


UNIVERSIDADE FEDERAL DO PARANÁ

ADRIANO CARDON CASTRO

CÁLCULO DE AUTONOMIA PARA VEÍCULOS ELÉTRICOS UTILIZANDO  
MODELO DE PREVISÃO COM LÓGICA NEBULOSA



CURITIBA

2024

ADRIANO CARDON CASTRO

CÁLCULO DE AUTONOMIA PARA VEÍCULOS ELÉTRICOS UTILIZANDO  
MODELO DE PREVISÃO COM LÓGICA NEBULOSA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Sistemas de Energia, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Alexandre Rasi Aoki

CURITIBA

2024

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)  
UNIVERSIDADE FEDERAL DO PARANÁ  
SISTEMA DE BIBLIOTECAS – BIBLIOTECA CIÊNCIA E TECNOLOGIA

Castro, Adriano Cardon

Cálculo de autonomia para veículos elétricos utilizando modelo de previsão com lógica nebulosa. / Adriano Cardon Castro. – Curitiba, 2024.

1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica.

Orientador: Prof. Dr. Alexandre Rasi Aoki

1. Veículos elétricos. 2. Lógica Nebulosa. 3. Autonomia. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Engenharia Elétrica. III. Aoki, Alexandre Rasi. IV. Título.

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE TECNOLOGIA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
ELÉTRICA - 40001016043P4

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **ADRIANO CARDON CASTRO** intitulada: **Cálculo de autonomia para veículos elétricos utilizando modelo de previsão com lógica nebulosa**, sob orientação do Prof. Dr. ALEXANDRE RASI AOKI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 09 de Agosto de 2024.

Assinatura Eletrônica  
13/08/2024 19:38:29.0  
ALEXANDRE RASI AOKI  
Presidente da Banca Examinadora

Assinatura Eletrônica  
20/08/2024 17:14:31.0  
EDGAR BARASSA  
Avaliador Externo (BARASSA & CRUZ CONSULTING)

Assinatura Eletrônica  
14/08/2024 08:31:04.0  
ANDRÉ AUGUSTO MARIANO  
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica  
14/08/2024 12:45:23.0  
LUIS HENRIQUE ASSUMPTÃO LOLIS  
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Av. Cel. Francisco H. dos Santos, 210, Bairro Jardim das Américas, Bloco PK/PL - DELT, Setor Tecnologia, Campus Centro Politécnico - Curitiba - Paraná - Brasil  
CEP 81530-000 - Tel: (41) 3361-3622 - E-mail: [ppgee@ufpr.br](mailto:ppgee@ufpr.br)

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.  
Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 389621

**Para autenticar este documento/assinatura, acesse <https://siga.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp> e insira o código 389621**

“All processes that are stable we shall predict. All  
processes that are unstable we shall control.”

János Neumann

“I never lose. I either win or learn.”

Nelson Mandela

## **AGRADECIMENTOS**

À minha esposa Adriana e ao meu filho Gianluca pela paciência em ouvir minhas preocupações e me ajudar nos momentos difíceis. Temos um lar com harmonia que me permite estudar e avançar nos conhecimentos.

Aos meus pais, Ana Maria e Aldo, pelo amor, auxílio e palavras de incentivo ao longo de toda minha carreira.

Ao Prof. Dr. Alexandre Rasi Aoki pelos ricos debates e diversos encontros durante este projeto, além da paciência para uma orientação primorosa.

Aos colegas da Renault do Brasil e França por me permitir executar os ensaios, dialogar sobre as dúvidas e obter os esclarecimentos. Muito obrigado Xavier Mathevet pelo ensinamento durante este projeto.

Ao amigo Zeno Nadal, um precursor na mobilidade elétrica no Brasil, sempre disponível para trocar as experiências dos usuários e compartilhar o conhecimento profundo da infraestrutura de recarga.

## RESUMO

Uma das alternativas para a redução da emissão global dos gases de efeito estufa consiste na adoção de veículos elétricos à bateria. No entanto, existem características técnicas e econômicas do veículo e da infraestrutura que limitam a velocidade de adoção pelos usuários finais como a autonomia máxima alcançável e o tempo de carregamento da bateria. Ciclos homologados são usados pela indústria automobilística para estabelecer o consumo energético e autonomia dos veículos, mas devido às influências de condução e fatores externos estes valores são dificilmente obtidos em condições reais. Desta maneira modelos matemáticos são desenvolvidos para simular a previsão de alcance considerando o comportamento do condutor, meio ambiente, o que demanda uma integração complexa e validação prolongada. Para orientar o usuário no planejamento e uso do veículo em uso cotidiano, empresas de mobilidade disponibilizam aplicativos que a partir do modelo do veículo e dados externos atualizados (tráfego, condições meteorológicas) calculam os percursos, autonomia e carregamentos necessários para concluir o trajeto. Este trabalho propõe um método baseado em lógica nebulosa para calcular a autonomia e estado de carga da bateria SOC no destino. O método desenvolvido faz a determinação dos parâmetros dos conjuntos nebulosos a cada amostra do trajeto realizado, considerando as características específicas. Isso permite analisar o comportamento do modelo Fuzzy e adequá-lo corretamente. Ao final, os dados obtidos são comparados com as informações oriundas do veículo testado e com os aplicativos comerciais. Os resultados são coerentes com o objetivo do projeto proposto e fundamentais para entender a complexidade do assunto.

Palavras-chave: Lógica Nebulosa. Veículo elétrico. Planejamento de Rota. Autonomia.



## **ABSTRACT**

One of the alternatives for reducing global greenhouse gas emissions is the adoption of battery-powered electric vehicles. However, there are technical and economic characteristics of the vehicle and infrastructure that limit the speed of adoption by end users, such as the maximum achievable range and battery charging time. Homologated cycles are used by the automotive industry to establish the energy consumption and range of vehicles, but due to the influences of driving and external factors, these values are difficult to obtain in real conditions. Thus, mathematical models are developed to simulate the range prediction considering the driver's behavior and the environment, which requires complex integration and prolonged validation. To guide the user in planning and using the vehicle in daily use, mobility companies provide applications that, based on the vehicle model and updated external data (traffic, weather conditions), calculate the routes, range and charges necessary to complete the journey. This work proposes a method based on fuzzy logic to calculate the range and state of charge of the SOC battery at the destination. The developed method determines the parameters of the fuzzy sets for each segment of the journey, considering the specific characteristics. This allows the behavior of the Fuzzy model to be analyzed and adapted correctly. Finally, the data obtained is compared with the information from the tested vehicle and with commercial applications. The results are consistent with the objective of the proposed project and fundamental to understanding the complexity of the subject.

Keywords: Fuzzy Logic. Electric Vehicle. Route Planning. Range.



## LISTA DE ILUSTRAÇÕES

FIGURA 1: EMISSÕES DE CO <sub>2</sub> NOS PRINCIPAIS PAÍSES DE 1970 A 2021, EM Gt CO <sub>2</sub> .....	17
FIGURA 2: FONTE DE EMISSÕES DE CO <sub>2</sub> NA CHINA, POR ATIVIDADE, Mt CO <sub>2</sub> .....	17
FIGURA 3: PREVISÃO DE VENDAS DE VEÍCULOS ELÉTRICOS (BEV E PHEV).....	24
FIGURA 4: PREVISÃO DE VENDAS DE VEÍCULOS ELÉTRICOS (BEV E PHEV) POR MERCADO	25
FIGURA 5: CENTRO DE RECARGA PARA VEÍCULOS ELÉTRICOS, COM DUAS ESTAÇÕES DE RECARGA E QUATRO PONTOS DE RECARGA.....	26
FIGURA 6: DISTRIBUIÇÃO DE ELETROPOSTOS.....	30
FIGURA 7: AUTONOMIAS CICLO URBANO E ESTRADA E RELAÇÃO DE AUTONOMIA.....	34
FIGURA 8: CURVAS REAIS E PROJETADAS DE CARREAMENTO EM CC EM FUNÇÃO DO ESTADO DE CARGA DA BATERIA SOC .....	36
FIGURA 9: CURVAS REAIS E PROJETADAS DE CARREGAMENTO EM CC EM FUNÇÃO DO ESTADO DE CARGA DA BATERIA SOC PARA CARREGADORES TESLA V3.....	37
FIGURA 10: FAIXAS DE TEMPERATURA DE FUNCIONAMENTO DA BATERIA .....	38
FIGURA 11: CONSUMO DE ENERGIA EM FUNÇÃO DA DIFERENÇA DE TEMPERATURAS INTERNAS T <sub>i</sub> E EXTERNAS T <sub>o</sub> , PERÍODO DIURNO .....	39
FIGURA 12: CONSUMO DE ENERGIA EM FUNÇÃO DA DIFERENÇA DE INTERNAS T <sub>i</sub> E EXTERNAS T <sub>o</sub> , PERÍODO NOTURNO .....	40
FIGURA 13: CONSUMO DE ENERGIA EM MODO AQUECIMENTO EM CICLO URBANO .....	41
FIGURA 14: CONSUMO DE ENERGIA EM MODO RESFRIAMENTO EM CICLO URBANO .....	41
FIGURA 15: INTENSIDADE DE ENERGIA E REDUÇÃO DA AUTONOMIA EM FUNÇÃO DA TEMPERATURA INICIAL DA JORNADA .....	42
FIGURA 16: DISTRIBUIÇÃO DO NÚMERO DE SEGMENTOS EM FUNÇÃO DO EDI (ECO-DRIVING INDICATOR) E UTILIZAÇÃO DE ECO-DRIVE.....	44
FIGURA 17: VISÃO GERAL DA ARQUITETURA DO SISTEMA .....	45
FIGURA 18: ARQUITETURA DO SISTEMA PARA VALIDAÇÃO .....	45
FIGURA 19: ESTIMATIVAS DE ROTA A PARTIR DE LISBOA .....	46
FIGURA 20: POTÊNCIA E INCLINAÇÃO EM USO URBANO E ESTRADA .....	47
FIGURA 21: DISTRIBUIÇÃO DE AUTONOMIAS PARA TESLA MODEL 3 LR.....	50
FIGURA 22: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR .....	51

FIGURA 23: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM TEMPERATURA EXTERNA ENTRE 20°C E 30°C.....	51
FIGURA 24: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM CONDIÇÕES DE TEMPERATURA E VELOCIDADE LIMITADAS .....	52
FIGURA 25: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM TEMPERATURAS BAIXAS.....	53
FIGURA 26: DEGRADAÇÃO DA BATERIA EM FUNÇÃO DA QUILOMETRAGEM ACUMULADA ....	53
FIGURA 27: CATEGORIAS DE MODELOS PARA ESTIMATIVA DE CONSUMO.....	54
FIGURA 28: OPÇÕES DE COMBINAÇÕES PARA DETERMINAR A AUTONOMIA.....	56
FIGURA 29: AUTONOMIA EM FUNÇÃO DA VELOCIDADE E DA TEMPERATURA EXTERNA .....	56
FIGURA 30: EXEMPLO DO APLICATIVO ABRP .....	58
FIGURA 31: EXEMPLO DO APLICATIVO PLUGSHARE .....	59
FIGURA 32: EXEMPLO DO APLICATIVO GOOGLE MAPS.....	59
FIGURA 33: EXEMPLO DO APLICATIVO TUPINAMBÁ.....	60
FIGURA 34 : MODELO DE FORÇAS EM UM VEÍCULO .....	62
FIGURA 35: ESQUEMA SIMPLIFICADO DE UM VEÍCULO ELÉTRICO.....	66
FIGURA 36: FATORES DE CÁLCULO NA AUTONOMIA.....	66
FIGURA 37: MODELO CONCEITUAL PARA CLASSIFICADOR COM LÓGICA FUZZY PARA ESTIMATIVA DE AUTONOMIA .....	67
FIGURA 38: ESQUEMÁTICO DO FATOR $F_{cons1}$ .....	69
FIGURA 39: FATOR DE ENVELHECIMENTO DA BATERIA .....	70
FIGURA 40: FATOR DE INTENSIDADE DE VENTO .....	71
FIGURA 41: FATOR DE INCLINAÇÃO DE ROTA .....	73
FIGURA 42: FATOR DE INTENSIDADE DE TRÁFEGO.....	74
FIGURA 43: FATOR DE CONDUÇÃO .....	75
FIGURA 44: FATOR DE AR-CONDICIONADO.....	76
FIGURA 45: FATOR DE CONSUMO 1.....	77
FIGURA 46 : FATOR DE VELOCIDADE .....	78
FIGURA 47 : FATOR DE CONSUMO DE VELOCIDADE .....	79
FIGURA 48: TRAJETO PLANEJADO CURITIBA A JOINVILLE .....	80
FIGURA 49: ALTIMETRIA TRAJETO PLANEJADO CURITIBA A JOINVILLE .....	80
FIGURA 50: TRAJETO PERCORRIDO CURITIBA A JOINVILLE .....	83

FIGURA 51: ALTIMETRIA DO PERCURSO.....	84
FIGURA 52: COMPOSIÇÃO DE AMOSTRA POR SEGMENTOS .....	84
FIGURA 53: 10 SEGMENTOS POR AMOSTRA.....	85
FIGURA 54: 25 SEGMENTOS POR AMOSTRA.....	86
FIGURA 55: 100 SEGMENTOS POR AMOSTRA.....	86
FIGURA 56: 300 SEGMENTOS POR AMOSTRA .....	87
FIGURA 57: VELOCIDADE MÉDIA NOS SEGMENTOS PARA 25 SEGMENTOS POR AMOSTRA	87
FIGURA 58: FATOR DE CONSUMO $F_{cons1}$ .....	88
FIGURA 59: FATOR DE CONSUMO $F_{cons2}$ .....	89
FIGURA 60: FATOR DE CONSUMO $F_{cons}$ .....	90
FIGURA 61: AUTONOMIA EM FUNÇÃO DA DISTÂNCIA PERCORRIDA.....	91
FIGURA 62: AUTONOMIA EM FUNÇÃO DA AMOSTRA COLETADA.....	91
FIGURA 63 : AUTONOMIA NO TRECHO DELIMITADO .....	92
FIGURA 64: ERRO RELATIVO DE ESTIMAÇÃO MODIFICADO .....	92
FIGURA 65 : ALTIMETRIA TRECHO CURITIBA (PR) À SERRA DO RELOGIO (PR).....	95
FIGURA 66 : ALTIMETRIA TRECHO SÃO JOSÉ DOS PINHAIS (PR) A REGISTRO (SP).....	95
FIGURA 67 : ALTIMETRIA TRECHO REGISTRO (SP) A SÃO PAULO (SP).....	96
FIGURA 68 : FAIXAS DE OPERAÇÃO DE SOC.....	99

## LISTA DE TABELAS

TABELA 1: CLASSIFICAÇÃO DE POTÊNCIA DOS ELETROPOSTOS .....	27
TABELA 2: DISTRIBUIÇÃO DE ELETROPOSTOS (EP) NA ALEMANHA, HOLANDA E FRANÇA ...	28
TABELA 3: AUTONOMIA E CONSUMO DE VEÍCULOS ELÉTRICOS .....	32
TABELA 4: AUTONOMIA E CONSUMO DE VEÍCULOS ELÉTRICOS .....	33
TABELA 5: DEFINIÇÃO DE PALAVRAS-CHAVE .....	35
TABELA 6: RESULTADO DAS CONSULTAS .....	35
TABELA 7: REVISÃO DA LITERATURA MENCIONADA .....	48
TABELA 8: APLICATIVOS PARA CÁLCULO DE ROTA E PONTOS DE CARREGAMENTO .....	55
TABELA 9: FATOR DE INFLUÊNCIA DOS CONSUMIDORES NA AUTONOMIA .....	57
TABELA 10: FATOR DE INFLUÊNCIA DO MODO ECO NA AUTONOMIA .....	57
TABELA 11: COMPARAÇÃO DOS APLICATIVOS .....	61
TABELA 12: CARACTERÍSTICAS DO VEÍCULO ELÉTRICO .....	79
TABELA 13: RESULTADOS DO TRAJETO PERCORRIDO .....	82
TABELA 14: DADOS RELATIVOS À ALTITUDE .....	83
TABELA 15: RESULTADO DO MODELO EM LÓGICA NEBULOSA .....	93
TABELA 16: RESULTADO DE ROTEIROS COMPLEMENTARES .....	94
TABELA 17 : SUMÁRIO DE ERROS RELATIVOS .....	96

## LISTA DE ABREVIações

ANEEL	Agência Nacional de Energia Elétrica
CA	Corrente Alternada
CC	Corrente Contínua
CO <sub>2</sub>	Dióxido de carbono
EPA	Agência de Proteção Ambiental dos Estados Unidos da América
EV	Veículo Elétrico
HEV	Veículo Híbrido
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais.
ICE	Motor de combustão interna
kW	kilowatt
kWh	kilowatt-hora
PBEV	Programa Brasileiro de Etiquetagem Veicular
PHEV	Veículo Elétrico Híbrido Plug-in
SAE	Sociedade dos Engenheiros Automotivos
SOC	Estado de Carga
TTW	Tanque-à-Roda
WLTP	Procedimento de teste harmonizado para veículos leves

## GLOSSÁRIO

**Ansiedade de autonomia:** reconhecida como uma das principais preocupações de usuários de veículos elétricos, está relacionada ao medo que a energia contida na bateria não seja suficiente para chegar ao destino planejado ou ao ponto de recarga, causando imobilização temporária.

**Autonomia totalmente elétrico (AER)** significa o total de quilômetros percorridos eletricamente após a bateria ter sido totalmente carregada e, no caso de um veículo elétrico híbrido plug-in, antes de o motor ligar pela primeira vez. A autonomia AER é determinada por procedimentos de teste e é normalmente definido em termos de um alcance específico do ciclo de direção, como autonomia urbana e autonomia em estrada.

**Estado de carga da bateria (SOC)** significa o nível de carga restante na bateria em relação ao nível máximo de carga da bateria expresso em porcentagem.

**Estação de recarga:** Infraestrutura física conectada à rede elétrica que fornece ao eletroposto a energia para carregar um veículo elétrico em corrente alternada (CA) ou corrente contínua (CC). Em função da potência fornecida, elas se classificam em velocidade de recarga lenta (entre 3,7 kW a 7,4 kW), semi-rápida (entre 11 kW a 22 kW), rápidas (entre 30 kW a 100 kW) e ultra-rápidas (acima de 150 kW).

**Frenagem regenerativa:** em momentos de desaceleração do veículo, por exemplo em frenagem, o motor se converte em gerador de energia e esta é absorvida na bateria de tração, aumentando a autonomia do veículo.

**ROTA 2030 e MOVER:** Programas do governo brasileiro de fomento à Pesquisa, Desenvolvimento e Inovação em Mobilidade com o objetivo primário de promover a introdução de novas tecnologias para melhorar a eficiência energética, reduzir a pegada de Carbono e aumentar a localização de manufatura no país.

**Veículo elétrico a bateria (BEV)** significa qualquer veículo que opera exclusivamente por meio de uma bateria ou conjunto de baterias.

**Veículo elétrico híbrido plug-in (PHEV)** significa um veículo elétrico híbrido plug-in (PHEV) que usa o motor durante a operação de esgotamento de carga (por exemplo, para complementar a energia da bateria/motor elétrico).

## SUMÁRIO

1	INTRODUÇÃO .....	16
1.1	CONTEXTO.....	20
1.2	OBJETIVOS .....	21
1.3	JUSTIFICATIVA .....	22
1.4	ESTRUTURA DA MONOGRAFIA .....	22
2	ECOSSISTEMA DE VEÍCULOS ELÉTRICOS .....	24
2.1	MERCADO GLOBAL.....	24
2.2	SISTEMAS DE CARREGAMENTO.....	26
2.3	DISTRIBUIÇÃO DE ELETROPOSTOS.....	28
2.4	CÁLCULO DE AUTONOMIA .....	30
2.4.1	REGULAMENTAÇÃO BRASILEIRA SEGUNDO CICLO SAE J1634:2017 .....	30
2.4.2	VALORES DE AUTONOMIA ANUNCIADOS NO PBEV .....	32
2.4.3	FATORES INFLUENCIADORES NA AUTONOMIA.....	34
2.5	REVISÃO DA LITERATURA .....	35
2.5.1	ANÁLISE DE ARTIGOS .....	36
2.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO .....	47
3	CASO DE APLICAÇÃO .....	49
3.1	FONTES DE DADOS PÚBLICOS PARA VEÍCULOS ELÉTRICOS .....	50
3.2	APLICATIVOS DE SIMULAÇÃO DE AUTONOMIA .....	54
3.2.1	A BETTER ROUTE PLANNER .....	57
3.2.2	PLUGSHARE .....	58
3.2.3	GOOGLE MAPS .....	59
3.2.4	TUPINAMBÁ .....	60
3.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO .....	60
4	MATERIAIS E MÉTODOS .....	62
4.1	DESENVOLVIMENTO DO MODELO DE ENERGIA DE MOVIMENTO .....	62
4.2	MODELAMENTO COMPUTACIONAL .....	65
4.2.1	ENVELHECIMENTO DA BATERIA SOH.....	69
4.2.2	INTENSIDADE DO VENTO .....	70
4.2.3	INCLINAÇÃO DA ROTA .....	71
4.2.4	TRÁFEGO.....	73
4.2.5	CONDUÇÃO .....	74
4.2.6	AR-CONDICIONADO.....	75
4.2.7	FATOR DE CONSUMO 1 .....	76




4.2.8 FATOR DE CONSUMO 2 .....	78
4.3 DESCRIÇÃO DO VEÍCULO TESTADO E PERCURSO REALIZADO .....	79
5 TESTES E RESULTADOS .....	82
5.1 ROTEIRO INICIAL.....	82
5.2 ROTEIROS COMPLEMENTARES .....	94
5.3 DISCUSSÃO DOS RESULTADOS .....	96
6 CONCLUSÃO E TRABALHOS FUTUROS .....	100
REFERÊNCIAS .....	102
ANEXO 1 - TABELA PROGRAMA BRASILEIRO DE ETIQUETAGEM VEICULAR, NOVEMBRO 2023 .....	106
ANEXO 2 – ESCALA DE VENTOS DE BEAUFORT.....	107
ANEXO 3 – CONDIÇÕES METEREOLÓGICAS INICIAIS EM 24/01/24 .....	108

## 1 INTRODUÇÃO

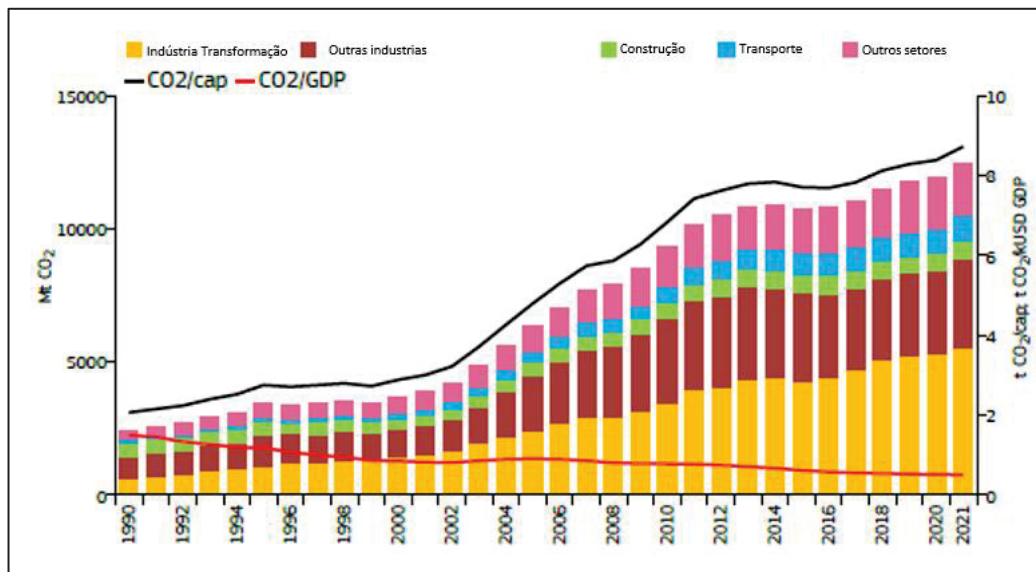
Com um pequeno decréscimo em 2020 devido a redução da atividade econômica causada pela pandemia da COVID-19, as emissões mundiais de dióxido de carbono em 2022 alcançaram 37 Gt, um aumento de 70% em comparação a 2000. A China torna-se o líder isolado com uma participação de 32% (12 Gt) das emissões de CO<sub>2</sub>, os Estados Unidos contam com 12% (4,4 Gt) e a Europa mantém-se em terceiro com 7% (2,6 Gt), como mostrado na FIGURA 1. No caso da China, não obstante os investimentos realizados na introdução de geração de energia renováveis e o aumento das vendas de veículos elétricos, estas ações não foram suficientes para compensar o aumento do consumo de óleo, gás e carvão, como mostrado na FIGURA 2.

Em 2023, a temperatura média global da superfície foi cerca de 1,2 °C acima dos níveis pré-industriais, contribuindo para ondas de calor e outros eventos climáticos extremos. O setor da energia é a principal causa do ar poluído que mais de 90% da população mundial respira, ocasionando mais de seis milhões de mortes prematuras por ano (IEA, 2023).

Mesmo com as políticas em vigor e a abundância de tecnologias para atender os objetivos de segurança energética e de sustentabilidade, a previsão é ter um aumento das temperaturas médias globais de 2,4 °C em 2100, o que ocasionará impactos ainda mais graves no clima e na população. Os planos para a redução de emissões compreendem o aumento da capacidade de produção de energia renovável, a aceleração dos planos de eficiência energética, aumento da eletrificação dos transportes e redução das emissões de metano provenientes de operações de combustíveis fósseis. Estas ações em conjunto poderiam fornecer mais de 80% das reduções de emissões necessárias até 2030 para colocar o setor da energia no caminho para limitar o aquecimento a 1,5 °C.

FIGURA 1: EMISSÕES DE CO<sub>2</sub> NOS PRINCIPAIS PAÍSES DE 1970 A 2021, EM Gt CO<sub>2</sub>

FONTE: ADAPTADO DE JRC (2022)

FIGURA 2: FONTE DE EMISSÕES DE CO<sub>2</sub> NA CHINA, POR ATIVIDADE, Mt CO<sub>2</sub>

FONTE: ADAPTADO DE JRC (2024)

Em nível mundial, o setor de transporte contribui com uma parcela de 21% do total das emissões, alcançando em 2022 cerca de 8 Gt de CO<sub>2</sub>, 3% mais do que em 2021. Como forma de atenuar este crescimento, as vendas globais de veículos elétricos, movidos 100% a bateria (*Battery Electric Vehicle* - BEV) e combinados com motor a combustão e recarregáveis (*Plug-in Hybrid Vehicle* - PHEV), vêm aumentando

seguidamente com mais de 10 milhões de carros vendidos em 2022 (participação de 14%) e 14 milhões em 2023 (participação de 17%) (EV-VOLUMES, 2023).

O aumento de vendas é o resultado de fatores comerciais, regulatórios, econômicos e sociais. Com a expansão da oferta de modelos e versões, com novas tecnologias de condução e sofisticados equipamentos a bordo, há o interesse do cliente final em possuir um produto moderno, coerente com a sua necessidade e que representa uma solução econômica viável. Para o governo, este impulso é feito através de políticas públicas e que possibilitam as empresas automobilísticas, montadoras e fornecedores, a desenvolver os produtos para estes clientes. Para as economias nacionais, com o crescimento dos investimentos em fontes de energia sustentáveis, pode-se abrir a mão de onerosas importações de combustível fóssil e obter uma relativa independência energética. Do lado social, com menor poluição nas grandes cidades, é esperada uma melhora na qualidade de vida e saúde da população. No entanto este processo é dinâmico, de longo prazo e que necessita um trabalho específico e intenso em todas as camadas econômicas e industriais.

A China através do programa NEV (*New Energy Vehicle*) concentra os esforços desde 2009 para o desenvolvimento de veículos movidos predominantemente por energia elétrica, como veículos elétricos *plug-in* (PHEV), veículos elétricos a bateria (BEV) e veículos elétricos com célula de combustível (FCEV). O programa tem planos e objetivos definidos até 2030, sendo que a penetração dos veículos elétricos neste país atingiu 40% em 2023, com 7,8 milhões de unidades vendidas, com as marcas chinesas responsáveis por 78% do mercado, impulsionado pelas vendas de veículos compactos e subcompactos. Para reduzir a poluição atmosférica, a China pretende atingir uma quota de vendas de 50% de NEV até 2030 nas suas regiões-chave para o controle da poluição atmosférica, que juntas representam quase 80% do mercado automóvel. A capacidade de produção da China para NEV em 2025 deve atingir mais de 36 milhões de veículos quando os planos das empresas automobilísticas e governos locais forem combinados. As vendas devem ficar em torno de 17 milhões de veículos, criando um excedente de quase 20 milhões de unidades. (NIKKEI ASIA, 2024).

Os fabricantes BYD, GWM, Xiaomi alocam volumes de exportação para Europa, Sudeste Asiático e América do Sul como alternativa para esta crise, ameaçando a hegemonia das montadoras japonesas e europeias em seus próprios mercados consumidores. Como defesa, os governos destes países estabelecem

barreiras alfandegárias alegando que a concorrência é desleal, fruto de forte subsídios do governo chinês aos fabricantes.

Dentro do rol de políticas industriais nacionais para a promoção de desenvolvimento local, o governo brasileiro junto com o setor automobilístico e sociedade civil, estabeleceu programas para atender as metas de redução de emissão de gases de efeito estufa (GEE) e que visam reduzir as suas emissões em 48% até 2025 e 53% até 2030, em relação às emissões de 2005. Em 2023 o Brasil reiterou seu compromisso de alcançar emissões líquidas neutras até 2050, ou seja, tudo que o país emitir deverá ser compensado com fontes de captura de carbono, como o plantio de florestas, recuperação de biomas ou outras (BNDES, 2024).

Ao cabo de mais de dez anos de existência, o setor automobilístico tem participado dos programas Inovar Auto (2012 - 2017), Rota 2030 (2018 - 2022), Mover (2023 - 2027), que promovem melhorias na eficiência energética dos veículos vendidos concomitante com uma política industrial, de desenvolvimento e de pesquisa. Dentre as várias formas de atender os requisitos solicitados, devem-se desenvolver sistemas de propulsão eletrificados de forma mais intensa. Para que isso aconteça e que haja uma “neointustrialização” do setor, o governo brasileiro estabeleceu um retorno gradual do imposto de importação dos veículos elétricos de 35%, suspenso entre 2015 e 2023, e que este aporte, anunciado como sendo de R\$19 bilhões em quatro anos, seja direcionado para uma industrialização de novas tecnologias no país (MDIC, 2023).

O mercado de veículos elétricos no Brasil está em formação, com parque circulante de 32.586 veículos acumulados entre 2012 e dezembro 2023, dentro de uma frota total circulante de 73 milhões de automóveis e caminhonetes (IBGE, 2024).

Para que os resultados desta política industrial sejam efetivos e relevantes, deve-se ter um tratamento a longo prazo, considerando a dimensão continental, as condições da infraestrutura de estradas e distribuição de energia elétrica, bem como os investimentos em sistema de recarga de eletropostos. De acordo com ABVE (PV MAGAZINE, 2024), o país contava com 3.800 eletropostos em 2023 e a estimativa é que esse número de postos públicos ou semipúblicos chegue a 10 mil unidades em 2024. Como referência, a China contabiliza uma rede de 1,8 milhões de carregadores públicos, sendo 760.000 de recarga rápida.

Um dos pontos críticos desta operação passa pela disponibilidade efetiva dos eletropostos nos grandes centros para permitir a rodagem urbana com segurança bem

como nas vias intermunicipais e interestaduais. Como se observa em países mais avançados na Eletromobilidade, há uma grande complexidade na gestão e operação destes eletropostos, o que gera uma insatisfação e insegurança do usuário final.

## 1.1 CONTEXTO

Os consumidores brasileiros realizaram em 2023 a escolha de seus novos veículos com tecnologias de eletrificação avançada, sendo 33.049 veículos PHEV e 19.310 veículos BEV. Por ter um sistema de propulsão que necessita de uma recarga externa por fonte elétrica, se faz necessária a disponibilização de eletropostos, seja nas residências, pontos de paradas mais longos como estacionamentos de centro comerciais e nas rodovias. (ABVE, 2024)

Estes eletropostos inicialmente foram instalados em parte por empresas de distribuição de energia (EDP, Neoenergia, Celesc, Copel, CPFL), dentro dos programas da Agência Nacional de Energia Elétrica (ANEEL), através da Chamada Pública de P&D Estratégico N° 022/2018. (ANEEL, 2018).

Em paralelo, grupos empresariais e *startups* iniciaram os investimentos para disponibilizar estes eletropostos e poder garantir a preferência na oferta dos serviços de energia. Estes equipamentos, instalados em locais de grande circulação, rodovias com alto fluxo de veículos, permitiram as empresas melhor conhecer as características de instalação, uso e manutenção de eletropostos semirrápidos (potência entre 11 e 22 kW), rápidos (entre 50 e 100 kW) e ultrarrápidos (acima de 150 kW). Seja por iniciativa própria, seja por entraves burocráticos, a maior parte destes serviços não eram cobrados do usuário final, o que de um lado gerou um movimento inicial dos interessados, mas de outro impedia que o usuário pudesse reclamar caso o serviço não estivesse disponível.

Para os eletropostos públicos e semipúblicos (com restrição parcial de acesso), a cobrança dos serviços de eletropostos tem como objetivo obter uma receita através de uma tarifa com base em energia entregue (kWh) ou tempo de recarga (minutos), além de cobrir as necessidades de manutenção e reparos. O pagamento pelos serviços de carregamento está se tornando uma prática mais comum, principalmente em rodovias nacionais e grandes centros urbanos.

No entanto, a disponibilidade técnica do equipamento não é garantia de acesso imediato ao mesmo devido a diversos fatores, dos quais podem ser citados a

inoperabilidade, a utilização por outro usuário, eventual mal funcionamento ou incompatibilidade técnica. Com o intuito de tornar mais satisfatória a experiência do usuário, são disponibilizados no mercado aplicativos para celulares ou programas embarcados no veículo que fazem o mapeamento dos pontos de carregamentos, descrevendo as funcionalidades e condições de operação, bem como possibilitam os pagamentos. Como exemplos, citam-se o ABRP (*A Better Routeplanner*), o *Plugshare* e o Tupinambá.

Estes aplicativos suportam o usuário nas escolhas antes e durante a realização do percurso, principalmente para aqueles que não estão acostumados e carecem de experiência.

Todavia, outros fatores e escolhas podem determinar o êxito na execução do trajeto previsto, tais como o estilo de condução (agressivo ou econômico), as condições de tráfego e temperaturas, a utilização de rotas mais eficientes (presença de aclives e declives), a utilização de consumidores elétricos (ar-condicionado, aquecimento de volante e assentos) compõem uma vasta gama de decisões que podem facilitar ou prejudicar a chegada ao ponto de destino.

A interação destes fatores, entre outros, torna a experiência complexa e específica para cada usuário, o que gera insegurança e preocupações. Principalmente pelo fato que se houver uma pane imobilizadora devido à falta de energia, pode-se ter gastos extras com deslocamento e remoção do veículo.

## 1.2 OBJETIVOS

Considerando a crescimento da mobilidade elétrica no Brasil e seus desafios, este projeto traz elementos para entender os aspectos fundamentais e prover uma solução relacionada ao cálculo de autonomia para veículos elétricos. O principal objetivo é propor uma solução eficaz e versátil que possibilite o usuário conhecer os principais fatores, como eles impactam no resultado do percurso, apresentar as curvas de influências entre eles e disponibilizar os cálculos de cada alternativa.

Portanto, os objetivos específicos são:

- Avaliar a metodologia de cálculo de autonomia para veículos elétricos presente na regulamentação brasileira, segundo Portaria N°16, (07/10/20) e normativa de medição SAE J1634;



- Avaliar os aplicativos disponíveis no mercado para o cálculo de autonomia para veículos elétricos, comparando as características principais;
- Especificar os fatores e parâmetros que determinam a autonomia e as funções de pertinência;
- Propor um método de lógica nebulosa que permita gerar estimativas e tomadas de decisão através de funções de pertinência associada a cada fator; e
- Validar o método proposto com os ensaios com veículos elétricos em diferentes condições de uso.

### 1.3 JUSTIFICATIVA

Os veículos elétricos a bateria (BEV), diferentemente de veículos híbridos Plug-in (PHEV), não possuem alternativas para a propulsão própria na ausência de energia elétrica armazenada. Com isso, o usuário deve planejar antecipadamente o percurso, conhecer as características da rota e dos eletropostos envolvidos e se precaver com uma margem de segurança, em tempo e energia, caso não seja possível executar o plano original. A ansiedade de autonomia junto com a ansiedade de carregamento são as principais preocupações dos usuários, seja em mercados iniciais ou já mais estabelecidos. Uma vez que a oferta de veículos cresce, que os preços de veículos diminuem e o mercado tem confiança na tecnologia, os fatores autonomia e carregamento serão primordiais para promover uma maior adoção dos veículos elétricos.

Este projeto analisa a complexidade para o cálculo de autonomia de veículos elétricos além da abordagem física e integra modelos em lógica Fuzzy com conjuntos nebulosos. Considera-se uma proposta inovadora que se distingue das técnicas de modelamento disponíveis na literatura para veículos elétricos no Brasil e que poderá abrir novos campos de estudos futuros.

### 1.4 ESTRUTURA DA MONOGRAFIA

O estudo está dividido em seis capítulos, incluindo a introdução e conclusão. O Capítulo 1 descreve o cenário de emissões globais, as tendências de aumento de

temperatura média e as políticas públicas de programas para adoção de veículos elétricos, bem como os objetivos do projeto. O Capítulo 2 descreve os aspectos gerais do mercado de veículos elétricos, apresenta as características técnicas de carregamento e a distribuição de eletropostos na Europa e Brasil, analisa o método de medição da autonomia da regulamentação brasileira, destacando os elementos mais relevantes para o cliente final e fatores influenciadores na autonomia e apresenta a revisão bibliográfica. No capítulo 3 aborda-se os aplicativos de simulação de autonomia, comparando os resultados com testes reais detalhados. No capítulo 4, apresenta-se, os materiais e métodos, considerando o desenvolvimento do modelo de energia de movimento, o modelamento computacional com classificador Lógica Fuzzy para estimativa da autonomia, os conjuntos nebulosos e a descrição do teste inicial. No capítulo 5 aborda-se a realizações do teste inicial e complementares, os resultados de autonomia e fator de consumo final, bem como os erros relativos do modelo proposto em comparação ao sistema embarcado do veículo e do aplicativo escolhido. O Capítulo 6 mostra as principais análises e ponderações, além de propostas para eventuais estudos futuros.

## 2 ECOSSISTEMA DE VEÍCULOS ELÉTRICOS


### 2.1 MERCADO GLOBAL

O volume global de vendas em 2023 de veículos elétricos a bateria (BEV) e híbridos plug-in (PHEV) alcançou 14 milhões de veículos, um crescimento de 34% comparado com 2022. Os BEV totalizaram 10 milhões, com a liderança da China com aproximadamente 60% de participação, seguido da Europa com 20% e Estados Unidos com 8%. (IEA, 2024)

Neste trabalho não serão analisados os comportamentos e características de veículos híbridos HEV (Hybrid Electric vehicle) ou MHEV (Mild Hybrid Electric vehicle) pois são totalmente independentes de uma fonte de recarga externa.

Este crescimento impulsionado pela China segue a tendência mundial prevista pelas agências internacionais IEA (*International Energy Agency*) e WWF (*World Wild Fund for Nature*) em decorrência dos planos de redução das emissões de CO<sub>2</sub> e das futuras restrições de vendas de veículos poluentes, como na Europa a partir de 2035. A previsão é o domínio de vendas dos veículos elétricos a bateria a partir de 2030, como mostrado na FIGURA 3.

FIGURA 3: PREVISÃO DE VENDAS DE VEÍCULOS ELÉTRICOS (BEV E PHEV)

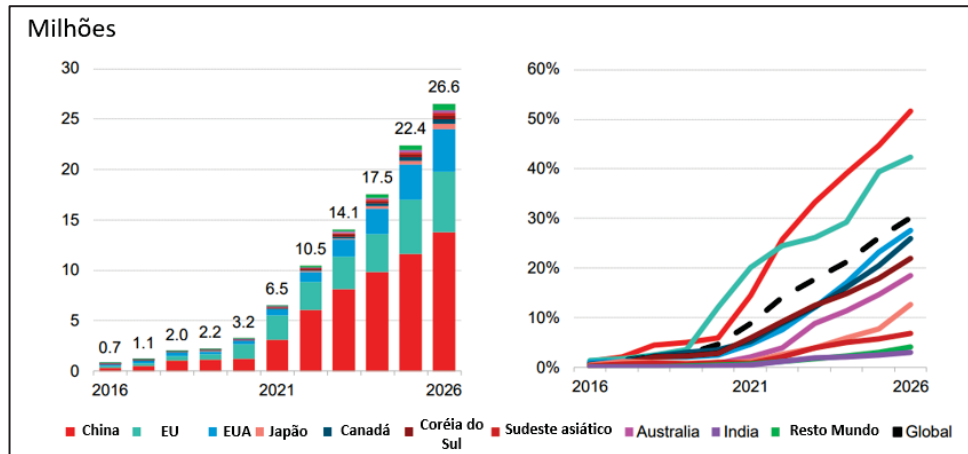


FONTE: ADAPTADO DE BLOOMBERGNEF (2023)

As projeções de vendas globais de veículos elétricos a longo prazo apontam para uma participação de 44% até 2030 e 75% até 2040. Segundo BloombergNEF

(2023) haverá um aumento rápido entre 2022 e 2035, seguindo uma tradicional “curva S” de adoção, mas com momentos distintos para cada região e país, como indicado na FIGURA 4. A principal barreira mencionada continua sendo a capacidade de implementação de uma infraestrutura pública de carregamento, situação mais crítica para países com dimensões continentais como o Brasil.

FIGURA 4: PREVISÃO DE VENDAS DE VEÍCULOS ELÉTRICOS (BEV E PHEV) POR MERCADO



FONTE: ADAPTADO DE BLOOMBERGNEF (2023)

Outra barreira identificada é o fornecimento de metais para a construção das baterias de tração, com a necessidade de grandes investimentos em todas as áreas da cadeia de abastecimento de baterias. Hoje existem mais de 7,4 TWh de capacidade de produção planejada até 2025 e deverão ser investidos pelo menos US\$ 188 bilhões em células de bateria e fábricas de componentes até o final da década. A procura por baterias de íons de lítio deve atingir 244TWh cumulativamente até 2050. Graças ao aumento de reservas exploráveis e uma redução dos metais no uso de baterias, as reservas de cobalto e níquel são agora suficientes. No entanto para o lítio o cenário parece mais desafiador e as reservas atualmente conhecidas seriam esgotadas, mesmo considerando as reciclagens. Novos produtos químicos para baterias e reduções no tamanho das baterias são vitais para compensar essa demanda.

Fabricantes de automóveis investem na localização da produção de seus fornecedores para garantir a competitividade, a redução dos custos de fornecimento e controle da cadeia de fabricação.

## 2.2 SISTEMAS DE CARREGAMENTO

O atendimento da mobilidade para veículos elétricos requer investimentos na parte da infraestrutura de carregamento. Um centro de recarga consiste em uma ou múltiplas estações de recarga e estacionamentos acomodados, como mostrado na FIGURA 5. Ele é operado por um responsável de ponto de carregamento (CPO) e indicado pelo endereço e coordenadas de localização GPS.

Uma estação de recarga é um equipamento com um ou mais pontos de recarga, compartilhando uma interface comum de identificação do usuário e pagamento (leitor de cartão, RFID ou aplicativos)

O ponto de recarga é onde efetivamente a energia elétrica será entregue podendo ter um ou vários conectores (tomadas ou plugues), sendo que um ponto de recarga é definido por recarregar um veículo por vez.

Um conector é a interface física entre a estação de recarga e o veículo elétrico através do qual a energia elétrica é entregue. Normalmente, o número de pontos de recarga e o número de conectores são iguais, mas nem sempre. Por exemplo, existem estações de recarga compostas por dois pontos de recarga e três conectores. Nesse caso, não podem ser utilizados mais de dois conectores e não podem ser carregados mais de dois veículos ao mesmo tempo (um CA e outro CC).

FIGURA 5: CENTRO DE RECARGA PARA VEÍCULOS ELÉTRICOS, COM DUAS ESTAÇÕES DE RECARGA E QUATRO PONTOS DE RECARGA



FONTE: AUTOR (2024)

Os eletropostos são classificados de acordo com a potência entregue. Categoria 1 são os eletropostos de corrente alternada (CA) e categoria 2 com corrente contínua (CC).

Quando a conversão de CA da rede em CC, necessária para carregar a bateria, ocorre no veículo, a capacidade do conversor CA-CC no carro determina quanto da capacidade de carga disponível da estação de carregamento pode ser utilizada, limitado a 22 kW geralmente.

Já quando a conversão de CA da rede em CC, necessária para carregar a bateria, ocorre fora do veículo no ponto de carregamento, é possível que o ponto de carregamento carregue com alta potência (> 22 kW). Na TABELA 1 são mostradas as categorias, subcategorias e máximas potências dos eletropostos, de acordo com a Regulamentação Europeia 2023/ 1804, anexo III.

TABELA 1: CLASSIFICAÇÃO DE POTÊNCIA DOS ELETROPOSTOS

<b>Categoria</b>	<b>Subcategoria</b>	<b>Máxima potência</b>
Categoria 1 (CA)	Lenta CA, monofásica	$P < 7,4 \text{ kW}$
	Média CA, mono/bi/trifásica	$7,4 \leq P \leq 22 \text{ kW}$
	Rápida CA, trifásica	$P > 22 \text{ kW}$
Categoria 2 (CC)	Lenta CC, trifásica	$P < 50 \text{ kW}$
	Rápida CC, trifásica	$50 \leq P < 150 \text{ kW}$
	Nível 1, Ultrarrápida CC, trifásica	$150 \leq P \leq 350 \text{ kW}$
	Nível 2, Ultrarrápida CC, trifásica	$P > 350 \text{ kW}$

FONTE: REGULAMENTAÇÃO EUROPEIA 2023/ 1804 (2023)

A potência dos eletropostos deve ser coerente com a necessidade de abastecimento do veículo, bem como as particularidades e restrições técnicas. Os eletropostos da categoria 1 (CA) podem ser instalados em residências, edifícios e centro comerciais com um custo mais reduzido, dispõem de gestão de acesso a distância e proporções reduzidas. Servem para alimentar o veículo a carga plena durante um período entre 4 e 8 horas. Os eletropostos da categoria 2 (CC), são instalados em postos de abastecimento, shoppings e estacionamentos públicos. Devido à alta potência de carregamento, estes carregadores rápidos são equipados

com sistemas de resfriamento para evitar superaquecimento durante o processo de carregamento.

### 2.3 DISTRIBUIÇÃO DE ELETROPOSTOS

Na questão de disponibilidade de pontos de recarga, o panorama mundial é complexo e diversificado. A TABELA 2 mostra a distribuição de eletropostos na Holanda, Alemanha e França. (EUROPEAN ALTERNATIVE FUELS OBSERVATORY, 2024).

TABELA 2: DISTRIBUIÇÃO DE ELETROPOSTOS (EP) NA ALEMANHA, HOLANDA E FRANÇA

Máxima potência	Holanda	Alemanha	França
P < 7,4 kW	5.947	926	37.794
7,4 ≤ P ≤ 22 kW	141.237	89.420	58.837
P > 22 kW	2.731	1.209	1.565
P < 50 kW	169	1.953	2.276
50 ≤ P < 150 kW	740	4.544	6.719
150 ≤ P ≤ 350 kW	2.643	13.747	4.173
P > 350 kW	164	1.440	4.281
Total EP	153.631	113.239	115.645
Frota PHEV + BEV	2.554.057	6.609.549	1.404.740
Razão (Frota PHEV + BEV) / EP	16	58	12

FONTE: ADAPTADO DE EUROPEAN ALTERNATIVE FUELS OBSERVATORY (2024)

A Holanda cobre uma área de 37 mil km<sup>2</sup>, população de 17 milhões de habitantes e tem uma rede com mais de 150 mil pontos para uma frota de 1,2 milhões de PHEV e 1,36 milhões de BEV, o que resulta em 16 veículos PHEV+ BEV para cada eletropostos. Cerca de 90% dos pontos são de potência média, coerente com o deslocamento em grandes centros e veículos com boa autonomia (> 200 km) (EUROPEAN COMMISSION, 2024).

Na Alemanha, com uma área de 357 mil km<sup>2</sup>, população de 83 milhões de habitantes, tem uma rede identificada de 113 mil pontos. A frota de veículos elétricos de passageiros, a maior da Europa com 6,6 milhões de unidades, resulta numa proporção de 58 veículos elétricos PHEV + BEV para cada eletroposto. A



característica do país, com tráfego intenso entre as cidades cobrindo um deslocamento acima de 400 km, se faz notar a presença de carregadores ultrarrápidos (acima de 150 kW) (EUROPEAN COMMISSION, 2024).

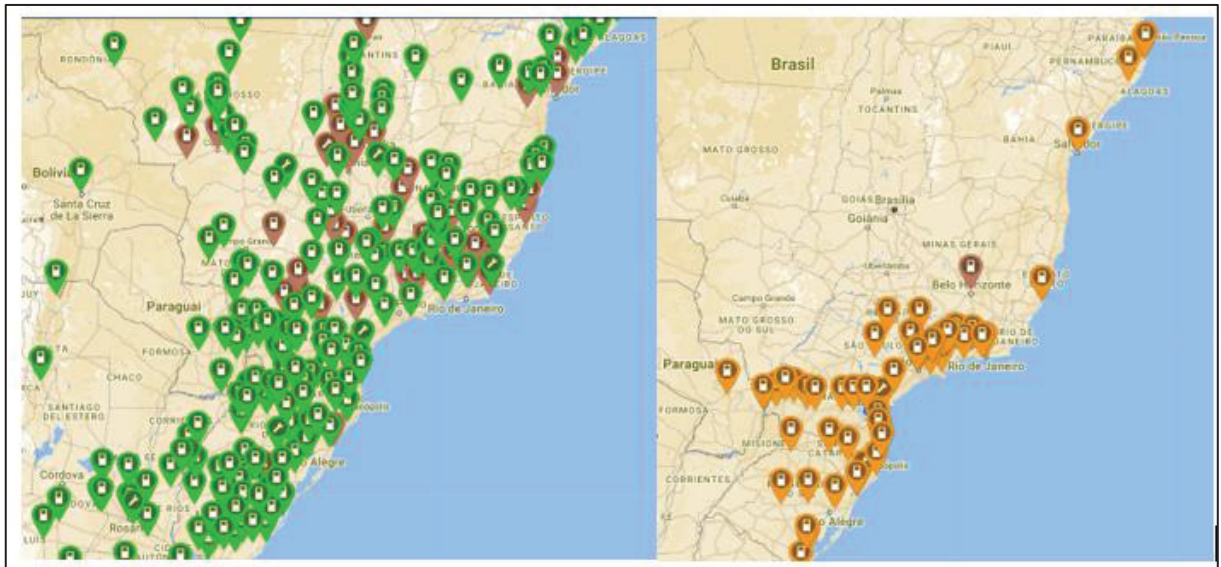
No caso da França, a área total cobre 638 mil km<sup>2</sup>, população de 67 milhões de habitantes e possui atualmente 115 mil pontos de carregamento. A frota de veículos elétricos consiste em 519 mil PHEV e 875 mil BEV. Com uma razão de 12 veículos elétricos PHEV + BEV para cada eletroposto, nota-se uma preponderância de eletropostos lentos (<7,4kW), possivelmente em áreas de circulação com maior tempo de estadia ou por restrições técnicas-econômicas.

No caso do Brasil, as estatísticas ainda não são contabilizadas por uma única entidade. Segundo ABVE, a estimativa de 2023 indica 3.880 eletropostos disponíveis, com menos de 100 unidades de potência acima de 50 kW. Tomando-se em base uma frota circulante de 32.586 veículos BEV, a relação de 9,8 veículos por unidade é considerada satisfatória, mas nota-se que a distribuição destes eletropostos em grandes cidades não condiz com as necessidades, pois estes eletropostos são buscados com frequência pelos usuários ao mesmo tempo, formando filas e longas paradas.

Em termos de infraestrutura pública e privada no Brasil, o governo e as empresas privadas têm trabalhado para promover uma abordagem diferenciada para este novo negócio. Do lado governamental, os programas de pesquisa e desenvolvimento (P&D) da ANEEL regulam as áreas de desenvolvimento nas quais as empresas elétricas devem investir e destinam sua cota compulsória de 0,5% das receitas. Em 2020, a ANEEL autorizou a contratação de R\$ 616 milhões para o desenvolvimento de infraestrutura para veículos elétricos. Empresas de energia elétrica como EDP, CELPE, COPEL e CPFL implementaram carregadores rápidos e ultrarrápidos em rodovias e postos públicos desde então. Marcas de veículos como Audi, BMW, Porsche e Volvo investiram em carregadores ultrarrápidos nos últimos anos para acompanhar seus clientes em sua experiência com BEV.

Como mostrado na FIGURA 6, encontra-se uma maior concentração de eletropostos nos estados da região sul e sudeste. Os pontos em verde determinam os carregadores em CA e em laranja os carregadores em CC.

FIGURA 6: DISTRIBUIÇÃO DE ELETROPOSTOS



FONTE: PLUGSHARE (2024)

## 2.4 CÁLCULO DE AUTONOMIA

### 2.4.1 REGULAMENTAÇÃO BRASILEIRA SEGUNDO CICLO SAE J1634:2017

As agências governamentais definem a padronização das métricas de eficiência energética para que os fabricantes tenham uma referência única e auditável do consumo, emissões e autonomia dos veículos elétricos. De acordo com o país de comercialização, é necessária a homologação no padrão exigido. Atualmente os ciclos mais referenciados são:

- EPA: ciclo estabelecido pela *Environmental Protection Agency*, utilizado nos Estados Unidos, conforme a norma SAE J1634:2017;
- WLTP: *Worldwide Harmonized Light Vehicle Test Procedure*, ciclo mundial unificado em utilização pelos países europeus;
- CLTC: *China Light Duty Vehicle Test Cycle*, utilizado no mercado Chinês;
- PBEV: Programa Brasileiro de Etiquetagem Veicular, utilizado no Brasil. O ciclo de condução combinado descrito nas normas ABNT NBR 7024:2017 e 16567:2016 e SAE J1634:2017.

Para este estudo, será detalhada a norma SAE J1634:2017 “Procedimento de teste de consumo de energia e autonomia de veículos elétricos de bateria” que determina o consumo de energia do veículo e testes de autonomia de veículos

elétricos, baseando-se no procedimento de Testes de Emissões Federal (FTP) da EPA, na qual são estabelecidos três ciclos: ciclo urbano (*Urban Dynamometer Driving Schedule* - UDDS), ciclo estrada (*Highway Fuel Economy Driving Schedule* - HFEDS), e ciclo de velocidade constante (*Constant Speed Cycle* - CSC). A autonomia em quilômetros é calculada como a distância total de ensaio conduzida a partir do início do ensaio até o ponto em que o veículo atinja a velocidade zero após satisfazer os critérios de fim de ensaio, como incapacidade de manter a velocidade estabelecida do ciclo, entre outras. O cálculo da autonomia urbana e estrada são calculados separadamente ao final do ciclo.

Conforme disposição da Portaria do PBEV INMETRO 169/2023, que estabelece os requisitos de avaliação da Conformidade para Veículos Leves de Passageiros e Comerciais Leves, foi exigido que as únicas informações de consumo energético a serem publicadas em manuais de utilização, pontos de venda, informativos publicitários e em quaisquer outros meios de comunicação, físico ou virtual, devem ter sua base de cálculos e procedimentos de acordo com os critérios das normas técnicas ABNT NBR 7024, ABNT NBR 16567 e SAE J1634 ou ABNT equivalente, nas suas versões mais atuais, ou substitutivas, sendo os valores obtidos nos ensaios de homologação e reajustados de acordo com os critérios explicitados.

É estabelecido que o valor de autonomia em quilometragem por litro equivalente (km/l<sub>eq</sub>) de veículo elétrico a bateria deve ser ajustado para refletir o uso cotidiano, descrito como autonomia real, através da aplicação da equação (1).

$$A_{req} = A_{eq} \times 0,7 \quad (1)$$

sendo  $A_{req}$  a autonomia por litro equivalente ajustada no ciclo urbano ou estrada, em km/l<sub>eq</sub> para BEV,  $A_{eq}$  a autonomia por litro obtida em ensaio de consumo no ciclo urbano ou estrada, em km/l<sub>eq</sub>.

Para o cálculo da autonomia por litro de gasolina equivalente dos BEV deverá ser considerada a densidade energética da gasolina, conforme a equação (2).

$$A_{eq} = \frac{DE}{CE} \quad (2)$$

sendo  $A_{eq}$  a autonomia equivalente à gasolina em  $\text{km}/l_{eq}$  para BEV,  $DE$  é a densidade energética da gasolina em  $\text{MJ}/l$  (28,99  $\text{MJ}/l$ ) e  $CE$  o consumo energético em  $\text{MJ}/\text{km}$  medido em cada fase.

As informações disponibilizadas no site do PBEV contêm o fator de ajuste de 70% e constitui a única informação autorizada a ser comunicada ao cliente. As montadoras tiveram até 30 de setembro de 2023 para atender a portaria 169/2023 e após esta data elas são sujeitas a denúncias dos órgãos do governo e retirada do programa PBEV. Este fator de ajuste de 70% é normatizado pelo organismo federal EPA dos Estados Unidos para tomar em conta o uso de veículo elétrico em condições mais agressivas de uso, uso intenso de ar condicionado e aquecimento da cabine devido as temperaturas extremas. Existem modos alternativos para se informar o consumo ajustado na legislação vigente, como a média de cinco ensaios ou considerando casos de resultados de uso clientes, mas estas alternativas não são estipuladas no caso do PBEV. (EPA, 2024)

#### 2.4.2 VALORES DE AUTONOMIA ANUNCIADOS NO PBEV

A TABELA 3 mostra a autonomia em km, os consumos energéticos em  $\text{MJ}/\text{km}$  consumos equivalentes urbano e estrada em  $\text{km}/l_{eq}$  de três veículos elétricos da versão disponível do PBEV de novembro/2023.

TABELA 3: AUTONOMIA E CONSUMO DE VEÍCULOS ELÉTRICOS

Modelo	Autonomia km	Consumo Energético $\text{MJ}/\text{km}$	Consumo equivalente Cidade $\text{km} / l_{eq}$	Consumo equivalente Estrada $\text{km} / l_{eq}$
Renault E-Kwid	185	0,44	52,7	39,6
BYD Dolphin Plus	330	0,51	42,1	36,8
Audi RS e-tron GT	313	0,69	29,3	29,1

FONTE: PBEV (2023)

A norma estabelece uma ponderação de 55% para o consumo energética do ciclo urbano e 45% para o ciclo estrada. Ao se desconsiderar o fator de correção, pode-se calcular as autonomies cidade e estrada obtidas no ciclo de homologação e a relação

entre elas, como mostrada na TABELA 4. Inclui-se a capacidade das baterias líquidas anunciadas pelos construtores.


TABELA 4: AUTONOMIA E CONSUMO DE VEÍCULOS ELÉTRICOS

Modelo	Capacidade bateria kWh	Autonomia sem fator km	Autonomia Cidade km	Autonomia Estrada km	Relação Autonomia Cidade / Estrada
Renault E-Kwid	26,8	264	298	224	1,33
BYD Dolphin Plus	60,45	471	500	437	1,14
Audi RS e-tron GT	93,4	447	449	445	1,01

FONTE: AUTOR (2024)

De acordo com as características técnicas do veículo (peso, aerodinâmica, potência do motor elétrico e capacidade da bateria), nota-se que para veículos concebidos para uso urbano como o Renault E-Kwid a relação entre as autonomias cidade e estrada (1,33) é mais elevada que o Audi RS e-tron GT (1,01). Por isso fica evidente a necessidade de o proprietário conhecer esta particularidade para escolher o melhor produto conforme as condições de uso e que ele tenha em consideração quando utilizá-lo. A FIGURA 7 elaborada a partir dos dados do programa PBEV mostra as autonomias em ciclo urbano e estrada para veículos elétricos participantes e a relação entre elas. Veículos que tem a autonomia urbana mais próxima da autonomia em estrada, tem o fator próximo de um e quanto maior for autonomia urbana em comparação a autonomia em estrada, maior é o fator final.

FIGURA 7: AUTONOMIAS CICLO URBANO E ESTRADA E RELAÇÃO DE AUTONOMIA



FONTE: AUTOR (2024)

A lista completa revisada para todos os veículos homologados se encontra no anexo I.

### 2.4.3 FATORES INFLUENCIADORES NA AUTONOMIA

Uma vez que os veículos elétricos são homologados em consumo energético e autonomia, torna-se necessário informar ao usuário final que as condições de ensaio realizados podem ser diferentes das reais e os valores de autonomia podem variar. As montadoras disponibilizam ferramentas de cálculos de consumo que tomam em conta parâmetros como estado de carga (*state of charge* - SOC) da bateria de tração, velocidade de deslocamento e temperatura externa. Informações estas que não são suficientes para abranger todos os casos dos usuários, causando insatisfação e insegurança no uso.

## 2.5 REVISÃO DA LITERATURA

O desenvolvimento da revisão de literatura baseia-se em pesquisas de autores sobre assuntos com as palavras-chave mencionadas na TABELA 5, definidas sobre o problema a ser analisado e o método a ser aplicado.

TABELA 5: DEFINIÇÃO DE PALAVRAS-CHAVE

Eixo	Problema	Método
Palavras-chave	Autonomia	Simulação
	Carregamento	

FONTE: AUTOR (2024)

Para ter dados atualizados de publicações recentes, consultou-se conferências internacionais, agências reguladoras, relatórios de empresas de consultoria e informes de imprensa das indústrias do setor. A TABELA 6 apresenta o resultado do total dos artigos consultados.

TABELA 6: RESULTADO DAS CONSULTAS

Artigos	Resultados
Selecionados para consulta	154 artigos
Selecionados para análise	54 artigos
Selecionados para revisão	9 artigos

FONTE: AUTOR (2024)

A revisão da literatura analisou as publicações mais recentes da Agência Internacional Energia como o *Global EV Outlook 2024*, *World Energy Outlook 2023*, *Net Zero Roadmap 2023 Update*. Para completar a pesquisa acadêmica, focou-se nas palavras-chave da TABELA 5 analisando as mais relevantes, os resumos e conclusões. A opção de ampliar a busca de materiais, utilizando não apenas o software *Publish or Perish* ou resultados do *Google Scholar*, permitiu encontrar artigos que contribuíram para a análise aprofundada do conhecimento industrial e de serviços aliada à revisão da legislação em casos semelhantes.



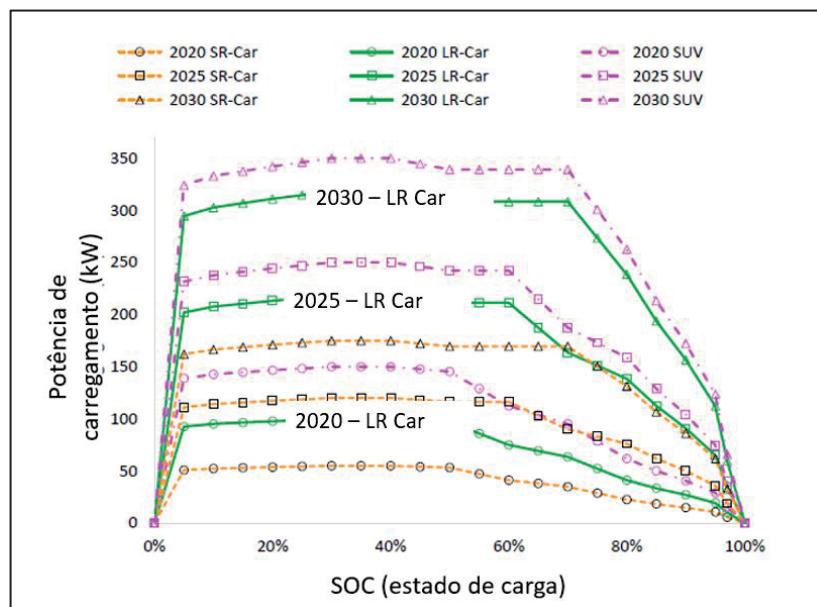
Importante ressaltar que não se encontrou na literatura nacional um artigo que descreva um cálculo de autonomia utilizando uma modelagem em lógica Fuzzy. Desta maneira este projeto pode ser considerado como um precursor neste campo de conhecimento.

### 2.5.1 ANÁLISE DE ARTIGOS

O planejamento de infraestrutura para carregamento em corrente contínua em estradas na Califórnia é abordado por Lee e Wood (2020). A localização dos eletropostos e capacidade de entrega são determinados através do cálculo de volume e padrão das viagens em simulação do uso de energia dos veículos, das condições de carregamento e se analisa a capacidade de oferta da rede de distribuição.

A FIGURA 8 demonstra a curva de carregamento dos veículos analisados, considerando três modelos de veículos (SR – *short range*, curta autonomia, LR – *long range*, longa autonomia, SUV – Sport Utility vehicle, proposta de veículo com a maior autonomia), e em três diferentes períodos, 2020, projeção para 2025 e projeção para 2030.

FIGURA 8: CURVAS REAIS E PROJETADAS DE CARREAMENTO EM CC EM FUNÇÃO DO ESTADO DE CARGA DA BATERIA SOC




FONTE: ADAPTADO DE LEE, DONG-YEON (2020)

A FIGURA 9 simula o crescimento destas potências até 800 kW no futuro com os três modelos de veículos e as três projeções de épocas (2020, 2025, 2030)

utilizando um carregador tipo Tesla V3. As curvas mostram uma potência máxima de 800 kW, mas que decresce em função do SOC da bateria.

FIGURA 9: CURVAS REAIS E PROJETADAS DE CARREGAMENTO EM CC EM FUNÇÃO DO ESTADO DE CARGA DA BATERIA SOC PARA CARREGADORES TESLA V3



FONTE: ADAPTADO DE LEE, DONG-YEON (2020)

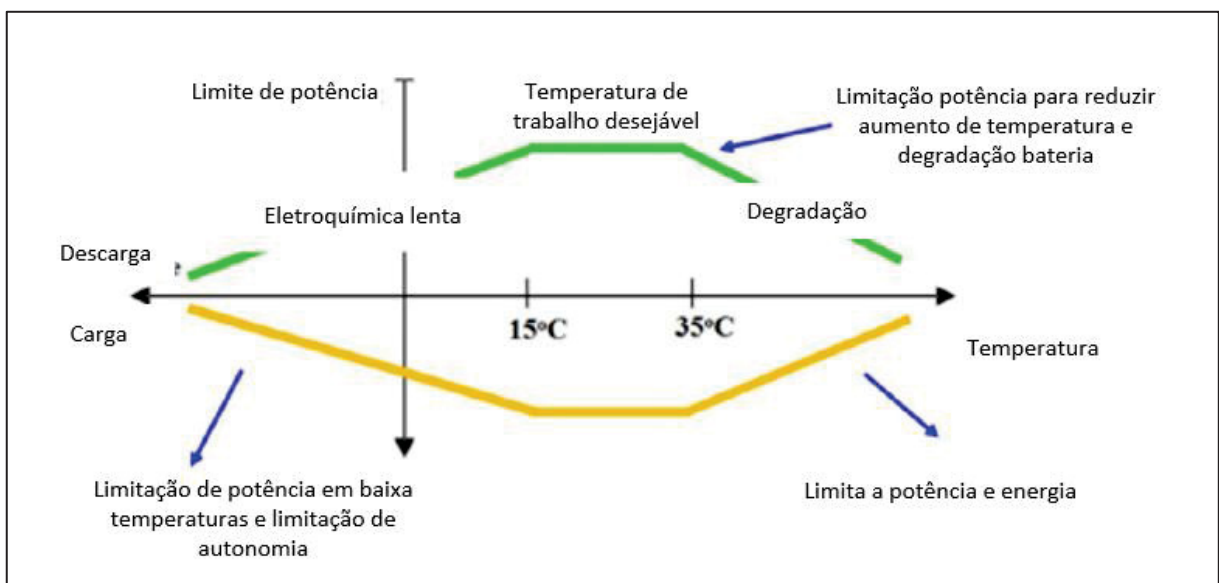
É citado que o modelo depende da qualidade dos dados considerados, que possam captar o comportamento de viagem e condução no mundo real e as características das sessões de carregamento. Uma análise holística da rede é necessária sobre a interoperabilidade dos pontos de carregamento para atender as necessidades de 2025 e 2030, através das ferramentas de simulação EVI-Pro EVI-Roadtrip e EVI On-demand.

Ashkrof et al. (2020) exploram a escolha de rota dos motoristas de veículos elétricos a bateria e preferências de carregamento. Coletando dados de 505 usuários na Holanda, os entrevistados foram solicitados a escolher uma rota entre seis alternativas: rodovias, vias arteriais, caminhos e ruas locais com e sem carregamento rápido. A pesquisa envolve os atributos como tempo e custo de viagem, variáveis relacionadas ao veículo (estado de carga na origem e destino) e características de carregamento (disponibilidade de um ponto de carregamento lento no destino, duração do carregamento rápido, tempo de espera na fila de uma estação de carregamento rápido) que podem influenciar a escolha da rota dos motoristas e o

comportamento de carregamento significativamente. Em geral, qualquer parada para recarregar ou reabastecer um carro durante uma viagem não é desejável. Quando o estado de carga (SOC) na origem é alta e um carregador lento no destino está disponível, rotas sem carregamento rápido são provavelmente preferidas. Além disso, as ruas locais (associadas a velocidades lentas e menos consumo de energia) podem ser preferidas se o SOC no destino for baixo.

Sobre a influência da temperatura ambiente para o desempenho da bateria de tração, Miyauchi et al. (2023) indicam que durante os processos de carga/descarga, as baterias começam a gerar calor devido às suas reações eletroquímicas, sendo necessário um controle sobre a temperatura das células da bateria, bem como nos gradientes de temperatura entre as células. Em altas temperaturas, a bateria acelera o envelhecimento devido ao superaquecimento, reduzindo consideravelmente a sua vida útil. Em baixas temperaturas, a potência geral da bateria é reduzida devido a diminuição de sua condutividade, afetando o desempenho da bateria. Portanto, a bateria tem uma faixa de temperatura “desejável” de trabalho, entre 15°C e 40°C, onde o sistema de gestão térmica deve garantir, para sua função e vida útil não são comprometidas. Jaguemont e van Mierlo (2020) apontam as temperaturas e performances envolvidos na FIGURA 10.

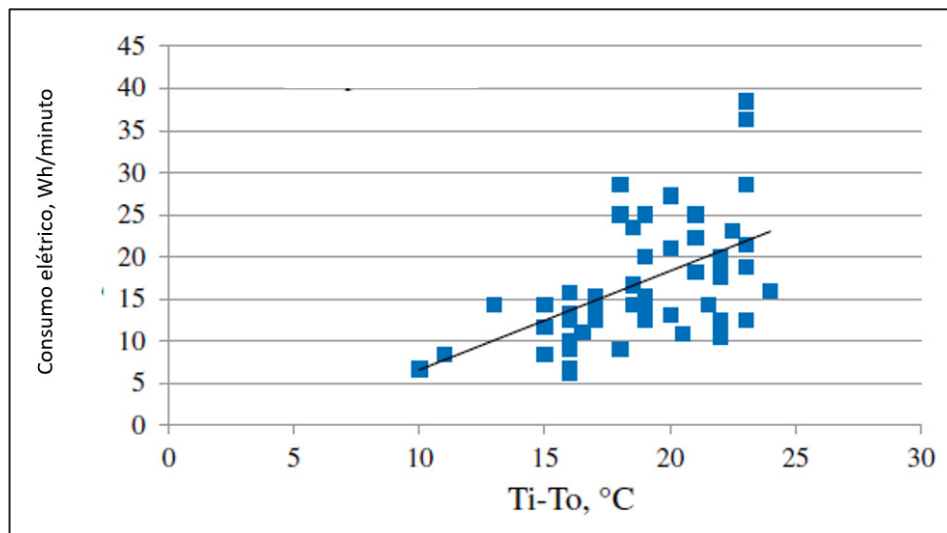
FIGURA 10: FAIXAS DE TEMPERATURA DE FUNCIONAMENTO DA BATERIA



FONTE: ADAPTADO DE JAGUEMONT, VAN MIERLO (2020)


Um segundo efeito da temperatura externa está relacionado ao aumento do consumo da energia da bateria para conservar a temperatura interna da cabine, como explicado por Doyle e Muneer (2019). Na média, 18% e 14% da capacidade energética da bateria são atribuídos aos requisitos de aquecimento e arrefecimento, respectivamente. O estudo apresenta um algoritmo de previsão de temperatura sob várias condições de climas. Estudos anteriores limitaram a consideração à flutuação da radiação solar e o aquecimento ambiente para o espaço da cabine de um veículo como mostrado nas FIGURA 11 e FIGURA 12. Os gráficos mostram a energia consumida em Wh/minuto em relação a diferença entre a temperatura interna da cabine ( $T_i$ ) e a temperatura do ar exterior da cabine ( $T_o$ ), no período diurno e noturno. Este modelo de previsão de temperatura pode ser desenvolvido para prever a energia exigida pela bateria para aquecer e resfriar o espaço da cabine do veículo e ser usado numa aplicação de planejamento de rotas para reduzir a ansiedade de autonomia quando os motoristas realizam uma viagem sob várias condições climáticas ambientais, otimizando o consumo de energia do veículo elétrico.

FIGURA 11: CONSUMO DE ENERGIA EM FUNÇÃO DA DIFERENÇA DE TEMPERATURAS INTERNAS  $T_i$  E EXTERNAS  $T_o$ , PERÍODO DIURNO



FONTE: ADAPTADO DOYLER, MUNEER (2019)

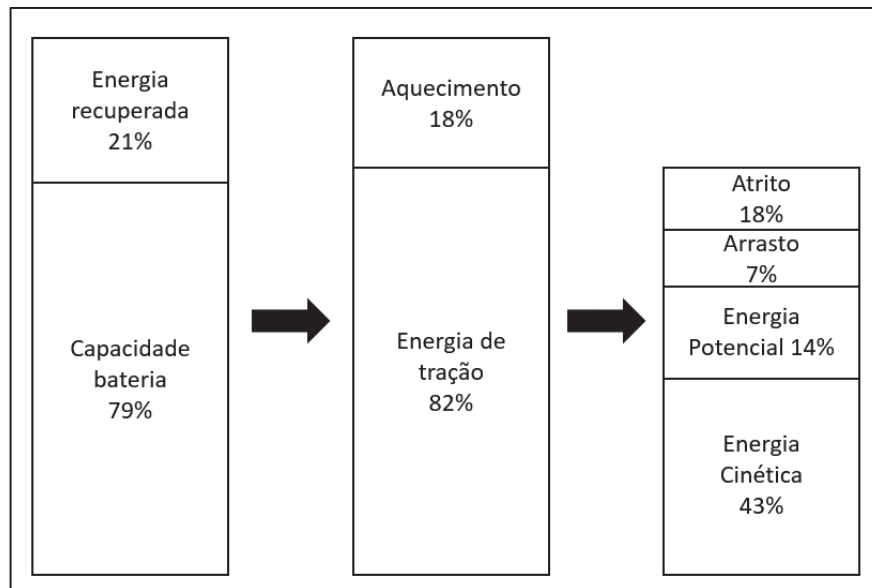
FIGURA 12: CONSUMO DE ENERGIA EM FUNÇÃO DA DIFERENÇA DE INTERNAS  $T_i$  E EXTERNAS  $T_o$ , PERÍODO NOTURNO



FONTE: ADAPTADO DOYLER, MUNEER (2019)

As conclusões apresentadas no estudo são importantes para a proposta deste trabalho, visto que ainda que no Brasil a ocorrência de temperaturas abaixo de  $0^\circ\text{C}$  seja baixa, a incidência de temperaturas acima de  $30^\circ\text{C}$  é elevada o que implica e maior carga térmica para resfriamento. Doyle e Meuneer (2019) mencionam que a introdução de um sistema de aquecimento auxiliar pode reduzir as necessidades de energia térmica em 23%, reduzindo de 18% para 14%, permitindo um ganho de 4% da energia da bateria capacidade a ser alocada à energia de propulsão, como mostrado na FIGURA 13.

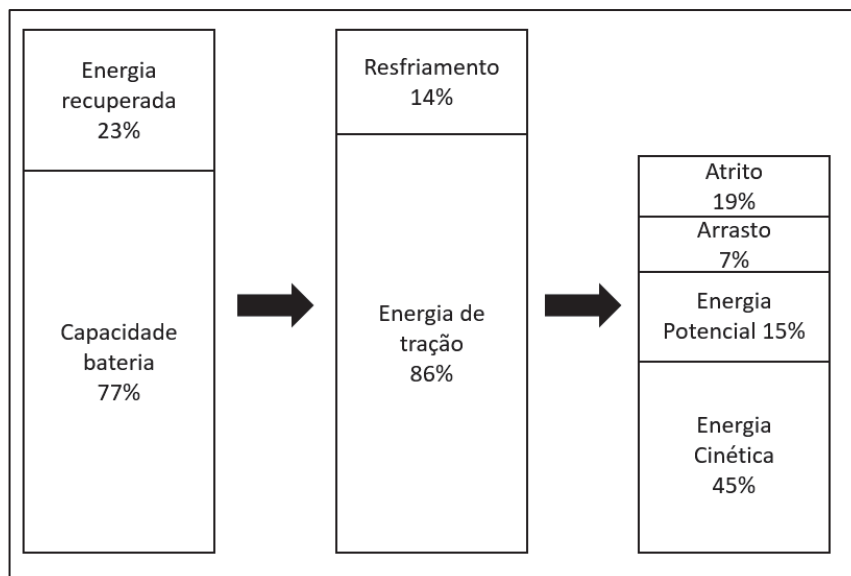
FIGURA 13: CONSUMO DE ENERGIA EM MODO AQUECIMENTO EM CICLO URBANO



FONTE: ADAPTADO DOYLER, MUNEER (2019)

A FIGURA 14 mostra o consumo de energia do VE quando o sistema de refrigeração está em operação com uma porcentagem da capacidade total de energia da bateria. Em média, o resfriamento sistema utiliza 14% da capacidade total da bateria, ou seja, menos quatro pontos percentuais de energia do que o aquecimento sistema. Ao comparar este último com o consumo de energia do VE em modo de aquecimento o sistema de refrigeração aproveita mais energia regenerativa e mais energia é alocada à tração.

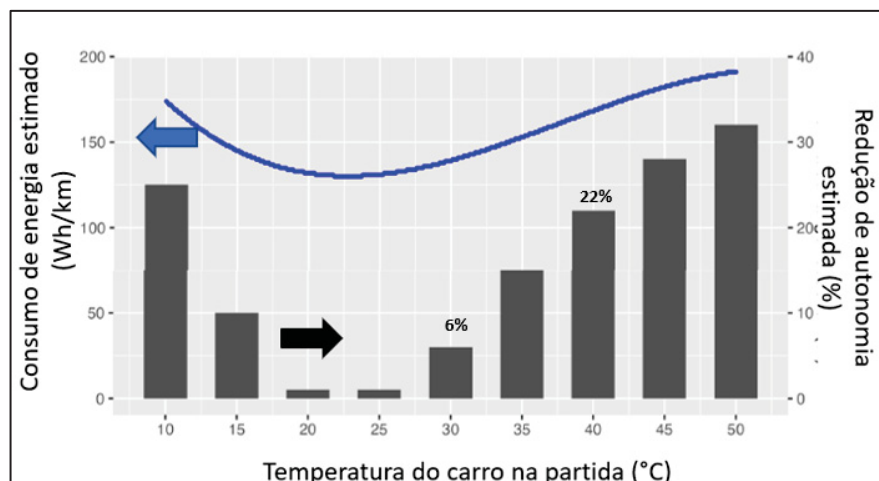
FIGURA 14: CONSUMO DE ENERGIA EM MODO RESFRIAMENTO EM CICLO URBANO



FONTE: ADAPTADO DOYLER, MUNEER (2019)

De acordo com Hamwi et al. (2022) no estudo sobre a influência da temperatura elevada realizada no Kuwait com mais de 3.000 trechos medidos de um veículo elétrico, indica que a intensidade energética atinge um mínimo na temperatura inicial entre 22°C e 23°C e que aumenta com a diminuição da temperatura abaixo deste ponto e com o aumento temperatura acima deste ponto, como mostrado na FIGURA 15. Ajustando um modelo aos dados empíricos para temperatura, a intensidade energética modelada entre 30°C e 40°C será superior em 6% e 22%, respectivamente.

FIGURA 15: INTENSIDADE DE ENERGIA E REDUÇÃO DA AUTONOMIA EM FUNÇÃO DA TEMPERATURA INICIAL DA JORNADA



FONTE: ADAPTADO HAMWI ET AL. (2022)

Embora a temperatura ambiente medida no veículo forneça uma indicação do funcionamento nas condições durante cada viagem, ela não fornece informações detalhadas nas condições ambientais antes e durante a operação. É necessária uma incluir uma correlação entre temperatura ambiente, temperaturas de operação do carro e condições da cabine (pré-condicionamento) para se calcular o consumo energético e autonomia do veículo.

Um estudo relativo ao comportamento do usuário é apresentado por Günther et al. (2017). Através de uma amostra de 54 condutores expostos numa situação de autonomia crítica (SOC mínimo), identifica-se as motivações para uma condução econômica, que minimiza o consumo de energia. Esta condução inclui práticas de condução exatamente no limite de velocidade ou mesmo abaixo dele, evitando as acelerações ou frenagens bruscas seguindo o fluxo de tráfego, evitando o uso de

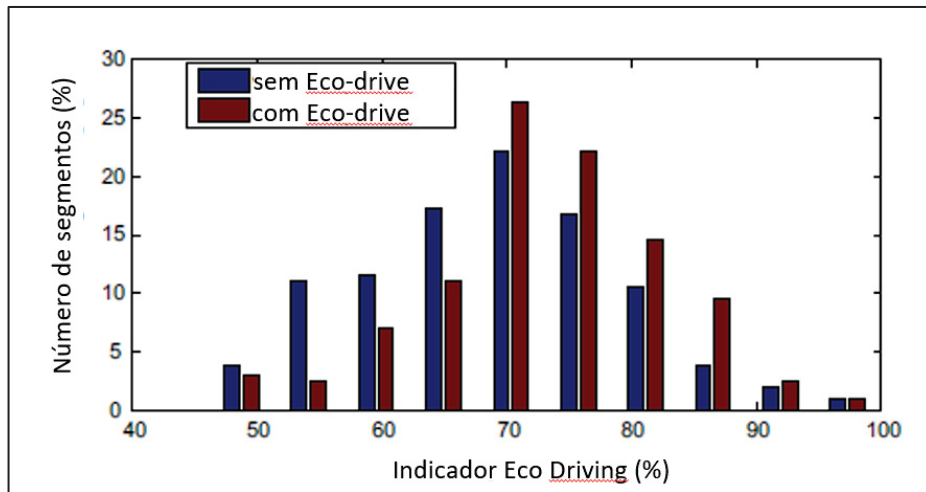
consumidores elétricos (ar-condicionado) e aumentando o uso eficiente da frenagem regenerativa, economizando energia durante a desaceleração. A utilização bem-sucedida de estratégias de condução ecológica tem o potencial de reduzir o consumo de energia de um veículo elétrico em mais de 25%. No entanto, a execução da condução ecológica está fortemente relacionada com a motivação dos condutores.

Blaszczyk e Kopeć (2022) indicam que um estilo de condução agressivo impacta o consumo médio de combustível em área urbana em até 30% superior ao estilo de condução calmo. Nos testes em autoestradas, o consumo médio de combustível aumentou 4%. Isso é diferente para veículo elétrico, onde a condução não qualificada aumenta significativamente a necessidade de energia. Um motorista experiente com conhecimento técnico sobre um veículo elétrico pode alcançar melhor resultado no modo conforto com um estilo de condução adequado. Um motorista inexperiente obterá uma autonomia menos, mesmo no modo eco.

Este fator da experiência também é evidenciado por Dib et al. (2014). Num percurso de 5 km em ambiente urbano com declives, paradas e muitos semáforos, os participantes dirigem a mesma rota duas vezes. É definida uma relação EDI (*eco-driving indicator*) que expressa a energia gasta no roteiro e a energia mínima otimizada calculado por um programa. A primeira rodada é feita sem o sistema de condução ecológica proposto que é ativado apenas durante o segundo turno. O objetivo é avaliar o ganho em termos de eficiência energética do sistema de direção ecológica com diversos motoristas. A FIGURA 16 mostra a porcentagem de deslocamentos durante todo o percurso como função do EDI para o primeiro e segundo turnos. Pode-se observar que, com o uso do sistema de direção ecológica, mais segmentos estão presentes com indicadores mais altos. Isso implica que os motoristas melhoraram a eficiência do seu comportamento de condução durante a segunda volta.



FIGURA 16: DISTRIBUIÇÃO DO NÚMERO DE SEGMENTOS EM FUNÇÃO DO EDI (ECO-DRIVING INDICATOR) E UTILIZAÇÃO DE ECO-DRIVE

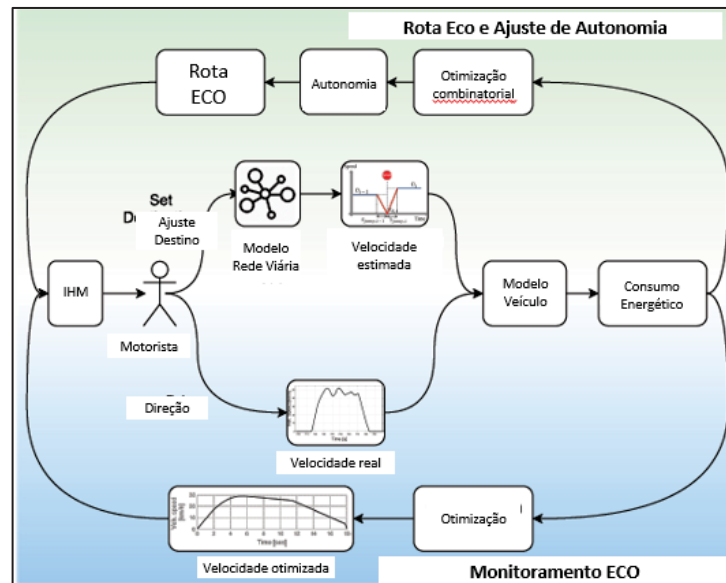


FONTE: ADAPTADO DE DIB ET AL (2014)

No âmbito de pesquisa sobre planejadores de rota para veículos elétricos (ERP – *Electric Route Planner*), buscou-se conhecer as principais técnicas disponíveis como métodos de cálculo de consumo de energia para veículos elétricos, algoritmos de predição de rotas, técnicas de mineração de dados e aprendizado de máquina para cálculo de autonomia, entre outros. O conhecimento destas técnicas é fundamental para poder analisar os aplicativos comerciais do mercado, fazer a comparação correta e propor melhorias futuras.

Thibault et al. (2018) propõem estratégias baseadas em modelos para prever e otimizar o consumo de energia de uma viagem. Após o modelamento ideal do veículo da rota, é utilizada uma rede neural artificial (ANN – *Artificial neural network*). Esta proposta alcançou resultados experimentais superiores em comparação com as abordagens existentes na previsão do consumo de energia dos veículos, ao sugerir uma rota eficiente e fornecendo assistência para condução ecológica, conforme mostrado na FIGURA 17.

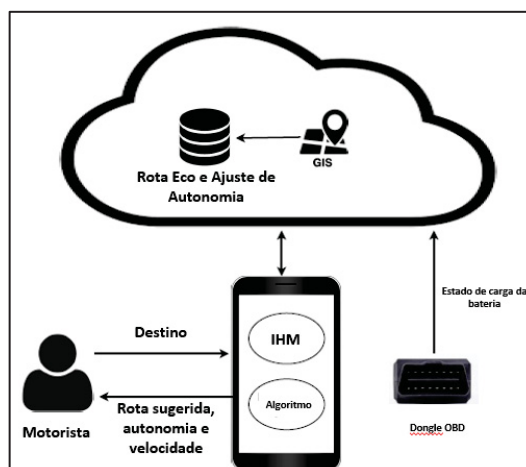
FIGURA 17: VISÃO GERAL DA ARQUITETURA DO SISTEMA



FONTE: ADAPTADO DE THIBAUT ET AL (2018)

Além do desenvolvimento do sistema da FIGURA 17, os autores apresentam o sistema de interface ao usuário via smartphone (que serve como interface homem máquina - IHM), um servidor de computação em nuvem que recupera em tempo real dados de tráfego e um dispositivo de captação dos dados via porta OBD-CAN que informa o estado da bateria, conforme FIGURA 18. Em média, a condução mais ecológica e melhor rota permitiram aumentar a autonomia em 9% e 12% respectivamente (em comparação com a rota mais rápida), reduzindo o consumo de energia. A autonomia calculada permite ao motorista ter um conhecimento mais preciso se o destino é alcançável ou não.

FIGURA 18: ARQUITETURA DO SISTEMA PARA VALIDAÇÃO



FONTE: ADAPTADO DE THIBAUT ET AL (2018)

Ferreira et al (2012) utilizam um modelo aprendido de Naïve Bayes de dados passados disponíveis de estado de carga SOC da bateria, comportamento passado do motorista. informações meteorológicas de vento e temperatura, velocidade média, informações de tráfego para calcular e comparar o consumo real com o previsto e estabelecer a autonomia disponível. A estimativa de autonomia é mostrada no celular através do Google Maps, como mostrado na FIGURA 19, o que a torna uma proposta interessante como precursora das ferramentas de cálculo de rota.

FIGURA 19: ESTIMATIVAS DE ROTA A PARTIR DE LISBOA




FONTE: FERREIRA ET AL (2012)

Bi et al (2018) utilizam dados de veículos para propor os modelos de estimativa não linear (quadrática e Weibull) para autonomia restante sob diferentes condições. Os modelos consideram o estado de carga da bateria (SOC), as condições de velocidade e temperatura como fatores de impacto para a autonomia restante. A relação não linear significativa entre velocidade e distância percorrida por SOC é explorada e considerada no modelo. Os resultados indicam que as velocidades de condução econômicas têm uma tendência crescente à medida que a temperatura aumenta.

Para medir a energia gasta no deslocamento de um veículo elétrico, Wu et al. (2015) propõem um método considerando as características técnicas do veículo

comparados durante cinco meses de medições. Como se trata de um projeto lançado em 2012, ele contém dados da fase inicial de adoção como a influência da inclinação (positiva e negativa) e potência em ciclo urbano e ciclo estrada, como mostrado na FIGURA 20. O modelo proposto descreve a potência instantânea do EV em três partes, incluindo as perdas pelo motor, as perdas pela resistência de deslocamento e possíveis ganhos com a aceleração;

FIGURA 20: POTÊNCIA E INCLINAÇÃO EM USO URBANO E ESTRADA



FONTE: ADAPTADO DE WU ET AL. (2015)

## 2.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A otimização energética dos veículos elétricos é primordial para que o usuário tenha a maior autonomia possível. Isso é suportado no desenvolvimento de componentes embarcados, como o controle de temperatura das células da bateria, a gestão dos consumidores elétricos, os modos de condução personalizados (econômico ou esportivo), a redução dos atritos e melhora da aerodinâmica. Mas o trabalho minucioso sobre estes parâmetros físicos não é suficiente, dado que as condições de rodagem e condução podem impactar severamente, como visto nas publicações citadas.

Técnicas de predição de consumo e autonomia baseadas em regressão de dados disponíveis, com a sistema de aprendizado de máquinas são fundamentais para aprimorar a exatidão dos cálculos.

Assim a metodologia para o cálculo do consumo de energia consiste na criação de um modelo de veículo que simule os parâmetros baseados em requisitos cinemáticos e dinâmicos ou por meio de modelos estatísticos baseados em medições do consumo, quer seja a partir de dados do mundo real ou ciclos de teste. Usar medições do mundo real tem a vantagem de prever valores mais realistas para o

consumo de energia, mas depende de dados disponíveis e modelos estatísticos, sendo seguidamente dissociado da dinâmica do veículo e do comportamento do sistema de transmissão. Em contraste, usar um modelo de veículo oferece uma ligação direta com a dinâmica do veículo e comportamento do sistema de transmissão, facilitando a identificação de influências dos parâmetros sobre o consumo de energia. É necessário quantificar as correlações entre os parâmetros cinemáticos do veículo elétrico e seu consumo de energia usando dados do mundo real, a fim de prever o consumo de veículos elétricos como um passo intermediário em direção à previsão da autonomia final.

Um modelo que usa dados do mundo real em comparação com o uso de valores de teste de ciclo produz valores de consumo de energia mais realistas e agrega valor para tópicos de pesquisa que dependem de dados de consumo como entrada. Estudos de Avaliações de Ciclo de Vida (*Life Cycle Assessment* - LCA) e Custo Total de Propriedade (*Total Cost of Ownership* - TCO) utilizam o consumo de energia com base no WLTP ou outros ciclos padronizados e não os valores mais próximos que os usuários encontram.

A TABELA 7 apresenta uma visão geral dos artigos avaliados, comparando com as áreas estudadas no projeto proposto.

TABELA 7:REVISÃO DA LITERATURA MENCIONADA

	THIBAULT ET AL. (2018)	ASHKROF ET AL. (2020)	GÜNTHER ET AL (2017)	LEE, WOOD (2020)	FERREIRA ET AL (2012)	DOYLE, MUNEER (2019)	BŁASZCZYK, KOPEĆ (2022)	HAMWI ET AL. (2022)	WU ET AL (2015)	MIYAUCHI ET AL (2023)
GERENCIAMENTO TERMICO										
CONSUMO ENERGETICO										
ESTIMATIVA DE ENERGIA										
IMPACTO DO MEIO AMBIENTE NA AUTONOMIA										
IMPACTO DA CONDUÇÃO NA AUTONOMIA										
FERRAMENTAS DE SIMULAÇÃO PARA CARREGAMENTO										
PLANEJADOR DE ROTA										
MODELAMENTO DE DADOS										

FONTE: AUTOR (2024)

### 3 CASO DE APLICAÇÃO

A experiência do usuário com um veículo elétrico se inicia com a consulta das informações disponibilizadas pelas montadoras, verificando os modelos, versões e configurações. Entre várias informações apresentadas, o interessado pode conhecer o desempenho em aceleração de 0 - 100 km/h e que representa o que o usuário vai encontrar na maioria das condições de uso. Para auferir estes dados, as montadoras seguem ensaios padronizados e que são reproduzidos pela imprensa especializada.

Para que o usuário tenha mais segurança no momento de escolher o veículo elétrico, as montadoras disponibilizam as características técnicas acrescidas de simuladores. As informações técnicas como capacidade de armazenar energia da bateria (medida em kWh), os alcances medidos em ciclos padrão (medidos em km), das características de carregamento em carga CA e CC (medidos em kW) estão disponíveis nos catálogos. Já os simuladores de autonomia levam em conta condições ambientais (temperatura ambiente), uso de consumidores de energia (ar-condicionado), velocidade de deslocamento, por exemplo. No entanto, os simuladores proveem os resultados, mas não garantem que a informação relatada de autonomia calculada corresponderá ao uso real.

Após a primeira escolha do veículo, o potencial cliente tem a oportunidade de testar o veículo em condições controladas de curta duração (*test drive*), no qual o vendedor irá mostrar as principais características e responder perguntas específicas. No entanto o potencial cliente terá uma experiência limitada de uso em poucos quilômetros rodados. Algumas marcas disponibilizam os veículos para uma sessão mais longa de teste ou são promovidos eventos em circuitos fechados. Estas etapas são importantes para que o cliente se acostume com as características específicas de veículos elétricos como desempenho mais responsivo em acelerações e que utilize o efeito de regeneração da energia em desacelerações e frenagens.

A cada novo potencial cliente, este esforço da equipe de vendas é necessário para que o cliente obtenha satisfação completa da sua compra. Desta maneira, deve se esperar que não houvesse surpresas ao iniciar a experiência de rodar em um veículo elétrico, mas isso não acontece em muitos casos, podendo ter insatisfações, queixas ou devolução do bem comprado.


### 3.1 FONTES DE DADOS PÚBLICOS PARA VEÍCULOS ELÉTRICOS

A agregação da conectividade embarcada possibilita que os veículos elétricos possam recuperar as informações das estações de carregamento em tempo real, atualizar as rotas em função das condições de autonomia e aumentar a exatidão dos cálculos de autonomia.

Um dos desafios para este projeto foi obter dados públicos sobre frotas de veículos elétricos considerando vários fatores, visto que não foi possível obtê-los através de uma frota cativa própria. Pode-se verificar esta possibilidade através do projeto Teslalogger (Wilheim, 2021), cujo objetivo do projeto é obter os dados de veículos da marca Tesla a partir do carro sem que seja necessário o consentimento da Tesla (senha da conta pessoal). Os dados de estado de saúde da bateria podem ser calculados, servindo de argumento em casos contra o fabricante em casos de mal desempenho.

Para a análise inicial, considera-se os dados registrados do veículo Model 3 LR, com uma autonomia de 380 km de média e consumo de 19,7 kWh/100km. O valor original de autonomia registrado é de 568 km em ciclo homologado EPA. Conforme a FIGURA 21, se verifica uma distribuição gaussiana com dados do tipo *outliers* abaixo de 230 km e acima de 535 km.

FIGURA 21: DISTRIBUIÇÃO DE AUTONOMIAS PARA TESLA MODEL 3 LR




FONTE: TESLALOGGER (2024)

Na FIGURA 22, se observa a distribuição gaussiana de consumo na totalidade das condições, com uma média de 19,9 kWh/100 km. Abaixo na tabela da mesma

figura são disponibilizadas as condições que cada medição foi realizada, por exemplo a velocidade máxima e velocidade média em km/h.

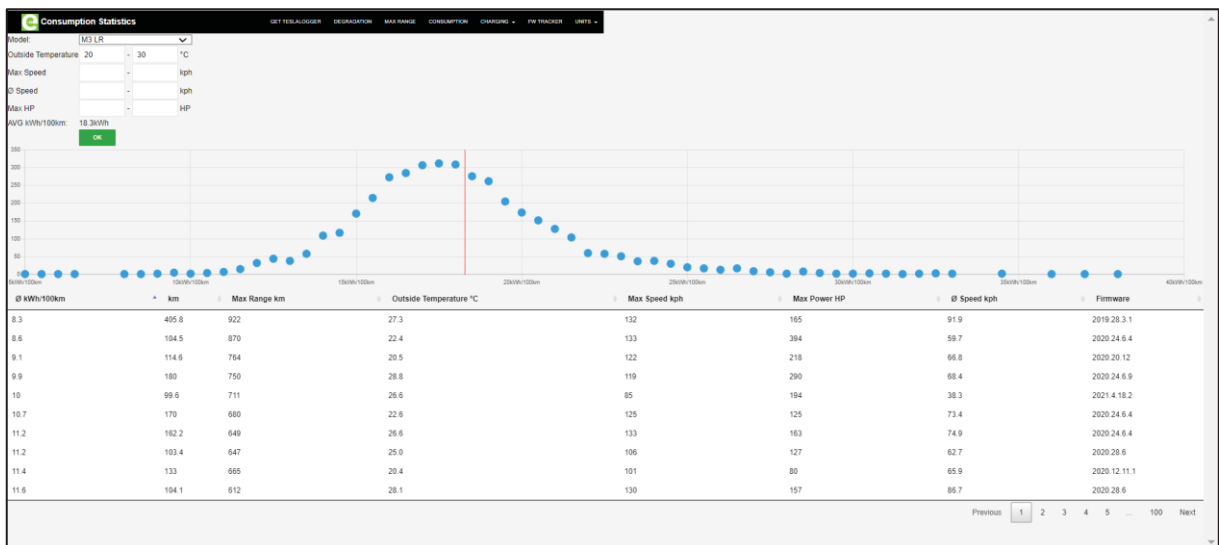
FIGURA 22: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR



FONTE: TESLALOGGER (2024)

Ao se limitar as temperaturas externas entre 20°C e 30°C, a média de consumo reduz para 18,3 kWh/100km, como mostrada na FIGURA 23. Este exercício mostra que em temperaturas mais brandas, o consumo nesta faixa de temperatura é menor que no escopo anterior.

FIGURA 23: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM TEMPERATURA EXTERNA ENTRE 20°C E 30°C

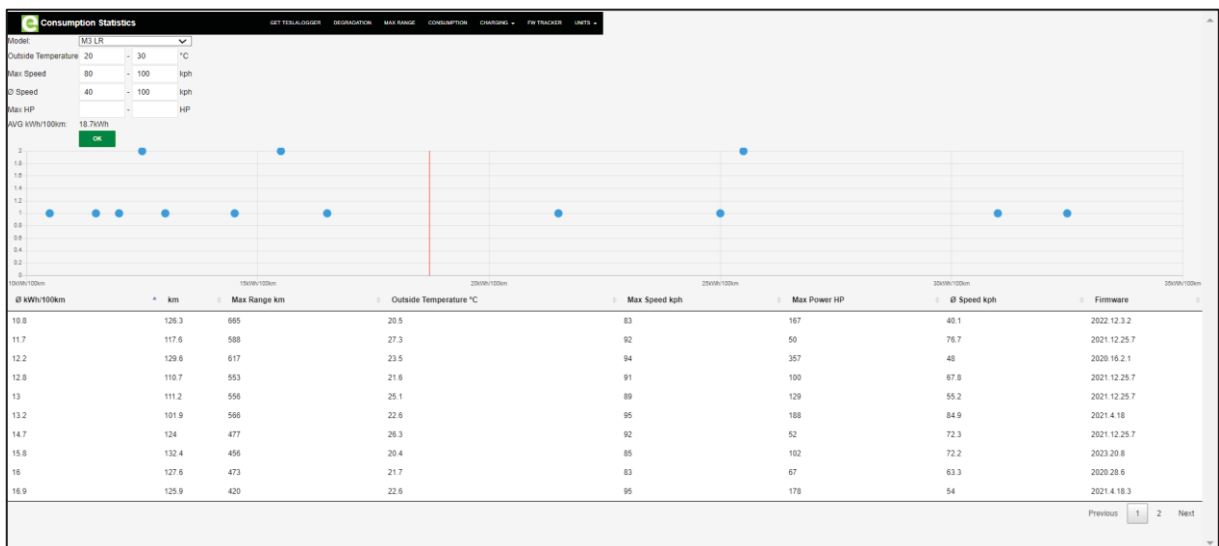


FONTE: TESLALOGGER (2024)



Ao se observar as condições com mais detalhes, percebe-se a influência da velocidade máxima e velocidade média. A tabela da FIGURA 24 informa que as velocidades médias entre 40 e 100 km/h, velocidades máximas entre 80 e 100 km/h e temperaturas externas entre 20° e 30°C, se obtiveram consumos mínimos entre 10 e 15 kWh/100 km e máximos entre 25 e 32 kWh/100km, o que representa uma distribuição com grande amplitude.


FIGURA 24: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM CONDIÇÕES DE TEMPERATURA E VELOCIDADE LIMITADAS



FONTE: TESLALOGGER (2024)

Ao se limitar as temperaturas externas entre -20°C e 10°C, a média de consumo aumentou para 21,9 kWh/100km, como mostrada na FIGURA 25, o que evidencia a influência de temperaturas mais baixas no consumo energético.


FIGURA 25: DISTRIBUIÇÃO DE CONSUMO PARA TESLA MODEL 3 LR EM TEMPERATURAS BAIXAS



FONTE: TESLALOGGER (2024)

Outra fonte de análise disponibilizada pelo Teslalogger é a degradação da capacidade da bateria para este modelo, demonstrada pela redução de autonomia em função da quantidade acumulada de quilômetro. Para o Modelo 3 LR, pode-se ter degradação de 10% em 150.000 km e 14% em 275.000 km como mostrado na FIGURA 26.

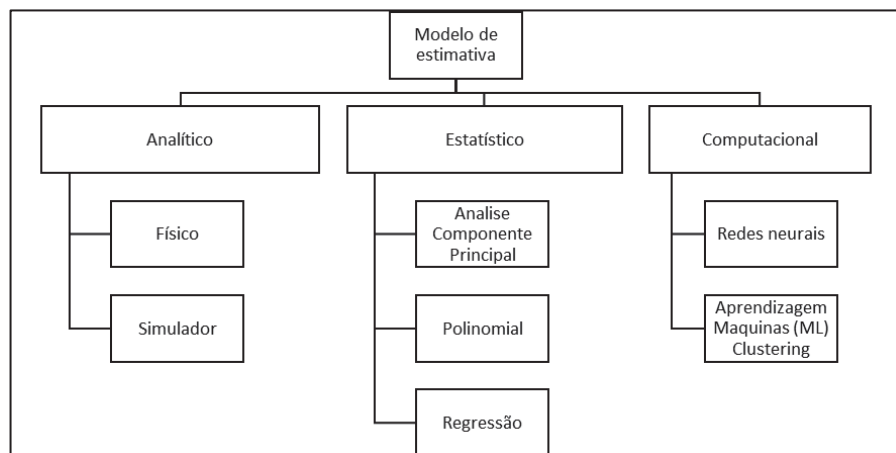
FIGURA 26: DEGRADAÇÃO DA BATERIA EM FUNÇÃO DA QUILOMETRAGEM ACUMULADA



FONTE: TESLALOGGER (2024)

Caso a base de dados seja disponibilizada, análises estatísticas ou modelos matemáticos podem ser desenvolvidos com regressões não-lineares, como mostrado na FIGURA 27. Outra forma de estimar a autonomia pode ser com um modelo computacional com redes neurais ou aprendizado de máquinas (*clustering*) (QI et al., 2018)

FIGURA 27: CATEGORIAS DE MODELOS PARA ESTIMATIVA DE CONSUMO



FONTE: ADAPTADO DE QI ET AL (2024)

### 3.2 APLICATIVOS DE SIMULAÇÃO DE AUTONOMIA

O fator de ansiedade de autonomia (“range anxiety”), citado por usuários iniciantes como principal preocupação no uso de veículos elétricos, trata da incerteza em saber se a energia na bateria será suficiente para chegar ao destino desejado.

Os simuladores fornecidos pelas montadoras proveem informações limitadas, devido à complexidade ou para evitar queixas dos clientes. Empresas de desenvolvimento de aplicativos, compreendendo esta limitação das montadoras, conseguem disponibilizar ferramentas de cálculo, integrados com o veículo ou não, para que atributos importantes sejam incluídos, como estado de carga da bateria SOC e estado de vida da bateria SOH, impacto da altimetria na autonomia e disponibilidade de carregadores ao longo da rota. Os dados tomados em conta podem ser recalculados em função do uso e condições externas, como ocorrência de ventos e tráfego. Os sistemas embarcados mais avançados podem reservar antecipadamente os pontos de recargas para permitir uma redução do tempo total da viagem, bem como orientar para uma condução mais eficiente.

Uma lista não-exaustiva de aplicativos disponibilizada no mercado é encontrada na TABELA 8. *Electric Route Planner* (ERP) com acesso aos dados do veículo estão indicados na coluna “embarcados”. Os ERP com acesso limitado a rede de comunicação dos veículos estão indicados na coluna “interface secundária”. Os aplicativos de ERP mais sofisticados no mercado mundial podem agregar diferentes fontes de dados, como preços dinâmicos de tarifas em função do tempo e potência, disponibilidades de equipamentos, condições meteorológicas e modalidades de pagamento. Estes aplicativos podem ser gratuitamente usados ou utilizar planos de assinatura, em função do nível de serviço e complexidade na gestão dos dados.

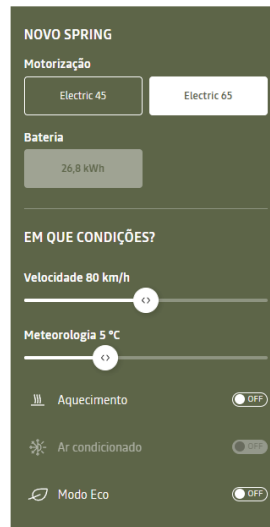
TABELA 8: APLICATIVOS PARA CÁLCULO DE ROTA E PONTOS DE CARREGAMENTO

Aplicativo	Embarcados	Interface secundária
Tesla	Tesla	-
Google Maps	Volvo, Renault, General Motors	-
Ionity	Não	Não
Chargepasse	Não	Não
Electrify America	Não	Não
Plugsurfing	Não	Não
Shell recharge pass	Não	Não
Chargepoint	Não	Não
A Better Route Planner ABRP	Não	Sim
Plugshare	Não	Não
Tupinambá	Não	Não
NeoCharge	Não	Não
Mobilize Charge Pass	Não	Não
EV Volt	Não	Não
Zelectric	Não	Não
Waze	Não	Não

FONTE: AUTOR (2024)

A Dacia, fabricante mundial francesa do grupo Renault, disponibiliza o modelo Spring na versão elétrica, com bateria de 26,8 kWh e 230 km de autonomia em ciclo WLTP. No site do fabricante ([www.dacia.pt](http://www.dacia.pt)), no simulador de autonomia, como mostrado na FIGURA 28, é possível escolher os parâmetros como velocidade, temperatura ambiente, uso do aquecimento, uso do ar-condicionado e uso do modo econômico.


FIGURA 28: OPÇÕES DE COMBINAÇÕES PARA DETERMINAR A AUTONOMIA



FONTE: DACIA (2024)

A FIGURA 29 representa graficamente a autonomia calculada em quilômetros em função da velocidade do veículo (km/h) e a temperatura externa verificada em graus Celsius. Confirma-se que a menor velocidade combinada com uma temperatura ambiente próxima de 30°C disponibiliza a maior autonomia. Na TABELA 9, tem-se a influência da consumidores e na TABELA 10 apresenta a influência do modo Eco, sendo que quanto maior for o valor alcançado, maior será a autonomia disponível.

FIGURA 29: AUTONOMIA EM FUNÇÃO DA VELOCIDADE E DA TEMPERATURA EXTERNA



FONTE: AUTOR (2024)

TABELA 9: FATOR DE INFLUÊNCIA DOS CONSUMIDORES NA AUTONOMIA

Temp. externa	Velocidade [km/h]				
	30	50	80	90	110
0°C	95%	94%	97%	97%	97%
5°C	94%	96%	98%	99%	100%
20°C	100%	100%	100%	100%	100%
35°C	83%	90%	96%	95%	98%

FONTE: AUTOR (2024)

TABELA 10: FATOR DE INFLUÊNCIA DO MODO ECO NA AUTONOMIA

Temp. externa	Velocidade [km/h]				
	30	50	80	90	110
0°C	108%	107%	108%	109%	100%
5°C	107%	107%	109%	109%	100%
20°C	107%	107%	109%	109%	100%
35°C	107%	107%	109%	109%	100%

FONTE: AUTOR (2024)

Na TABELA 10, o fator de influência é neutro a partir de velocidade acima de 100 km/h. pois a função ECO não possibilita esta condição. Esta ferramenta não disponibiliza critérios como a topologia do terreno, existência de tráfego, circulação em circuito urbano e estrada, entre outros.

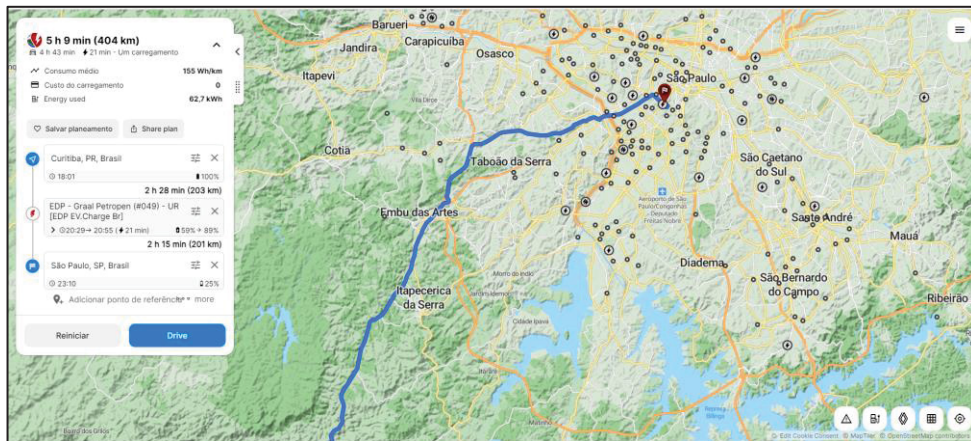
Para uma comparação entre os aplicativos, foram selecionados três exemplos que representam diferentes conceitos de utilização e que foram testados em detalhes.

### 3.2.1 A BETTER ROUTE PLANNER

O ABRP ([www.abetterrouteplanner.com](http://www.abetterrouteplanner.com)) é um aplicativo que calcula a maneira mais rápida e eficiente de chegar ao destino para veículos elétricos. Para usá-lo, deve-se primeiramente selecionar o modelo do veículo, inserir o destino para obter uma rota planejada completa, incluindo estações de carregamento e duração da viagem. Possui uma interface simples, como mostrado na FIGURA 30 e fornece a topografia da rota para planejar o momento correto de economia e regeneração. Pode-se incluir a temperatura e condições da estrada. Na versão gratuita é permitido o

compartilhamento no Google Maps para obter atualizações de trânsito ao vivo. A versão premium possui tráfego integrado e espelhamento na tela do multimídia através do Android Auto ou Apple Carplay. Ele não permite fazer reservas, mas pagamentos podem ser realizados através de registro com fornecedores de serviço.

FIGURA 30: EXEMPLO DO APLICATIVO ABRP



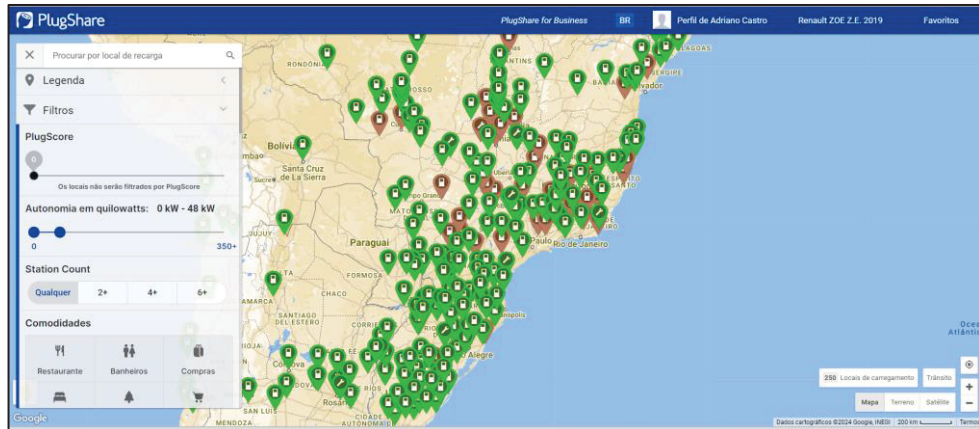
FONTE: A BETTER ROUTE PLANNER (2024)

### 3.2.2 PLUGSHARE

O aplicativo PlugShare ([www.plugshare.com](http://www.plugshare.com)) pode ser usado para planejar viagens em um veículo específico e mostra um mapa com os pontos de carregamento de carga CA e CC, como mostrado na FIGURA 31. Podem ser aplicados filtros para otimizar a escolha dos pontos e ver os comentários dos outros usuários, o que pode ajudar na escolha, mas não tem nenhuma garantia da veracidade das informações. Ele não mostra como a elevação afeta seu alcance, apenas mostra o provável alcance máximo com um grande círculo verde no mapa, não permite fazer reservas nem pagamentos dos carregadores.



FIGURA 31: EXEMPLO DO APLICATIVO PLUGSHARE

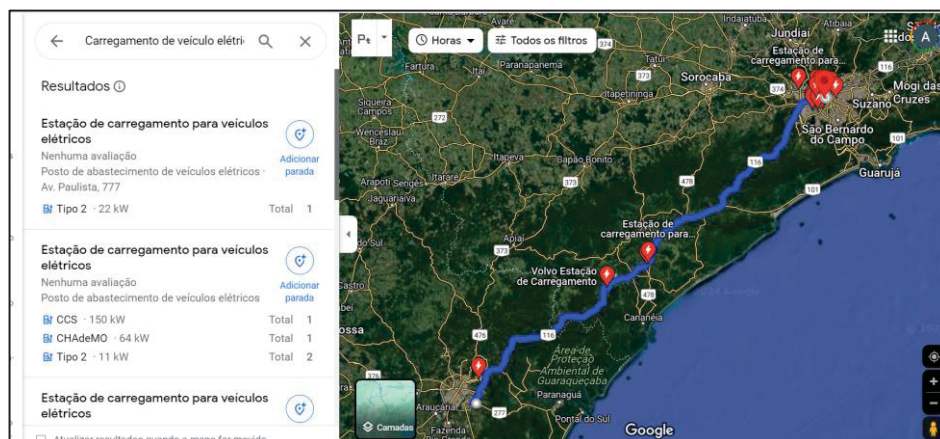


FONTE: PLUGSHARE (2024)

### 3.2.3 GOOGLE MAPS

Por se tratar de uma ferramenta já disponibilizada no mercado para não-usuários de veículos elétricos, o Google Maps ([www.google.com.br/maps](http://www.google.com.br/maps)) tem uma base maior de dados para planejar a rota com maior exatidão, baseada em dados de tráfegos e alternativas. No entanto, na versão não integrada ao veículo, não permite o pagamento ou reserva de pontos de carregamento, nem avisa da disponibilidade do ponto no momento, como mostrado na FIGURA 32.

FIGURA 32: EXEMPLO DO APLICATIVO GOOGLE MAPS



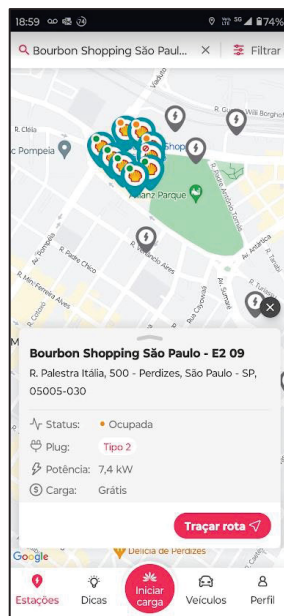
FONTE: GOOGLE MAPS (2024)



### 3.2.4 TUPINAMBÁ

Com mais de 2000 pontos de recarga mapeados, o aplicativo Tupinambá ([www.tupinambaenergia.com.br](http://www.tupinambaenergia.com.br)) serve de base para outros aplicativos do mercado ao disponibilizar os dados próprios. Ele localiza os carregadores, calcula a rota, realiza a reserva até 15 minutos de antecedência, permite a liberação da carga e possibilita o pagamento. Ele utiliza a base do Google Maps ou Waze como aplicativo de rota, como mostrado na FIGURA 33. No entanto, o aplicativo não considera características do veículo, nem condições do meio ambiente.

FIGURA 33: EXEMPLO DO APLICATIVO TUPINAMBÁ



FONTE: AUTOR (2024)

## 3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Na amostragem dos aplicativos consolidados na TABELA 11, se ressalta que não há uma única versão que disponibilize todas as características necessárias para um planejamento seguro da rota. O usuário deverá se habituar a utilizar o que melhor prover as informações sobre o local, disponibilidade e previsão de autonomia.

TABELA 11: COMPARAÇÃO DOS APLICATIVOS

Planejador	Desktop	Versão no veículo	Conexão veículo	Disponibilidade de carregador	Cálculo em função do relevo	Tráfego	Multi veículos	Custo da versão	Pagamento da carga
ABRP	✓	Premium	✓	X	✓	Premium	Premium	Premium 50 €/ ano	X
Plugshare	✓	✓	X	X	X	X	X	-	X
Google Maps	✓	✓	X	X	X	✓	X	-	Não
Tupinambá	X	X	X	✓	X	X	✓	-	✓

FONTE: AUTOR (2024)

No Brasil atualmente os fornecedores de serviços de carregamento não compartilham as informações de cada rede, o que obriga os usuários a usar vários aplicativos durante o planejamento e execução dos roteiros.

Para que este trabalho tenha uma fundamentação teórica aprofundada e que se possa comparar com dados confiáveis, optou-se a tomar o aplicativo “A Better Route Planner” como referência, pois ele oferece uma lista de configurações extensa para a simulação, dados de consumo energético total e monitoramento instantâneo do roteiro de deslocamento.

## 4 MATERIAIS E MÉTODOS


Como os veículos elétricos são caracterizados por uma autonomia de condução limitada, torna-se necessário ter aplicativos de planejamento de rotas para calcular o deslocamento mais eficiente (tempo de deslocamento total e energia consumida) e modelos de simulação para estimar a autonomia.

A primeira etapa para entender os fatores no impacto de consumo, é desenvolver um modelo matemático com as características técnicas do desempenho do veículo que se aproxime do consumo real. Em seguida, o objetivo é ter um modelo computacional com base nos dados aferidos e que tenha um resultado representativo da prova real. Por último, compara-se este modelo com os aplicativos disponíveis no mercado para se certificar que o modelo desenvolvido se aproxima destes aplicativos.

### 4.1 DESENVOLVIMENTO DO MODELO DE ENERGIA DE MOVIMENTO

O modelo do deslocamento longitudinal deve considerar as forças que se opõe ao movimento, conforme mostrado na figura 34. (MIRI ET AL, 2020)

FIGURA 34 : MODELO DE FORÇAS EM UM VEÍCULO



FONTE: ADAPTADO DE MIRI ET AL. (2020)

- Força de resistência ao gradiente  $R_{\theta}$  devido à inclinação da estrada em relação ao plano horizontal.

- Força de resistência ao rolamento  $R_R$  principalmente devido ao atrito entre os pneus e a estrada.
- Força de arrasto aerodinâmico  $R_A$  devido ao atrito entre a carroceria do veículo e o ar.
- Força de resistência à inércia  $R_I$  relacionada às forças necessárias para a aceleração linear do veículo  $R_{Ia}$  e o aumento da velocidade de rotação dos componentes rotativos  $R_{I\epsilon}$ .
- Força de resistência de transmissão  $R_T$  relacionada às perdas entre o motor e as rodas devido à transmissão eficiência  $\eta_G$ .

Desta forma a potência empregada no deslocamento  $P_{Rodas}$  é definida por equação (3) (MIRI ET AL., 2020):

$$P_{Rodas} = (R_\theta + R_R + R_A + R_I + R_T) * V_{Veículo}, \quad (3)$$

onde:

$$R_\theta = M_{Veículo} \cdot g \cdot \text{sen}\alpha, \quad (4)$$

$$R_R = C_{RR} \cdot M_{Veículo} \cdot g \cdot \text{cos}\alpha, \quad (5)$$

$$R_A = \frac{1}{2} \cdot \rho \cdot A_F \cdot C_d \cdot (V_{Veículo} - V_{vento})^2, \quad (6)$$

$$R_I = R_{Ia} + R_{I\epsilon} = \delta \cdot M_{Veículo} \cdot a, \quad (7)$$

$$R_T = (R_R + R_A + R_\theta + R_I) \cdot \frac{(1-\eta_G)}{\eta_G}, \quad (8)$$

sendo  $V_{Veículo}$  a velocidade do veículo em (m/s),  $V_{vento}$  é a velocidade do vento em (m/s) que tem sinal positivo quando é vento em favor do deslocamento e sinal negativo quando é contra o deslocamento.  $C_{RR}$  é o coeficiente de resistência ao rolamento,  $M_{Veículo}$  é a massa do veículo em (kg),  $g$  é a aceleração devido à gravidade ( $m/s^2$ ),  $\alpha$  é o ângulo de inclinação da estrada em ( $^\circ$ ),  $\rho$  é a densidade do ar em ( $kg/m^3$ ),  $A_F$  é área frontal em ( $m^2$ ),  $C_d$  é o coeficiente de arrasto,  $a$  é a aceleração do veículo em ( $m/s^2$ ) e  $\delta$  é o coeficiente de inércia rotativa que se presume ser em torno de 1,15 (valor típico). Já o valor de  $C_{RR}$ , expresso pela equação (9) pode ser aproximado como uma função linear da velocidade do veículo para um automóvel de passageiros em estradas de concreto para a maior parte da pressão dos pneus. Esta aproximação fornece uma estimativa satisfatória para velocidades até 128 km/h. (EHSANI ET AL., 2005)

$$C_{RR} = 0.01 \cdot \left(1 + \frac{V_{Veículo}}{100}\right), \quad (9)$$

A potência consumida  $P_{cons\ aero}$  pelo arrasto aerodinâmico é influenciada pela resultante da velocidade do veículo subtraída da intensidade e direção do vento, conforme equação (10):

$$P_{cons\ aero} = \left(\frac{1}{2} \cdot \rho \cdot A_F \cdot C_d \cdot (V_{Veículo} - V_{vento})^2\right) * V_{Veículo} \quad (10)$$

Caso a velocidade  $V_{vento}$  seja nula, tem-se a equação **Erro! Fonte de referência não encontrada.**:

$$P_{cons\ aero} = \frac{1}{2} \cdot \rho \cdot A_F \cdot C_d \cdot V_{Veículo}^3$$

A potência de tração para mover o veículo é provida pelo motor conectado a bateria. A potência retirada da bateria é expressa pela equação (11):

$$P_{el,out} = \frac{P_{Rodas}}{\eta_M} + P_0, \quad (11)$$

onde  $\eta_M$  é a eficiência energética da transmissão, motor e sistema de conversão. Os componentes auxiliares do veículo consomem uma potência  $P_0$ , também conhecida como consumo básico. Durante a frenagem e declives, a força de tração é negativa e a energia é transmitida de volta a bateria descrita por equação (12):

$$P_{el,in} = P_{Rodas} \cdot \eta_G + P_0 \quad (12)$$

onde  $\eta_G$  é a eficiência da transmissão mecânica e conversor de energia.

Para estimar a demanda total de energia de uma viagem, a potência elétrica  $P_{el}$  fluindo para dentro ou para fora da bateria é integrada ao longo do tempo T é expressa pela equação (13):

$$E_{el} = \int_0^T P_{el} dt \quad (13)$$

Esta equação pode ser utilizada como primeira aproximação da demanda de energia, mas tem uma limitada exatidão devido as condições do percurso que não possam ser contabilizadas (segmentação). Para que o consumo de energia seja estimado levando em conta as particularidades da condução e do terreno em trechos menores, é sugerida a equação (14):

$$E_{total} = \sum d_k E_{el} C_k \quad (14)$$

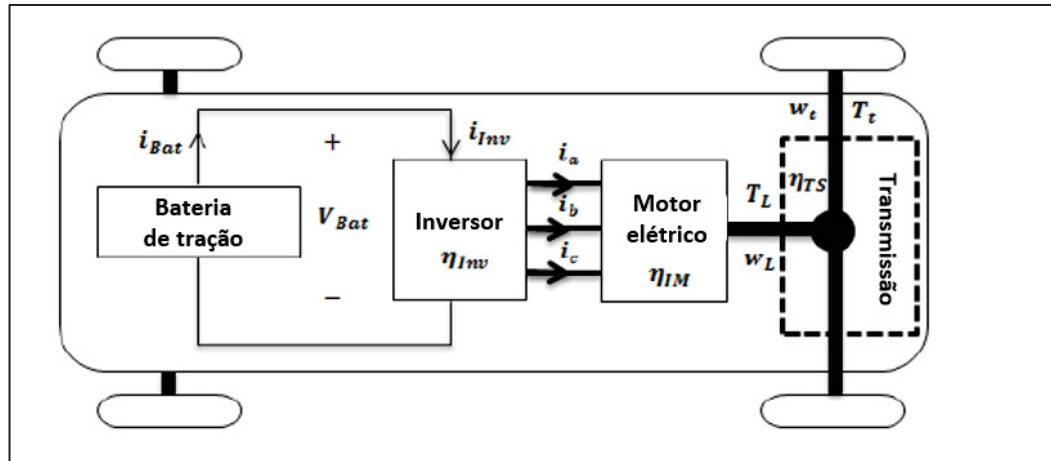
onde  $d_k$  (em m) denota o comprimento do trecho  $k$  da rota e  $E_{el} C_k$  (em Wh/m) denota o consumo de energia por unidade de distância para a rota trecho  $k$ . A divisão do roteiro em trechos menores requer uma complexidade maior de cálculo e um maior tempo de tratamento dos dados. Esta divisão para trechos com mais declives e aclives deve ser menor para considerar os efeitos positivos e negativos no consumo de energia com maior exatidão.

Como mostrado na equação (3) é necessário o desenvolvimento de um banco de dados de fatores fundamentais do veículo, como especificações técnicas disponíveis, para obter uma primeira estimativa do consumo.

## 4.2 MODELAMENTO COMPUTACIONAL

Na realização deste trabalho foram consultadas ferramentas de simulação de consumo energético de veículos elétricos. A ferramenta *ADvanced Vehicle SimulatOR* (ADVISOR) (NREL, 2003) disponibiliza uma interface para calcular os consumos energéticos e emissões de veículos a partir dos dados detalhados, os quais são conhecidos pelos fabricantes, unicamente. O *Future Automotive Systems Technology Simulator* (FASTSim) (NREL, 2015) é um modelo de simulação do conjunto motriz de veículo de alto nível que exige dados confidenciais em relação às características do veículo. Dado o escopo do trabalho, optou-se a utilização dos dados públicos disponíveis do programa PBEV que consideram os procedimentos de preparação e realização de testes seguindo a norma SAE J1634 (SAE, 2021). Os componentes que caracterizam um veículo elétrico são: sistema de armazenamento de energia, transmissão, motor elétrico e inversor eletrônico de potência, como indicado na FIGURA 35 (SARRAFAN, 2017).

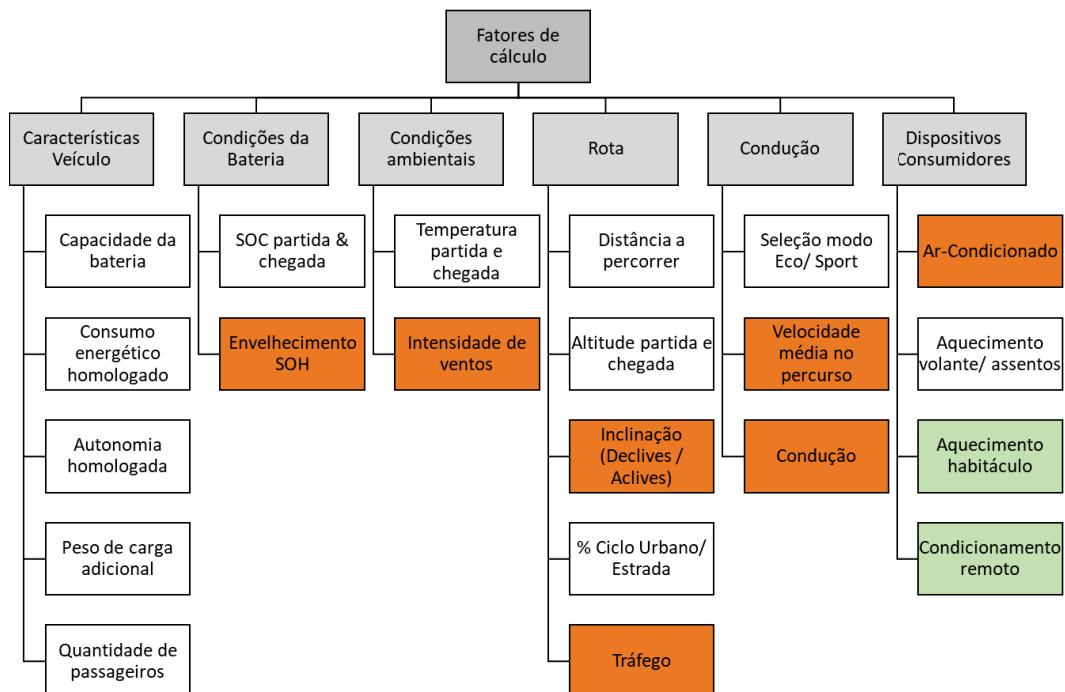
FIGURA 35: ESQUEMA SIMPLIFICADO DE UM VEÍCULO ELÉTRICO



FONTE: ADAPTADO DE SARRAFAN ET AL. (2017)

Para avaliar a capacidade do veículo de atingir o destino é necessário incluir fatores como o estado de carga da bateria SOC, condições ambientais, características da rota, modo de condução e utilização de consumidores extras, como demonstrados na FIGURA 36.

FIGURA 36: FATORES DE CÁLCULO NA AUTONOMIA



FONTE: AUTOR (2024)

O método desenvolvido para o cálculo da autonomia determina se a rota traçada pode ser executada dadas as condições indicadas, como apresentada na equação (15):

$$\Delta D = D_{exec} - D_{obj} \quad (15)$$

onde  $\Delta D$  é a diferença de distância,  $D_{exec}$  é a máxima distância possível considerando os fatores de cálculo e  $D_{obj}$  é a distância objetivo a realizar. Se  $\Delta D < 0$ , não é possível realizar o percurso com as condições apresentadas.

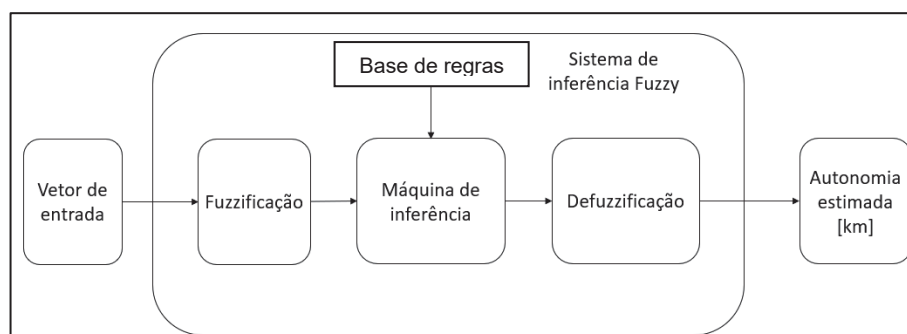
A máxima distância possível  $D_{exec}$  em km é descrita na equação (17):

$$D_{exec} = \frac{E_{bat} * F_{cons}}{CE_{misto}} \quad (16)$$

onde  $E_{bat}$  é a capacidade atual da bateria em kWh,  $F_{cons}$  é o fator calculado que engloba os parâmetros que influenciam o consumo energético e  $CE_{misto}$  é o consumo energético homologado em kWh/100 km, ponderado pela utilização do ciclo urbano e estrada.

A segunda parte do modelamento do consumo energético utiliza o método computacional em lógica nebulosa (*Fuzzy Logic*). O modelo conceitual, apresentado na FIGURA 37, é desenvolvido com base na estimativa metodológica da *Fuzzy Logic Classifier* (FLC).

FIGURA 37: MODELO CONCEITUAL PARA CLASSIFICADOR COM LÓGICA FUZZY PARA ESTIMATIVA DE AUTONOMIA



FONTE: AUTOR (2024)



Um controlador nebuloso (ZADEH, 1973) é um conjunto de regras de produção do tipo **SE** <premissa>, **ENTÃO** <conclusão>, que definem ações de controle em função das diversas faixas de valores que as variáveis de estado do problema podem assumir. Estas faixas de valores são modeladas por conjuntos nebulosos e denominados por termos linguísticos. A maior dificuldade na criação de sistemas nebulosos em geral, e de controladores nebulosos em particular, encontra-se na definição dos termos linguísticos e das regras.

A determinação dos fatores da interface de “fuzzificação” foi baseada em fontes bibliográficas e propostas pelos fabricantes de equipamentos. O processo é interativo no momento que a base de dados possa ser incorporada ou que a base de regras seja revista. A integração da base de dados mais ampla irá determinar uma maior robustez e acuracidade ao modelo proposto (SUN ET AL., 2019).

Os parâmetros do vetor de entrada são disponibilizados pelo modelo de acordo com o veículo e características de uso. O sistema de inferência produz a saída do classificador processando as regras. Na última etapa, o mecanismo de inferência calcula a autonomia final.

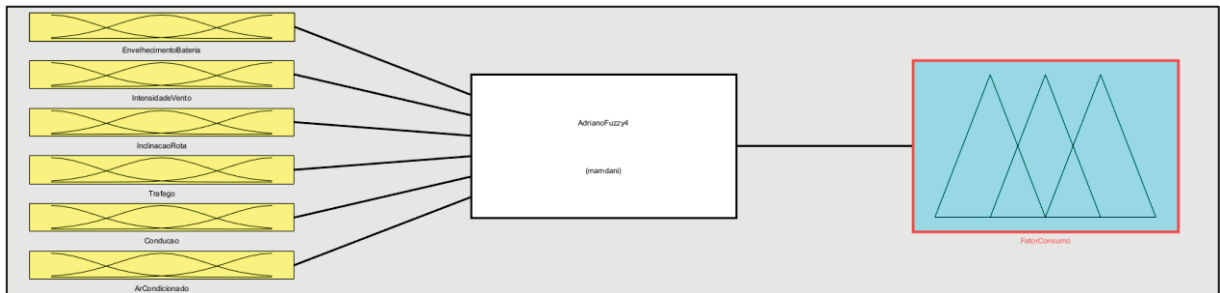
Para a simulação de autonomia de veículos elétricos deste projeto, foram determinados os seguintes fatores de influência, marcados em laranja na FIGURA 36:

- Condições da bateria:
  - Envelhecimento da bateria SOH
- Condições ambientais
  - Intensidade dos ventos
- Rota
  - Inclinação (declives e aclives)
  - Condição de tráfego
- Modo de condução
  - Estilo de condução
  - Velocidade média do percurso
- Dispositivos consumidores
  - Ar-Condicionado

Os itens não destacados são considerados como dados de entrada do modelo e itens marcados em verde não serão considerados neste modelo como aquecimento do habitáculo, condicionamento remoto por se tratar de dispositivos não comumente usados em países com temperaturas médias acima de 10°C, como o Brasil.

Na FIGURA 38 apresenta-se o escopo do modelo de inferência, como os conjuntos nebulosos a esquerda, o conjunto de regras Mandami ao centro e o fator de consumo do modelo a direita.

FIGURA 38: ESQUEMÁTICO DO FATOR  $F_{cons1}$



FONTE: AUTOR (2024)

O fator de consumo  $F_{cons}$  descrito na equação (17) é o fator a ser modelado pela lógica Fuzzy. Ele contém o parâmetro final de ajuste da autonomia homologada.

$$F_{cons} = F_{cons1} \cdot F_{cons2} \quad (17)$$

Sendo que o fator  $F_{cons1}$  incorpora os fatores relativos ao envelhecimento da bateria, intensidade de vento, inclinação da rota, condições de tráfego, estilo de condução e uso do ar-condicionado. Já o fator  $F_{cons2}$  contém o fator de velocidade de deslocamento em cada amostra de trecho (conjunto de segmentos) percorrida. Este fator permite o modelo da lógica Fuzzy a levar em conta o fato que a maior parte da energia gasta no deslocamento é dispensada para conter o arrasto aerodinâmico, como descrito na equação **Erro! Fonte de referência não encontrada.**

Os fatores utilizados para o modelamento em lógica nebulosa são descritos nos capítulos seguintes.

#### 4.2.1 ENVELHECIMENTO DA BATERIA SOH

O envelhecimento da bateria SOH é nível de degradação da capacidade de armazenamento de energia, representada como uma porcentagem da sua capacidade inicial. Este fator pode ser informado através de equipamentos dedicados ou aplicativos. Foram considerados três condições (nova, usada, velha) em função da quilometragem acumulada, como mostrado na FIGURA 39.


O conjunto nebuloso “Velha” foi adotado com forma trapezoidal e parâmetros [0,70 0,70 0,75 0,8], o conjunto nebuloso “Usada” foi adotado com forma trapezoidal e parâmetros [0,78 0,80 0,95 0,97] e o conjunto nebuloso “Nova” foi adotado com forma trapezoidal e parâmetros [0,95 0,98 1,00 1,00].

A condição de bateria nova é determinada por ter entre 0 e 2 anos de uso ou uma quilometragem acumulada de 80.000 km o que representaria para um veículo de autonomia de 400 km, valor aproximado para o veículo testado com uma bateria de 60 kWh, um acúmulo de 200 ciclos de carga e recarga. Se consideramos que as baterias foram projetadas para mais de 2000 ciclos de carga e recarga, isso representaria 5% do total da vida útil. O envelhecimento pode ser acelerado se as condições de uso da bateria forem com maior temperatura, maior profundidade de descarga (DoD), taxa de descarga (fator C), quantidade de cargas rápidas, entre outros (CASALS ET AL., 2022)

Para este projeto foi considerada a hipótese que a condição de bateria usada é determinada por ter entre 2 e 8 anos de uso, com um acúmulo de 320.000 km, o que representaria um total de 800 ciclos de carga e recarga e cerca de 20% do total da vida útil.

A condição de bateria velha é determinada por ter mais de oito anos de uso e que consegue armazenar até 80% da capacidade original (SOH) de uma bateria nova.

FIGURA 39: FATOR DE ENVELHECIMENTO DA BATERIA



FONTE: AUTOR (2024)

#### 4.2.2 INTENSIDADE DO VENTO

A Intensidade do vento impacta o consumo em velocidade mais altas, como no caso de rodagem em estrada. Para simplificação, a velocidade do vento se soma


a velocidade do veículo para se obter a força de arrasto. São consideradas as condições no momento de partida do veículo, sendo fraco, médio e forte, de acordo com a velocidade, como mostrado na FIGURA 40. Para simplificar o processo de modelamento, não foram considerados a direção relativa (longitudinal ou transversal) ao movimento do veículo.

O conjunto nebuloso “Fraco” foi adotado com forma trapezoidal e parâmetros [0 0 20 30], o conjunto nebuloso “Médio” foi adotado com forma trapezoidal e parâmetros [25 35 55 65] e o conjunto nebuloso “Forte” foi adotado com forma trapezoidal e parâmetros [60 75 100 100].

Baseado na escala de vento de Beufort, que se encontra no Anexo II, consideramos o vento fraco com uma velocidade até 10 km/h, como uma leve brisa e que faz a vegetação levemente se inclinar. O vento médio é caracterizado por fazer a vegetação media se mover com mais intensidade (pequenos galhos) e uma velocidade de até 20 km/h. Para ventos acima de 20 km/h, quando as folhas se desprendem das arvores e as copas da arvores balançam, considera-se que os ventos são fortes. Este método de avaliação dos ventos foi usado durante o percurso de avaliações.

A direção do vento e intensidade do vento interfere na energia consumida no deslocamento na proporção cúbica conforme descrito pela equação **Erro! Fonte de referência não encontrada.**

FIGURA 40: FATOR DE INTENSIDADE DE VENTO



FONTE: AUTOR (2024)

#### 4.2.3 INCLINAÇÃO DA ROTA


A resistência ao movimento devido a inclinação da rota, como visto na equação (4)(4)(4)(4), tem um impacto importante na autonomia. Para este projeto, tomou-se como hipótese cinco classificações, sendo “AcliveForte”, “AcliveLeve”, “Plano”, “DecliveLeve” e “DecliveForte”, em função da percentagem de altitude total variada em relação a quantidade de quilômetros acumulada, como mostrado na FIGURA 41. Esta classificação pode ser expandida no caso que o trecho a ser percorrida contenha trechos com aclives e declives mais acentuados, como encontrados em zonas mais montanhosas.

O conjunto nebuloso “AcliveForte” foi adotado com forma trapezoidal e parâmetros [0,0350 0,5023 0,0800 0,0800], o conjunto nebuloso “AcliveLeve” foi adotado com forma trapezoidal e parâmetros [0,0073 0,0220 0,0339 0,0474], o conjunto nebuloso “Plano” foi adotado com forma trapezoidal e parâmetros [-0,0150 -0,0053 0,0064 0,0150], o conjunto nebuloso “DecliveLeve” foi adotado com forma trapezoidal e parâmetros [-0,0381 -0,0238 -0,0138 -0,0031] e o conjunto nebuloso “DecliveForte” foi adotado com forma trapezoidal e parâmetros [-0,1000 -0,1000 -0,0391 -0,0283].

O conjunto nebuloso “Acliveforte” se caracteriza com uma inclinação positiva superior a 10% (ganho de altitude em relação ao percurso total), típica em subidas de serras nas costas brasileiras. Para o conjunto nebuloso “AcliveLeve” foi considerado uma inclinação entre 5% e 10%, que se encontra em cadeias de trajetos nas planícies. O conjunto nebuloso “Plano” se considera os trechos com inclinação inferior a 5%, positiva ou negativa. O conjunto nebuloso “DecliveLeve” foi considerado para uma inclinação negativa de até 10% e o conjunto nebuloso “DecliveForte” foi adotado para inclinação negativa acima de 10%.

Devido ao impacto na energia consumida, expressada pela equação (7), estes conjuntos nebulosos devem ser criteriosamente ajustados para cada trecho, sabendo que quanto mais segmentado for o trecho a percorrer, mais exato poderá ser o resultado da simulação.

FIGURA 41: FATOR DE INCLINAÇÃO DE ROTA



FONTE: AUTOR (2024)

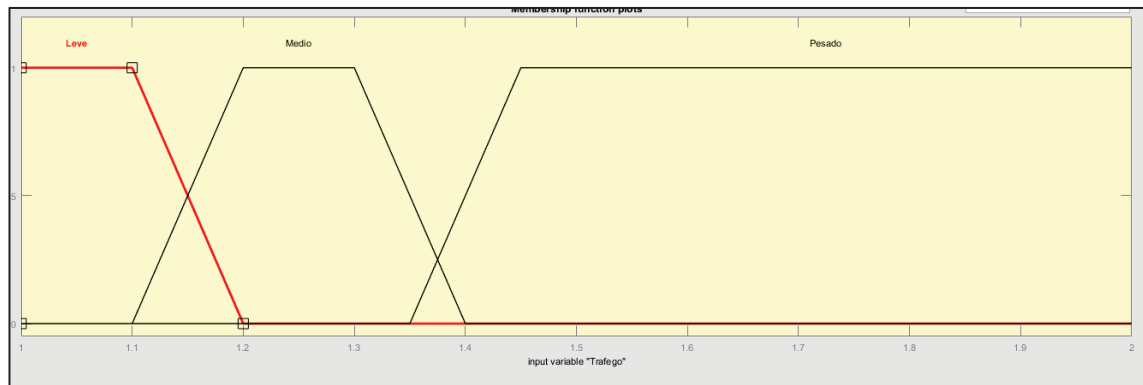
#### 4.2.4 TRÁFEGO

A intensidade do tráfego é considerada relevante para os veículos elétricos, pois ainda que o consumo de energia em modo parado seja somente dos consumidores elétricos, deve-se tomar em conta o movimento do veículo que não consegue desenvolver uma velocidade contínua e assim poder recuperar a energia quando o movimento é interrompido. Se considera três condições, sendo tráfego leve, médio e pesado, como mostrado na FIGURA 42. As hipóteses foram baseadas de acordo com Dib et al. (2014).

Para este projeto, se tomou como hipótese o conjunto nebuloso “Leve” foi adotado com forma trapezoidal e parâmetros [1,000 1,000 1,2000 1,2000], o conjunto nebuloso “Médio” foi adotado com forma trapezoidal e parâmetros [1,1000 1,2000 1,3000 1,4000] e o conjunto nebuloso “Pesado” foi adotado com forma trapezoidal e parâmetros [1,3500 1,4500 2,0000 2,0000].

O conjunto nebuloso “Leve” deve ser considerado que o veículo alcança o destino na rota planejada com um tempo aceitável, por exemplo até 10 minutos a mais para um tempo estimado de 30 minutos. Para um conjunto nebuloso “Médio”, o tempo aceitável seria de até 20 min a mais para um tempo previsto de 30 minutos, e para o conjunto nebuloso “Pesado”, o tempo seria acima de 20 min para um tempo previsto de 30 minutos.

FIGURA 42: FATOR DE INTENSIDADE DE TRÁFEGO



FONTE: AUTOR (2024)

#### 4.2.5 CONDUÇÃO


O modo de condução pode ser caracterizado por diferentes maneiras, em função das mudanças bruscas em acelerações e desacelerações, agressividade para retomar a velocidade de cruzeiro, utilização mais acentuada do freio regenerativo. Para este projeto, se considerou três condições sendo a condução calma, normal e agressiva, como mostrado na

FIGURA 43. A hipótese foi elaborada conforme estudo de Blaszczyk e Kopeć (2022) e Günther et al. (2017).

O conjunto nebuloso “Calmo” foi adotado com forma trapezoidal e parâmetros [0,8000 0,8000 0,8700 0,9300], o conjunto nebuloso “Normal” foi adotado com forma triangular e parâmetros [0,9000 1,0000 1,1000] e o conjunto nebuloso “Agressivo” foi adotado com forma trapezoidal e parâmetros [1,0500 1,1500 1,2000 1,2000].

O conjunto nebuloso “Calmo” é considerado quando o motorista mantém uma velocidade mais constante, evitando ultrapassagens desnecessárias e utilizando do efeito de regeneração nas frenagens quando possível. O conjunto nebuloso “Normal” além das boas práticas da condução Calma, é frequente acelerações mais fortes para alcançar uma velocidade mais elevada rapidamente, mas sem abusos. Já na condução considerado como conjunto nebuloso “Agressivo”, o motorista tem uma capacidade de manobra mais elevada, empregando fortes acelerações e freadas, sem tirar o benefício da inércia de movimentação do veículo.

FIGURA 43: FATOR DE CONDUÇÃO



FONTE: AUTOR (2024)

#### 4.2.6 AR-CONDICIONADO


A escolha da temperatura da cabine em função da temperatura externa, condições de insolação, isolamento térmico impacta diretamente na quantidade de energia consumida pelos equipamentos como o compressor, ventiladores e aquecedores. No caso do modelo, foram considerados a diferença de temperatura da cabine e do ambiente como leve, média e alta, como mostrado na FIGURA 44. A hipótese foi construída com base em Doyle e Muneer (2019).

O conjunto nebuloso “Leve” e foi adotado com forma trapezoidal e parâmetros [0,0000 0,0000 4,0000 5,0000], o conjunto nebuloso “Media” foi adotado com forma triangular e parâmetros [4,0000 6,0000 8,0000 10,0000] e o conjunto nebuloso “Alta” foi adotado com forma trapezoidal e parâmetros [6,0000 10,0000 20,0000 20,0000].

O conjunto nebuloso “Leve” é caracterizado quando a diferença de temperatura é menor que 5°C, o conjunto nebuloso “Médio” se caracteriza quando a diferença de temperatura está entre 6° a 10°C e para diferenças acima de 10° se caracteriza como conjunto nebuloso “Alta”. Estas regiões podem variar de acordo com a intensidade de elementos externos, como incidência solar, tempo que o carro ficou exposto ao calor, frio, sem se locomover, quantidade de pessoas dentro de veículo, entre outras.



FIGURA 44: FATOR DE AR-CONDICIONADO




FONTE: AUTOR (2024)

#### 4.2.7 FATOR DE CONSUMO 1

O fator  $F_{cons1}$  caracteriza o impacto na autonomia calculada dos fatores acima descritos. Em função das condições em cada amostra de trecho (conjunto de segmentos), o impacto no fator de consumo poderá ser vermelho (fator que aumenta o consumo kWh/100 km e reduz autonomia em km), amarelo, verde ou azul (fator que reduz o consumo kWh/100 km e aumenta a autonomia em km), como mostrado na FIGURA 45. Para o estabelecimento de regras, se procurou colocar as condições mais frequentes e as mais extremas, para se determinar os possíveis resultados do modelo proposto.

O conjunto nebuloso "Vermelho" foi adotado com forma trapezoidal e parâmetros [0,5000 0,5000 0,6500 0,7500], o conjunto nebuloso "Amarelo" foi adotado com forma trapezoidal e parâmetros [0,6760 0,7760 0,87560 0,95560], o conjunto nebuloso "Verde" foi adotado com forma trapezoidal e parâmetros [0,9550 0,9800 1,0400 1,0504], o conjunto nebuloso "Azul" foi adotado com forma trapezoidal e parâmetros [1,0540 1,0800 1,2000 1,2000].

FIGURA 45: FATOR DE CONSUMO 1



FONTE: AUTOR (2024)

Após selecionados os conjuntos nebulosos, define-se o conjunto de regras para Mamdani que relaciona os conjuntos com o fator de consumo. As propostas iniciais foram feitas considerando uma relação única entre os conjuntos e o fator, e não relacionando os conjuntos entre si.


1. Se (EnvelhecimentoBateria é Nova) então (FatorConsumo é Verde)
2. Se (EnvelhecimentoBateria é Usada) então (FatorConsumo é Amarelo)
3. Se (EnvelhecimentoBateria é Velha) então (FatorConsumo é Vermelho)
4. Se (IntensidadeVento é Fraco) então (FatorConsumo é Verde)
5. Se (IntensidadeVento é Medio) então (FatorConsumo é Amarelo)
6. Se (IntensidadeVento é Forte) então (FatorConsumo é Vermelho)
7. Se (InclinaçãoRota é Plano) então (FatorConsumo é Verde)
8. Se (InclinaçãoRota é DecliveLeve) então (FatorConsumo é Verde)
9. Se (InclinaçãoRota é DecliveForte) então (FatorConsumo é Azul)
10. Se (InclinaçãoRota é AcliveLeve) então (FatorConsumo é Amarelo)
11. Se (InclinaçãoRota é AcliveForte) então (FatorConsumo é Vermelho)
12. Se (Tráfego é Leve) então (FatorConsumo é Verde)
13. Se (Tráfego é Medio) então (FatorConsumo é Verde)
14. Se (Tráfego é Pesado) então (FatorConsumo é Amarelo)
15. Se (Condução é Calmo) então (FatorConsumo é Azul)
16. Se (Condução é Normal) então (FatorConsumo é Verde)
17. Se (Condução é Agressivo) então (FatorConsumo é Amarelo)
18. Se (ArCondicionado é Leve) então (FatorConsumo é Verde)
19. Se (ArCondicionado é Media) então (FatorConsumo é Verde)
20. Se (ArCondicionado é Alta) então (FatorConsumo é Amarelo)

#### 4.2.8 FATOR DE CONSUMO 2

O fator  $F_{cons2}$  contém o fator de velocidade de deslocamento, expressa em (km/h) em cada amostra de trecho (conjunto de segmento) percorrida. No decurso das avaliações dos dados deste projeto, verificou-se que o modelo proposto deveria conter um fator que descrevesse a influência do arrasto aerodinâmico com maior precisão uma vez que a equação **Erro! Fonte de referência não encontrada.** evidencia este fato.

Para a velocidade de deslocamento foram estabelecidos cinco conjuntos nebulosos de velocidade, como mostrado na FIGURA 46. O conjunto nebuloso “Lento” foi adotado com forma trapezoidal e parâmetros [0,0000 0,0000 30,3000 40,5700], o conjunto nebuloso “Médio” foi adotado com forma trapezoidal e parâmetros [30,0000 45,0000 55,0000 65,0000], o conjunto nebuloso “Médio-Veloz” foi adotado com forma trapezoidal e parâmetros [56,4000 59,6000 101,0000 107,70000], o conjunto nebuloso “Veloz” foi adotado com forma trapezoidal e parâmetros [105,1000 109,0000 124,0000 132,0000] e o conjunto “SuperVeloz” foi adotado com forma trapezoidal e parâmetros [117,3000 132,3000 187,3000 187,3000]

FIGURA 46 : FATOR DE VELOCIDADE




FONTE: AUTOR (2024)

O fator  $F_{cons2}$  caracteriza o impacto na autonomia calculada pela velocidade de deslocamento, conforme a FIGURA 47. Ele é estabelecido através do conjunto de regras para Mandami que relaciona os conjuntos nebulosos com o fator de consumo:

- Se (Velocidade é Lento) então (FatorConsumo é Azul)
- Se (Velocidade é Médio) então (FatorConsumo é Verde)
- Se (Velocidade é Médio-Veloz) então (FatorConsumo é Verde)
- Se (Velocidade é Veloz) então (FatorConsumo é Amarelo)

- Se (Velocidade é SuperVeloz) então (FatorConsumo é Vermelho)

FIGURA 47 : FATOR DE CONSUMO DE VELOCIDADE



FONTE: AUTOR (2024)

### 4.3 DESCRIÇÃO DO VEÍCULO TESTADO E PERCURSO REALIZADO

A avaliação do modelo proposto foi realizada com um veículo elétrico da fabricante Renault, com as características da TABELA 12:

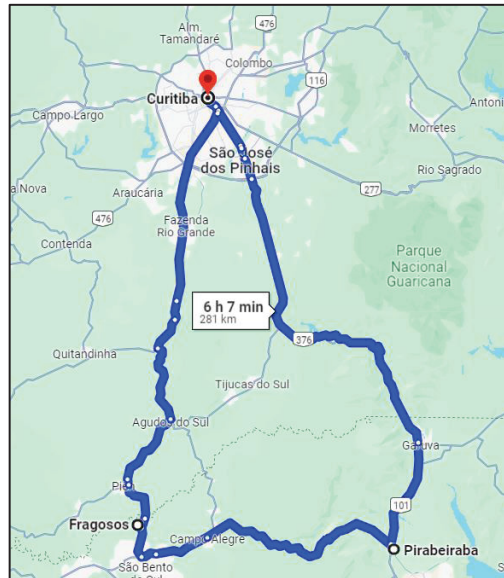
TABELA 12: CARACTERÍSTICAS DO VEÍCULO ELÉTRICO

Fabricante	Renault
Modelo	Megane E-Tech
Capacidade bateria	60 kWh
Potência / Torque	160 kW / 220 Nm
Carregador de Bateria	AC 2,2 - 22 kW DC máximo 130 kW
Peso líquido mínimo	1636 kg
Peso bruto máximo	2158 kg
Autonomia Combinada (PBEV)	337 km
Consumo Energético combinado (PBEV)	0,51 MJ/km
Autonomia Ciclo Urbano (sem fator de correção)	495 km
Autonomia Ciclo Estrada (sem fator de correção)	464 km
Consumo energético urbano (sem fator de correção)	13,6 kWh/100 km
Consumo energético estrada (sem fator de correção)	14,5 kWh/100 km
Distância Acumulada (hodômetro)	15577 km

FONTE: AUTOR (2024)

O percurso escolhido envolveu o deslocamento entre Curitiba (PR) a Joinville (SC) sem ponto de carregamento intermediário, com 281 km de distância de acordo com Google Maps, como mostrado na FIGURA 48.


FIGURA 48: TRAJETO PLANEJADO CURITIBA A JOINVILLE



FONTE: GOOGLE MAPS (2024)

De acordo com o PlugShare, identificado pela FIGURA 49, a distância a percorrer soma 280 km com um declive acentuado a partir da distância percorrida de 130 km (TRECHO 2), um plano de 60 km (TRECHO 3) e um acive acentuado (TRECHO 4) a partir de 190 km do ponto de partida.

FIGURA 49: ALTIMETRIA TRAJETO PLANEJADO CURITIBA A JOINVILLE



FONTE: ADAPTADO PLUGSHARE (2024)

Como instrumentos de aquisição de medição do percurso, foi usado o aplicativo Wikiloc ([pt.wikiloc.com](http://pt.wikiloc.com)), o qual permite o registro e pós-processamento dos dados brutos num arquivo com extensão “.GPX” editável. A taxa de aquisição foi de aproximadamente um conjunto de dados (tempo, latitude, longitude, altitude) por segundo. Os principais dados foram registrados em tabelas acompanhados de registros fotográficos. Os registros de latitude e longitude foram transformados em unidade de distância usando a equação de Haversine da trigonometria esférica. Para estes cálculos, utilizou-se um raio médio da esfera terrestre de 3963 quilômetros. A imprecisão dos cálculos aumenta conforme se afasta da linha do Equador.

## 5 TESTES E RESULTADOS

### 5.1 ROTEIRO INICIAL

Para o roteiro de Curitiba a Joinville com retorno a Curitiba, os resultados obtidos são apresentados na TABELA 13 e FIGURA 50.

TABELA 13: RESULTADOS DO TRAJETO PERCORRIDO

<b>Trecho</b>	<b>Unidade</b>	<b>Trecho</b>
Local partida	-	Curitiba
Local chegada	-	Curitiba
Temperatura partida	°C	19
Tempo de deslocamento	h	03:50
Distância de deslocamento	km	283
Consumo Energético informado Veículo	kWh/ 100 km	15,10
Consumo Energético calculado	kWh/ 100 km	16,90
Energia utilizada	kWh	48
SOC chegada	%	20
Uso bateria	%	80

FONTE: AUTOR (2024)

FIGURA 50: TRAJETO PERCORRIDO CURITIBA A JOINVILLE



FONTE: WIKILOC (2024)

Para este trajeto, foram calculados os dados relativos à altitude e desníveis conforma a TABELA 14.

TABELA 14: DADOS RELATIVOS À ALTITUDE


Trecho	Unidade	Trecho 1
Total de pontos aqisitados	-	10912
Local Partida	-	Curitiba
Local Chegada		Curitiba
Elevação Máxima	m	996
Elevação Mínima	m	7
Desnível Positivo	m	3511
Desnível Negativo	m	3511

FONTE: AUTOR (2024)

O registro da elevação do trecho percorrido é mostrado na FIGURA 51, onde na abcissa tem-se os segmentos registrados e na ordenada a altitude encontrada.



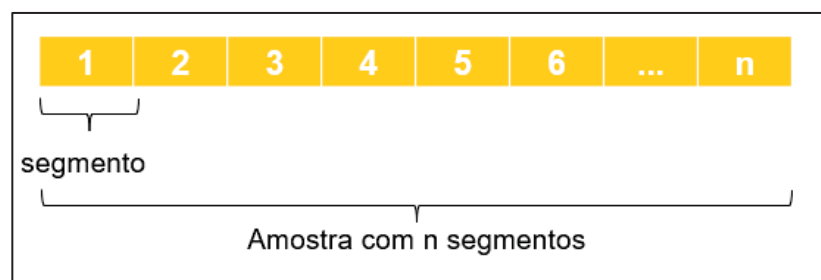
FIGURA 51: ALTIMETRIA DO PERCURSO



FONTE: AUTOR (2024)

Para que a contabilização dos trechos seja representativa em relação a velocidade média e inclinação média do trecho, foram testados amostras com a soma de 10 segmentos FIGURA 53, com a soma de 25 segmentos FIGURA 54, com a soma de 100 segmentos FIGURA 55 e com a soma de 300 segmentos FIGURA 56. Após análises realizadas com os dados adquiridos e a variação dos resultados com os parâmetros dos conjuntos nebulosos, se decidiu tomar o padrão de 25 segmentos por amostras e efetuar os cálculos finais. Na FIGURA 52 apresenta-se a composição de amostra por segmentos.


FIGURA 52: COMPOSIÇÃO DE AMOSTRA POR SEGMENTOS



FONTE: AUTOR (2024)


Como o tempo de aquisição é próximo de um segmento por segundo, a distância percorrida por segmento (em metros) é um indicador da velocidade média no segmento. Quanto maior a distância percorrida no tempo medido, maior a velocidade. Pode-se perceber que na FIGURA 56 as variações de velocidade são menores do que na FIGURA 54 e isso resulta numa menor sensibilidade para trechos com grandes variações de velocidade.

FIGURA 53: 10 SEGMENTOS POR AMOSTRA




FONTE: AUTOR (2024)

FIGURA 54: 25 SEGMENTOS POR AMOSTRA




FONTE: AUTOR (2024)

FIGURA 55: 100 SEGMENTOS POR AMOSTRA



FONTE: AUTOR (2024)


FIGURA 56: 300 SEGMENTOS POR AMOSTRA



FONTE: AUTOR (2024)

O resultado com 25 segmentos por amostra resulta na velocidade média calculada de 436 amostras, conforme FIGURA 57.

FIGURA 57: VELOCIDADE MÉDIA NOS SEGMENTOS PARA 25 SEGMENTOS POR AMOSTRA




FONTE: AUTOR (2024)

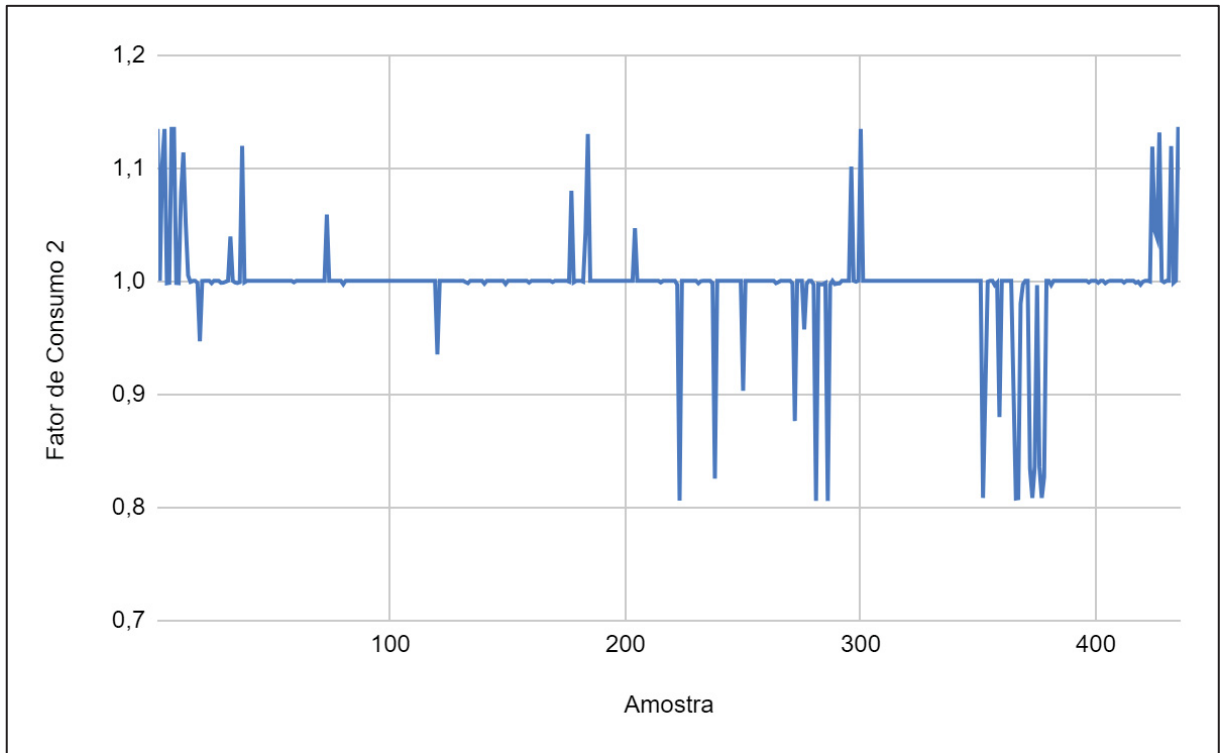
As informações de SOC da bateria (em %) e consumo auferido (em kWh/100 km) foram coletadas no veículo testado ao final do percurso.

Após a execução do modelo em lógica Fuzzy e considerando os dados do trajeto, os fatores  $F_{cons1}$  e  $F_{cons2}$  obtidos são apresentados na FIGURA 58 e FIGURA 59.

FIGURA 58: FATOR DE CONSUMO  $F_{cons1}$




FONTE: AUTOR (2024)

FIGURA 59: FATOR DE CONSUMO  $F_{cons2}$ 

FONTE: AUTOR (2024)


O fator final  $F_{cons}$  que exprime por amostra a correção nos parâmetros de autonomia é apresentado na FIGURA 60.

FIGURA 60: FATOR DE CONSUMO  $F_{cons}$ 

FONTE: AUTOR (2024)


A autonomia do trajeto atualizada com a distância percorrida (em quilômetros) e cada amostra coletada (contendo 25 segmentos por amostra) está mostrada na FIGURA 61 e FIGURA 62. Ao se comparar as curvas, pode-se verificar as influências dos cálculos de fator de consumo  $F_{cons}$  no trecho realizado.

FIGURA 61: AUTONOMIA EM FUNÇÃO DA DISTÂNCIA PERCORRIDA



FONTE: AUTOR (2024)

FIGURA 62: AUTONOMIA EM FUNÇÃO DA AMOSTRA COLETADA




FONTE: AUTOR (2024)

No trecho delimitado entorno do ponto central da amostra 200, pode-se conferir a mudança efetuada na autonomia ao longo das amostras, conforme a FIGURA 63.



FIGURA 63 : AUTONOMIA NO TRECHO DELIMITADO

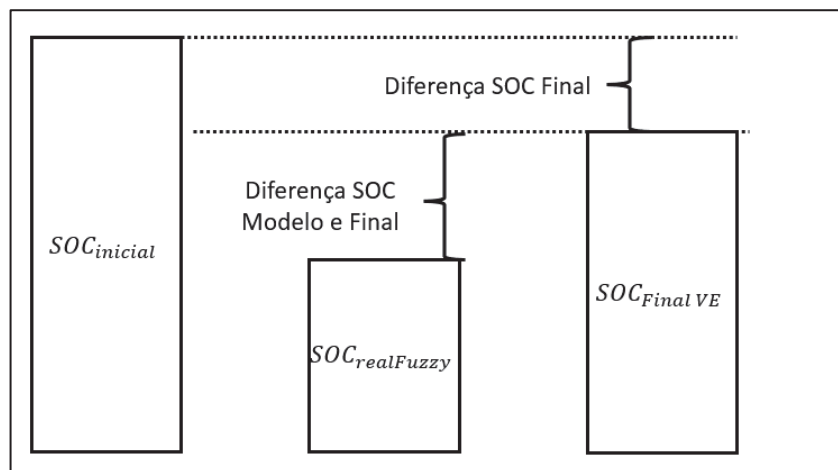


FONTE: AUTOR (2024)

A equação (18) representa o erro da estimativa  $SOC_{realFuzzy}$  em relação a diferença entre o  $SOC_{inicial}$  e  $SOC_{FinalVE}$ , como indicado na FIGURA 64.

$$ErroRelativo[\%] = \frac{(SOC_{FinalVE} - SOC_{realFuzzy})}{(SOC_{inicial} - SOC_{FinalVE})} \quad (18)$$

FIGURA 64: ERRO RELATIVO DE ESTIMAÇÃO MODIFICADO



FONTE: AUTOR (2024)

O resultado da modelo proposto para o trecho realizado  mostrado na TABELA 15.

TABELA 15: RESULTADO DO MODELO EM LÓGICA NEBULOSA

Trecho	Unidade	Trecho 1
Distância percorrida	km	283
Energia Partida	kWh	60
Autonomia restante real	km	83
Autonomia restante simulada	km	127
SOC real HMI	%	20,00
SOC Fuzzy	%	31,22
Erro Relativo Fuzzy	%	- 14
SOC ABRP	%	32,00
Erro Relativo ABRP	%	-15

FONTE: AUTOR (2024)

O valor de SOC Fuzzy de 31,22% difere de 2,50% do valor SOC calculado pelo ABRP de 32% para o trajeto realizado.

## 5.2 ROTEIROS COMPLEMENTARES

Na sequência, foram efetuados os cálculos para roteiros complementares utilizando o mesmo veículo inicial, variando-se as velocidades médias e as condições de rodagem, conforme apresentado na TABELA 16.


TABELA 16: RESULTADO DE ROTEIROS COMPLEMENTARES

Trecho		2	3	4	5	6	7
Partida		Curitiba	Serra do Relógio	São José dos Pinhais	Registro	São Paulo	Registro
Chegada		Serra do Relógio	Curitiba	Registro	São Paulo	Registro	São José dos Pinhais
Distância percorrida	km	207	209	202	199	185	211
Consumo final	kWh/100 km	14	16	13	16	12	17
Autonomia restante calculada	km	228	244	259	239	289	210
Autonomia restante real	km	190	159	210	156	275	122
SOC real veículo	%	45	41	52	42	61	35
SOC real Fuzzy	%	44	44	50	51	56	46
SOC ABRP	%	49	46	54	41	55	35
Erro relativo Fuzzy	%	2	-5	3	-16	11	-18
Erro Relativo ABRP	%	-7	-8	-4	2	15	0

FONTE: AUTOR (2024)

As altimetrias envolvidas no trecho percorrido de Curitiba - PR à Serra do Relógio - PR é representada pela FIGURA 65.


FIGURA 65 : ALTIMETRIA TRECHO CURITIBA (PR) À SERRA DO RELOGIO (PR)



FONTE: AUTOR (2024)


As altimetrias envolvidas no trecho percorrido de São José dos Pinhais – PR a Registro – SP é representada pela FIGURA 66 e de Registro - SP a São Paulo – SP é representada pela FIGURA 67.

FIGURA 66 : ALTIMETRIA TRECHO SÃO JOSÉ DOS PINHAIS (PR) A REGISTRO (SP)



FONTE: AUTOR (2024)

FIGURA 67 : ALTIMETRIA TRECHO REGISTRO (SP) A SÃO PAULO (SP)



FONTE: AUTOR (2024)

### 5.3 DISCUSSÃO DOS RESULTADOS

O modelo computacional desenvolvido com a lógica nebulosa para calcular a autonomia de veículos possibilita a adequação dos parâmetros que mais influenciam a autonomia de modo rápido, sem o emprego de equações matemáticas complexas e sem uma base de dados extensa.

Para o veículo testado nos trajetos realizados, o resultado do Erro Relativo expresso pela equação (18) calculado pela metodologia Fuzzy é compilado na

TABELA 17.

TABELA 17 : SUMÁRIO DE ERROS RELATIVOS

Trecho		1	2	3	4	5	6	7
Erro relativo Fuzzy	%	-14	2	-5	3	-16	11	-18
Erro relativo ABRP	%	-15	-7	-8	-4	2	15	0

FONTE: AUTOR (2024)

Dos trechos realizados, é necessária uma separação em duas classes: trechos circulares ininterruptos e ponto a ponto. A primeira classe representa aqueles trechos em que não houve parada intermediária para carregamento e o ponto de partida coincide com a chegada. A segunda classe representa por ter distintos ponto de partida e chegada.

A realização de trecho circular ininterrupto requer que o trajeto tenha uma quantidade de quilômetros que seja realizado com a energia inicial da bateria de tração. Para isso é necessário conhecer o trajeto de antemão, prever os trechos planos, com declives, com aclives e controlar a velocidade dentro dos limites estabelecidos. No trecho 1, considerando os 283 quilômetros e 3511 metros de desnível acumulado, se obteve uma diferença de -14% em erro estimado. Tomando-se em conta a diferença 44 quilômetros de diferença entre a autonomia restante prevista pelo carro e a autonomia do modelo, pode-se dizer que está numa faixa aceitável. É interessante notar o ABRP denotou um SOC de 32% ao chegar no objetivo, valor próximo obtido pela lógica Fuzzy de 31,22% e o erro relativo foi de -15%.

Para o trecho 2 e trecho 3, caracterizados por serem ponto a ponto com declive e aclives entre 1153 metros e 756 metros de altitude, uma distância de 209 quilômetros e 202 quilômetros, desnível positivo de 2778 metros e desnível negativo de 2951 metros, o modelo proposto teve um erro relativo de 2% e -5%, respectivamente. O ABRP resultou num erro relativo de -7% e -8% na medição do trajeto, portanto o modelo proposto calculou o SOC final com maior exatidão.

Para o trecho 4 caracterizado como ponto a ponto, com distância de 202 quilômetros e forte declive de 925 a 15 metros, o resultado obtido foi de 3% em relação ao SOC real do veículo e o ABRP obteve um erro de -4%. É importante notar que neste trecho o modelo proposto considerou a situação de declive acentuado, o qual reduz o gasto energético requerido pelo movimento, como demonstrado pelo consumo energético de 13 kWh/100km contra o consumo homologado de estrada de 14,5 kWh/100 km.

Para o trecho 5 caracterizado como ponto a ponto, com distância de 199 quilômetros e forte aclive de 15 a 820 metros, o erro relativo obtido foi -16% em relação ao SOC real do veículo e o ABRP obteve um erro de 2%. O modelo proposto neste tipo de trecho requer um estudo mais aprofundado, com uma medição de corrente efetiva verificada na saída da bateria de tração e o cálculo de potência do motor

elétrico, bem como o desenvolvimento de um método que considere a inclinação com uma quantidade de amostras por segmento diferente do que foi escolhido para o projeto. Também é necessário verificar se no momento de carregamento no ponto de chegada a quantidade prevista de energia, com um SOC de 42% que representa 34,8 kWh de energia para carregar completamente a bateria foi efetivada. O veículo elétrico pode através de cálculos de modelos embarcados ser mais “pessimista” para evitar que o motorista seja surpreendido pelo esgotamento acelerado da energia.

Para o trecho 6 caracterizado como ponto a ponto, com distância de 185 quilômetros e forte declive de 820 a 15 metros, o erro relativo obtido foi 11% em relação ao SOC real do veículo e o ABRP obteve um erro de 15%. A velocidade de rodagem foi moderada devido a quantidade de tráfego e radares. Para este tipo de trecho com forte declive a quantidade de energia regenerada pode ter sido maior que o conjunto nebuloso calculou. Medições físicas complementares do funcionamento da bateria de tração e conjunto motriz podem ajudar a entender e aprimorar o modelo considerado.

Para o trecho 7 caracterizado como ponto a ponto, com distância de 211 quilômetros e forte aclive de 15 a 925, o erro relativo obtido foi -18% em relação ao SOC real do veículo e o ABRP obteve um erro de 0%. As análises deste trecho são similares ao trecho 5 de forte aclive.

Se o trecho 4 e trecho 5 fossem unificados sem considerar o carregamento intermediário, a energia resultante consumida seria de 50% e 49% da bateria de 60 kWh, totalizando 99% da bateria para o modelo Fuzzy e 46% e 49%, totalizando 94% para o modelo ABRP. Desta maneira o erro acumulado entre o modelo Fuzzy seria de 5 pontos percentuais em relação para ABRP. Se os trechos 6 e 7 fossem unificados, a energia resultante consumida seria de 44% e 54%, totalizando 98% da bateria para o modelo Fuzzy e 39% e 65%, totalizando 104% para o modelo ABRP, totalizando um erro de 6 pontos percentuais.


Para compreender estas diferenças entre o modelo proposto Fuzzy e os valores calculados pelo ABRP e o sistema embarcado do veículo, seriam necessárias medições físicas registradas do consumo instantâneo verificado através da corrente e tensões da bateria de tração e motor elétrico, bem como o sistema de carregamento externo para se medir qual a energia final consumida pelo veículo.

O cálculo do estado da bateria SOC é realizado pelo sistema do embarcado do veículo continuamente, de acordo com as características eletroquímicas de cada

célula e módulo. Ele toma em consideração a quantidade de energia dentro dos limites estabelecidos, pois existe uma faixa útil e de segurança. Por exemplo, no caso do Renault Megane E-Tech a capacidade total da bateria de íons de lítios é 65 kWh, mas o sistema limita a 60 kWh, numa configuração 96s3p para 288 células e tensão de alimentação de 400V.

Este buffer colocado nos limites de carga superior e inferior, impede o acesso às extremidades das faixas de SOC, como mostrado na FIGURA 68.

FIGURA 68 : FAIXAS DE OPERAÇÃO DE SOC



FONTE: ADAPTADO DE EV-DATABASE (2023)

No processo de carregamento diário, o sistema embarcado do Megane possibilita a interrupção do carregamento num nível abaixo de 100%. A remoção dos extremos não é feita apenas para a saúde da bateria, mas também para a operação segura do veículo. Uma bateria a 100% não está completamente carregada do ponto de vista eletroquímico da bateria e desta forma pode-se colocar mais energia mesmo que o sistema indique 100%, assim como ao atingir um SOC 0% é possível ainda obter energia, mas comprometendo a segurança e durabilidade da bateria.



## 6 CONCLUSÃO E TRABALHOS FUTUROS

O estudo apresentado engloba as áreas de infraestrutura de carregamento, influência de fatores ambientais na autonomia de veículos elétricos, funcionamento da bateria de tração e conjunto motriz elétrico, ciência de dados e métodos computacionais, influência de modos de condução na autonomia de veículos elétricos, ciência de transporte e planejamento de rotas. Dada a complexidade e abrangência dos temas envolvidos, procurou-se limitar a profundidade para garantir a execução de um modelo coerente e útil para estudos futuros.

O modelo proposto teve como objetivo a determinação de um fator de consumo que represente o roteiro e as condições da rodagem e que determine a autonomia final melhor que informações disponíveis pelos resultados de homologação e os valores usados pelo PBEV, com o fator de correção de 70%. O segundo objetivo foi comparar com os cálculos realizados pelo veículo, pelo aplicativo ABRP, e determinar o erro relativo das medições.

Com a modelagem Fuzzy desenvolvida neste trabalho, obteve-se uma abordagem coerente com a complexidade do veículo elétrico e do ecossistema. Esta abordagem permite fazer estimativas futuras a partir das experimentações e estudos executados. Cabe ressaltar que durante as pesquisas bibliográficas não se encontrou um trabalho nacional focado em veículo elétrico utilizando este método, o que torna este projeto um precursor da tecnologia para o cálculo de autonomia.

Com a determinação dos parâmetros dos conjuntos nebulosos a cada amostra do trajeto realizado, pode-se analisar o comportamento do modelo Fuzzy e adequá-lo corretamente. Os resultados foram coerentes com o objetivo do projeto proposto e fundamentais para entender a complexidade do assunto.

Atualmente a indústria automobilística emprega recursos e tecnologias na melhoria dos modelos de previsão de alcance dos veículos elétricos e este trabalho permitiu ao autor aprofundar os conhecimentos na área e assim contribuir com a melhoria da performance para o usuário final.

Como propostas de estudos futuros tem-se a aquisição de dados de funcionamento da bateria de tração e do motor elétrico para tornar o modelo Fuzzy mais robusto para auferir maior exatidão nos prognósticos de autonomia.

Um segundo estudo futuro pode ser baseado na aquisição de dados através da conectividade embarcada, tratamento dos dados e a personalização dos

parâmetros e veículo. Com a utilização da conectividade veicular cria-se um vetor de conhecimento, além de alavancar novos negócios, com a expansão da malha de carregamento, a interface entre os veículos com sistemas de carregamento (*Vehicle-to-grid*, gerenciamento de carregamento) e a disponibilização de sistemas embarcados para melhor simulação e acompanhamento.

A caracterização do veículo com parâmetros atualizados de funcionamento e a personalização do usuário é uma tendência no mercado para se auferir uma maior confiança na determinação da autonomia de veículos elétricos e que o usuário possa se planejar no deslocamento e que não tenha uma imobilização inesperada. Os modos de condução e seleção de regeneração permitem que haja uma personalização das configurações.

As montadoras de veículos atualmente investem somas consideráveis de recursos para que possam atender os requisitos e expectativas dos usuários no quesito autonomia do veículo elétrico. Este movimento é extremamente necessário devido a importância da mobilidade sustentável na atual conjuntura climática.

## REFERÊNCIAS

ABVE, 2024, 94 mil eletrificados: 2023 bate todas as previsões, publicado em 03/01/2024, disponível em <https://abve.org.br/2023-supera-todas-as-previsoes-94-mil-eletrificados/>

ANEEL, 2018, Chamada n° 022/2018, Projeto Estratégico: “Desenvolvimento De Soluções Em Mobilidade Elétrica Eficiente”, Brasília, 2018

ASHKROF, P.; HOMEM DE ALMEIDA CORREIA, G.; VAN AREM, b. Analysis of the effect of charging needs on battery electric vehicle drivers' route choice behaviour: a case study in the Netherlands. *Transportation research part d: transport and environment*, v. 78, 1 Jan. 2020.

BI, J., WANG, Y., SAI, Q., DING, C., Estimating remaining driving range of battery electric vehicles based on real-world data: A case study of Beijing, China, *Energy*, 2019, p. 833 – 843, vol 169.

BŁASZCZYK, P.; KOPEĆ, M. The effect of driving style on battery electric vehicle range. *Pomiary Automatyka Robotyka*, v. 27, n. 1, p. 85–92, 20 Feb. 2023.

BLOOMBERGNEF, 2023, Electric Vehicle Outlook, 2023 [https://assets.bbhub.io/professional/sites/24/2431510\\_bnefelectricvehicleoutlook2023\\_execsummary.pdf](https://assets.bbhub.io/professional/sites/24/2431510_bnefelectricvehicleoutlook2023_execsummary.pdf), acessado em 09/01/2024

BNDES, 2024. Painel NDC - nossa contribuição para as metas de redução de emissões do Brasil. Acessado em [http:// https://www.bndes.gov.br/wps/portal/site/home/desenvolvimento-sustentavel](http://https://www.bndes.gov.br/wps/portal/site/home/desenvolvimento-sustentavel) em 09/01/24.

CANALS CASALS, L., ETXANDI-SANTOLAYA, M., BIBILONI-MULET, P.A., CORCHERO, C., TRILLA, L. Electric Vehicle Battery Health Expected at End of Life in the Upcoming Years Based on UK Data. *Batteries* 2022, 8, 164. <https://doi.org/10.3390/batteries8100164>

ÇEVEN, S.; ALBAYRAK, A.; BAYIR, R. Real-time range estimation in electric vehicles using Fuzzy logic classifier. *Computers and Electrical Engineering*, v. 83, 1 May 2020.

CLEANTECHNICAA, 2023, 26% BEV Share in China - China EV Sales Report <https://cleantechnica.com/2023/12/01/26-bev-share-in-china-china-ev-sales-report/>, acessado em 09/01/2024

CLEANTECHNICAB, 2023, 1st & 2nd place wins for tesla in Europe, <https://cleantechnica.com/2024/01/04/1st-2nd-place-wins-for-tesla-in-europe/>, acessado em 09/01/2023

DIB W., CHASSE A., MOULIN P., SCIARETTA A., CORDE G., Optimal energy management for an electric vehicle in eco-driving applications, *Control Engineering Practice*, Volume 29, 2014, Pages 299-307, ISSN 0967-0661

- DIAS, I. de L. G. Análise experimental da influência do ar-condicionado automotivo nas emissões e no consumo de combustível em veículos leves considerando o ciclo urbano (FTP-75). 2017. Disponível em <http://hdl.handle.net/1843/BUBD-AYLNWP>.
- DOYLE, A.; MUNEEER, T. Energy consumption and modelling of the climate control system in the electric vehicle. *Energy Exploration and Exploitation*, v. 37, n. 1, p. 519–543, 1 Jan. 2019.
- EHSANI M., GAO Y., GAY S., AMADI AL, *Modern Electric, Hybrid Electric, and Fuel Cells, fundamentals, theory, and design*, CRC Press, 2005.
- ENELX, 2024, The Different EV Charging Connector Types <https://evcharging.enelx.com/ca/en/resources/blog/552-ev-charging-connector-types>, acessado 09/01/2024
- EPA, 2024, 40 CFR 600.210-12 (Aug. 20, 2024) - Subpart C—Procedures for Calculating Fuel Economy and Carbon-Related Exhaust Emission.
- EUROPEAN COMISSIONA, 2024, European Alternative Fuels Observatory disponível em <https://alternative-fuels-observatory.ec.europa.eu/transport-mode/road/european-union-eu27>
- EUROPEAN COMISSIONB, 2024, European Alternative Fuels Observatory disponível em <https://alternative-fuels-observatory.ec.europa.eu/transport-mode/road/germany/vehicles-and-fleet>
- EUROPEAN ALTERNATIVE FUELS OBSERVATORY, 2024, disponível em <https://alternative-fuels-observatory.ec.europa.eu/general-information/recharging-systems>, acessado em 21/09/2024
- EV-DATABASE, 2024, Renault Megane e-tech ev60 220hp, disponível em <https://ev-database.org/car/1521/renault-megane-e-tech-ev60-220hp>, acessado em 09/01/2024
- IEA (2024), Global EV Outlook 2024, IEA, Paris <https://www.iea.org/reports/global-ev-outlook-2024>, Licence: CC BY 4.0
- EV-VOLUMES, 2023, EVs forecast to account for two thirds of global light-vehicle sales in 2035, <https://www.ev-volumes.com/country/total-world-plug-in-vehicle-volumes/>, acessado em 09/01/2024
- FERREIRA j., MONTEIRO VITOR., AFONSO JOÃO, Data Mining Approach for Range Prediction of Electric Vehicle, Conference on Future Automotive Technology – Focus Electromobility, 26-27 March 2012, Munich, Germany, pp1-15.
- GEOTAB, 2024, what 6,000 EV batteries tell us about EV battery health disponível em <https://www.geotab.com/blog/ev-battery-health/> acessado em 09/01/2024.
- GÜNTHER, M.; RAUH, N.; KREMS, J. F. Conducting a study to investigate eco-driving strategies with battery electric vehicles - a multiple method approach. *Transportation Research Procedia*. Anais. Elsevier B.V., 2017.

HAMWI, H., RUSHBY T., MAHDY, M., BAHAJ, A., Effects of high ambient temperature on electric vehicle efficiency and Range: Case Study of Kuwait. *Energies*, v. 15, n. 9, 1 May 2022.

IBGE, 2024, Frota de Veículos, <https://cidades.ibge.gov.br/brasil/pesquisa/22/28120>, acessado em 09/01/2024.

IEA, CO<sub>2</sub> Emission in 2022, 2023, IEA, Paris, disponível em [www.iea.org](http://www.iea.org)

INMETRO, TABELAS PBE VEICULAR, 2023. Disponível em < <https://www.gov.br/inmetro/pt-br/assuntos/avaliacao-da-conformidade/programa-brasileiro-de-etiquetagem/tabelas-de-eficiencia-energetica/veiculos-automotivos-pbe-veicular>, acessado em 09/01/2024.

K. SARRAFAN, D. SUTANTO, K. M. MUTTAQI & G. TOWN, Accurate range estimation for an electric vehicle including changing environmental conditions and traction system efficiency, *IET Electrical Systems in Transportation*, vol. 7, (2) pp. 117-124, 2017.

LEE, D.-Y.; WOOD, E. DC Fast Charging Infrastructure for Electrified Road Trips. National Renewable Energy Laboratory (NREL), CEC IEPR Workshop, August 6, 2020

LUIS JIMENEZ-PALACIOS, J. Understanding and quantifying motor vehicle emissions with vehicle specific power and TILDAS remote sensing., MIT, 1999

MDIC, 2023, MOVER: Programa De Mobilidade Verde é lançado; <https://www.gov.br/planalto/pt-br/acompanhe-o-planalto/noticias/2023/12/mover-novo-programa-amplia-acoes-para-mobilidade-verde-e-descarbonizacao> acessado em 09/01/2024

MIRI, I., FOTOUHI A., EWIN A., Electric vehicle energy consumption modelling and estimation—A case study, *International Journal of Energy Research*, 2020

MIYAUCHI, E. T., PIVATTO, D., ANDRE, E., CORDEIRO, M. Thermal management—a key technology for the success of e-mobility., *AEA – Brazilian Society of Automotive Engineering - SIMEA 2023*.

NIKKEI ASIA, China's EV overcapacity spurs global fears of more price cuts, <https://kr-asia.com/chinas-ev-overcapacity-spurs-global-fears-of-more-price-cuts>, acessado em 20/08/2024.

PLUGSHARE, 2024, disponível em <https://www.plugshare.com/br> acessado 09/01/24

PROCOBRE, 2020, Eletropostos instalação de equipamentos de recarga para grandes demandas, disponível em [https://www.pnme.org.br/wp-content/uploads/2020/04/guia\\_promobe\\_eletroposto\\_simples\\_v2.pdf](https://www.pnme.org.br/wp-content/uploads/2020/04/guia_promobe_eletroposto_simples_v2.pdf), acessado em 21/08/2024

PV MAGAZINE, 2024 ,Eletromobilidade avança e deve ganhar impulso com a fabricação de VEs no brasil <https://www.pv-magazine-brasil.com/2024/01/09/eletromobilidade-avanca-e-deve-ganhar-impulso-com-a-fabricacao-de-ves-no-brasil/>, acessado em 09/01/2024

QI, X., WU, G., BORIBOONSOMSIN, K., BARTH, M., Data-Driven Decomposition Analysis and Estimation of Link-Level Electric Vehicle Energy Consumption Under Real-World Traffic Conditions. *Transportation Research Part D: Transport and Environment*, v. 64, p. 36–52, 1 out. 2018.

RAJENDRAN, G., VAITHILINGAM, C., NAIDU, K., ORUGANTI, K., Energy-Efficient Converters for Electric Vehicle Charging Stations. *SN Applied Sciences*, v. 2, n. 4, 1 abr. 2020.

REGULAMENTAÇÃO EUROPÉIA, 2023/1804, European Parliament and Of The Council of 13 September 2023 on The Deployment of Alternative Fuels Infrastructure, and repealing Directive 2014/94/EU.

SAE, 2021 - Battery Electric Vehicle Energy Consumption and Range Test Procedure J1634\_202104 -disponível em [https://www.sae.org/standards/content/j1634\\_202104/](https://www.sae.org/standards/content/j1634_202104/)

SANDRI, S.; CORREA, C. Lógica nebulosa. V Escola De Redes Neurais, Promoção: Conselho Nacional De Redes Neurais, pp. C073-c090, 19 de julho, 1999 - ITA, São José Dos Campos - SP

SUN, S., ZHANG, J., BI, J., WANG, Y., MOGHADDAM, M., A machine learning method for predicting driving range of battery electric vehicles. *Journal of Advanced Transportation*, v. 2019, 2019.

THIBAULT, L.; DE NUNZIO, G.; SCIARRETTA, A. A unified approach for electric vehicles range maximization via eco-routing, eco-driving, and energy consumption prediction. *IEEE Transactions on Intelligent Vehicles*, v. 3, n. 4, p. 463–475, 1 Dec. 2018.

WILHELM R., Teslalogger Version 1.57., disponível em <https://www.teslalogger.de>,

Handbuchversion vom Februar 2024

WIKILOC, 2024, disponível em <https://pt.wikiloc.com/trilhas-carro/renault-sjp-renault-vila-funchal-158996524> acessado em 22/01/2024

WU, X., FREESE, D., CABRERA, A., KITCH, W., D Electric vehicles' energy consumption measurement and estimation. *Transportation Research Part D: Transport and Environment*, v. 34, p. 52–67, 1 Jan. 2015.

ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes., *IEEE Transactions on Systems, Man, and Cybernetics*, vol. Smc-3, no. 1, Jan. 1973





## ANEXO 2 – ESCALA DE VENTOS DE BEAUFORT



### A Escala Beaufort

Índice da força	Descrição	Velocidade do vento (km/h - nós)		Efeito do vento	
				Em terra	No mar
0	Calmaria	0 - 1 km/h	0 - 1 nó	Calmaria	O mar parece um espelho
1	Bafagem	1 - 5 km/h	1 - 3 nós	Vento fraco	Mar ligeiramente ondulado
2	Aragem	6 - 11 km/h	4 - 6 nós	Sente-se o vento no rosto. A vegetação inclina-se ao vento	Ondas muito pequenas e curtas. As cristas não quebram
3	Vento fraco	12 - 19 km/h	7 - 10 nós	Folhas e ramos das árvores balançam. As bandeiras ficam armadas	Ondas pequenas e encorpadas. As cristas se rompem
4	Vento moderado	20 - 28 km/h	11 - 16 nós	Folhas e papéis voam. Galhos menores balançam	Ondas pequenas e longas. Arrebentação constante
5	Vento fresco	29 - 38 km/h	17 - 21 nós	Árvores pequenas balançam. Lagos e represas com ondas pequenas com cristas	Ondas moderadas, longas e definidas. Muita arrebentação. O vento pode arrastar a espuma
6	Vento muito fresco	39 - 49 km/h	22 - 27 nós	Galhos grandes se movem. Ouve-se o vento zumbir nos fios. Difícil usar guarda-chuva	Grandes ondas. Cristas extensas e numerosas. A espuma é arrastada pelo vento
7	Vento forte	50 - 61 km/h	28 - 33 nós	Todas as árvores se movimentam. É difícil andar contra o vento	O mar levanta. A espuma é arrastada na direção do vento
8	Vento muito forte	62 - 74 km/h	34 - 40 nós	Partem-se os galhos das árvores. É quase impossível andar contra o vento.	Ondas longas. Cristas rolam com barulho. A espuma é arrastada fortemente

Continua na próxima página



### ANEXO 3 – CONDIÇÕES METEREOLÓGICAS INICIAIS EM 24/01/24

