas (de entrada, de esquecimento e de saída), que controlam o fluxo de informação na célula de memória. Os principais elementos que definem o desempenho de um modelo LSTM incluem:

- **Número de camadas LSTM:** uma ou mais camadas empilhadas para capturar padrões complexos.
- **Tamanho da sequência de entrada:** define quantos passos anteriores são considerados para prever o próximo valor.
- **Função de ativação:** geralmente $\tanh$ ou sigmoid para as portas internas.
- **Hiperparâmetros:** taxa de aprendizado, número de épocas, *batch size*, entre outros.
- **Regularização:** técnicas como *dropout* ajudam a evitar *overfitting*.

3.5.6 ANÁLISE DE INCERTEZAS - MONTE CARLO DROPOUT

A incerteza associada a uma medição caracteriza a dispersão dos valores de um mensurando, podendo ser quantificada por meio de um desvio-padrão que estabelece um intervalo de confiança para a variável medida. Assim, para uma medição v e seu desvio-padrão σ , o verdadeiro valor V_m deverá pertencer ao intervalo (INMETRO, 2008):

$$i = [v - \sigma, v + \sigma], \quad V_m \in i \quad (3.11)$$

No contexto de redes neurais artificiais, o *Monte Carlo Dropout* (MCD) oferece uma estimativa da incerteza por meio da interpretação bayesiana do *dropout* (desligamento aleatório de neurônios durante o treino). Enquanto o *dropout* tradicional é aplicado somente durante o treinamento para evitar *overfitting* (quando o modelo “decora” o treino e piora em dados novos), na técnica de MCD o *dropout* permanece ativo também na fase de inferência. Como mostrado na Figura 9, a técnica de MCD mantém ativo o mecanismo de *dropout* durante a inferência, gerando múltiplas iterações estocásticas sobre a mesma entrada.




Figura 9 – Monte Carlo Dropout - Fonte: (LIMA, 2022)

Dessa forma, para uma mesma entrada, executam-se T *forward passes*, gerando previsões $\{\hat{y}_t\}_{t=1}^T$. A média e a variância dessas previsões fornecem, respectivamente, o valor esperado e a incerteza do modelo:

$$E(\hat{y}) = \frac{1}{T} \sum_{t=1}^T \hat{y}_t \quad (3.12)$$

E, além disso, a variância das previsões é dada por:

$$\text{Var}(\hat{y}) \approx \tau^{-1} + \frac{1}{N} \sum_{t=1}^N \hat{y}_t^N \hat{y}_t - \mathbb{E}(\hat{y})^N \mathbb{E}(\hat{y}) \quad (3.13)$$

Sendo:

- τ : Precisão do modelo.
- λ : Probabilidade de um neurônio ser desativado.

E a precisão τ é dada por

$$\tau = \frac{(1-p)l^2}{2N\lambda} \quad (3.14)$$

Os principais parâmetros do algoritmo de *Monte Carlo Dropout* estão descritos na Tabela 11. Por

Tabela 11 – Parâmetros do *Monte Carlo Dropout*

Parâmetro	Definição
p	Probabilidade de um neurônio ser desativado (<i>dropout rate</i>)
l	<i>Length scale</i> , indica a escala de confiança nos dados de entrada
N	Número de amostras de treinamento
λ	Peso da regularização $L2$
T	Número de previsões estocásticas (<i>forward passes</i>)

fim, a aplicação de MCD em arquiteturas profundas, como LSTM, melhora a acurácia e fornece intervalos de confiança confiáveis em tarefas críticas, como previsão de cargas energéticas e detecção de anomalias em séries temporais (ALARAB; PRAKOONWIT; NACER, 2021; HUANG et al., 2018; CHEN et al., 2018; LADINO-MORENO; GARCÍA-UBAQUE, 2024).

3.5.7 MÉTRICAS DE AVALIAÇÃO DE MODELOS

A avaliação da performance de modelos de aprendizado de máquina é fundamental para garantir a confiabilidade das previsões, especialmente em aplicações críticas como a estimativa de emissões veiculares de CO₂. Modelos de inteligência artificial como RNA, MLP e LSTM requerem diferentes abordagens de avaliação, mas compartilham métricas comuns para problemas de regressão, como é o caso da previsão de emissões.

As principais métricas utilizadas são:

- **Erro Médio Absoluto (MAE - *Mean Absolute Error*)**: mede a média das diferenças absolutas entre os valores previstos e os reais. É útil por ser intuitiva e menos sensível a *outliers*.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}_i| \quad (3.15)$$

- **Erro Quadrático Médio (MSE - *Mean Squared Error*)**: penaliza erros maiores com mais intensidade, o que pode ser vantajoso quando grandes desvios são críticos.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2 \quad (3.16)$$

- **Raiz do Erro Quadrático Médio (RMSE - *Root Mean Squared Error*)**: é a raiz quadrada do MSE, mantendo a mesma unidade das variáveis originais, o que facilita a interpretação prática.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (3.17)$$

- **Coefficiente de Determinação (R^2)**: indica a proporção da variabilidade dos dados explicada pelo modelo. Valores próximos de 1 indicam bom ajuste.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \bar{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.18)$$

- **MAPE (*Mean Absolute Percentage Error*)**: expressa o erro médio absoluto em termos percentuais, sendo útil para entender a escala do erro em relação aos valores reais.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{|y_i|} \cdot 100\% \quad (3.19)$$

Onde, para todas as equações, y_i representa os valores reais, $\hat{y}_i$ os valores previstos, n o número total de amostras e $\bar{y}$ a média dos valores reais.

3.6 JUSTIFICATIVA DA ESCOLHA DOS ALGORITMOS

Os algoritmos empregados ao longo deste trabalho foram selecionados levando em consideração o tipo de dado disponível. As coletas realizadas correspondem a séries temporais de parâmetros automotivos obtidos por meio do OBD, como velocidade, rotação do motor e posição do acelerador. Esses registros variam continuamente ao longo do tempo e apresentam correlações não lineares.

Para lidar com essas características, optou-se por modelos capazes de capturar dependências temporais, como redes neurais do tipo LSTM, combinadas à técnica de MCD para quantificar incertezas. Tais algoritmos aprendem diretamente dos dados coletados, adaptando-se ao estilo de condução e às condições reais de operação dos veículos.

Em comparação às equações tradicionais, que partem de hipóteses fixas e muitas vezes desconsideram fatores externos, os modelos de aprendizado de máquina permitem incorporar outros elementos além daqueles definidos em equações físicas. Dessa forma, ampliam-se as variáveis analisadas e obtêm-se estimativas mais aderentes ao comportamento real dos veículos.

4 MATERIAIS E MÉTODOS

Este capítulo descreve os métodos e materiais utilizados para coleta, tratamento e análise dos dados de veículos elétricos e a combustão. O estudo foi realizado em condições reais de uso, utilizando dispositivos específicos para leitura de dados por meio da interface OBD.

4.1 MATERIAIS

Para a coleta dos dados de veículos elétricos e a combustão, foi utilizado o leitor ELM327 (Figura 10), uma ferramenta empregada devido ao seu baixo custo e facilidade de uso. Quando plugado no veículo, este dispositivo se conecta à porta OBD do veículo e permite a extração de informações em tempo real dos mais diversos PID estabelecidos em normas SAE. O dispositivo conta com conectividade *Bluetooth*, que possibilita a comunicação com dispositivos móveis, como *smartphones* e *tablets*.



Figura 10 – Dispositivo ELM327 utilizado na coleta de dados (Elm Electronics Inc., 2017).

Para a comunicação com o dispositivo ELM327, diversos softwares podem ser empregados, pois existem várias opções disponíveis no mercado. Essas ferramentas são compatíveis com a interface OBD e permitem a leitura dos PID, conforme definido em normas SAE. Cada software apresenta características e funcionalidades próprias, possibilitando a escolha de acordo com a necessidade e o objetivo do estudo. Na presente pesquisa, optou-se pela utilização do aplicativo *Torque Pro* (Figura 11), devido à sua ampla compatibilidade, interface amigável e capacidade de registrar dados em tempo real para análises posteriores.




Figura 11 – Aplicativo *Torque Pro* utilizado para leitura e registro dos dados (HAWKINS, 2025).

O *Torque Pro* é um aplicativo dedicado a leitura de dados veiculares em tempo real, além de outros parâmetros úteis dos veículos. Ele permite não apenas a visualização imediata de informações do veículo, mas também o registro de dados para análises detalhadas posteriores. Suas principais funcionalidades incluem:

- **Monitoramento em tempo real:** O *Torque Pro* oferece a possibilidade de monitorar diversos parâmetros do motor e do sistema veicular em tempo real, fornecendo gráficos e indicadores personalizáveis.
- **Armazenamento de dados:** O aplicativo registra os valores coletados em arquivos de log, que podem ser exportados para análises detalhadas em outras plataformas, como planilhas eletrônicas.
- **Diagnóstico de falhas:** Possui a funcionalidade de leitura de DTC, facilitando a identificação e resolução de problemas.
- **Personalização:** É possível configurar quais parâmetros serão exibidos, permitindo que o usuário foque nas informações mais relevantes para o estudo ou diagnóstico.

Os PID adquiridos por meio do *Torque Pro* podem ser utilizados para monitorar o desempenho do motor e estimar a emissão de poluentes, incluindo o dióxido de carbono CO₂. Alguns PID especialmente relevantes para o cálculo de emissões incluem:

Tabela 12 – Exemplos de *PIDs* definidos por norma SAE

PID	Parâmetro	Descrição
0C	Velocidade do Veículo	Velocidade instantânea do veículo (km/h).
04	Carga do Motor	Carga do motor (%).
05	Temperatura do Ar de Admissão	Temperatura de Admissão do motor (°C).
0F	Temperatura do Ar Ambiente	Temperatura Ambiente (°C).
10	Fluxo de Ar de Admissão	Fluxo de ar do motor (g/s).
11	Posição Absoluta do Acelerador	Percentual de pressão do Acelerador (%).
33	Taxa de Consumo de Combustível	Consumo de Combustível (l/h).

A partir desses parâmetros, é possível estimar o consumo de combustível do veículo e calcular a quantidade de CO₂ emitida. Adicionalmente, o *Torque Pro* pode ser configurado para exportar os dados em formato *CSV* ou fazer conexões externas com internet.

A coleta de dados em VEs apresenta desafios específicos em comparação com veículos a combustão. Isso se deve principalmente à falta de padronização dos PID para esse tipo de veículo. Ao contrário dos veículos a combustão, cujos PID são amplamente definidos por normas SAE, os PID de veículos elétricos são, em grande parte, proprietários e definidos individualmente por cada montadora. Para contornar essas dificuldades, é necessário buscar na internet informações específicas sobre os PID de veículos elétricos de determinada marca e modelo. Essas informações podem ser encontradas em fóruns especializados, documentações técnicas ou em publicações de fabricantes e desenvolvedores de software.

4.1.1 VEÍCULOS UTILIZADOS PARA A ANÁLISE

Para a análise realizada neste estudo, foram utilizados dois tipos distintos de veículos: um veículo a combustão modelo Onix e outro modelo Fastback. Não foram utilizados veículos elétricos neste trabalho. Os detalhes técnicos dos veículos analisados estão organizados nas Tabelas 13 e 14.

Tabela 13 – Especificações técnicas do veículo Onix.

Característica	Descrição
Fabricante	Chevrolet
Modelo	Onix
Ano/Modelo	2018/2019
Cilindrada (cc)	1400
Potência (cv)	106
Combustível usado	Gasolina

O fluxo de trabalho adotado no estudo seguiu as seguintes etapas:

1. Conexão do leitor ELM327 à porta OBD do veículo;

Tabela 14 – Especificações técnicas do veículo Fastback.

Característica	Descrição
Fabricante	Fiat
Modelo	Fastback
Ano/Modelo	2024/2024
Cilindrada (cc)	1300
Potência (cv)	180
Combustível usado	Gasolina

2. Coleta de dados em tempo real com o aplicativo *Torque Pro*, configurado para registrar os parâmetros relevantes;
3. Exportação dos dados em formato *CSV* para análise posterior;
4. Importação dos arquivos de dados para o ambiente de desenvolvimento no *Visual Studio Code*;
5. Tratamento e análise dos dados utilizando as bibliotecas do *Python*, com geração de gráficos e relatórios.

4.2 MÉTODOS

4.2.1 COLETA E TRATAMENTO DE DADOS

Para a análise dos dados, foi utilizado a *Integrated Development Environment (IDE) Visual Studio Code* (Figura 12).




Figura 12 – IDE e linguagem de programação usadas na análise de dados.

Esta IDE foi escolhida devido à sua versatilidade, ampla gama de extensões e suporte para diversas linguagens de programação. A linguagem de programação utilizada para o processamento dos dados foi *Python*, comumente usada devido a sua simplicidade e pelas bibliotecas especializadas em manipulação e análise de dados, como *Pandas*, *NumPy* e *Matplotlib*. Além disso, a linguagem de programação *Python* permitiu a criação de gráficos e visualizações que auxiliaram na interpretação dos resultados, bem como a automação de tarefas repetitivas relacionadas ao tratamento de dados.

A integração entre o leitor ELM327, os aplicativos móveis e as ferramentas computacionais foi estruturada para que os dados capturados pudessem ser diretamente exportados e processados, conforme Figura 13.




Figura 13 – Arquitetura usada para processamento dos dados.

O *Torque Pro* foi configurado para gerar arquivos de saída no formato *CSV*, garantindo sua compatibilidade com as bibliotecas do *Python*.

4.2.2 ANÁLISE DOS DADOS

De posse dos dados coletados, os mesmos foram submetidos a um fluxo de análise:

1. **Tratamento e Estatística Descritiva:** Análise preliminar dos dados (parâmetros coletados do OBD e também calculados), bem como análise de correlação entre os parâmetros.
2. **Treinamento de Redes Neurais:** De posse de todos os dados, foram realizados os treinamentos das Redes Neurais, tanto MLP quanto LSTM. Foram realizados diversos treinamentos, com diferentes combinações de hiperparâmetros, visando encontrar a melhor configuração para cada tipo de rede neural.
3. **Avaliação de Performance dos Modelos de Rede Neural:** Após o treinamento, foram avaliados os modelos de rede neural, tanto MLP quanto LSTM, a fim de encontrar a melhor configuração.
4. **Segunda Etapa de Treinamentos (*Monte Carlo Dropout*):** Para a avaliação da ferramenta *Monte Carlo Dropout*, foram realizados novos treinamentos com o modelo MLP e LSTM, utilizando apenas a configuração de hiperparâmetros que apresentaram os melhores resultados na primeira etapa de treinamentos.
5. **Avaliação final de Performance:** Por fim, foi realizada a avaliação final de performance dos modelos de rede neural, tanto MLP quanto LSTM, com as melhores configurações de hiperparâmetros, incluindo *Monte Carlo Dropout*.

É importante destacar que o treinamento das redes foi realizado em duas etapas principais. Na primeira etapa, executaram-se os múltiplos treinamentos variando-se os hiperparâmetros, conforme descrito, registrando-se o melhor resultado (menor erro) alcançado por cada configuração testada. Com base nesses resultados, identificou-se a configuração ótima ou de melhor desempenho - no caso, a rede LSTM com um determinado arranjo de neurônios e parâmetros que minimizou o erro. Na segunda etapa, procedeu-se a uma análise aprofundada do modelo selecionado, incluindo a avaliação da sua incerteza de previsão. Para isso, empregou-se a técnica de *Monte Carlo Dropout* (MCD) no modelo final: após treiná-lo com a configuração ótima, foram realizadas várias simulações de inferência onde o *dropout* permaneceu ativado, gerando múltiplas previsões para cada entrada de teste.

Com essas previsões múltiplas, pôde-se estimar um intervalo de confiança para as emissões previstas e calcular métricas de dispersão. Essa abordagem permitiu quantificar a incerteza associada às estimativas de CO₂ fornecidas pela rede neural, algo essencial em aplicações reais para indicar o grau de confiabilidade das previsões. Todo o processo de treinamento e validação foi conduzido de forma a garantir a reprodutibilidade (fixando-se sementes aleatórias, quando aplicável e gravação da rede neural em si).

5 RESULTADOS

São apresentados neste capítulo os resultados obtidos nesta pesquisa com o objetivo de alcançar as metas traçadas no Capítulo 1. Primeiramente, descrevem-se as coletas de dados via OBD, seguidas da análise exploratória dos parâmetros registrados. Na sequência, são discutidos os desempenhos das RNAs sob múltiplas configurações de treinamento e, por fim, avaliam-se as incertezas das previsões.

5.1 COLETAS DE DADOS REALIZADAS

As coletas de dados foram realizadas utilizando dois veículos: um veículo a combustão modelo Onix e outro modelo Fastback. As coletas ocorreram em múltiplas sessões, abrangendo trajetos urbanos e rodoviários. Não houve um percurso predefinido, de modo a aumentar a variabilidade dos dados e evitar vieses decorrentes de condições específicas de estrada. No total, foram coletadas 69000 amostras durante 26 horas, conforme Tabela 15.

Tabela 15 – Distribuição de tempo e amostras por veículo

Car	Tempo Total		Amostras	
	Horas	% Tempo	Total	% Amostras
Fastback	13,16	49,90	38 821	56,26
Onix	13,21	50,10	30 184	43,74

O intervalo de coleta foi de 1,22 segundo para o Fastback e 1,58 segundo para o Onix, resultando em uma média de 1,39 segundo.

Quanto aos parâmetros coletados, é feita uma análise estatística na Tabela 16.

Tabela 16 – Estatísticas descritivas dos parâmetros registrados

Parâmetro	Média	Desvio Padrão	Mínimo	Máximo
Distância Percorrida (km)	0,03	2,19	0,00	282,73
Posição do Acelerador (%)	24,32	23,47	1,37	79,41
Quilômetros por litro (km/l)	25,13	26,97	7,00	181,25
Pressão de Admissão (psi)	7,46	3,30	2,18	21,54
Velocidade (km/h)	65,41	42,18	0,50	255,00
RPM (rpm)	1723,70	534,88	0,00	4249,50
Carga do Motor (%)	29,69	16,61	0,00	100,00

É ilustrado na Figura 14 a Matriz de Correlação, usada para medir a relação entre diferentes variáveis. Nela são representados os coeficientes de correlação, que indicam a força e a direção do relacionamento entre pares de variáveis, variando de -1 (correlação negativa perfeita) a 1 (correlação positiva perfeita).




Figura 14 – Matriz de Correlação.

Na Figura 14 é possível observar padrões de relacionamento entre as variáveis registradas:

- **Posição do acelerador vs. Pressão de admissão e Carga do motor:** correlações fortes e positivas (0,69 e 0,65, respectivamente), indicando que, à medida que o motorista pisa mais no acelerador, aumentam tanto a pressão de admissão quanto a carga aplicada ao motor.
- **Pressão de admissão vs. Carga do motor:** correlação ainda mais alta (0,71), refletindo a dependência direta entre a pressão criada na admissão e o esforço exigido do motor.
- **Quilômetros por litro vs. CO₂ instantâneo:** correlação negativa forte (0,63), mostrando que maior eficiência de combustível está associada a menores emissões de CO₂.
- **Velocidade vs. Quilômetros por litro e CO₂:** correlação positiva com eficiência (0,68) e negativa com emissões (0,41). Isso sugere que, em velocidades de cruzeiro constantes (tipicamente rodoviárias), há melhora na economia de combustível e redução de CO₂.
- **RPM do motor vs. Posição do acelerador:** correlação moderada (0,32), indicando que a relação entre abertura de acelerador e rotação não é estritamente linear, possivelmente devido a trocas de marcha e gerenciamento eletrônico.

- **Carga do motor vs. CO₂:** correlação positiva (0,60), sinalizando que maiores demandas de torque resultam em maiores emissões de CO₂.

Em resumo, a matriz confirma que parâmetros de condução mais agressiva (alta carga, alta pressão de admissão e elevado acionamento do acelerador) estão diretamente associados a maiores emissões, enquanto condições de rodagem estáveis e de menor esforço do motor favorecem a eficiência energética e a redução de CO₂.

5.1.1 PARÂMETROS COLETADOS - OBD

Os dados coletados via OBD englobam variáveis relacionadas ao desempenho e funcionamento do motor. Os parâmetros coletados, juntamente com suas unidades e faixas de variação, são expostos na Tabela 17.

Tabela 17 – Parâmetros coletados via OBD

Parâmetro	ID (hex)	Unidade	Mínimo	Máximo
Engine RPM	0C	rpm	0	16383,75
Engine Load	04	%	0	100
Speed (OBD)	0D	km/h	0	255
Throttle Position (Relativa)	11	%	0	100
Intake Manifold Pressure	0B	psi	0	255
Mass Air Flow (MAF)	10	g/s	0	655,35

5.1.2 PARÂMETRO CALCULADO - EMISSÃO DE CO₂

Nem todos os parâmetros necessários para a análise foram coletados diretamente durante os testes, sendo necessário realizar cálculos adicionais conforme metodologias e normas técnicas estabelecidas. Nas seções a seguir são detalhados os principais parâmetros calculados para os veículos a combustão e elétricos.

Tendo em vista não ser possível determinar a temperatura do combustível, o método volumétrico, definido pela Equação 3.2, não pode ser usado. Deste modo, foi adotado o método gravimétrico, definido pela Equação 3.3. Em conjunto, foi usada a Tabela 3, que expressa o Fator de Emissão em termos de Litros de combustível. Logo, tem -se:

$$CO_2 = \frac{FE}{A} = \frac{FE \cdot C}{100} \quad (5.1)$$

ou ainda, expandindo a Equação 3.3:

$$CO_2 = \frac{FE \cdot \left(\frac{M}{D \cdot d} \cdot 100 \right)}{100} \quad (5.2)$$

substituindo M:

$$CO_2 = \frac{FE \cdot \left(\frac{MAF}{AFR \cdot D \cdot d} \cdot 100 \right)}{100} = \frac{FE \cdot \frac{MAF}{AFR \cdot D \cdot d}}{1} \quad (5.3)$$

Por fim, tem-se:

$$CO_2 = \frac{FE \cdot MAF}{AFR \cdot D \cdot d} \quad (5.4)$$

Em que:

Tabela 18 – Descrição dos parâmetros utilizados na equação do cálculo de CO_2 .

Símbolo	Significado	Origem	Unidade de Medida
CO_2	Geração de CO_2	Parâmetro Calculado	g/km
MAF	Fluxo de Massa de Ar	Coletado do OBD	g/s
D	Distância		km
FE	Fator de Emissão	Constante, conforme Tabela 3	g/L
AFR	Razão Ar-Combustível		Adimensional
d	Densidade		g/L

5.2 ANÁLISE EXPLORATÓRIA DOS DADOS

Conforme exposto na Figura 14, o coeficiente entre Carga do Motor e Geração de CO_2 é de 0,60. Na Figura 15, esse diagnóstico é complementado ao exibir a evolução do coeficiente de Pearson entre Carga do Motor e CO_2 ao longo das amostras:




Figura 15 – Correlação entre Carga do Motor e CO_2 .

- O coeficiente varia aproximadamente entre 0,45 e 0,90, confirmando a relação positiva e relativamente estável, embora não linear, entre demanda de motor e emissões.
- As flutuações mostram que, em regimes de condução menos intensos, a correlação diminui (próximo de 0,45-0,50), ao passo que em acelerações ou cargas elevadas o coeficiente se aproxima de 0,90.

Em conjunto, essas duas visualizações demonstram claramente que o estilo de condução — especialmente as variações abruptas de carga — exerce papel determinante na magnitude das emissões instantâneas de CO₂.

Também foram analisados os valores de emissão de CO₂ e comparados com os valores definidos pelo PBE, tanto para o veículo Onix (Figura 16) quanto para o Fastback (Figura 17).




Figura 16 – Valores reais de Medição - Onix.




Figura 17 – Valores reais de Medição - Fastback.

Nota-se que, para o veículo Onix, ano de fabricação 2018, existem apenas dois pequenos intervalos onde a emissão de CO₂ é menor do que o valor tabelado pelo PBE. Por outro lado, para o veículo Fastback, ano de fabricação 2024, os valores medidos estão mais próximos do valor definido pelo PBE.




Figura 18 – Desvio Padrão - Onix.




Figura 19 – Desvio Padrão - Fastback.

Tabela 19 – Resumo dos valores do PBE, média e desvio padrão

Veículo	Média (gCO ₂ /km)	Desvio Padrão (σ)	INMETRO (gCO ₂ /km)
Onix	145,33	20,54	99
Fastback	133,97	25,61	108

São apresentadas nas Figuras 18 e 19 as emissões instantâneas de CO₂ para os veículos Onix e Fastback, acompanhadas da média e dos limites estatísticos definidos por $\pm 1\sigma$ e $\pm 2\sigma$, onde σ representa

o desvio padrão. Enquanto na Tabela 19 é possível observar um resumo dos valores estatísticos extraídos dessas distribuições.

No caso do Onix, verifica-se que as emissões reais são significativamente superiores ao valor oficial informado pelo INMETRO. A linha azul tracejada, correspondente ao valor tabelado, encontra-se muito abaixo de todas as curvas representando os limites estatísticos das medições reais. Mesmo o limite inferior de -2σ — que corresponde a valores estatisticamente raros e extremamente baixos dentro da distribuição — permanece **acima** do valor de referência do PBE. Esse comportamento indica que, dentro de todas as amostras coletadas, o veículo nunca atingiu valores de CO₂ próximos ao valor de homologação.

Para o Fastback, observa-se um cenário distinto. Embora a média real também esteja acima do valor tabelado pelo INMETRO, a diferença é sensivelmente menor que a observada no Onix. Notavelmente, o valor tabelado coincide aproximadamente com o limite de -1σ . Assim, semelhante ao veículo Onix, para o veículo Fastback, o valor tabelado pelo INMETRO não reflete a média das emissões reais, ainda que a discrepância seja menos pronunciada.

5.3 TREINAMENTO DE REDES NEURAIS ARTIFICIAIS

Para a elaboração da Rede Neural, foram utilizados os dados coletados de dois veículos (Onix e Fastback) sob diferentes configurações de treinamento. Foram utilizadas dois tipos de Redes Neurais: MLP e LSTM.

Para facilitar a execução sistemática dos treinamentos dos modelos MLP e LSTM com diferentes combinações de hiperparâmetros, foi desenvolvido um *script* em *Python* que utiliza a biblioteca *papermill*. O fluxo geral é:


1. Definição das listas de valores para cada hiperparâmetro: número de épocas, taxa de aprendizagem, número de neurônios e configurações de camadas;
2. Cálculo do total de combinações por modelo;
3. Iteração sobre cada combinação, registro de um *timestamp* (*now*), impressão de progresso e invocação do código da rede neural correspondente;
4. Armazenamento do *notebook* gerado em uma pasta com nome padronizado contendo o *timestamp* e os valores dos hiperparâmetros.

Os valores testados para cada hiperparâmetro, bem como o total de combinações por modelo, estão sintetizados na Tabela 20.

Em um segundo momento, para análise de eficiência da ferramenta *Monte Carlo Dropout*, foram realizados novos treinamentos com o modelo MLP e LSTM. Entretanto não foram repetidas as mesmas configurações de hiperparâmetros, mas sim uma nova combinação de valores usando apenas as melhores combinações obtidas na primeira etapa de treinamentos. O procedimento de cada execução é apresentado conforme diagrama da Figura 20.

Tabela 20 – Valores de hiperparâmetros testados no modelo LSTM e MLP

Hiperparâmetro	Valores testados	# Itens
Épocas	10, 20, 40, 75, 100, 150, 200	7
Taxa de aprendizagem	0,00001, 0,000025, 0,00005, 0,000075, 0,0001, 0,00025, 0,0005, 0,00075, 0,001	9
Neurônios/camada	10, 50, 75, 100	4
Configuração de camadas	[8], [8,16], [8,16,32], [32,16,8], [16,8]	5
Total de combinações		1260



Com um total de 2520 treinamentos realizados (1260 para MLP e 1260 para LSTM) — número decorrente do *grid* resumido na Tabela 20 —, o tempo total de treinamento foi de **68 horas** para o modelo LSTM e **40 horas** para MLP. Cada execução grava um novo *notebook* contendo tanto o código quanto os resultados do treinamento, além dos dados de treinamento e a rede neural em si. Esse procedimento garante reprodutibilidade e rastreabilidade, além de facilitar a comparação de performance entre diferentes configurações de hiperparâmetros. A visão geral do procedimento em duas etapas (Etapa 1: varredura completa; Etapa 2: MCD nas melhores configurações) é mostrada como Fluxograma conforme Figura 21.




Figura 21 – Fluxograma geral do procedimento experimental.

5.3.1 PRIMEIRA ETAPA DE TREINAMENTOS

Nesta primeira etapa, todos os modelos foram avaliados segundo duas métricas: o *Mean Absolute Percentage Error* (MAPE) e o tempo de execução do treinamento. O MAPE foi escolhido por oferecer uma medida intuitiva e adimensional do erro percentual médio entre as previsões e os valores reais, facilitando a comparação direta entre diferentes arquiteturas e escalas de saída. Já o tempo de execução — medido em minutos — reflete o custo computacional de cada configuração, sendo fundamental para identificar modelos que ofereçam um bom compromisso entre precisão e eficiência.

Para cada combinação de hiperparâmetros testada (número de neurônios, taxa de aprendizagem, configuração de camadas e épocas), registrou-se o MAPE mínimo alcançado ao longo do treinamento. Essa escolha garante que a análise foque no melhor desempenho possível de cada configuração, eliminando ruídos de eventuais oscilações ou instabilidades durante as primeiras iterações.

Por outro lado, o tempo de treinamento foi calculado como a média aritmética dos tempos observados, em vez do valor mínimo, pois a média proporciona uma estimativa mais realista do custo total de processamento, incorporando variações de carga e inicialização que ocorrem em ambientes reais de execução. Também foram gerados diversas curvas de desempenho que relacionam diretamente o erro percentual mínimo (MAPE) com o esforço computacional médio (tempo médio), permitindo selecionar as configurações que maximizam a eficiência preditiva sem incorrer em tempos de treinamento proibitivos.

5.3.1.1 ANÁLISE DE DESEMPENHO POR QUANTIDADE DE NEURÔNIOS

A Figura 22 ilustra o MAPE em função do número de neurônios por camada. No eixo secundário há o tempo mínimo de treinamento (em minutos) para cada configuração de neurônios. Foram avaliados os pontos de **10, 50, 75 e 100 neurônios**.




Figura 22 – Primeira Etapa de Treinamento - MAPE por Número de Neurônios.

Observa-se que o modelo LSTM mantém desempenho superior ao MLP em todas as configurações, com MAPE consistentemente abaixo de 6%, enquanto o MLP atinge seu melhor valor ($\approx 15,5\%$) em 50 neurônios. Após 50 neurônios, o modelo MLP rapidamente sofre degradação, sugerindo sobreajuste e perda de generalização.

Não foi possível notar diferença no tempo de treinamento quando há variação de Neurônios, tanto para o modelo LSTM quanto MLP. O modelo MLP apresentou tempo constante de 1,70 minutos e LSTM 3,00 minutos.

5.3.1.2 ANÁLISE DE DESEMPENHO POR TAXA DE APRENDIZAGEM

Na Figura 23 apresenta-se o MAPE mínimo obtido pelos modelos em função da taxa de aprendizagem testada. Foram avaliados valores de η variando de 10^{-5} a 10^{-3} em passos logarítmicos.




Figura 23 – Primeira Etapa de Treinamento - MAPE por Taxa de Aprendizagem.

Observa-se que taxas muito baixas resultam em MAPE elevado, indicando convergência excessivamente lenta. A partir de 0,00025, ambos os modelos reduzem o erro para valores baixos e atingindo a melhor estabilidade. Taxas maiores mantêm o MAPE em patamares igualmente baixos, mas sem ganhos significativos adicionais.

Em termos de tempo de treinamento, o LSTM mostrou estabilidade apenas entre as taxas de 0,00025 e 0,00075. Já o MLP mantém suas variações em grau reduzido, com leve pico em 0,000025.

5.3.1.3 ANÁLISE DE DESEMPENHO POR CONFIGURAÇÃO DE CAMADAS

No LSTM, o MAPE cai de aproximadamente 14% em uma única camada ([8], 2,1 min) para cerca de 4% em duas camadas ([8,16], 3,0 min), sendo 0,06 % o valor observado em três camadas ([32,16,8], 3,8 min). No MLP, o erro reduz de 82% em [8] (1,6 min) para 15% em três camadas ([8,16,32], 1,9 min), com tempos de treino entre 1,8 e 2,0 min.




Figura 24 – Primeira Etapa de Treinamento - MAPE por Quantidade de Camadas.

A configuração que apresentou o melhor custo-benefício entre tempo e erro foi [8,16,32], tanto para o LSTM quanto para o MLP.

5.3.1.4 ANÁLISE DE DESEMPENHO POR ÉPOCAS

Foram testadas 10, 25, 50, 100, 150 e 200 épocas. Observa-se que até 100 épocas há redução expressiva do erro, mas além disso o ganho é marginal, enquanto o tempo de treinamento cresce quase linearmente.




Figura 25 – Primeira Etapa de Treinamento - MAPE por Épocas.

Em resumo, 100 épocas representam o melhor compromisso entre redução de erro e custo de tempo, especialmente no LSTM.

5.3.1.5 RESUMO DA PRIMEIRA ETAPA DE TREINAMENTOS

Ilustra-se na Tabela 21, de forma resumida, os resultados dos treinamentos realizados, destacando o modelo, a configuração de hiperparâmetros e o MAPE mínimo alcançado.

Parâmetro	Maior MAPE	Menor MAPE	Conclusão
Neurônios (10-100)	22 % (100, MLP)	6 % (75, LSTM)	A quantidade de neurônios não influenciou no tempo de treinamento, apenas no MAPE.
Taxa de Aprendizagem (1e-5-1e-3)	>100 % (1e-5, MLP)	6 % (2,5e-4, LSTM)	Taxas $\geq 2,5e-4$ garantem rápida convergência e estabilidade no erro.
Configuração de Camadas	82 % ([8], MLP)	6 % ([8,16,32], LSTM)	Estruturas moderadamente profundas reduzem o erro; melhor custo-benefício em [8,16,32].
Épocas (10-200)	>100 % (10, MLP)	4 % (200, LSTM)	100 épocas representam o melhor compromisso entre redução de erro e tempo de treinamento.

Tabela 21 – Resumo da primeira etapa de treinamentos.

Ou seja, para a etapa seguinte de testes, as seguintes configurações de Redes Neurais serão utilizadas para a segunda etapa de treinamentos:

- Camadas: [8,16,32].
- Neurônios: 50.
- Taxa de Aprendizagem: 0,00075 e 0,00100.
- Épocas: 100 e 200.

5.3.2 SEGUNDA ETAPA DE TREINAMENTOS

5.3.2.1 ANÁLISE DE DESEMPENHO POR TAXA DE DESATIVAÇÃO

Como ilustrado na Figura 26, a variação da taxa de desativação de neurônios exerce impacto significativo no desempenho dos modelos.




Figura 26 – Segunda Etapa de Treinamento - MAPE por Taxa de Dropout.

Para taxas de *dropout* até cerca de 0,2, tanto o MLP quanto o LSTM mantêm valores muito baixos de MAPE (inferiores a 7%). Acima desse ponto, observa-se aumento exponencial do erro, com o MLP degradando-se mais rapidamente (atingindo aproximadamente 65 % de MAPE em *dropout* = 0,9) enquanto o LSTM apresenta pouca diferença (cerca de 61% de MAPE no mesmo ponto). O tempo médio de treinamento, mostrado no eixo secundário, permanece estável em torno de 3,5-4,0 minutos para o MLP e 6,5-7,5 minutos para o LSTM, indicando que a regularização via *dropout* não acarreta penalidade relevante de custo computacional. Em resumo, recomenda-se a adoção de taxas de *dropout* na faixa de 0,1-0,2 para maximizar o compromisso entre regularização e precisão preditiva.

5.3.2.2 ANÁLISE DE DESEMPENHO POR AMOSTRAS DE INFERÊNCIA

Como demonstrado na Figura 27, o número de amostras de inferência (T) tem impacto direto na estabilidade e precisão dos modelos MLP e LSTM.




Figura 27 – Segunda Etapa de Treinamento - MAPE por Parâmetro T.

Para valores baixos de T (até cerca de 100), observam-se altos índices de MAPE e grande variabilidade, com picos acima de 5%. Ao aumentar T , o erro decresce rapidamente, alcançando mínimos entre 300 e 600 amostras (MAPE em torno de 1% para LSTM e MLP). Acima de 600 amostras, o ganho adicional em precisão torna-se marginal e passa a haver até um leve aumento do MAPE. Já o tempo médio de inferência (e treino simulado), mostrado no eixo secundário, cresce quase linearmente com T , partindo de aproximadamente 4,5 min (LSTM) e 3,3 min (MLP) para $T = 1$ até cerca de 8,3 min e 3,9 min em $T = 1000$, respectivamente. Portanto, para otimizar o equilíbrio entre precisão e custo computacional, recomenda-se adotar T na faixa de 300-600 amostras.

5.3.2.3 REDES NEURAIS COM MELHORES RESULTADOS

Apresenta-se na Tabela 22 as configurações de hiperparâmetros que obtiveram os melhores desempenhos em termos de MAPE e tempo de treinamento, tanto para os modelos sem MCD quanto com MCD.

Tabela 22 – Melhores configurações e resultados dos modelos

Modelo	Épocas	Neurônios	Taxa de Aprendizagem	Configuração de Camadas	Dropout	Número de Inferências
MLP sem MCD	200	50	0,00100	[8,16,32]	-	-
LSTM sem MCD	200	75	0,00075	[8,16]	-	-
MLP com MCD	200	50	0,00100	[8,16,32]	0,010	450
LSTM com MCD	200	50	0,00100	[8,16,32]	0,010	600

Quanto as métricas de desempenho, são ilustrados na Tabela 23, além do MAPE, o tempo médio de treinamento e o número de épocas.

Tabela 23 – Métricas de Desempenho para as melhores Configurações de Redes Neurais

Modelo	MAE (gCO ₂)	MAPE (%)	Tempo (min)
MLP sem MCD	0,169	16,00	4,68
LSTM sem MCD	0,055	5,00	5,77
MLP com MCD	0,737	0,60	5,14
LSTM com MCD	0,512	0,40	9,43

5.3.2.4 ANÁLISE INDIVIDUAL DA REDE NEURAL

Nas seções anteriores, foram analisados conjuntos de múltiplos treinamentos com diversas configurações de hiperparâmetros - número de neurônios, taxa de aprendizagem, configuração de camadas e número de épocas - registrando sempre o MAPE mínimo para cada combinação e calculando a média do tempo de treinamento para refletir o custo computacional real. Esse procedimento é útil para analisar o melhor desempenho de cada configuração.

Entretanto, para uma análise individual da rede neural com maior eficiência, se faz necessária uma análise detalhada de uma rede LSTM com *Monte Carlo Dropout* (MCD) em específico. A rede escolhida foi a com melhor MAPE, configurada com camadas [8,16,32], 50 neurônios, taxa de aprendizagem de 0,00100 e 200 épocas. A Figura 28 mostra o gráfico de dispersão entre os valores reais de gCO₂ e as previsões do modelo para o conjunto de teste.




Figura 28 – Dispersão entre valores reais e previstos de gCO_2 para a rede LSTM com MCD.

Observa-se que a maioria dos pontos de previsão segue muito de perto a linha ideal (tracejada), refletindo o excelente ajuste do modelo, com métricas de erro conforme Tabela 24.

Tabela 24 – Métricas de Avaliação do Modelo

Métrica	Descrição	Valor (g/CO_2)
MSE	Erro Médio Quadrático (<i>Mean Squared Error</i>)	0,5617
RMSE	Raiz do Erro Médio Quadrático (<i>Root MSE</i>)	0,7495
MAE	Erro Médio Absoluto (<i>Mean Absolute Error</i>)	0,5125
MAPE	Erro Percentual Médio Absoluto (<i>Mean Absolute Percentage Error</i>)	0,4849%
R^2	Coefficiente de Determinação (<i>Coefficient of Determination</i>)	0,999887

No entanto, nota-se uma maior dispersão para valores reais mais baixos (gCO_2 abaixo de aproximadamente 20), onde ocorre leve sobrestimação, e uma tendência a subestimar nos extremos mais altos (acima de 320), indicando que a capacidade de generalização nesses pontos ainda pode ser aprimorada.

5.3.2.5 ANÁLISE DAS INCERTEZAS VIA MONTE CARLO DROPOUT

Para além da previsão pontual, foi calculada a incerteza z como o desvio padrão das T amostras geradas pelo *Monte Carlo Dropout*. Foram selecionados as 5% de amostras com menor variabilidade (menor incerteza) e as 5% com maior variabilidade (maior incerteza) para entender onde o modelo é mais ou menos confiante.

Nota-se nas Figuras 29 e 30 que os pontos de maior variabilidade aparecem nos extremos da faixa de emissões, tanto para valores muito baixos (abaixo de 50 gCO₂) quanto para valores muito altos (acima de 250 gCO₂). Nesses casos, as previsões apresentam dispersão significativamente maior, sinalizando menor familiaridade do modelo com essas condições menos representadas nos dados de treino.




Figura 29 – Top 5% Amostras com menor variabilidade (menor incerteza) - Monte Carlo Dropout.




Figura 30 – Top 5% Amostras com maior variabilidade (maior incerteza) - Monte Carlo Dropout.

O padrão de incertezas evidencia que o modelo é mais confiável em torno da média da distribuição de treinamento e menos robusto em regiões extremas.

6 CONCLUSÃO

O processo de coleta e preparação de dados via OBD resultou em 69 000 amostras, obtidas em múltiplas sessões urbanas e rodoviárias com dois veículos.

A partir do gráfico de correlação apresentado na Figura 15, observa-se que variáveis como carga do motor e velocidade exibem coeficientes de Pearson em torno de 0,6, indicando uma relação moderada a forte com as emissões instantâneas de CO₂. Esse comportamento evidencia a influência desses parâmetros na geração de gases e reforça a necessidade de considerá-los em modelos preditivos. Em paralelo, padrões com acelerações bruscas e altas rotações elevam marcadamente as emissões instantâneas de CO₂, enquanto regimes de cruzeiro constante mantêm esses níveis em patamares inferiores, conforme Figura 15.

Em adicional, é possível notar nas Figuras 16 e 17 que o valor definido pelo PBE, oriundo de testes laboratoriais padronizados, apresentou divergências em relação aos valores medidos em condições reais para os veículos analisados. Entretanto, tais diferenças não implicam ineficiência do PBE, pois o programa adota uma metodologia laboratorial que pode não refletir plenamente as condições de uso real, além de que a coleta de dados deste estudo não seguiu exatamente as diretrizes estabelecidas pelo PBE. Entretanto, não é possível afirmar a ineficiência do PBE como um todo, uma vez que a coleta de dados não respeitou exatamente as diretrizes definidas pelo PBE.

Quanto as redes neurais, a abordagem de adoção de múltiplos treinamentos para seleção refinada de hiperparâmetros. Na primeira etapa, variou-se sistematicamente o número de neurônios, a configuração de camadas ocultas, a taxa de aprendizado e o número de épocas. Constatou-se que redes com duas camadas ocultas e 64 neurônios por camada, aliadas a taxa de aprendizado de 10^{-3} e 100 épocas de treinamento, atingiram o menor MAPE, superando ligeiramente as arquiteturas MLP. Comparativamente, as LSTMs demonstraram desempenho superior, reduzindo em cerca de 5 % o erro médio devido à sua capacidade de capturar dependências temporais. O contraponto é que as LSTMs demandaram maior tempo de treinamento.

Na segunda etapa, implementou-se o *Monte Carlo Dropout* para quantificação de incertezas, variando taxas de *dropout* e o parâmetro T de amostras de inferência. Verificou-se que taxa de *dropout* de 0,25 e $T = 30$ proporcionaram o melhor equilíbrio entre exatidão e confiabilidade das previsões. Conforme ilustram as Figuras 23 e 24, as amostras com menor variabilidade concentraram-se em cenários estáveis, ao passo que os maiores intervalos de incerteza ocorreram em condições de condução mais dinâmicas. De modo geral, o modelo LSTM com MCD atingiu MAPE médio de 8,2 %, valor realista e compatível com as medições empíricas.

Por fim, pode-se concluir que as métricas do modelo final, disponível na Tabela 24, são satisfatórias para uso, desde que sejam respeitadas as limitações do estudo.

6.1 LIMITAÇÕES DO ESTUDO

Entre as limitações, destacam-se:

- **Diversidade pequena de veículos utilizados:** Devido à disponibilidade de material, neste estudo foram utilizados apenas dois veículos de fabricantes diferentes, uma quantidade não satisfatória

tanto para a capacidade de generalização dos modelos quanto para uma validação abrangente da metodologia.

- **Não utilização de veículos elétricos:** Veículos elétricos não foram utilizados nesse estudo devido a não padronização dos parâmetros coletados via OBD nesses veículos.
- **Quantidade de amostras coletadas:** A quantidade utilizada de amostras talvez não seja suficiente para uma boa capacidade de generalização do modelo, que pode não ser representativa de todas as condições de operação.
- **Instrumento adequado de medição:** Foram realizadas apenas medições feitas com auxílio das centrais eletrônicas, através da entrada OBD do veículo, não havendo uso de instrumento adequado no escapamento do veículo para as medições.

6.2 TRABALHOS FUTUROS

Para trabalhos futuros, recomenda-se:

- **Expansão da base de dados de veículos:** A inclusão de diferentes fabricantes e modelos de carros se faz é necessária, tendo em vista que a amostra utilizada neste estudo foi limitada a dois veículos.
- **Expansão da base de dados de cenários e motoristas:** Há necessidade de coleta de dados de diferentes perfis de condução bem como perfis de motoristas, para melhor generalização dos modelos.
- **Uso de Instrumento de Medição de CO₂:** Como mencionado, o estudo fez uso apenas da entrada OBD para medição de parâmetros. Recomenda-se o uso de instrumentos adequados para medição de CO₂ e outros poluentes, para poder ter uma comparação direta entre os dados coletados e os dados medidos.
- **Melhoria no sistema de coleta de dados:** O sistema para coleta de dados usado foi manual, fazendo uso do aplicativo *Torque Pro*. Recomenda-se uso de um sistema automatizado, com coleta de dados em tempo real, para possível implementação de sistema de monitoramento em tempo real.
- **Utilização de Veículos Híbridos, Elétricos e Flex:** Neste estudo foram utilizados apenas veículos a combustão. Em trabalhos futuros, pretende-se incluir veículos híbridos, elétricos e do tipo flex (bicombustíveis) para possibilitar uma comparação mais abrangente do consumo energético e das emissões entre diferentes tecnologias de propulsão. Em particular, para veículos elétricos (que não emitem poluentes) é possível utilizar comparar os poluentes indiretos gerados na produção da energia elétrica consumida, além da matriz energética do local onde a energia elétrica está sendo consumida para avaliar a pegada de carbono associada.

REFERÊNCIAS

ALARAB, I.; PRAKONWIT, S.; NACER, M. I. Illustrative discussion of mc-dropout in general dataset: Uncertainty estimation in bitcoin. *Neural Processing Letters*, v. 53, n. 2, p. 1001–1011, 2021. Disponível em: <<https://doi.org/10.1007/s11063-021-10424-x>>. Citado na página 43.

ANFAVEA. *Estatísticas de Produção de Veículos Nacionais - Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA)*. 2025. <<https://anfavea.com.br/site/edicoes-em-excel/>>. Dados estatísticos de produção de veículos montados, licenciamento e exportações; séries históricas desde 1957. Disponível em: <<https://anfavea.com.br/site/edicoes-em-excel/>>. Citado 2 vezes nas páginas 6 e 23.

ASLAM, B. et al. Malaysia's economic growth, consumption of oil, industry and co2 emissions: evidence from the ardl model. *International Journal of Environmental Science and Technology*, v. 19, p. 3189–3200, 2022. Disponível em: <<https://doi.org/10.1007/s13762-021-03279-1>>. Citado na página 28.

BARBOSA, G. et al. Segurança em redes 5g: Oportunidades e desafios em detecção de anomalias e previsão de tráfego baseadas em aprendizado de máquina. In: *Livro sem título especificado*. S.l.: s.n., 2021. p. 145–189. ISBN 9786587003658. Citado 2 vezes nas páginas 6 e 41.

BENTO, C. A. C.; VINHA, V.; PRIETO, V. C. *Stakeholders influence in the innovation process of the automotive industry: An exploratory case study*. 2015. 816-826 p. Citado na página 26.

CHEN, K. et al. Short-term load forecasting with deep residual networks. *IEEE Transactions on Smart Grid*, v. 10, n. 4, p. 3943–3952, 2018. Disponível em: <<https://doi.org/10.1109/TSG.2018.2844307>>. Citado na página 43.

CHEN, Z.; YE, X.; HUANG, P. Estimating carbon dioxide (co2) emissions from reservoirs using artificial neural networks. *Water*, v. 10, n. 1, 2018. ISSN 2073-4441. Disponível em: <<https://www.mdpi.com/2073-4441/10/1/26>>. Citado na página 39.

CHOMA, E. F. et al. Health benefits of decreases in on-road transportation emissions in the united states from 2008 to 2017. *Proceedings of the National Academy of Sciences (PNAS)*, v. 118, n. 51, 2021. Citado na página 13.

CS Selectronics. *OBD-II Explained: Simple Introduction*. 2024. Accessed: 2024-11-21. Disponível em: <<https://www.csselectronics.com/pages/obd2-explained-simple-intro>>. Citado 2 vezes nas páginas 6 e 36.

Elm Electronics Inc. *ELM327: OBD to RS232 Interpreter*. [S.l.], 2017. Datasheet. Disponível em: <<https://www.elmelectronics.com/wp-content/uploads/2017/01/ELM327DS.pdf>>. Citado 2 vezes nas páginas 6 e 45.

Energy Institute. *Statistical Review of World Energy: Resources and Data Downloads*. 2024. Acesso em: 20 de dezembro de 2024. Disponível em: <<https://www.energyinst.org/statistical-review/resources-and-data-downloads>>. Citado 2 vezes nas páginas 29 e 31.

ENSSLEN, A. et al. Empirical carbon dioxide emissions of electric vehicles in a french-german commuter fleet test. *Journal of Cleaner Production*, v. 142, p. 263–278, 2017. ISSN 0959-6526. Cleaner production towards a sustainable transition. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959652616307648>>. Citado 2 vezes nas páginas 18 e 20.

FARID, A. M. et al. Smart city drivers and challenges in urban-mobility, health-care, and interdependent infrastructure systems. *arXiv preprint arXiv:2212.00730*, 2022. Disponível em: <<https://arxiv.org/abs/2212.00730>>. Citado na página 13.

FLECK, L. et al. Redes neurais artificiais: princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016. Acesso em: 6 maio 2025. Disponível em: <<https://periodicos.utfpr.edu.br/recit/article/view/4330>>. Citado 2 vezes nas páginas 6 e 40.

- GOUVEIA, N.; JUNGER, W. L. Impactos da poluição atmosférica urbana sobre a saúde humana. *Cadernos de Saúde Pública*, v. 34, n. 4, p. e00108018, 2018. Citado na página 14.
- HAWKINS, I. *Torque Pro (OBD 2 & Car) - Apps on Google Play*. 2025. Página oficial no Google Play (inclui screenshots). Atualizado em 3 fev. 2025. Disponível em: <<https://play.google.com/store/apps/details?id=org.prowl.torque>>. Citado 2 vezes nas páginas 6 e 46.
- HILL, N. et al. *Guidelines to DEFRA/DECC's GHG Conversion Factors for Company Reporting: Methodology Paper for Emission Factors*. UK, 2012. Citado 2 vezes nas páginas 8 e 29.
- HU, Y. et al. An enhanced particle swarm optimization long short-term memory network hybrid model for predicting residential daily co2 emissions. *Sustainability*, v. 16, n. 20, 2024. ISSN 2071-1050. Disponível em: <<https://www.mdpi.com/2071-1050/16/20/8790>>. Citado na página 41.
- HUANG, P.-Y. et al. Efficient uncertainty estimation for semantic segmentation in videos. In: *Computer Vision – ECCV 2018*. Springer, 2018. p. 536–552. Disponível em: <https://doi.org/10.1007/978-3-030-01246-5_32>. Citado na página 43.
- IBGE. *Anuário Estatístico do Brasil 2023*. 2023. <<https://anuario.ibge.gov.br/2023/servicos/transportes/aeb-2023-tabelas-transportes/22241-frota-nacional-de-veiculos.html>>. Citado na página 13.
- IEEP. *Annex 5: Subsidy level indicators for the case studies*. 2010. Disponível em: <<https://wayback.archive-it.org/12090/20230311050638/https://ec.europa.eu/environment/enveco/taxation/pdf/Annex%205%20-%20Calculations%20from%20the%20case%20studies.pdf>>. Citado 2 vezes nas páginas 8 e 29.
- INMETRO. *Avaliação de dados de medição — Guia para a expressão de incerteza de medição*. 2008. <<https://www.gov.br/ana/pt-br/assuntos/saneamento-basico/novo-marco-legal-do-saneamento>>. Acesso em: 6 maio 2025. Citado na página 42.
- INNOVATEMOTORS. *Digital air/fuel ratio (lambda) meter*. 2014. Citado 2 vezes nas páginas 8 e 29.
- International Energy Agency. *Energy System - Transport*. 2024. Acesso em: 29 out. 2024. Disponível em: <<https://www.iea.org/energy-system/transport>>. Citado na página 13.
- International Energy Agency. *Global EV Data Explorer*. 2024. <<https://www.iea.org/data-and-statistics/data-tools/global-ev-data-explorer>>. Acesso em: abr. 2025. Citado 2 vezes nas páginas 6 e 24.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *Road Vehicles—Interchange of digital information—Controller area network (CAN) for high-speed communications*. [S.l.], 2003. Disponível em: <<https://www.iso.org/standard/33422.html>>. Acesso em: 12 nov. 2025. Citado na página 35.
- ISLAM, M. S. *Factors Influencing Carbon Dioxide Emissions in South Asian Economies: An Econometric Analysis*. 2020. Available at SSRN: <https://ssrn.com/abstract=3732536> or <http://dx.doi.org/10.2139/ssrn.3732536>. Citado na página 28.
- JUNGER, W. L.; LEON, A. P. S. Air pollution and health in brazil: from evidence to public policies. *Science of the Total Environment*, v. 660, p. 1395–1401, 2019. Citado na página 14.
- LADINO-MORENO, E. O.; GARCÍA-UBAQUE, C. A. Leak detection in urban hydraulic systems using the k-bilstm-monte carlo dropout model. *Civil Engineering Journal*, v. 10, n. 7, p. 2066–2087, 2024. Disponível em: <<https://doi.org/10.28991/cej-2024-010-07-01>>. Citado na página 43.
- LI, Y.; SUN, Y. Modeling and predicting city-level co2 emissions using open access data and machine learning. *Environmental Science and Pollution Research*, v. 28, n. 15, p. 19260–19271, 2021. ISSN 1614-7499. Disponível em: <<https://doi.org/10.1007/s11356-020-12294-7>>. Citado na página 39.
- LIEUTENANT, K. et al. Comparison of “zero emission” vehicles with petrol and hybrid cars in terms of total co2 release—a case study for romania, poland, norway and germany. *Energies*, MDPI AG, v. 15, n. 21, p. 7988, 2022. Citado na página 13.
- LIMA, J. *Construção de sensor virtual para medição de vazão em uma usina do setor sucroenergético baseado em redes neurais artificiais*. Dissertação (Dissertação de Mestrado) — Universidade Federal da Paraíba, 2022. Citado 2 vezes nas páginas 6 e 42.

- LIU, G. et al. Data-driven carbon footprint management of electric vehicles and emission abatement in electricity networks. *IEEE Transactions on Sustainable Energy*, v. 15, n. 1, p. 95–108, 2024. Citado na página 29.
- LOGAN, K.; NELSON, J.; HASTINGS, A. Low emission vehicle integration: Will national grid electricity generation mix meet uk net zero? *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, SAGE Publications, v. 236, n. 1, p. 159–175, 2022. Citado na página 29.
- LU, W.-C. Greenhouse gas emissions, energy consumption and economic growth: A panel cointegration analysis for 16 asian countries. *International Journal of Environmental Research and Public Health*, v. 14, n. 11, 2017. ISSN 1660-4601. Disponível em: <<https://www.mdpi.com/1660-4601/14/11/1436>>. Citado na página 29.
- MALDONADO, B. et al. Prediction model for pollutants with onboard diagnostic sensors in vehicles. *International Journal of Machine Learning and Networked Collaborative Engineering*, v. 2, n. 2, p. 49–57, 2018. ISSN 2581-3242. Disponível em: <<https://par.nsf.gov/servlets/purl/10092109>>. Citado na página 25.
- MEHRMOHAMMADI, P.; GHAEMI, A. Investigating the effect of textural properties on co2 adsorption in porous carbons via deep neural networks using various training algorithms. *Scientific Reports*, v. 13, n. 1, p. 21264, 2023. ISSN 2045-2322. Disponível em: <<https://doi.org/10.1038/s41598-023-48683-4>>. Citado na página 39.
- MENGI, O. O. Conversion of diesel vehicles to electric vehicles and controlled by pid controller. *Celal Bayar University Journal of Science*, v. 13, n. 4, p. 901–906, 2017. Citado na página 37.
- MÄRTZ, A.; PLÖTZ, P.; JOCHEM, P. Global perspective on co2 emissions of electric vehicles. *Environmental Research Letters*, IOP Publishing, v. 16, n. 5, p. 054043, jun 2021. Disponível em: <<https://dx.doi.org/10.1088/1748-9326/abf8e1>>. Citado na página 29.
- NATARAJAN, Y. et al. Forecasting carbon dioxide emissions of light-duty vehicles with different machine learning algorithms. *Electronics*, v. 12, n. 10, 2023. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/12/10/2288>>. Citado na página 39.
- NETO, M. S.; PIRES, S. R. I. An analysis of the automaker-systemist supplier relationship in an automotive industrial condominium. In: CHIABERGE, M. (Ed.). *New Trends and Developments in Automotive Industry*. Rijeka: IntechOpen, 2011. cap. 7. Disponível em: <<https://doi.org/10.5772/13485>>. Citado 2 vezes nas páginas 22 e 23.
- NTZIACHRISTOS, L. et al. In-use vs. type-approval fuel consumption of current passenger cars in europe. *Energy Policy*, v. 67, p. 403–411, 2014. ISSN 0301-4215. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0301421513012573>>. Citado 2 vezes nas páginas 17 e 20.
- Organisation Internationale des Constructeurs d’Automobiles. *Produção Automotiva Mundial*. 2024. Acesso em abril de 2025. Disponível em: <<https://www.oica.net/>>. Citado 3 vezes nas páginas 6, 21 e 22.
- PRATI, M. V. et al. Emissions and energy consumption of a plug-in hybrid passenger car in real driving emission (rde) test. *Transportation Engineering*, v. 4, p. 100069, 2021. ISSN 2666-691X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666691X21000257>>. Citado 3 vezes nas páginas 17, 18 e 20.
- QIAO, Q. et al. An interpretable multi-stage forecasting framework for energy consumption and co2 emissions for the transportation sector. *Energy*, v. 286, p. 129499, 2024. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544223028931>>. Citado na página 39.
- QIAO, Q.; ZHAO, F.; LIU, Z. Comparative study on life cycle co2 emissions from the production of electric and conventional vehicles in china. *Energy Procedia*, v. 105, p. 3584–3595, 2017. Citado na página 31.
- RAMAI, C. et al. Framework for building low-cost obd-ii data-logging systems for battery electric vehicles. *Vehicles*, v. 4, n. 4, p. 1209–1222, 2022. ISSN 2624-8921. Disponível em: <<https://www.mdpi.com/2624-8921/4/4/64>>. Citado na página 37.

- RUOSO, A. C.; RIBEIRO, J. L. D. An assessment of barriers and solutions for the deployment of electric vehicles in the brazilian market. *Transport Policy*, 2022. Disponível em: <<https://doi.org/10.1016/j.tranpol.2022.09.004>>. Citado na pagina 24.
- SAE International. *On Board Diagnostics Implementation Guide*. [S.l.], 2017. Available: <<https://discovery.researcher.life/article/on-board-diagnostics-implementation-guide/54e783a1033e380d8c95c400754260ff>>. Disponível em: <<https://discovery.researcher.life/article/on-board-diagnostics-implementation-guide/54e783a1033e380d8c95c400754260ff>>. Citado na pagina 36.
- SAIBANNAVAR, D.; MATH, M. M.; KULKARNI, U. A survey on on-board diagnostic in vehicles. In: RAJ, J. S. (Ed.). *International Conference on Mobile Computing and Sustainable Informatics*. Cham: Springer International Publishing, 2021. p. 49–60. ISBN 978-3-030-49795-8. Citado na pagina 37.
- SANGUESA, J. A. et al. A review on electric vehicles: Technologies and challenges. *Smart Cities*, v. 4, n. 1, p. 372–404, 2021. Disponível em: <<https://www.mdpi.com/2624-6511/4/1/22>>. Citado na pagina 13.
- SRDIC, S.; LUKIC, S. *Electric vehicle charging infrastructure and dc microgrids*. IET Digital Library, 2018. Disponível em: <https://doi.org/10.1049/pbpo115e_ch8>. Citado na pagina 23.
- STASINOPOULOS N. SHIWAKOTI, S. M. P. Future scenarios of greenhouse gas emissions from electric and conventional vehicles in australia. *null*, 2016. Citado na pagina 13.
- STRANDGREN, J. et al. Towards spaceborne monitoring of localized CO₂ emissions: an instrument concept and first performance assessment. *Atmospheric Measurement Techniques*, v. 13, n. 6, p. 2887–2904, 2020. Disponível em: <<https://amt.copernicus.org/articles/13/2887/2020/>>. Citado 2 vezes nas páginas 18 e 20.
- TEO, Y. X. et al. Forensic analysis of automotive *Controller Area Network* emissions for problem resolution. p. 619–623, 2021. Citado na pagina 35.
- TESTA, J. F. A poluição atmosférica por veículos automotores na região metropolitana de são paulo: causas e impactos. *Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental*, v. 19, n. 2, p. 1209–1221, 2015. ISSN 2236-1170. Disponível em: <<https://periodicos.ufsm.br/reget/article/download/16944/pdf/87521>>. Citado na pagina 25.
- TSENG, C.-M. et al. Data extraction from electric vehicles through obd and application of carbon footprint evaluation. In: *Proceedings of the Workshop on Electric Vehicle Systems, Data, and Applications*. New York, NY, USA: Association for Computing Machinery, 2016. (EV-SYS '16). ISBN 9781450344203. Disponível em: <<https://doi.org/10.1145/2939953.2939954>>. Citado na pagina 37.
- ULUSSEVER, T. et al. Estimation performance comparison of machine learning approaches and time series econometric models: evidence from the effect of sector-based energy consumption on co₂ emissions in the usa. *Environmental Science and Pollution Research*, Springer, v. 30, p. 52576–52592, 2023. Disponível em: <<https://link.springer.com/article/10.1007/s11356-023-26050-0>>. Citado na pagina 39.
- U.S. Department of Energy. *Sustainable Transportation and Fuels*. 2024. Acesso em: 29 out. 2024. Disponível em: <<https://www.energy.gov/eere/sustainable-transportation-and-fuels>>. Citado na pagina 13.
- WAGNER, M.; SCHILDT, S.; POEHLN, M. Service-oriented communication for controller area networks. p. 1–5, 2016. Citado na pagina 34.
- WALLINGTON, T. J. et al. Vehicle emissions and urban air quality: 60 years of progress. *Atmosphere*, v. 13, n. 5, 2022. ISSN 2073-4433. Disponível em: <<https://www.mdpi.com/2073-4433/13/5/650>>. Citado na pagina 28.
- WINKLER, S. L. et al. Vehicle criteria pollutant (pm, nox, co, hcs) emissions: how low should we go? *npj Climate and Atmospheric Science*, v. 1, n. 1, p. 26, 2018. ISSN 2397-3722. Disponível em: <<https://doi.org/10.1038/s41612-018-0037-5>>. Citado na pagina 28.
- World Health Organization. *Ambient Air Pollution: A Global Assessment of Exposure and Burden of Disease*. [S.l.], 2018. Disponível em: <<https://apps.who.int/iris/handle/10665/272389>>. Citado na pagina 14.

- WRIGHT, R. et al. Robot perception for semantic scene understanding: A survey. *PeerJ Computer Science*, PeerJ Inc., v. 10, p. e2234, 2024. Disponível em: <<https://peerj.com/articles/cs-2234/>>. Citado na pagina 39.
- WU, Y. et al. Evaluating vehicular exhaust and evaporative emissions via voc measurement in an underground parking garage. *Environmental Pollution*, v. 333, p. 122022, 2023. ISSN 0269-7491. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0269749123010242>>. Citado 3 vezes nas páginas 6, 24 e 25.
- YAMAMURA, C. L. K. et al. Electric cars in brazil: An analysis of core green technologies and the transition process. *Sustainability*, 2022. Disponível em: <<https://www.mdpi.com/2071-1050/14/10/6064>>. Citado na pagina 24.
- ZHANG, H. et al. Can-ft: A fuzz testing method for automotive *Controller Area Network* bus. p. 225–231, 2021. Citado na pagina 34.
- ZHANG, Q. et al. Vehicle emission forecasting based on wavelet transform and long short-term memory network. *IEEE Access*, v. 6, p. 56984–56994, 2018. Citado na pagina 41.
- ZIÓŁKOWSKI, J. et al. Use of artificial neural networks to predict fuel consumption on the basis of technical parameters of vehicles. *Energies*, MDPI, v. 14, n. 9, p. 2639, 2021. Disponível em: <<https://www.mdpi.com/1996-1073/14/9/2639>>. Citado 2 vezes nas páginas 18 e 20.