

Luísa Mendes Heise

**Predição de consumo de energia em veículos
elétricos em entregas de uma indústria de
alimentos e bebidas com o uso de modelos
híbridos físico-estatísticos**

São Paulo

2023

Luísa Mendes Heise

Predição de consumo de energia em veículos elétricos em entregas de uma indústria de alimentos e bebidas com o uso de modelos híbridos físico-estatísticos

Trabalho de formatura apresentado à Escola Politécnica da Universidade de São Paulo para a obtenção do diploma de Engenheiro de Produção

Orientador: Prof. Dr. Hugo Tsugunobu Yoshida Yoshizaki

Universidade de São Paulo – USP
Escola Politécnica
Departamento de Engenharia de Produção (PRO)

São Paulo
2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catalogação-na-publicação

Heise, Luísa

Predição de consumo de energia em veículos elétricos em entregas de uma indústria de alimentos e bebidas com o uso de modelos híbridos físico estatísticos / L. Heise -- São Paulo, 2023.

100 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Produção.

1.veículos elétricos 2.logística 3.sustentabilidade 4.modelo de energia
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Produção II.t.

Agradecimentos

Ao Prof. Hugo, que gentilmente concordou em orientar-me e ofereceu todo o suporte necessário para a realização deste trabalho.

Ao Prof. Flávio Vaz de Almeida, com quem tive conversas que se mostraram verdadeiros pontos de inflexão essenciais para a conclusão deste trabalho.

Ao meu amigo André Ferreira, cuja ajuda em inúmeros *debugs* de código, revisões de textos, *brainstorming* e, principalmente, palavras de incentivo, foram essenciais.

Ao Alexandre Duarte, por acompanhar-me nas visitas e inspeções de dados, contribuindo em diversas revisões e análises deste trabalho.

Ao Pedro Henrique Callil-Soares pela boa vontade em pensar em soluções técnicas e ajuda com a execução técnica deste trabalho.

Ao supervisor Fábio por sua paciência e prestatividade durante as diversas visitas ao centro de distribuição.

A Jonatas, Daniel, Caio e Bianca, cuja colaboração foi fundamental para obtenção dos dados para realização deste trabalho.

À minha família pelo incentivo e inspiração para seguir firme durante toda minha formação.

Ao João Vitor por todo o companheirismo e apoio.

Aos meus amigos Giulia, Fernanda e Marcello, por trazerem alegria e palavras de incentivo neste período.

Aos meus amigos e colegas da POLI e do Turing USP, que tornaram os seis anos de escola uma experiência mais leve.

Cada um de vocês desempenhou um papel fundamental na conclusão deste trabalho, e agradeço profundamente por isso.

Resumo

A necessidade de reduzir as emissões de gases de efeito estufa (GEEs) tem impulsionado a adoção de veículos elétricos a bateria (BEVs) em frotas de caminhões de entrega. No entanto, essa mudança traz desafios e oportunidades específicos. Por um lado, veículos elétricos são mais eficientes e, muitas vezes, possuem um custo variável menor do que veículos a combustão. Por outro, a autonomia dos BEVs, ou seja, a distância que pode ser percorrida sem recarga da bateria, é limitada. Tal aspecto é especialmente relevante devido à baixa densidade energética das baterias e à infraestrutura limitada de pontos de recarga em trânsito.

Diversos fatores afetam a autonomia dos veículos elétricos, como o tipo de carga, o relevo, o tráfego, o tipo de estrada, as condições climáticas e o estilo de direção. Alguns desses fatores têm uma relação direta com características geograficamente delimitadas, como congestionamentos, relevo e tipo de via.

Foram desenvolvidos modelos de energia híbridos, compostos por modelagem física e estatística (físico-estatísticos), abrangendo uma variedade de escalas, que vão desde o microscópico até o macroscópico, e incorporando diferentes modelagens de regeneração de energia: nenhuma regeneração, regeneração linear e não-linear. Esses modelos foram aplicados a conjuntos de dados de GPS que apresentavam alta latência. Foram obtidas taxas de erro variáveis, sendo o modelo microscópico com modelagem exponencial da energia regenerada o que levou ao menor erro percentual médio, no valor de 2,35% nos dados de teste.

Conclui-se que modelos com granularidade mais refinada na estimação de energia tem o erro associado menor. Nesse sentido, em aplicações em que é possível prever de antemão os parâmetros necessários para modelos mais precisos, o seu uso pode melhorar a confiabilidade os processos associados, como roteirização e dimensionamento de frotas.

Palavras-Chave – veículos elétricos, modelo de energia, regeneração, sustentabilidade, logística, frotas eletrificadas

Abstract

The need to reduce greenhouse gas emissions has driven the adoption of battery electric vehicles (BEVs) in delivery truck fleets. However, this shift presents specific challenges and opportunities. On one hand, electric vehicles are more efficient and often have lower variable costs than combustion vehicles. On the other, the range of BEVs, *i.e.*, the distance they can travel without recharging their battery, is limited. This aspect is particularly relevant due to the low energy density of batteries and the limited infrastructure of charging points on the road.

Various factors affect the range of electric vehicles, such as the type of load, terrain, traffic, road type, weather conditions, and driving style. Some of these factors have a direct relationship with geographically delimited features, such as congestion, terrain, and road type.

Hybrid energy models have been developed, combining physical and statistical modeling (physico-statistical), covering a range of scales from microscopic to macroscopic, and incorporating different energy regeneration models: no regeneration, linear regeneration, and non-linear regeneration. These models were applied to GPS datasets with high latency. Variable error rates were obtained, with the microscopic model using exponential regeneration energy modeling producing the lowest average percentage error at 2.35% in the test data.

Models with finer granularity in energy estimation have lower associated errors. Because of that, in applications where it is possible to predict the parameters needed for more accurate models in advance, their use can improve the reliability of associated processes, such as routing and fleet sizing.

Keywords – electric vehicles, energy model, regeneration, sustainability, logistics, electrified fleets

Lista de tabelas

Tabela 1 – Preço dos caminhões leves a combustão (<i>ICVs</i>) mais vendidos até setembro de 2023	19
Tabela 2 – Preço e autonomia média dos caminhões elétricos (<i>BEVs</i>) já utilizados em operação pela empresa do estudo	20
Tabela 3 – Parâmetros de entrada do modelo	47
Tabela 4 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada sem regeneração	53
Tabela 5 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada com regeneração linear	55
Tabela 6 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada com regeneração exponencial	56
Tabela 7 – Valores de consumo por distância ajustado (EC) para os modelos	57
Tabela 8 – Valores de consumo por distância e por massa ajustado (EC/kg) para os modelos	58
Tabela 9 – Valores de erro quadrático médio para os modelos em kWh ²	59
Tabela 10 – Distribuição de erros (em kWh) dos modelos no conjunto de teste . .	60
Tabela 11 – Distribuição de erros percentuais (SOC) dos modelos no conjunto de teste	61
Tabela 12 – Resultado do dimensionamento de frota com base no erro do tipo 1 . .	69
Tabela 13 – Dados de treino agregados - para regressão	95
Tabela 14 – Dados de teste - para cálculo de erros	98

Lista de ilustrações

Figura 1 – Série histórica do preço médio de revenda do diesel S10 e diesel S500 na cidade de São Paulo. Fonte: ANP - Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (2023) Elaboração: autor	18
Figura 2 – Série histórica do PLD (Preço de Liquidação das Diferenças) semanal médio para o Sudeste Fonte: Energia Elétrica (2023) Elaboração: autor	19
Figura 3 – E-Delivery 14. Fonte: Volkswagen	23
Figura 4 – Carregador do veículo elétrico Fonte: autor	24
Figura 5 – Histograma de nível de bateria no retorno ao CD Fonte: autor	25
Figura 6 – Fluxograma do processo de entregas e procedimento de emergência Fonte: autor	25
Figura 7 – Ilustração do resultado de um algoritmo de map-matching. Os pontos vermelhos são os registros de GPS e os azuis são os pontos na trajetória reconstruída. Fonte: Saki; Hagen (2022)	35
Figura 8 – Diagrama do sistema do software EVPRE Fonte: Shamma <i>et al.</i> (2022)	37
Figura 9 – Diagrama da solução de <i>scheduling</i> para frota de ônibus elétrico Fonte: Rogge <i>et al.</i> (2018)	37
Figura 10 – Estrutura metodológica Fonte: autor	39
Figura 11 – Ponteiro de leitura do nível de bateria Fonte: autor	42
Figura 12 – Exemplos de fotos de <i>checklist</i> de retorno com indicações de bateria Fonte: autor	42
Figura 13 – Exemplos de foto de <i>checklist</i> de retorno sem possibilidade de leitura de nível de bateria Fonte: autor	42
Figura 14 – Diagrama com quantidade e seleção das rotas para análise Fonte: autor	43
Figura 15 – Rotas consideradas descontínuas. Fonte: autor	44
Figura 16 – Exemplo de rota (em azul) e pontos de entrega (em vermelho) Fonte: autor	45
Figura 17 – Histograma de massa por pacote Fonte: autor	45
Figura 18 – Fluxos de potência num típico veículo elétrico. Fonte: Genikomsakis; Mitrentsis (2017)	47
Figura 19 – Regressão linear de energia gasta em função de energia estimada sem regeneração em dados de treino Fonte: autor	54
Figura 20 – Gráficos de diagnóstico da regressão linear de energia gasta em função de energia estimada sem regeneração Fonte: autor	54
Figura 21 – Regressão linear de energia gasta em função de energia estimada com regeneração linear em dados de treino Fonte: autor	55

Figura 22 – Gráficos de diagnóstico da regressão linear de energia gasta em função de energia estimada com regeneração linear	Fonte: autor	56
Figura 23 – Regressão linear de energia gasta em função de energia estimada com regeneração exponencial em dados de treino	Fonte: autor	57
Figura 24 – Gráficos de diagnóstico da regressão exponencial de energia gasta em função de energia estimada com regeneração exponencial	Fonte: autor	57
Figura 25 – Distribuição de erros dos modelos mesoscópicos e macroscópicos	Fonte: autor	59
Figura 26 – Ilustração de relação entre EC e α	Fonte: autor	66
Figura 27 – Histograma de consumo $\frac{kWh}{km}$ em dados de teste	Fonte: autor	67
Figura 28 – KDE (<i>Kernel Density Estimation</i>) de consumo $\frac{kWh}{km}$ em dados de teste	Fonte: autor	67
Figura 29 – Percentual (%) de caminhões dimensionados para cada α em relação ao dimensionamento do menor α avaliado (α_{min}) - $\alpha_{min} = 0.001$	Fonte: autor	68
Figura 30 – Tentativa de clusterização de rotas	Fonte: autor	71
Figura 31 – Ilustração sobre o <i>trade-off</i> entre confiabilidade e complexidade de modelos de energia.	Fonte: autor	72

Glossário

BEV - Veículo elétrico a bateria (*Battery Electric Vehicle*)

CD - Centro de distribuição

EC - Consumo de energia por distância (*Energy Consumption*)

GEE - Gases de efeito estufa

GPS - Sistema de posicionamento global (*Global Positioning System*)

ICV - Veículo de combustão interna (*Internal Combustion Vehicle*)

SOC - Nível de bateria / Estado da carga (*State of Charge*)

TCO - Custo total de propriedade (*Total Cost of Ownership*)

Sumário

1	INTRODUÇÃO	15
1.1	Motivação	15
1.1.1	Aspecto ambiental	15
1.1.2	Desafios e oportunidades em frotas eletrificadas	17
1.1.3	Importância de modelos de energia para veículos elétricos	20
1.2	Diagnóstico da operação	22
1.3	Objetivo do trabalho	26
1.4	Estrutura do trabalho	26
2	REVISÃO DA LITERATURA	29
2.1	Estimação de emissão de gases de efeito estufa (GEE)	29
2.2	Estimativa de consumo de energia em veículos elétricos	30
2.3	Estimativa de Estado de Carga (SOC)	32
2.4	Preparação de dados de GPS	34
2.5	Aplicações de Modelos de Energia	35
3	MATERIAIS E MÉTODOS	39
3.1	Coleta de dados	40
3.1.1	Dados de GPS	40
3.1.2	Dados de pontos de entrega	41
3.1.3	Dados de SOC na volta ao centro de distribuição	41
3.2	Preparação de dados	43
3.2.1	Limpeza e filtragem inicial de rotas	43
3.2.2	Designação de pontos de entrega e estimação da perda de massa ao longo da rota	44
3.2.3	<i>Map-matching</i>	45
3.3	Separação em dados de treino e teste	46
3.4	Aplicação e estimação de parâmetros de modelos microscópicos	46
3.4.1	Dados do veículo e parâmetros do modelo de energia	46
3.4.2	Energia nas rodas do caminhão	47
3.4.3	Sistemas regenerativos	48
3.4.3.1	Regeneração linear	48
3.4.3.2	Regeneração exponencial	49
3.4.3.3	Estimativa numérica de coeficientes de regeneração	49
3.4.4	Regressão linear da energia consumida em função da energia estimada	49

3.5	Estimativa do consumo energético para modelos macroscópicos, mesoscópicos e análise de erros para os modelos desenvolvidos	51
4	RESULTADOS E DISCUSSÃO	53
4.1	Coeficientes de modelo sem sistema regenerativo	53
4.2	Coeficientes do modelo com sistema regenerativo linear	54
4.3	Coeficientes de modelo com sistema regenerativo exponencial	55
4.4	Derivação de parâmetros macroscópicos e mesoscópicos	56
4.5	Avaliação de erros em dados de teste	58
4.6	Comparação entre os modelos	58
4.7	Fontes de ruído e erro no modelo	62
4.7.1	Energia consumida	63
4.7.2	Energia estimada	63
4.7.2.1	Estimação de massa	63
4.7.2.2	Estimação de velocidade e aceleração e associados ao intervalo de integração	64
4.8	Análises derivadas dos modelos de energia	64
4.8.1	Dimensionamento de frotas com autonomia fixa (parâmetro macroscópico)	64
4.8.2	Clusterização de rotas	70
4.9	Síntese de aprendizados	71
5	CONCLUSÕES E PRÓXIMOS DESENVOLVIMENTOS	75
5.1	Conclusão	75
5.2	Próximos desenvolvimentos	76
	Referências	77
	Apêndice A - Ambiente e código	85
	Apêndice B - Dados	95

1 Introdução

O presente trabalho de formatura foi conduzido como um estudo de caso feito com uma empresa do ramo de alimentos e bebidas. Em específico, este trabalho foi desenvolvido no contexto de um centro de distribuição (CD) que atende uma grande cidade brasileira. Neste capítulo são apresentados motivações e objetivos do estudo, além da contextualização do problema e da operação da empresa em questão. Durante o texto, quando o termo "veículo elétrico" for utilizado, ele se refere a "veículo elétrico a bateria", ou seja, *BEVs*.

1.1 Motivação

1.1.1 Aspecto ambiental

O Brasil foi responsável por 1,32% das emissões globais de CO₂ no ano de 2021 (Our World in Data, 2021). Veículos pesados, como caminhões, são responsáveis por uma parcela considerável da emissão de gases de efeito estufa: no ano de 2020, os caminhões foram responsáveis pela emissão de 16 milhões de toneladas de CO_{2,eq} apenas no estado de São Paulo (Companhia Ambiental do Estado de São Paulo (CETESB), 2022).

No Brasil, veículos com motor a combustão interna *flex-fuel* dominam o mercado de veículos a passeio. Esses veículos são capazes de funcionar tanto com etanol hidratado quanto com gasolina C. No total, o etanol representa cerca da metade do consumo de combustível (em volume) da frota de automóveis de passageiros, seja como etanol hidratado ou na mistura de gasolina C. Simplesmente operar os veículos *flex-fuel* apenas com etanol seria capaz de reduzir as emissões de GEEs da frota de passeio em 31% (Mera *et al.*, 2023).

Ao contrário do cenário de veículos de passeio, no caso dos caminhões, a maioria da frota ainda opera com veículos a Diesel. Segundo o **Anuário da Indústria Automobilística Brasileira** (2023), 99,127% dos caminhões licenciados em 2022 eram a Diesel, ao passo que apenas 0,564% eram elétricos e 0,281% a gás. Segundo EPA (United States Environmental Protection Agency) (2023), emissões de motores a Diesel contribuem para a formação de ozônio em níveis terrestres, prejudicando a vegetação e desencadeando a produção de chuva ácida, com impactos diretos no solo e corpos d'água. Além disso, prejudicam a saúde humana e têm elevada taxa de emissão de gases de efeito estufa.

Globalmente, diversas iniciativas pretendem buscar alternativas aos veículos movidos a combustíveis fósseis, dada a necessidade urgente de mitigar as mudanças climáticas. A eletrificação das frotas tem o mérito de melhorar a eficiência energética, uma vez que os

motores elétricos são mais eficientes do que os motores de combustão interna (ICV) (Basso *et al.*, 2019), mas essa eficiência não se traduz necessariamente em emissões menores de gases de efeito estufa (GEEs), uma vez que tal resultado é dependente da composição da matriz energética empregada para recarregar as baterias.

Em países cuja matriz elétrica tem alta intensidade de emissão de CO₂, como China e Índia, os veículos elétricos a bateria (*BEVs*) podem, na verdade, emitir quantidades maiores de CO₂ por quilômetro rodado do que veículos a combustão semelhantes em outros locais, segundo Doucette; McCulloch (2011). Em um sentido similar, Kawamoto *et al.* (2019) calcularam a distância necessária a ser percorrida por um veículo elétrico à bateria (*BEV*) de modo que suas emissões se igualassem com um veículo a combustão interna (*ICV*) ao longo de seu ciclo de vida, o chamado DIP (*Distance of Intersection Point*). Nesse estudo foi verificado que quanto mais limpa a matriz energética de um país, menor seria o DIP e, para a Austrália, em particular, as emissões de *BEVs* sempre eram mais elevadas do que de *ICVs*.

Os veículos elétricos não são a única alternativa para a redução na emissão de GEEs. Há também a possibilidade do uso de veículos a combustão movidos por biocombustíveis, como o etanol. O Brasil se encontra num cenário propício para ambas soluções, dada a baixa taxa de emissão de sua matriz energética e seu protagonismo relacionado ao combustível etanol, que data da década de 1970, com a política do Pró-Álcool. Segundo Moreira; Pacca; Goldemberg (2022), do ponto de vista ambiental, a co-produção de eletricidade e biocombustível a partir de cana-de-açúcar, utilizada para alimentar veículos híbridos, seria uma boa prática para melhorar a eficiência energética em veículos leves, podendo reduzir demanda de energia destes em mais de duas vezes.

Segundo Sathre; Gustavsson (2023), caminhões elétricos com bateria apresentam um menor uso de energia primária e emissões de CO₂ ao longo de seu ciclo de vida em comparação com caminhões de combustão interna. O mesmo estudo aponta que o uso mais eficiente de energia e o menor impacto climático são observados quando os caminhões elétricos são alimentados por energia eólica e bioeletricidade co-gerada. Os veículos elétricos a bateria (*BEVs*) ainda têm a vantagem de não emitir gases durante sua operação, abrangendo não apenas o CO₂, mas também outros gases poluentes e material particulado (MP), que podem representar riscos para a saúde, especialmente em ambientes urbanos. Segundo Gouveia *et al.* (2006), existe uma correlação estatisticamente significativa entre o aumento dos níveis de poluentes na atmosfera e um aumento nas taxas de hospitalizações por diversas causas.

Conforme Carvalho (2011), a maior parte das emissões de carbono provenientes de veículos no Brasil se concentra em regiões urbanas, onde mais de 80% da população reside. De fato, no contexto urbano, os veículos elétricos demonstram ser uma escolha favorável. Conforme observado por Barnett (2011), caminhões de entrega urbana geralmente operam

a baixas velocidades médias, e os motores elétricos apresentam uma maior eficiência nesse cenário. Além disso, as frequentes desacelerações e paradas no trânsito urbano são ideais para tirar proveito do sistema de frenagem regenerativa, como mencionado por Hellgren (2007).

De acordo com Lee; Thomas; Brown (2013), fazendo uma avaliação do ciclo de vida de caminhões elétricos e a diesel, considerando um cenário de um ciclo de condução com paradas frequentes e baixa velocidade média, como o de uma grande cidade, caminhões elétricos emitem de 42% a 61% menos gases de efeito estufa (GEEs) e consomem de 32% a 54% menos energia do que caminhões a diesel, dependendo dos cenários de eficiência do veículo.

No Brasil, já existem políticas de incentivo ao uso de veículos elétricos. Segundo a CETESB (2023), o Proconve (Programa de Controle da Poluição do Ar por Veículos Automotores) é um programa do governo estadual de São Paulo que tem como um dos seus objetivos a redução de emissão de poluentes. Ele tem entrado em vigência em diferentes fases, que tornam os limites de gases emitidos cada vez menores, aumentando a atratividade econômica dos BEVs. Além disso, o rodízio de veículos em São Paulo não se aplica a carros elétricos e híbridos, já que a lei nº 15.997, de 27 de Maio de 2014, estabelece que os veículos elétricos, movidos a hidrogênio e os híbridos estão isentos do cumprimento da restrição determinada pelo Rodízio Municipal de Veículos.

1.1.2 Desafios e oportunidades em frotas eletrificadas

Em primeiro lugar, é importante destacar que, embora o custo global das baterias tenha diminuído nos últimos anos de \$1100/kWh em 2010 para \$137/kWh em 2020 (Bhardwaj; Mostofi, 2022), elas ainda representam um dos componentes mais caros dos veículos elétricos (BEVs) (Bhardwaj; Mostofi, 2022; Basso *et al.*, 2019). Outro ponto a ser considerado é a limitação da densidade energética das baterias. Em comparação com veículos de combustão interna, BEVs são mais eficientes, tendo eficiência perto de 90% (Fiori; Ahn; Rakha, 2016) e veículos a combustão algo perto de 40% (Paschoal *et al.*, 2017). Apesar disso, os BEVs ainda armazenam quantidades relativamente baixas de energia em suas baterias. Por exemplo, o diesel possui uma densidade energética de 45 MJ/kg (Hore-Lacy, 2011), enquanto as baterias dos BEVs geralmente armazenam entre 100 e 265 Wh/kg (Deng *et al.*, 2020), o que equivale a 0,36-0,95 MJ/kg. Isto é, a densidade energética do diesel é maior do que uma bateria elétrica. Aumentar essa densidade energética acarreta riscos de segurança, como o potencial de incêndios (Deng *et al.*, 2020).

Apesar disso, o custo variável de veículos elétricos se mostra como um grande diferencial em relação ao de veículos a combustão. Bhardwaj; Mostofi (2022) calcularam o Custo Total de Propriedade (em inglês *TCO* - *Total Cost of Ownership*), verificando o baixo custo variável dos BEVs na União Europeia.

No Brasil, também, verificamos que o custo da energia elétrica se mostra vantajoso. Segundo a ANP - Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (2023), desde janeiro de 2022, o preço médio de revenda do diesel S10 em São Paulo foi de $6,272 \frac{R\$}{L}$, como pode ser visto na Figura 1. O preço da energia no ambiente de contratação livre (ACL) tem uma oscilação alta, mas se manteve abaixo de $0,2 \frac{R\$}{kWh}$ no últimos meses, como pode ser visto na oscilação do PLD (Preço de Liquidação das Diferenças) na Figura 2. Considerando a autonomia nominal de 110km para uma bateria de 105 kWh (UOL - Universo Online, 2022), com um custo de $0,2 \frac{R\$}{kWh}$, temos o valor de $0,19 \frac{R\$}{km \text{ rodado}}$. Para um veículo a combustão, considerando o consumo 32L para cada 100km rodados para um veículo de 15T (Demir; Bektaş; Laporte, 2011), e com o valor de $6,2 \frac{R\$}{L \text{ de diesel S10}}$, temos o custo de $1,984 \frac{R\$}{km \text{ rodado}}$. Ou seja, uma diferença de aproximadamente dez vezes.

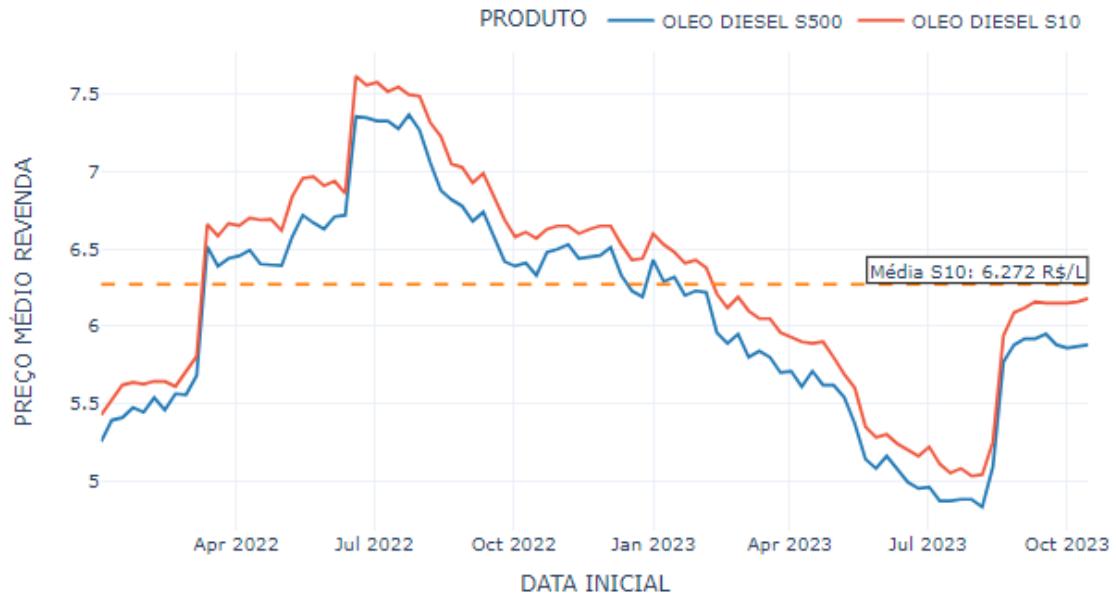


Figura 1 – Série histórica do preço médio de revenda do diesel S10 e diesel S500 na cidade de São Paulo.

Fonte: ANP - Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (2023)

Elaboração: autor

No entanto, apesar de o custo variável de veículos elétricos ser consideravelmente mais baixo do que veículos a combustão, seu custo fixo é mais elevado. Os cinco caminhões de porte leve mais vendidos no Brasil em 2023 têm valores de modelos 2023 entre 284 mil reais e 335 mil reais, segundo a FIPE - Fundação Instituto de Pesquisas Econômicas (2023), como pode ser visto na tabela 1. Os veículos elétricos, por outro lado, têm valores mais elevados. Por exemplo, o *BEV* Volkswagen E-Delivery 11 2023 (3 packs), que tem um Peso Bruto Total (PBT) de 11400 kg e capacidade máx. de carga útil de 7020kg, tem um valor superior a 900 mil reais, ao passo que, que o *ICV* VW Truck Delivery/9180 tem

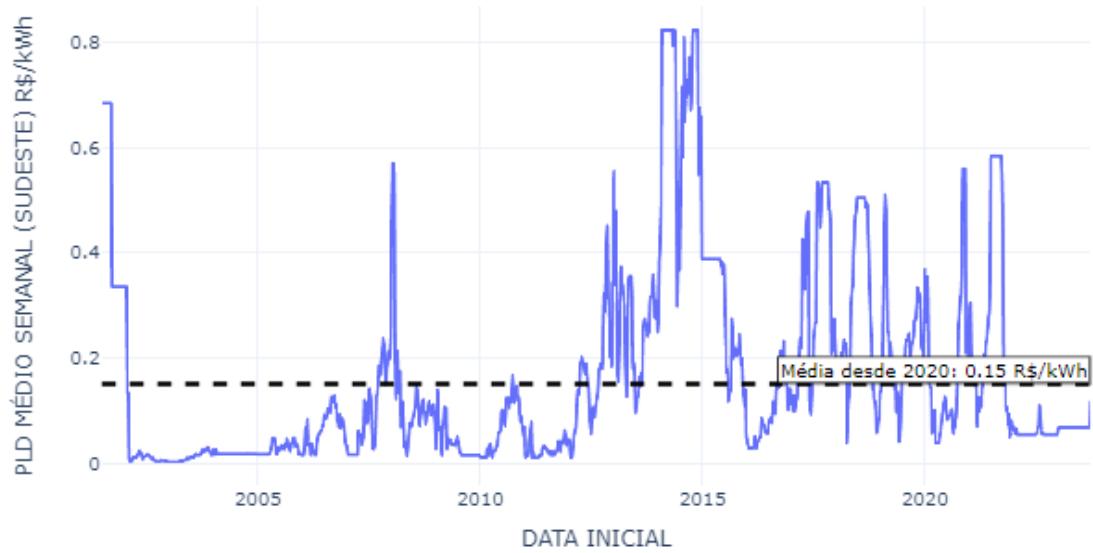


Figura 2 – Série histórica do PLD (Preço de Liquidação das Diferenças) semanal médio para o Sudeste

Fonte: Energia Elétrica (2023)

Elaboração: autor

um PBT de 9200 kg e capacidade máx. de carga útil de 6225kg, custando próximo a 335 mil reais.

Caminhão	Número de emplacamentos (jan-set 2023) (1)	Preço (Modelo 2023)(2)
M. Benz / Accelo 1016	1531	R\$ 329.830,00
VW Truck Delivery/9170	1213	R\$ 298.049,00
M. Benz / Accelo 815	829	R\$ 299.746,00
VW Truck Delivery/9180	618	R\$ 335.762,00
IVECO / Tector 9-190	433	R\$ 284.929,00

(1): FENABRAVE (2023)

(2): FIPE - Fundação Instituto de Pesquisas Econômicas (2023)

Tabela 1 – Preço dos caminhões leves a combustão (ICVs) mais vendidos até setembro de 2023

Caminhão	Capacidade da bateria	Peso bruto total (PBT)	Preço (1)
iEV1200T	97 kWh (2)	7500 kg (2)	R\$ 393.592,00
e-Delivery 14 (3 packs)	105 kWh (3)	14500 kg (3)	R\$ 1.031.786,00
e-Delivery 11 (3 packs)	105 kWh (3)	11400 kg (3)	R\$ 909.328,00

(1): FIPE - Fundação Instituto de Pesquisas Econômicas ([2023](#))

(2): Jac Motors ([2023](#))

(3): Volkswagen ([2023](#))

Tabela 2 – Preço e autonomia média dos caminhões elétricos (BEVs) já utilizados em operação pela empresa do estudo

Não apenas o custo fixo de veículos elétricos é maior do que o de veículos a combustão, existem incertezas maiores embutidas em sua operação. O processo de recarga das baterias geralmente requer muito tempo e a infraestrutura disponível para esse fim ainda é escassa (Basso *et al.*, [2019](#)). Por isso, o tempo entre os usos precisa ser bem calculado, assim como a autonomia esperada para uma dada rota.

Esses fatores resultam em veículos elétricos com um custo de aquisição elevado e autonomia limitada. Dessa forma, a baixa autonomia pode levar a dois cenários indesejados. O primeiro é a subutilização do caminhão, de modo a evitar o risco de ficar sem carga ao longo da rota. O segundo cenário é a parada do caminhão devido ao esgotamento da bateria, o que acarreta em custos de reboque e na interrupção da rota planejada. Assim, embora o custo variável relacionado à energia em veículos elétricos a bateria (BEVs) seja consideravelmente menor do que nos veículos de combustão interna (ICVs), os BEVs enfrentam desafios devido a seus maiores custos fixos e menor resiliência operacional.

1.1.3 Importância de modelos de energia para veículos elétricos

Considerando a baixa autonomia de veículos elétricos e o seu elevado tempo relativo para recarga, faz-se importante haver modelos confiáveis para a estimativa de energia consumida em uma dada rota, ou, de forma mais abrangente, em uma dada operação.

Do ponto de vista de planejamento e *scheduling* do carregamento de veículos elétricos, compreender como e quando a energia é consumida durante as operações diárias ajuda na implementação de estratégias de carregamento, garantindo que os veículos este-

jam prontos para atender às demandas de entrega ao longo do dia. Rogge *et al.* (2018) desenvolveram uma metodologia para estimação do TCO (*total cost of ownership*) de uma frota de ônibus elétricos, em que são considerados o *scheduling* de carregamento, assim como os custos de investimento e operacionais do sistema de ônibus. Um dos insumos cruciais para esse modelo é a estimativa de nível de bateria utilizado entre trechos.

Modelos confiáveis de estimativa de energia de veículos elétricos também são cruciais para realizar um planejamento de roteirização desses veículos. Em geral, algoritmos de roteamento assumem o consumo energético como uma função linear da distância, ou seja, uma autonomia constante. No entanto, o consumo de energia é influenciado não só pela distância percorrida, mas também por outros fatores, como a carga transportada, o perfil de velocidades e acelerações, a topografia e o uso de equipamentos auxiliares, como o ar-condicionado (Basso *et al.*, 2019). Ao incorporar essas informações no planejamento da roteirização, é possível estimar com mais precisão o consumo de energia necessário para cada rota. Isso poderia permitir uma programação mais eficiente, garantindo que os veículos tenham autonomia suficiente para completar as rotas designadas, evitando paradas indesejadas devido ao esgotamento da bateria.

Além dos fatores relacionados à rota, é importante considerar que diferentes veículos possuem eficiências variadas, dependendo do contexto em que são utilizados. Existem veículos mais adequados para diferentes situações. Por exemplo, um caminhão com baixo torque tem um desempenho melhor em trajetos de alta velocidade e de baixa inclinação, enquanto caminhões com alto torque apresentam um melhor desempenho em rotas com aclives e declives acentuados, segundo Velázquez-Martínez *et al.* (2016). No caso de veículos elétricos, Ahmed *et al.* (2022) encontraram uma correlação entre especificações técnicas e autonomia nominal. A escolha por parâmetros de torque pode comprometer variáveis preditoras de maior autonomia em condições padrão do fabricante. Nesse sentido, no caso de uma frota com mais de um modelo de caminhão elétrico, os modelos de energia poderiam ser úteis para a alocação de rotas para caminhões de modo a minimizar o gasto energético, já que os modelos incorporam tais diferenças de desempenho dos caminhões em diferentes cenários. Em veículos a combustão, é sabido que tal seleção de rotas é algo que impacta no consumo de energia, portanto, na emissão de gases, sendo que a seleção ótima de caminhos pode levar a uma diminuição de 4% nas emissões em comparação com métodos tradicionais de otimização de distância (Behnke; Kirschstein, 2017).

Além disso, na escolha de trajetos, os modelos de energia também poderiam ser utilizados para selecionar rotas de menor consumo entre dois pontos, visto que mesmo pequenas variabilidades na rota escolhida podem gerar um impacto perceptível na autonomia do veículo.

Dessa forma, modelos de energia são importantes para otimização de aspectos operacionais de veículos elétricos, como *scheduling* de carregamento e roteirização. Tais

aspectos, por sua vez, têm efeito direto no TCO e na taxa de emissão dos veículos a longo do seu ciclo de vida, o que impacta diretamente na sua viabilidade econômica e no seu impacto ambiental.

A eficácia desses modelos é ressaltada quando são capazes de extrapolar além das condições previamente observadas, permitindo a projeção e análise em contextos que ainda não foram diretamente vivenciados. Para tal, não apenas é necessário o desenvolvimento e validação de parâmetros de um modelo em específico, mas, também, a simulação de condições aderentes aos dados utilizados para o ajuste paramétrico do modelo. Isto é, no caso de um modelo que utiliza dados de operação com período entre amostragens de 10 segundos, o perfil simulado deve ser coerente com tal amostragem.

Em resumo, os modelos de energia, embora fundamentados em aspectos primordialmente mecânicos e físicos dos veículos, acarretam implicações estratégicas e operacionais significativas. Nesse contexto, torna-se crucial uma análise centrada nas lacunas e potencialidades desses modelos, adotando uma perspectiva de planejamento e operação característica da engenharia de produção.

1.2 Diagnóstico da operação

O presente trabalho de formatura foi conduzido como um estudo de caso feito com uma empresa do ramo de alimentos e bebidas. No centro de distribuição estudado durante esse trabalho, opera-se com 42 modelos de veículos elétricos do modelo Volkswagen e-Delivery 14 (Figura 3), com capacidade para 6 pallets. O total da frota do CD é de 159 veículos, ou seja, 26,4% da frota é eletrificada. Além disso, toda a energia que abastece o CD é de geração renovável e limpa. As entregas são feitas no contexto B2B. Anteriormente, o CD operou também com modelos iEV1200T da Jac Motors, no entanto, no período estudado, apenas os modelos da Volkswagen estavam em operação. A versão utilizada do e-Delivery 14 contém 3 packs de bateria, totalizando 105 kWh, como uma autonomia nominal de 110km.

Ao longo de 2023, foram realizadas oito visitas ao centro de distribuição, acompanhadas por análises de rotas e entrevistas com supervisores de operação e roteirização. Inspeções minuciosas foram conduzidas manualmente em fichas contendo informações de mais de 350 rotas para avaliar os níveis de bateria na chegada dos caminhões ao centro de distribuição. Uma análise individual de mais de 200 rotas foi realizada para identificar padrões operacionais, contribuindo assim para a curadoria de dados necessária para este trabalho.

O processo de entregas tem início com a roteirização, que utiliza um parâmetro de autonomia fixo para os veículos elétricos. A definição desse parâmetro é resultado de reuniões entre a equipe de liderança do centro de distribuição e a central de roteirização



Figura 3 – E-Delivery 14.

Fonte: Volkswagen

da empresa. Há esforços para estabelecer rotas fixas e manter motoristas consistentes para cada caminhão. No entanto, esse processo ainda não está completamente aderente.

Antes de saírem para as entregas, durante a noite, os caminhões elétricos são carregados em carregadores como os da Figura 4 por cerca de 8 horas. Um procedimento de verificação é executado no momento de saída, chamado de *checklist*, o qual abrange a inspeção de danos no veículo, a confirmação da existência de acessórios como extintor, cones e cofre, a disponibilidade de carrinhos auxiliares para o transporte das caixas, a verificação da quilometragem registrada no veículo e, no caso dos caminhões elétricos, a garantia de que o veículo só deixa o centro de distribuição com o painel indicando uma carga de bateria de 100%.

Durante o processo de entregas, o motorista recebe instruções para utilizar um aplicativo exclusivo da empresa. Dentro desse aplicativo, há certa flexibilidade para escolher a primeira entrega da rota. No entanto, uma vez que a primeira entrega é feita, o motorista deve seguir rigorosamente as orientações fornecidas pelo aplicativo para as entregas subsequentes. É uma exigência constante que o motorista esteja atento ao nível da bateria exibido no painel do caminhão. Quando a bateria atinge aproximadamente 50%, o motorista é instruído a informar imediatamente seu supervisor no centro de distribuição a respeito dessa situação.

A partir desse ponto, uma avaliação detalhada da viabilidade de continuar a rota é conduzida, ponto por ponto. Essa avaliação leva em consideração a indicação de autonomia exibida no painel do veículo, a distância estimada até a próxima entrega, fornecida pelo aplicativo da empresa, e a distância da próxima entrega até o centro de distribuição, obtida do aplicativo "Google Maps". Se a autonomia indicada no painel for suficiente para cobrir a soma das distâncias até a próxima entrega e de lá até o centro de distribuição,



Figura 4 – Carregador do veículo elétrico
Fonte: autor

o motorista prossegue com essa entrega. Esse processo é repetido em todas as entregas restantes. No entanto, se a autonomia prevista no painel for inferior à distância estimada, o veículo é direcionado a retornar ao centro de distribuição imediatamente.

Após o retorno ao centro de distribuição, é conduzida uma segunda verificação (*checklist*), que abrange a inspeção de possíveis danos recentes no veículo, a confirmação da presença de todos os acessórios e a anotação da quilometragem atual. Não é registrado ou armazenado de nenhuma maneira o nível da bateria durante esse processo de retorno. No entanto, são tiradas fotografias do painel do veículo para documentar a quilometragem percorrida. Nessas imagens, é comum que o indicador do nível de bateria seja visível como parte do registro. O desenho esquemático desse fluxograma de operação pode ser visto na Figura 6.

Para o desenvolvimento do trabalho, foram coletados dados de 329 *checklists* de retorno. Apenas um subconjunto destes pode ser utilizado para os modelos de energia, pela questão da viabilidade do uso dos dados da rota que será discutido em seções subsequentes do trabalho. Das 329 rotas, 149 tinham fotos em que não era possível verificar o nível de bateria na foto do *checklist*. O histograma dos níveis de bateria das 180 rotas restantes pode ser visto na Figura 5.

É verificável que, na amostra, a média de nível de bateria no retorno ao CD foi de 51,3% e o desvio padrão foi de 11,86%, evidenciando uma alta variabilidade no consumo de bateria entre as rotas. De fato, a cidade de operação possui uma grande diversidade de

regiões, algumas delas possuem maior concentração de semáforos, ou ruas mais estreitas, enquanto outras possuem ruas mais livres e menor adensamento de comércio e residências, além disso há uma grande diversidade de relevo. Tais fatos podem fazer com que o consumo em kWh/km tenha uma variabilidade alta.

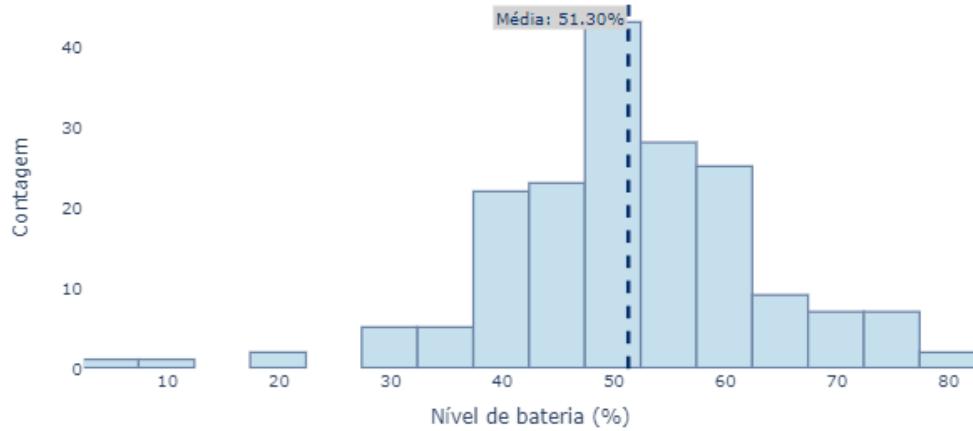


Figura 5 – Histograma de nível de bateria no retorno ao CD

Fonte: autor

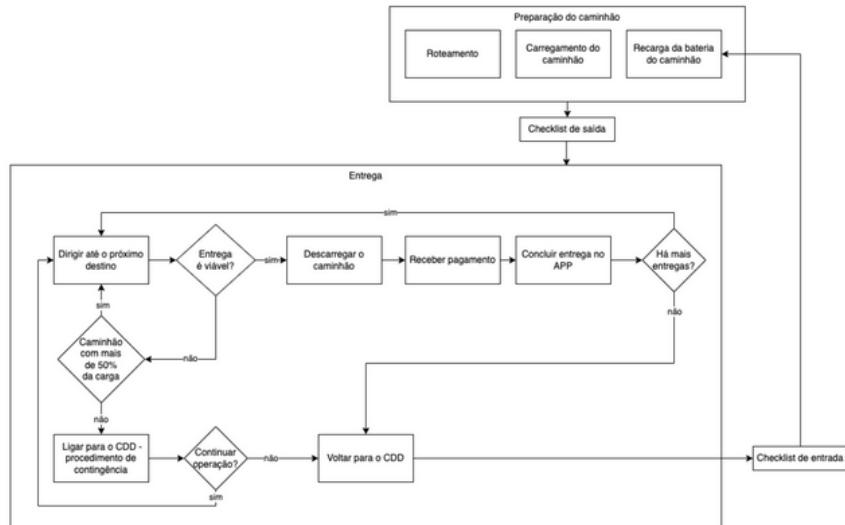


Figura 6 – Fluxograma do processo de entregas e procedimento de emergência

Fonte: autor

1.3 Objetivo do trabalho

O objetivo deste trabalho reside no desenvolvimento e avaliação de modelos híbridos (combinando modelagem física e estatística) de consumo de energia em três escalas distintas: macroscópica, mesoscópica e microscópica, utilizando dados provenientes de registros de operação já existentes nos sistemas da empresa em questão. Os dados utilizados são de rastreamento por GPS e informações sobre entregas em uma frota pertencente a uma indústria de bebidas e alimentos. De forma enumerada, os objetivos do trabalho são:

1. Aplicação de modelos de energia microscópicos com diferentes modelagens do mecanismo de regeneração e sua correção com um coeficiente linear obtido com validação estatística
2. Derivação de parâmetros macroscópicos de autonomia (kWh/km) referentes a cada uma das modelagens do mecanismo de regeneração
3. Derivação de parâmetros mesoscópicos de consumo energético por distância e massa (kWh/km/kg)
4. Análises de erros, limitações e aplicações dos modelos

Os produtos deste TF serão os modelos ajustados e as análises de suas limitações e cenários de aplicação.

1.4 Estrutura do trabalho

A estrutura deste trabalho inicia-se com a introdução, abordando as motivações para a investigação sobre veículos elétricos, a importância dos modelos de estimativa de energia para esses veículos e um diagnóstico operacional da empresa em questão.

Em seguida, realiza-se uma revisão de literatura, destacando as principais referências sobre estimativa de energia, gases de efeito estufa, estado de carga de baterias, preparação de dados de rastreamento por GPS e aplicações de modelos de energia.

O capítulo subsequente aborda os materiais e métodos, descrevendo os dados, a metodologia de obtenção e os procedimentos de limpeza e processamento. Além disso, são apresentados os modelos adotados, sua formulação matemática e os procedimentos para inferência de parâmetros.

Na seção de resultados e discussão, são analisados os erros e suas possíveis fontes, juntamente com análises de dimensionamento e clusterização de rotas baseadas nos modelos de energia. Ao final do capítulo, são resumidos os *insights* e casos de uso recomendados para cada tipo de modelo.

A conclusão sintetiza os principais aprendizados, seguida por sugestões para futuros desenvolvimentos.

Os apêndices fornecem acesso a parte dos dados e ao código fonte utilizado neste trabalho.

2 Revisão da Literatura

Neste capítulo é apresentada uma revisão de literatura focada nos temas de estimação de emissão de gases de efeito estufa em veículos a combustão (*ICV*), modelos de energia para veículos elétricos *BEV*, estimativas de estado de carga (*SOC*), preparação de dados de rastreio de GPS e, por fim, aplicações de modelos de energia para veículos elétricos.

2.1 Estimação de emissão de gases de efeito estufa (GEE)

Modelos de estimativa de consumo energético já datam bem anteriormente à popularização de veículos elétricos. Na realidade, a estimativa de consumo de combustível e de emissões de CO_2 em veículos a combustão já levou ao desenvolvimento de diversos modelos de estimativa de consumo energético. Isso ocorre devido à forte correlação entre o consumo de energia, o consumo de combustível e a emissão de CO_2 , uma vez que o consumo de combustível alimenta o sistema energético do motor, e a sua combustão é responsável pela emissão de gases. Nesse sentido, o desenvolvimento de modelos de emissão e consumo de combustíveis é precursor a modelos energéticos para veículos elétricos.

Conforme destacado por Paschoal *et al.* (2017), diversos modelos têm sido empregados para tais finalidades. Entre os mais notáveis para a estimativa de emissões de Gases de Efeito Estufa (GEE), destacam-se o MOBILE, o COPERT e o MOVES. O MOBILE, desenvolvido pela Agência de Proteção Ambiental dos Estados Unidos (U. S. Environmental Protection Agency, 2003), calcula a taxa de emissão da frota por categoria de veículo (em g/milhas), com base em variáveis relacionadas à frota e ao ambiente. O COPERT, cujo nome se refere ao Programa de Computador para Cálculo de Emissões de Transporte Rodoviário (*Computer Programme to Calculate Emissions from Road Transport*) (Ntziachristos *et al.*, 2009), estima as emissões do motor com base na distância percorrida e em fatores de correção associados à velocidade média e a sua variação. Por sua vez, o MOVES é um modelo desenvolvido pela USEPA (Koupal *et al.*, 2003) que busca calcular a Potência Específica do Motor (VSP, em kW/Mg) e correlacioná-la com a emissão de poluentes (em g/h).

Além dos modelos de GEE, também existem modelos de previsão de consumo de combustível. Dentre esses, um dos modelos citados por Paschoal *et al.* (2017) é o PERE. O PERE (*Physical Emission Rate Estimator*) foi desenvolvido pela U. S. Environmental Protection Agency (2004) para apoiar o desenvolvimento do MOVES, e busca estimar a taxa de consumo de combustível do veículo em g/s, utilizando para tal uma estimativa da potência demandada.

Por último, existem modelos que calculam ao mesmo tempo as emissões de GEE o uso de combustível. Um desses modelos é chamado de CMEM (*Modelo Abrangente de Emissões Modais, em inglês*). Este modelo é dividido em diferentes modos, usando informações sobre como o veículo é operado e um modelo para calcular a potência necessária pelo veículo. Então, junto com uma estimativa da velocidade do motor, ele calcula quanto combustível está sendo usado (Barth; Scora; Younglove, 2004).

2.2 Estimativa de consumo de energia em veículos elétricos

A modelagem do consumo de energia em uma rota é uma tarefa complexa, embora necessária. Para lidar com essa complexidade, diversos modelos de estimativa de energia têm sido propostos na literatura. Segundo Qi *et al.* (2018), a estimativa do consumo de energia de veículos elétricos pode abordar diferentes níveis de detalhe (granularidades), considerar uma variedade de fatores e seguir abordagens físicas ou baseadas em dados.

A primeira característica diz respeito à granularidade do modelo. Algumas aplicações requerem uma estimativa detalhada do consumo de energia ponto a ponto, enquanto outras demandam uma aproximação ao nível de conexões entre os nós de entrega. Assim, os modelos podem ser classificados como microscópicos, que estimam o consumo de energia em cada ponto específico, mesoscópicos, que utilizam parâmetros médios relativos a trechos da viagem, ou macroscópicos, que estimam o consumo com base em parâmetros médios ao longo de uma viagem inteira.

Em relação à granularidade, modelos macroscópicos de estimativa são mais ágeis e eficientes em termos de cálculo. Contudo, eles não levam em consideração variações pontuais no consumo de energia, o que pode resultar em falta de precisão quando se trata de necessidades específicas. Nesses casos, modelos mesoscópicos ou microscópicos podem ser utilizados. Zhang; Yao (2019) desenvolveram um modelo linear mesoscópico para veículos elétricos que leva em consideração, dentre outros fatores, as velocidades médias e o chamado VSP, a potência instantânea por unidade de massa. Com relação aos modelos microscópicos, segundo Fiori; Ahn; Rakha (2016), eles podem ser divididos entre modelos *forward* e *backward*. Os modelos *backward* calculam a potência necessária para possibilitar a tração do veículo nas rodas, e, de forma inversa, calculam a potência gerada nos motores. Por outro lado, os modelos *forward* partem da potência gerada pela interação de componentes internos do motor para dimensionar a energia gasta. Os modelos *forward* são amplamente utilizados na indústria para identificar os componentes com maior impacto no consumo energético do veículo. No entanto, eles tendem a ser mais complexos do que modelos *backward*, além de dependerem muito especificamente dos componentes do veículo modelado.

A segunda característica diz respeito ao modelo utilizado. Existem modelos estatís-

ticos, também conhecidos como baseados em dados (*data-driven*), nos quais algoritmos são utilizados para estimar o consumo de energia por meio do ajuste de parâmetros. Por outro lado, existem modelos analíticos, nos quais as equações são formuladas de maneira física e explicável. Além disso, também existem modelos híbridos, que combinam as abordagens estatística e analítica. Dada a disponibilidade abundante de dados provenientes de sistemas de rastreamento de veículos, seria viável criar modelos de consumo de energia que se baseiam unicamente nos dados, sem a necessidade de pressupostos físicos preestabelecidos. Um exemplo disso é o estudo realizado por Pamuła; Pamuła (2020) para ônibus elétricos, onde foi modelado o consumo de energia utilizando redes neurais recorrentes, sem uma formulação física na estrutura da modelagem. Entretanto, como mencionado em Fiori *et al.* (2021), abordagens baseadas em dados, apesar de atrativas por não dependerem de suposições prévias, possuem a desvantagem de que os parâmetros encontrados nesses modelos geralmente não podem ser extrapolados para outras estimativas, uma vez que são ajustados especificamente para tipos particulares de veículos, regiões e operações. Nesse contexto, a imposição de equações físicas aos modelos pode se mostrar vantajosa, uma vez que melhora a explicabilidade dos parâmetros e sua aplicabilidade a outras situações.

A terceira característica está relacionada ao impacto de variáveis externas no modelo. Devido à influência de diversos fatores no consumo de energia, estes podem ser explicitamente considerados na modelagem ou afetar indiretamente parâmetros como velocidade e aceleração. Em relação à incorporação de variáveis externas, esse processo varia conforme a aplicação. Em cenários com dados reais, onde informações sobre velocidade, congestionamentos e condições da via, como a presença de buracos, estão disponíveis, tais efeitos podem ser absorvidos no perfil de velocidades e acelerações medidos. Entretanto, em modelos de simulação, pode-se considerar essas variáveis e incluí-las na modelagem.

De forma geral, a formulação "backward" da potência de tração necessária nas rodas do caminhão é feita com uma derivação simples da segunda lei de Newton. Os princípios da dinâmica do veículo podem ser aplicados a qualquer veículo, seja ele elétrico ou não, explicando também a semelhança com modelos como o CMEM, (Barth; Scora; Younglove, 2004). Tal qual derivado em Abousleiman; Rawashdeh (2015), pode-se assumir que as forças que atuam no veículo são resistência ao rolamento, resistência ao gradiente da via (força gravitacional tangencial), força de resistência ao ar e a força de aceleração. A soma dessas forças, multiplicada pela velocidade, nos fornece uma potência instantânea necessária nas rodas para permitir o movimento do veículo. Baseada nas equações dinâmicas, a expressão final da potência nas rodas, $P_W(t)$ é:

$$P_W(t) = [(M(t) \cdot a(t)) + (M(t) \cdot g \cdot \sin \theta) + (M(t) \cdot g \cdot C_R \cdot \cos \theta) + (\frac{1}{2} \cdot \rho \cdot C_D \cdot A_f \cdot v(t)^2)] \cdot v(t) \quad (2.1)$$

Em que $P_W(t)$ é a potência de tração em W , $M(t)$ é a massa do veículo no instante

de tempo t em kg , $a(t)$ é sua aceleração em m/s^2 , v é a velocidade em m/s , g é a aceleração da gravidade em m/s^2 , θ é o ângulo da via (grade), C_R é o coeficiente de resistência ao rolamento, C_D é o coeficiente de arrasto, ρ é a massa específica do ar em kg/m^3 e A_f é a área frontal do veículo em m^2 . Essa expressão é utilizada em diversos modelos e aplicações, como Barth; Scora; Younglove (2004), Fiori *et al.* (2021), Pelletier; Jabali; Laporte (2019) ou tendo apenas algumas variações em sua formulação, como no VT-CPEM (Fiori; Ahn; Rakha, 2016).

Além dos elementos que impactam a potência de tração necessária para o veículo, existem fatores que afetam diretamente o uso dos sistemas auxiliares, gerando uma potência adicional. Dentre os sistemas que consomem tal potência adicional, podemos citar sistemas de som, luzes do painel e, principalmente, sistemas de HVAC, ou seja, ar-condicionado e aquecimento. Em temperaturas mais frias ou quentes, o uso de aquecedores e ar-condicionado se torna mais intensivo. Portanto, a temperatura pode ser considerada uma variável preditora do uso desses sistemas, tal qual modelado por Fiori *et al.* (2021).

No contexto de veículos elétricos, outro componente que pode ser incorporado à modelagem do consumo energético são os sistemas regenerativos. Assim, o consumo de energia em veículos elétricos pode ser dividido em duas partes: a energia cinética positiva e a energia cinética negativa, esta última relacionada às características regenerativas dos sistemas de frenagem do veículo, em inglês regenerative braking system (RBS). O RBS facilita a recuperação da energia, evitando a dissipação de energia em forma de calor em sistemas de frenagem baseados em atrito.

O impacto do sistema regenerativo no consumo de energia foi abordado de diversas maneiras na literatura. Shibata; Nakagawa (2015) e Abousleiman; Rawashdeh (2015) consideraram um coeficiente de regeneração constante, independente da potência, velocidade ou aceleração instantâneas. Por outro lado, uma abordagem alternativa, adotada por Hayes; Davis (2014), envolve a discretização de intervalos de potência instantânea, com variação percentual na regeneração em faixas, sendo 100% para valores inferiores a 20kW. Yang *et al.* (2014) adotaram um modelo no qual o coeficiente de regeneração varia em função da velocidade, com uma função distinta para velocidades acima e abaixo de 5m/s. Uma outra abordagem, usada no modelo VT-CPEM, Fiori; Ahn; Rakha (2016), é representar o coeficiente de regeneração como uma função exponencial em relação ao inverso da magnitude da frenagem.

2.3 Estimativa de Estado de Carga (SOC)

Pode-se dizer que a estimativa do estado de carga (*State of charge - SOC*) em veículos elétricos tem um paralelo com a estimativa do consumo de combustível em veículos a combustão interna. No contexto dos veículos a combustão, a estimativa do consumo de

combustível auxilia na compreensão de como a energia potencial química armazenada no combustível se converte em energia mecânica, impulsionando o veículo. Da mesma forma, nos veículos elétricos, a estimativa de *SOC* está relacionada à carga armazenada na bateria, que permite a geração de energia elétrica e, subsequentemente, sua conversão em energia mecânica para a locomoção do veículo. Não existe um consenso formal sobre a definição de SOC (Zheng *et al.*, 2018; Chang, 2013), mas, em geral, ela é definida como a razão entre a capacidade atual da bateria $Q(t)$ e sua capacidade nominal Q_N .

Existem diversos métodos para a estimação de *SOC*. Segundo Chang (2013), podem ser listados quatro principais categorias de métodos para tal estimação:

1. *Mensuração direta*: utiliza medidas como diferença de potencial e impedância e correlaciona tal medida com um valor de *SOC* (em %), por meio de uma curva. Um dos métodos mais utilizados nessa categoria é o método de tensão de circuito aberto (em inglês *Open Circuit Voltage Method*, *OCV*). Em geral, o *SOC* é modelado com um relacionamento linear em relação ao *OCV* para baterias de chumbo-ácido. No entanto, esse relacionamento não é linear em baterias de íon-lítio, o que impõe o uso de uma tabela de valores (*de-para*) de *OCV* e *SOC*.
2. *Estimativa contabilística* ou *Book-keeping estimation*: integra a quantidade de carga eliminada ao longo do tempo e a compara com a carga nominal da bateria de modo a estimar o *SOC*.
3. *Sistemas adaptativos*: utilizam diversas entradas, como medidas diretas de tensão instantânea, histórico de tensão da bateria e temperatura ambiente, para a modelagem dessas variáveis a um valor de *SOC* por meio de um sistema matemático como uma rede neural ou um filtro de Kalman.
4. *Métodos híbridos*: combinam as estratégias supracitadas para estimação de *SOC*.

Segundo Zheng *et al.* (2018), pode-se dizer que existe um *trade-off* entre minimização de erro e complexidade computacional do método de estimação de SOC. Segundo o mesmo trabalho, existe incerteza tanto na estimativa de $Q(t)$, como também no valor de referência Q_N . Em relação à capacidade nominal Q_N , ela pode ter seu valor alterado pelo envelhecimento e pela temperatura ambiente. É apontado que o fator do envelhecimento pode ser ignorado em intervalos curtos de tempo, no entanto, não é raro que as baterias de íon-lítio operem em um intervalo grande de temperaturas, o que pode influenciar na capacidade disponível. O erro associado à estimativa de $Q(t)$ é dependente do método utilizado, mas tende a depender também de variáveis em comum que afetam o valor de referência. Ainda de acordo com Zheng *et al.* (2018), mesmo para um método simples baseado em *OCV*, os efeitos de saúde da bateria, temperatura e histerese não são bem considerados nas tabelas de *SOC-OCV*. Apesar de muitos métodos de estimação

tenham reportado valores de erro baixos (menores que 1%), esses resultados são obtidos em condições controladas. No contexto de uma operação, ainda segundo o mesmo artigo, a depender do sistema do veículo, pode ser necessário recalibrar o sistema de estimativa a cada 9 dias para manter o erro do *SOC* em valores inferiores a 5%.

2.4 Preparação de dados de GPS

Dados de GPS (Global Positioning System) consistem em informações de localização obtidas por meio de satélites. Cada vez que um dispositivo, como um celular contendo um receptor de GPS, registra sua posição, ele coleta dados que incluem as coordenadas de latitude e longitude, a hora e, frequentemente, a velocidade do veículo.

No entanto, os dados de GPS são conhecidos por serem esparsos e imprecisos em algumas situações (Laranjeiro *et al.*, 2019). Isso ocorre porque a qualidade dos sinais de satélite pode ser afetada por obstáculos, como edifícios altos ou áreas com cobertura deficiente, resultando em leituras imprecisas ou atrasadas. Além disso, o próprio aparelho celular pode apresentar falhas no componente de sinal.

Algumas indicações de observações errôneas coletadas via GPS incluem velocidades e acelerações irrealistas. Segundo Schüssler; Axhausen (2008), velocidades acima de 180 km/h ou acelerações acima de 10 m/s^2 indicam pontos com medidas a serem descartadas.

Segundo Laranjeiro *et al.* (2019), a limpeza de dados de GPS pode ser feita em etapas. Em primeiro lugar, é calculado o deslocamento utilizando-se a distância de Haversine entre dois pontos de latitude e longitude determinada. Com essa informação e o intervalo de tempo, pode ser calculada a velocidade média entre os dois pontos e, em seguida, a aceleração média. Para a limpeza, pontos com valores extremos de aceleração e velocidade são retirados. É importante ressaltar que a velocidade média inferida e a velocidade instantânea medida pelo GPS são diferentes. No caso do GPS, o efeito Doppler é aplicado às ondas de rádio transmitidas pelos satélites para o receptor GPS de modo a estimar a velocidade do receptor (Zhang *et al.*, 2006).

Segundo Plaudis *et al.* (2021), mesmo com a retirada de pontos anormais, as rotas de GPS ainda são pouco precisas e podem ser associadas a dois tipos principais de erros: o primeiro é associado a um desvio do ponto real e o ponto registrado pelo GPS, o segundo é um erro de amostragem, em que existe a perda de informação entre dois pontos. De modo a minimizar os dois tipos de erro, dados de GPS são processados por algoritmos chamados de *map-matching*. Esses algoritmos têm a responsabilidade de associar as observações de GPS à infraestrutura de estradas e vias, tal como ilustrado na figura 7.

Muitos provedores de serviços de *map-matching*, como Valhalla, Mapbox e GraphHopper, utilizam o algoritmo de cadeia de markov oculta (HMM) baseado no trabalho de



Figura 7 – Ilustração do resultado de um algoritmo de map-matching. Os pontos vermelhos são os registros de GPS e os azuis são os pontos na trajetória reconstruída. Fonte: Saki; Hagen (2022)

Newson; Krumm (2009). Este método envolve a alocação de N segmentos possíveis para uma determinada observação, com base na proximidade espacial (utilizando a distância de Haversine) entre a observação e os diversos segmentos viários. Além disso, utilizando o grafo que descreve a estrutura viária do mapa, são calculados custos associados às transições potenciais entre as arestas representando os estados subsequentes do sistema. Dado o conhecimento das probabilidades de transição, o algoritmo de Viterbi, que encontra a sequência mais provável de estados ocultos em um modelo de cadeia de Markov, é aplicado para determinar a rota mais verossímil nesse contexto.

2.5 Aplicações de Modelos de Energia

Os modelos de estimação de gasto energético de veículos elétricos têm diversas aplicações a nível operacional e estratégico. Do ponto de vista operacional, os modelos de energia têm aplicações em *eco-routing* e em roteirização (Xiao *et al.*, 2021). A nível estratégico, os modelos podem, entre outros, ser utilizados para definição de instalação de infraestrutura de carregamento e dimensionamento de frotas (Pelletier; Jabali; Laporte, 2019),.

A aplicação de modelos de energia está relacionada não somente a sua proposição matemática e derivação de parâmetros estatísticos, mas também a sua aplicação em contextos ainda não observados. Nesse sentido, a aplicação de tais modelos pressupõe dados artificiais, que simulem o que seriam as condições de direção de situações hipotéticas. Nesse sentido, são utilizados simuladores de modo a estimar os perfis de velocidades e acelerações dos veículos. Um dos simuladores de referência é o *FASTSim: Future Automotive Systems Technology Simulator* (Brooker *et al.*, 2015). De forma similar, Genikomsakis; Mitrentsis (2017) desenvolveram um modelo de simulação integrado ao modelo de energia

VT-CPEM (Fiori; Ahn; Rakha, 2016) para estimação de consumo energético em rotas simuladas.

Existe um grande desafio do ponto de vista de integrar tais simulações em problemas de otimização numérica, uma vez que se torna, em muitos casos, computacionalmente desafiador fazer cálculos para todos os arcos possíveis entre nós de entrega, dada a natureza combinatória do problema. Nesse sentido, algumas simplificações podem ser adotadas. Xiao *et al.* (2021) utilizam uma linearização das funções de potência e de cálculo de energia microscópico, de modo a incluí-las como função de custo de um problema de otimização linear para roteirização de veículos elétricos. No trabalho de Pelletier; Jabali; Laporte (2019), é utilizado um modelo de energia microscópico sem regeneração para estimar a energia consumida entre um arco de um grafo de vias. O grafo de vias é diferente do grafo de entregas, no grafo das vias cada nó é um cruzamento e os arcos são os segmentos de via entre os cruzamentos. Nesse contexto, é assumido um perfil de velocidades trapezoidal entre dois nós da via e, então, é calculada a energia desse arco. No estudo, assume-se o caminho mais curto da via entre dois nós de entrega e, assim, é feito um cálculo de energia simplificado entre tais nós de entrega.

Shamma *et al.* (2022) desenvolveram o *Electric Vehicle Path and Range Estimator (EVPRE)*, um software de planejamento ótimo de rotas para veículos elétricos. Este software utiliza informações de vias, utilizando dados do OpenStreetMaps, Google Maps e Tomtom, do veículo e do *FASTSim* e alimenta um modelo físico para estimar o consumo energético e distância percorrida por uma dada rota. Com isso, é desenhado uma espécie de mapa de contorno de um veículo ao redor de um ponto. A região "verde", seria a região mais segura de operação do veículo. O modelo utilizado pelo EVPRE não incorpora uma modelagem para a regeneração dos freios. Atualmente, alguns algoritmos de otimização multiobjetivo estão sendo integrados a este software para possibilitar a otimização de rotas que atendam a múltiplos objetivos, tais como tempo, energia e tráfego (Shamma *et al.*, 2022).

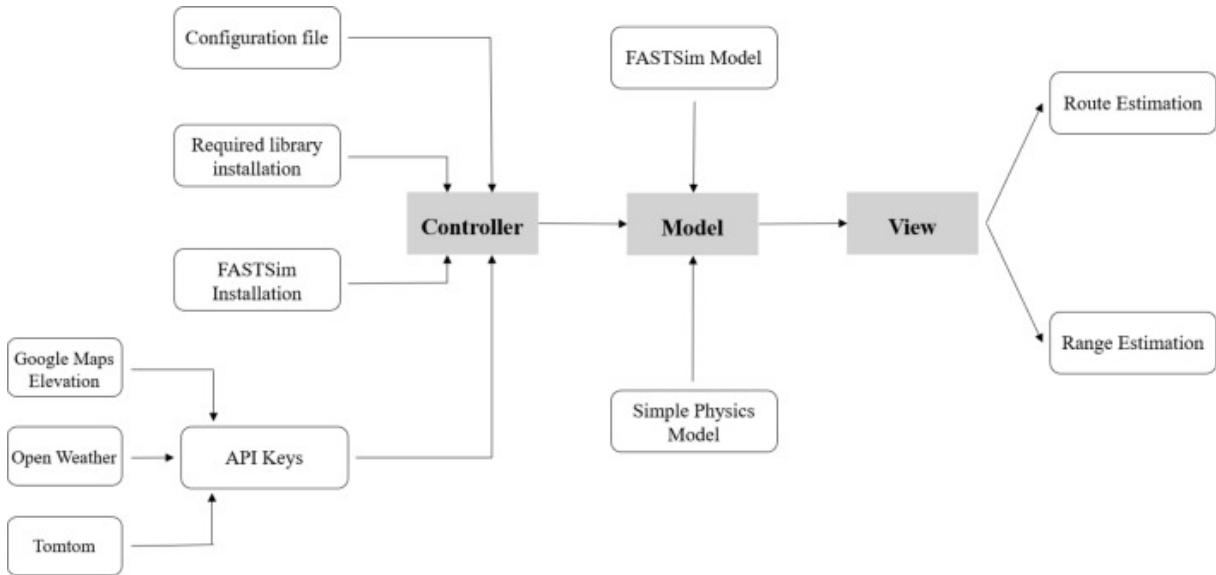
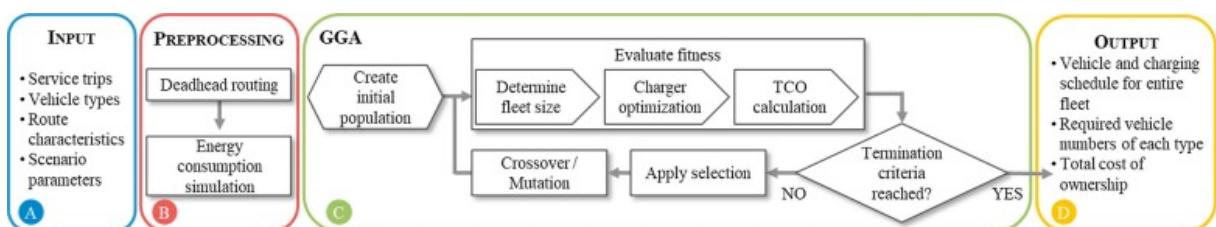


Figura 8 – Diagrama do sistema do software EVPRE

Fonte: Shamma *et al.* (2022)

Do ponto de vista estratégico, Rogge *et al.* (2018) desenvolveram uma metologia de otimização de custos para *scheduling* de viagens e carregamento de uma frota de ônibus elétricos, utilizando uma simulação de consumo de energia como *input* e, posteriormente, utiliza um algoritmo genético e um modelo de otimização linear para otimização do *scheduling* e da infraestrutura de carregamento. Por fim, são consideradas as implicações de custo (*TCO* - *Total cost of ownership*) da frota e da infraestrutura escolhida.

Figura 9 – Diagrama da solução de *scheduling* para frota de ônibus elétricoFonte: Rogge *et al.* (2018)

Por fim, tendo em vista as principais técnicas de tratamento de dados e de modelos de energia para veículos elétricos e suas aplicações, seguiu-se para a definição de materiais e métodos deste trabalho.

3 Materiais e Métodos

A metodologia empregada envolveu o uso de trajetos históricos para a estimativa de coeficientes de regeneração e a associação linear entre a energia estimada e a energia consumida em uma rota, resultando em uma relação análoga a uma eficiência, representada pelos coeficientes de inclinação e intercepto da regressão linear. Em seguida, parâmetros mesoscópicos e macroscópicos foram estimados e submetidos a validação em um conjunto de teste. O procedimento adotado neste estudo pode ser visualizado de forma esquemática na Figura 10.

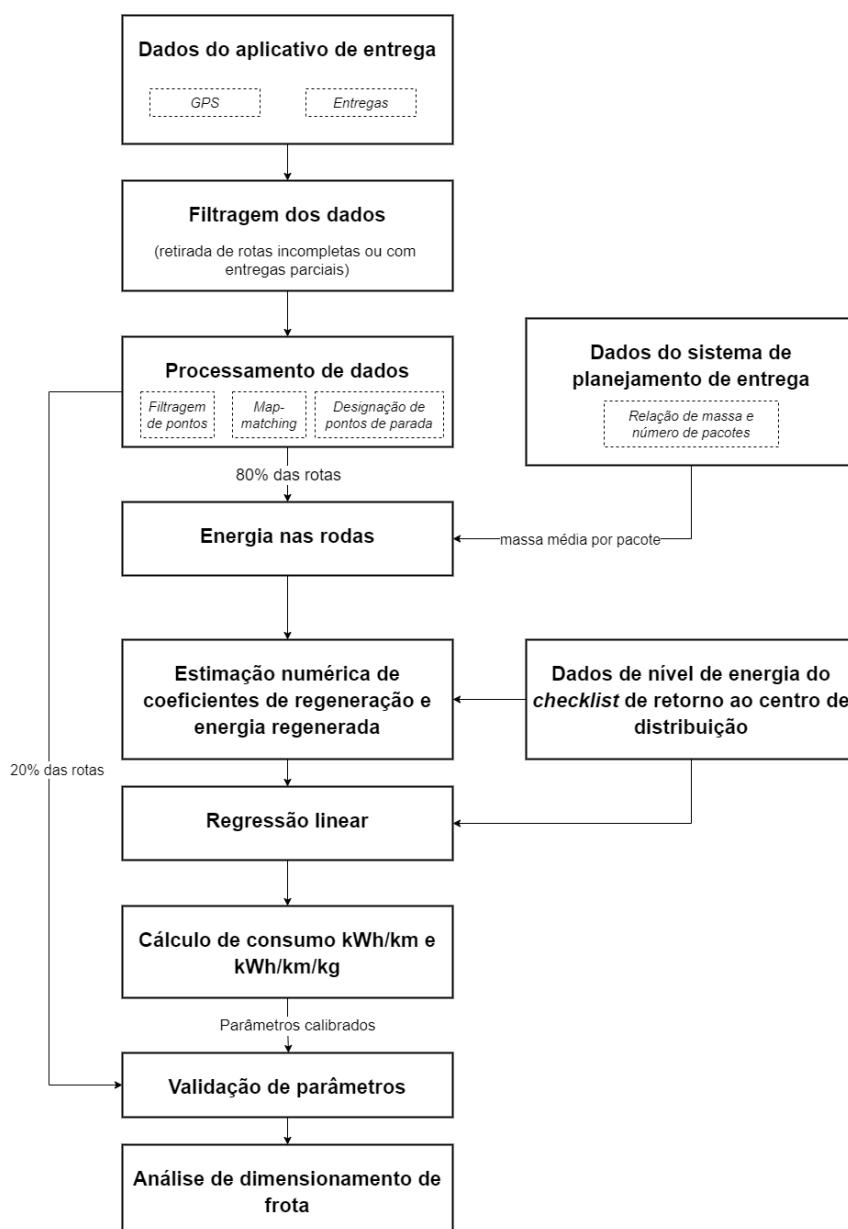


Figura 10 – Estrutura metodológica
Fonte: autor

3.1 Coleta de dados

3.1.1 Dados de GPS

Os dados das rotas realizadas por veículos elétricos durante os meses de julho, agosto e setembro de 2023 foram coletados como parte de uma operação de entrega de bebidas e alimentos. Cada rota foi acompanhada de registros de GPS que incluíam informações sobre a posição e a velocidade do veículo, obtidos por meio de um aplicativo exclusivo da empresa, instalado nos dispositivos móveis dos motoristas. Esses dados foram amostrados a uma frequência média de aproximadamente um ponto de rastreamento a cada 10 segundos.

O GPS fornecia a velocidade e as posições de latitude e longitude para um dado tempo, essas são as coordenadas que alimentam um algoritmo de *map-matching*. Com relação à velocidade, existem duas maneiras de calculá-la usando o GPS. A primeira envolve medir a diferença de posição ao longo do tempo, já que todas as leituras de posição do GPS são registradas com informações de horário. Basta dividir a distância percorrida de Haversine (equação 3.1) entre leituras consecutivas pelo tempo decorrido entre elas. A segunda abordagem para obter dados de velocidade é utilizar um receptor GPS e protocolo que forneçam diretamente informações de velocidade. Para os dados fornecidos, a velocidade estimada com o uso do efeito Doppler foi disponibilizada. Como a determinação com efeito Doppler é uma velocidade instantânea e tem um erro associado menor (D'Este; Zito; Taylor, 1999), ela foi escolhida para ser utilizada como entrada no modelo.

$$a = \sin^2\left(\frac{\Delta\text{lat}}{2}\right) + \cos(\text{lat}_1) \cdot \cos(\text{lat}_2) \cdot \sin^2\left(\frac{\Delta\text{lon}}{2}\right)$$

$$c = 2 \cdot \arctan[2 \left(\sqrt{a}, \sqrt{1-a} \right)]$$
(3.1)

$$D_{\text{haversine}} = R \cdot c$$

Em que:

- $D_{\text{haversine}}$: A distância entre os dois pontos na superfície da Terra.
- R : raio médio da Terra, que é usado para converter o ângulo central c em uma distância em quilômetros. O valor típico de R é aproximadamente 6.371 quilômetros.
- Δlat : Esta é a diferença de latitude entre os dois pontos na superfície da Terra.
- Δlon : É a diferença de longitude entre os dois pontos na superfície da Terra.
- lat_1 e lat_2 : São as latitudes dos dois pontos comparados.

Além da distância de Haversine, que leva em conta a curvatura da Terra, outra abordagem que pode ser utilizada para o cálculo de distâncias entre pontos de GPS é a conversão de coordenadas de latitude e longitude em um sistema de coordenadas projetadas (*Projected coordinate systems (PCS)*)), como o EPSG:3857 - Pseudo-Mercator, que permitem o uso de geometria planar (em duas dimensões). Como o tamanho da área considerada é de uma área geográfica pequena, as duas abordagens têm resultados semelhantes.

Neste trabalho, a distância entre dois pontos foi calculada utilizando a fórmula de Haversine. Para o cálculo de trechos envolvendo vários pontos, a conversão para o sistema de coordenadas pseudo-Mercator, EPSG:3857, foi empregada.

3.1.2 Dados de pontos de entrega

Foram fornecidos dados de latitude e longitude referentes aos pontos de entrega, juntamente com a ordem em que foram visitados, o número de caixas entregues e o status de cada entrega. Para fins de estimativa de peso por pacote, uma amostra da massa (em quilogramas) associada a cada pacote também foi disponibilizada e o valor de massa por pacote foi estabelecido em 25 kg, como detalhado abaixo.

3.1.3 Dados de *SOC* na volta ao centro de distribuição

Para verificar o nível de bateria (*SOC*) dos veículos ao final de cada rota, foram examinados os *checklists* de chegada dos caminhões, que incluíam uma fotografia (como as da figura 12) do painel com a indicação do nível da bateria.

Como indicado na Figura 11, cada intervalo entre os pontos equivale a 3,125% do nível de bateria. A determinação do nível de bateria foi realizada por meio da contagem do número de intervalos até atingir os quatro pontos de referência específicos, que eram 1; 0,75; 0,5 e 0,25. No entanto, é importante ressaltar que, para valores abaixo de 12,5% e acima de 0%, apenas uma única marcação intermediária estava disponível para aferição, limitando a precisão da medição nesse intervalo.

Dado que o propósito dessas fotografias não é registrar o nível de carga da bateria, mas sim servir como evidência da quilometragem do veículo, em algumas situações, a avaliação do nível da bateria não era viável, como na Figura 13.

Os valores de *SOC* que foram obtidos pelas fotografias foram convertidos em energia consumida por meio da fórmula 3.2, que considera o valor de capacidade nominal da bateria, ou seja, 105 kWh:

$$E_{\text{consumida}} = (1 - SOC) \cdot 105 \quad (3.2)$$



Figura 11 – Ponteiro de leitura do nível de bateria

Fonte: autor

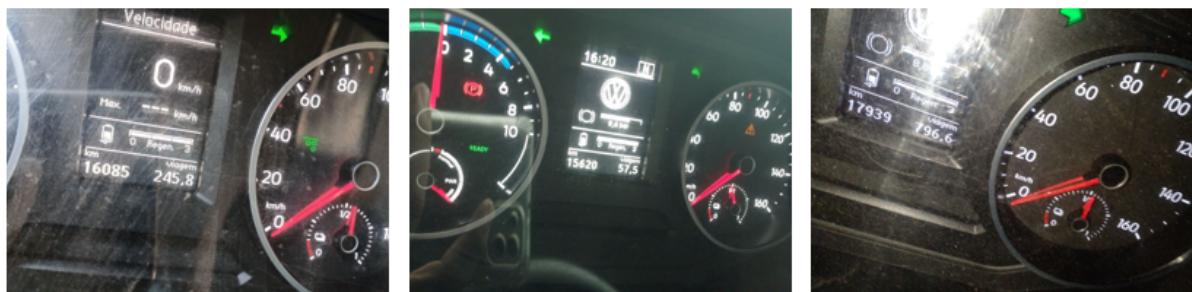


Figura 12 – Exemplos de fotos de *checklist* de retorno com indicações de bateria

Fonte: autor



Figura 13 – Exemplos de foto de *checklist* de retorno sem possibilidade de leitura de nível de bateria

Fonte: autor

3.2 Preparação de dados

3.2.1 Limpeza e filtragem inicial de rotas

Um processo de filtragem de rotas foi implementado com o intuito de selecionar aquelas que atendessem a critérios específicos, que podem ser visto na figura 14 e são detalhados no texto abaixo.

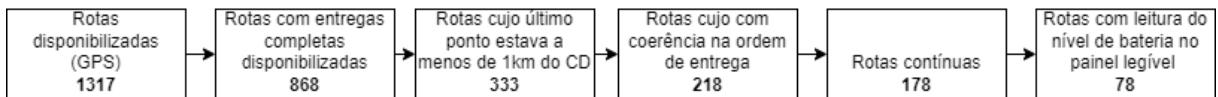


Figura 14 – Diagrama com quantidade e seleção das rotas para análise

Fonte: autor

Inicialmente, foram disponibilizadas 1317 rotas de veículos elétricos, que partiram do centro de distribuição de referência. Entretanto, apenas 868 dessas rotas tinham todas as suas entregas concluídas, sem entregas retornadas ou que foram parcialmente entregues. Dentre essas rotas, várias não incluíam o trajeto de volta ao centro de distribuição. Apesar do fato de os motoristas serem orientados a utilizarem o GPS durante toda a rota, o aplicativo de GPS pode apresentar instabilidade no envio de dados quando é executado em segundo plano. Uma vez que o aplicativo frequentemente opera em segundo plano durante o retorno ao centro de distribuição, um número significativo de rotas não continha informações de GPS com relação à parte do retorno ao CD.

Depois de eliminar as rotas que não atendiam a esses critérios, restaram 333 rotas. Posteriormente, as rotas que apresentavam inconsistências na ordem das entregas foram excluídas, pois significa que não era possível associar de maneira coerente os pontos de entrega aos pontos do trajeto percorrido. Essa inconsistência pode ocorrer devido a problemas no cadastro da localização de alguns clientes. Esse processo reduziu o número de rotas para 218.

Em seguida, as rotas foram submetidas a um processo de seleção que considerou apenas aquelas que apresentavam ser percursos ininterruptos, ou seja, rotas que exibiam continuidade visual em seu percurso: alguns exemplos de rotas excluídas por esse critério podem ser vistas na figura 15. Isso resultou em 178 rotas que atenderam a esse critério. Por último, as rotas que não continham registros de medição de bateria no *checklist* de retorno, ou cujos medidores de bateria não permitiam leitura (por exemplo, devido ao veículo estar desligado), foram excluídas da análise. Esse processo de triagem foi realizado para garantir a inclusão apenas de rotas completas e consistentes, nas quais a avaliação do nível de bateria fosse viável, a fim de assegurar a integridade dos dados utilizados no estudo. No final, restaram 78 rotas que foram utilizadas para análise.

Dentre as rotas selecionadas, foram aplicados procedimentos análogos ao descritos por Laranjeiro *et al.* (2019). Ou seja, foram excluídos pontos de velocidades e acelerações

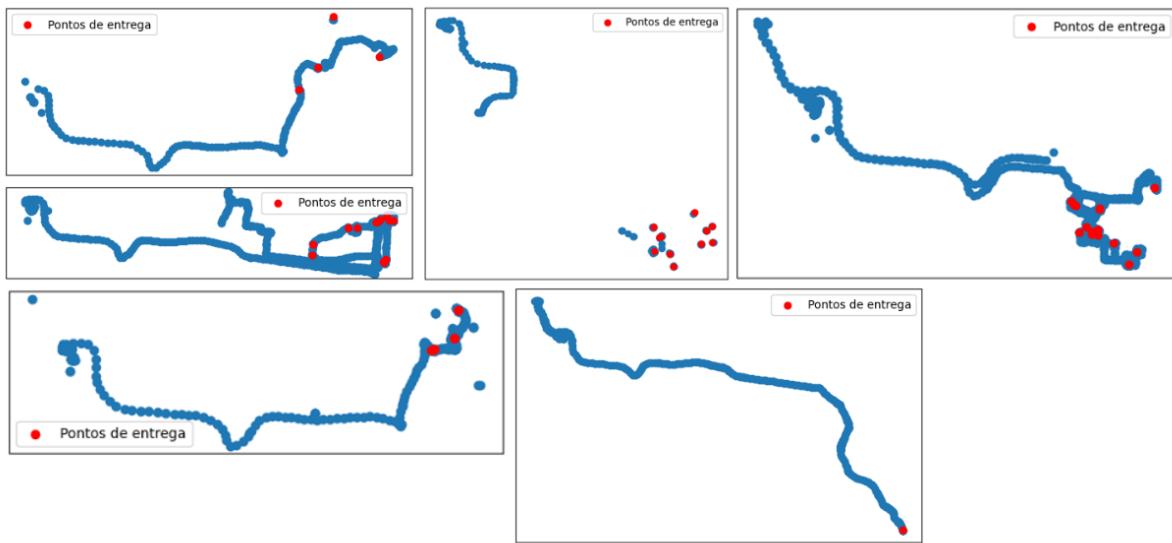


Figura 15 – Rotas consideradas descontínuas.

Fonte: autor

acima de certos valores dentro do passo a passo descrito no artigo, ou seja, acelerações maiores do que 10 m/s^2 e velocidades superiores a 180 km/h.

3.2.2 Designação de pontos de entrega e estimação da perda de massa ao longo da rota

Como mencionado, foram selecionadas apenas as rotas que constavam todas as entregas concluídas. Esse procedimento se justificou devido à complexidade inerente ao cálculo da massa restante no caminhão em casos de entregas incompletas, pois seria impossível saber o número de pacotes entregues. Posteriormente, para cada rota, o processo de identificação dos pontos de entrega específicos envolveu uma abordagem sequencial, onde a primeira entrega da rota era localizada ao percorrer a roteirização completa e, a partir desse ponto, estabelecia-se as restrições para a busca dos pontos de parada subsequentes apenas na porção restante da rota. Um exemplo de rota com seus pontos de entrega pode ser visto na Figura 16. Ressalta-se que as rotas nas quais não foi possível identificar os pontos de entrega na ordem adequada foram excluídas da análise, uma vez que foram observados alguns desvios nos dados, como registros incorretos de coordenadas geográficas dos clientes, o que poderia resultar em informações imprecisas e comprometer a integridade da análise.

Com o propósito de estimar a massa entregue nos pontos de entrega, foi utilizada uma amostra de dados que continha informações referentes ao número de pacotes e à massa total. Tal amostra continha 9845 entregas, em que se discriminavam o número de pacotes e a massa associada a tal número de pacotes. Podemos estimar um valor de massa específica do pacote para a entrega i como $m_{\text{pacote},i} = \frac{m_{\text{pacotes},i}}{N_{\text{pacotes},i}}$, em que $N_{\text{pacotes},i}$ denota o

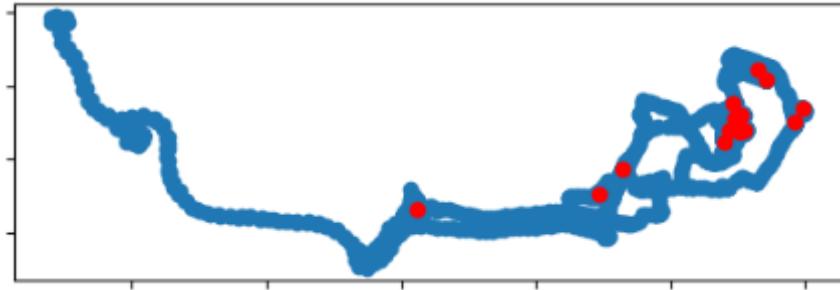


Figura 16 – Exemplo de rota (em azul) e pontos de entrega (em vermelho)
Fonte: autor

número de pacotes e $m_{\text{pacotes},i}$ a massa associada. O valor médio de $m_{\text{pacote},i}$, foi de 25,65 kg. Como pode ser visto na Figura 17, a dispersão de massa por pacote foi relativamente baixa, com a grande maioria dos pacotes se aproximando do valor médio. Para fins de estimativa de energia, m_{pacote} foi considerado como 25kg.

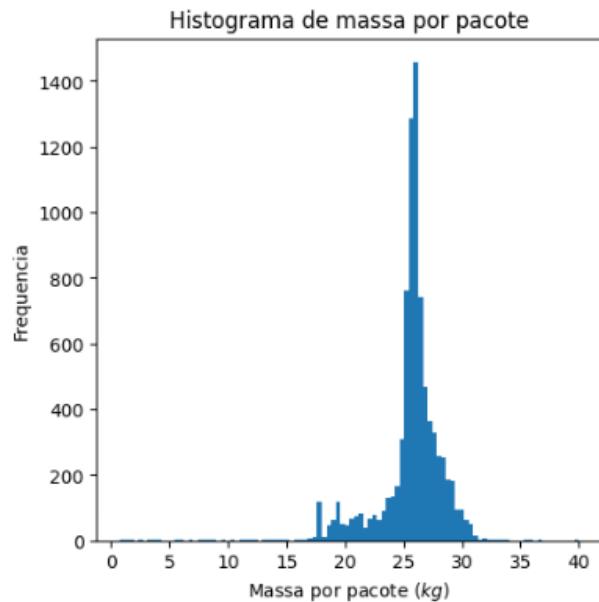


Figura 17 – Histograma de massa por pacote
Fonte: autor

Dessa forma, em um dado instante de tempo t , a massa do caminhão pode ser descrita como:

$$M(t) = M_0 + (n_{\text{pacotes},t} \cdot m_{\text{pacote},t}) \quad (3.3)$$

3.2.3 Map-matching

O tratamento de *map-matching* dos pontos amostrados por GPS envolveu o uso do serviço Valhalla Meili com base em informações específicas da região sudeste do Brasil, provenientes do OpenStreetMap (OSM) Geofabrik. Ademais, foram obtidos dados de

altimetria, a fim de calcular o perfil de elevação das vias percorridas. O processo compreendeu a configuração de um ambiente Docker para o servidor Valhalla, a preparação e a integração dos dados OSM da região em questão e a subsequente execução do serviço Meili para o mapeamento dos pontos de GPS em relação às estradas presentes no OSM. A saída deste processo consiste em correspondências precisas entre os pontos de GPS e as vias reais, para cada segmento também foi obtida a angulação em graus da via, ou seja, a declividade (*grade*).

3.3 Separação em dados de treino e teste

A separação de dados de teste e treinamento é uma prática fundamental em aprendizado de máquina e análise de dados. Ela envolve dividir um conjunto de dados em duas partes distintas: uma para treinamento do modelo (conjunto de treinamento) e outra para avaliação do modelo (conjunto de teste). Segundo James *et al.* (2013), a separação entre conjuntos de treino e teste deve ser feita por conta do fenômeno de sobreajuste (em inglês, *overfitting*) ao qual os modelos estatísticos estão sujeitos, em que os parâmetros do modelo se ajustam a ruído dos dados.

Das 78 rotas filtradas, 20%, ou seja, 16 delas, foram designadas a um conjunto de teste. As 62 rotas remanescentes foram utilizadas como conjunto de treino. Em específico, os dados de treino foram utilizados para estimação dos coeficientes de regeneração e do coeficiente de ajuste linear com a energia consumida. Os dados de teste foram utilizados para a mensuração do erro dos modelos.

3.4 Aplicação e estimação de parâmetros de modelos microscópicos

Nesta seção serão destacados os parâmetros dos modelos microscópicos, são eles:

- Coeficiente linear estimado por regressão
- Coeficientes de regeneração ajustados por uma otimização numérica

3.4.1 Dados do veículo e parâmetros do modelo de energia

Os parâmetros utilizados para entrada do modelo estão descritos na tabela 3.

Parâmetro	Significado	Unidade	Valor	Fonte
C_R	Coeficiente de resistência ao rolamento	-	0,01	Demir; Bektaş; Laporte (2011)
C_D	Coeficiente de arrasto	-	0,7	Demir; Bektaş; Laporte (2011)
M_0	Tara do caminhão	kg	6380	Volkswagen (2023)
m_{pacote}	Massa por pacote	kg/pacote	25	Tabulação da empresa
n_{pacotes}	Número de pacotes	pacotes	Calculado	Tabulação da empresa
a	Aceleração	m/s^2	Calculado	GPS
v	Velocidade	m/s	Calculado	GPS
g	Aceleração da gravidade	m/s^2	9,8	NIST (2023)
θ	Ângulo da via (<i>grade</i>)	rad	Calculado	OpenStreetMaps (via Valhalla)
ρ	Densidade do ar	kg/m^3	1,225	Picard <i>et al.</i> (2008)
A_f	Área frontal	m^2	4,24864	Volkswagen (2023)

Tabela 3 – Parâmetros de entrada do modelo

3.4.2 Energia nas rodas do caminhão

Uma representação de alto nível do fluxo de consumo de energia de um típico veículo elétrico pode ser verificado na figura 18. Neste trabalho não foram modeladas as potências associadas aos acessórios, ou seja, potências auxiliares.

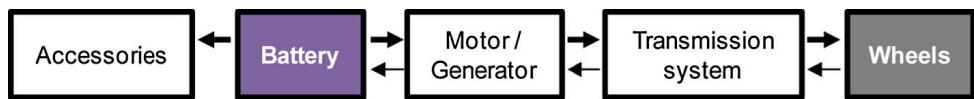


Figura 18 – Fluxos de potência num típico veículo elétrico.

Fonte: Genikomsakis; Mitrentsis (2017)

Tal como observado na seção de revisão de literatura, a potência nas rodas do caminhão pode ser descrita pela equação:

$$\begin{aligned}
 P_W(t) = & [(M(t) \cdot a(t)) + (M(t) \cdot g \cdot \sin \theta) + (M(t) \cdot g \cdot C_R \cdot \cos \theta) \\
 & + (\frac{1}{2} \cdot \rho \cdot C_D \cdot A_f \cdot v(t)^2)] \cdot v(t)
 \end{aligned} \tag{3.4}$$

Nesse sentido, a energia necessária para desempenhar tal potência é:

$$E_W = \int_0^t P_W(t) dt \quad (3.5)$$

Como a amostragem dos dados é discreta, a expressão 3.5 pode ser aproximada como:

$$E_W = \sum_{i=0}^N P_{W_i} \cdot (t_i - t_{i-1}) \quad (3.6)$$

De modo a obter a energia em kWh (unidade usualmente utilizada para capacidade de baterias veiculares), a unidade de potência na equação 3.6 deve estar em kW (o que pode ser obtido a partir do resultado da equação 3.4 dividido por 1000) e o intervalo de tempo deve estar em horas.

3.4.3 Sistemas regenerativos

Os sistemas regenerativos de veículos elétricos matematicamente podem ser representados como um coeficiente η_{RB} , que dita a porcentagem de uma potência negativa (que ocorre em cenários de frenagem ou descidas) que será utilizada para carregamento do sistema de baterias. Ou seja, a potência instantânea do veículo pode ser expressa como:

$$P(t) = \begin{cases} \frac{P_W(t)}{\eta_{DL} \cdot \eta_{EM} \cdot \eta_{BAT}} & \text{se } P_W(t) \geq 0 \\ P_W(t) \cdot \eta_{DL} \cdot \eta_{EM} \cdot \eta_{BAT} \cdot \eta_{RB} & \text{caso contrário} \end{cases} \quad (3.7)$$

Em que η_{DL} é a eficiência da direção, η_{EM} é a eficiência do motor elétrico e η_{BAT} é a eficiência da bateria. Para os fins dessa modelagem, não serão estimados η_{DL} e η_{EM} e η_{BAT} , e sim, apenas η_{RB} e um coeficiente β_1 a ser detalhado na seção sobre a regressão linear. Isso foi feito pela dificuldade de se isolar os efeitos de cada um desses coeficientes numa modelagem com dados com latência, isto é, o intervalo de tempo entre duas observações, tal qual a dos disponibilizados.

3.4.3.1 Regeneração linear

Na regeneração linear, tal como modelado por Abousleiman; Rawashdeh (2015), o coeficiente η_{RB} é constante e independente da aceleração. Assim:

$$\eta_{RB} = \begin{cases} \alpha_{\text{regeneração linear}} & \text{se } a \leq 0 \text{ e } P_W(t) \geq 0 \\ 0 & \text{caso contrário} \end{cases} \quad (3.8)$$

3.4.3.2 Regeneração exponencial

Tal como proposto por Fiori; Ahn; Rakha (2016), η_{RB} pode ser modelado como uma função da aceleração:

$$\eta_{RB} = \begin{cases} e^{-\frac{\alpha_{\text{regeneração exp}}}{a(t)}} & \text{se } a \leq 0 \text{ e } P_W(t) \geq 0 \\ 0 & \text{caso contrário} \end{cases} \quad (3.9)$$

Em que $a(t)$ é a aceleração instantânea do veículo.

3.4.3.3 Estimativa numérica de coeficientes de regeneração

A calibração de $\alpha_{\text{regeneração exp}}$ e $\alpha_{\text{regeneração linear}}$ se deu por meio da minimização de uma função de *Goodness-of-fit* (GoF). A função GoF utilizada foi o erro quadrático médio (MSE), enunciado na equação 3.10.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.10)$$

Nesse sentido, foi utilizado o parâmetro ótimo $\alpha_{RB}^* \in [\alpha_{\text{regeneração exp}}, \alpha_{\text{regeneração linear}}]$ que satisfizesse:

$$\alpha_{RB}^* = \arg \min MSE(\alpha_{RB}) \quad (3.11)$$

O problema de otimização foi resolvido com um solver utilizando o algoritmo de NelderMead, implementado na biblioteca SciPy (Virtanen *et al.*, 2020).

3.4.4 Regressão linear da energia consumida em função da energia estimada

A significativa latência média de 10 segundos entre os pontos de amostragem pode resultar em uma representação imprecisa de eventos de aceleração e velocidade do veículo, levando a um erro na escala do consumo de energia. Além disso, há a omissão das considerações relativas à eficiência do motor, da bateria e do motorista. Com isso, é plausível que a escala das estimativas de consumo de energia possa não estar devidamente ajustada. Adicionalmente, a não inclusão das potências dos sistemas auxiliares pode introduzir um erro sistemático nas estimativas. É importante ressaltar que os coeficientes de arrasto, atrito e parâmetros semelhantes, utilizados como base para a análise, não estão isentos de incertezas e erros inerentes. Estes coeficientes são, em sua maioria, derivados de experimentos realizados em condições específicas, as quais podem diferir substancialmente das condições do estudo em questão, introduzindo assim uma fonte adicional de incerteza nos cálculos. Além disso, o modelo adotado pode não abranger todas as variáveis

relevantes para a determinação precisa da energia envolvida no sistema, potencialmente subestimando ou superestimando o consumo.

Deste modo, a fim de diminuir o erro cometido pelo modelo pelos fatores supracitados, realizou-se um ajuste a partir de um modelo linear para estimar o consumo global de energia para cada rota. Nesse modelo, a variável dependente é representada pela energia consumida, conforme derivada pelo valor de *SOC* no painel do veículo. Essa abordagem foi adotada com o intuito de minimizar os impactos da latência, das ineficiências não consideradas e do impacto dos sistemas auxiliares, com o objetivo de proporcionar uma estimativa mais precisa e robusta do consumo energético.

A relação matemática entre duas variáveis, geralmente representadas como Y (variável dependente) e X (variável independente), na regressão linear simples pode ser expressa da seguinte forma (Devore, 2018):

$$Y = \beta_0 + \beta_1 \cdot X + \varepsilon \quad (3.12)$$

Em que Y é a variável dependente, X é a variável independente, β_0 é o intercepto, que representa o valor de Y quando X é zero. β_1 é o coeficiente linear, que representa a mudança em Y para uma unidade de mudança em X . ε é o erro, que representa a variabilidade não explicada pelos termos anteriores. A equação de regressão linear é usada para encontrar os valores estimados de Y com base nos valores de X e nos parâmetros da regressão por meio do método dos mínimos quadrados (Devore, 2018; James *et al.*, 2013).

O ajuste das retas foi feito com auxílio da biblioteca `statsmodels` do Python, Seabold; Perktold (2010).

De modo a verificar a validade do ajuste, foi feita uma análise dos resíduos da regressão. Em primeiro lugar, foi verificada a homocedasticidade dos resíduos. Homocedasticidade refere-se à igualdade das variâncias dos resíduos em todos os níveis da variável independente. Em outras palavras, a dispersão dos resíduos ao longo da linha de regressão deve ser constante. Essa propriedade pode ser verificada com o teste de Breusch-Pagan. Além disso, foi verificada a normalidade dos resíduos. A normalidade implica que os resíduos se distribuem de acordo com uma distribuição normal, o que é fundamental para a validade das inferências estatísticas associadas ao modelo. Para tal, foi avaliado o histograma dos resíduos.

3.5 Estimativa do consumo energético para modelos macroscópicos, mesoscópicos e análise de erros para os modelos desenvolvidos

Uma vez ajustados os coeficientes nos dados de treino, foram, então, estimados parâmetros macroscópicos e mesoscópicos com relação ao consumo energético. Para tal, o consumo energético dos modelos com regeneração linear, com regeneração exponencial e sem regeneração foram, ponto a ponto, multiplicados pelos coeficientes β_1 ajustados, tal qual a equação 3.13.

$$\text{Energia}_{\text{ajustada}} = \text{Energia}_{\text{calculada}} \cdot \beta_1 \quad (3.13)$$

Em seguida, esse consumo energético foi dividido pela distância em km percorrida no intervalo correspondente ao ponto, obtendo-se o consumo energético por quilômetro kWh/km instantâneo, como na equação 3.14.

$$EC_i \left[\frac{kWh}{km}, i \right] = \frac{\text{Energia}_{\text{ajustada}}}{D_{\text{percorrida}}} \quad (3.14)$$

Por fim, esse valor foi dividido pela massa instantânea $M(t)$ do caminhão, obtendo-se o valor de consumo energético por distância por massa em $kWh/km/kg$, tal qual a equação 3.15.

$$EC_{\text{específica},i} \left[\frac{\frac{kWh}{km}}{kg}, i \right] = \frac{EC, i}{M(t)} \quad (3.15)$$

Logo após, foram mantidos os pontos cuja distância percorrida foi maior do que $\epsilon = 0.01m$ e removidos pontos *outliers*, ou seja, foram considerados apenas os pontos de velocidade inferida ($\frac{\text{distância percorrida}}{\text{tempo percorrido}}$) entre percentil 10 e percentil 90. Uma vez filtrados os pontos, foi calculada a média dos valores de consumo por distância, EC_i , em kWh/km e consumo por distância por massa, $EC_{\text{específica},i}$, em $kWh/km/kg$ para cada um dos três modelos: sem regeneração, com regeneração linear e com regeneração exponencial.

Tendo tais parâmetros estimados via dados de treino, foi feita a validação deles nos dados de teste. Para o caso dos parâmetros mesoscópicos $EC_{\text{específica}}$, a energia foi estimada da seguinte forma: para cada trajeto T_i entre os nós de entrega o_{i-1} e o_i (sendo o primeiro e último nó o CD), foi calculado o valor estimado de energia, conforme a equação 3.16.

$$E_{\text{mesoscópica},i} = EC_{\text{específica}} \cdot D_{T_i} \cdot M(t) \quad (3.16)$$

E, enfim, a energia mesoscópica estimada para a rota inteira se deu pelo somatório de todos os T_i pertencentes à rota:

$$E_{\text{mesoscópica}} = \sum_i E_{\text{mesoscópica},i} \quad (3.17)$$

Para o caso dos parâmetros macroscópicos, foi calculada a energia estimada multiplicando-se a distância percorrida em cada rota pelo valor EC de cada modelo estimado (sem regeneração, com regeneração linear e com regeneração exponencial) e pelo valor nominal do fabricante, ou seja $\frac{105kWh}{110km}$, que foi chamado de estimador *dummy*. Para cada uma das estimativas, foi aferida a distribuição do erro medido (definido tal qual a equação 3.18) e o valor global de erro quadrático médio, o MSE, tal qual definido na equação 3.10 e do MAPE, definido na equação 3.19.

$$e = y_{real} - y_{predito} \quad (3.18)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left[\frac{y_{real,i} - y_{predito,i}}{y_{real,i}} \right] \cdot 100\% \quad (3.19)$$

Dados os procedimentos descritos neste capítulo, seguiu-se com a sua aplicação. Análises de erros, aplicações e aprendizados são discutidos no próximo capítulo.

4 Resultados e discussão

Neste capítulo, são apresentados os resultados e, subsequentemente, a análise dos mesmos. Inicialmente, os coeficientes dos modelos de regressão utilizados para estimar o consumo de energia dos veículos elétricos na frota são expostos. Posteriormente, a validação desses modelos é abordada, incorporando métricas de desempenho e a avaliação da precisão das previsões. Por fim, análises derivadas dos modelos de energia são conduzidas. A primeira é referente ao dimensionamento da frota, com base nos parâmetros macroscópicos estabelecidos. Uma segunda análise é a de agrupamento de rotas para tentativa de extração de parâmetros macroscópicos geograficamente delimitados.

4.1 Coeficientes de modelo sem sistema regenerativo

O modelo que não considera a regeneração de energia foi ajustado aos dados de treinamento, resultando em um coeficiente de determinação (R^2) de 0,731 e um valor F de 163,1, com base em 62 observações. Esse valor indica que o modelo consegue explicar uma parte considerável da variação dos dados. Além disso, por meio do teste Breusch-Pagan, foi possível descartar a presença de heterocedasticidade nos resíduos do modelo. Adicionalmente, é importante destacar que o intercepto do modelo não demonstrou significância estatística a um nível de significância de 5%.

Do ponto de vista físico, é esperado que o coeficiente angular da reta corrija um erro de escala presente no modelo físico, enquanto o intercepto pode ser interpretado como um nível de energia residual que permanece constante, independentemente das variações na energia estimada pelo modelo físico. A não significância dessa energia residual neste contexto é interessante, já que indica que não há algo como um erro sistemático sendo cometido. Esse erro sistemático poderia vir de uma estimativa ruim acerca da real capacidade da bateria, por exemplo. A figura com a regressão nos dados de treino pode ser vista na Figura 19 e os *plots* de diagnóstico dos resíduos pode ser visto na Figura 20.

Coeficiente	Desvio Padrão	Estatística t	P-valor (t)	Intervalo de Confiança a 95%
Intercepto	6.3791	3.323	1.919	0.06
Energia estimada	0.5274	0.041	12.771	0.00

Tabela 4 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada sem regeneração

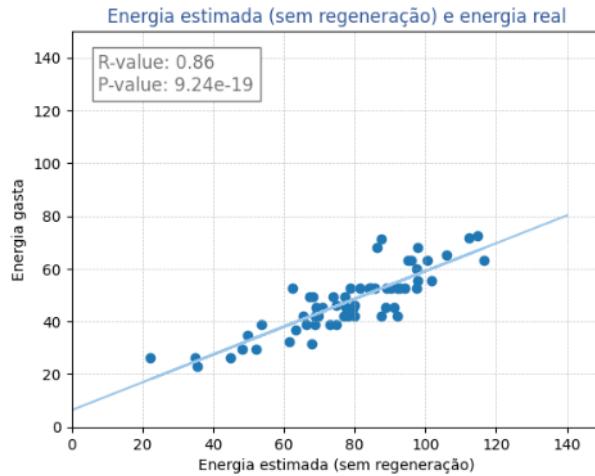


Figura 19 – Regressão linear de energia gasta em função de energia estimada sem regeneração em dados de treino

Fonte: autor

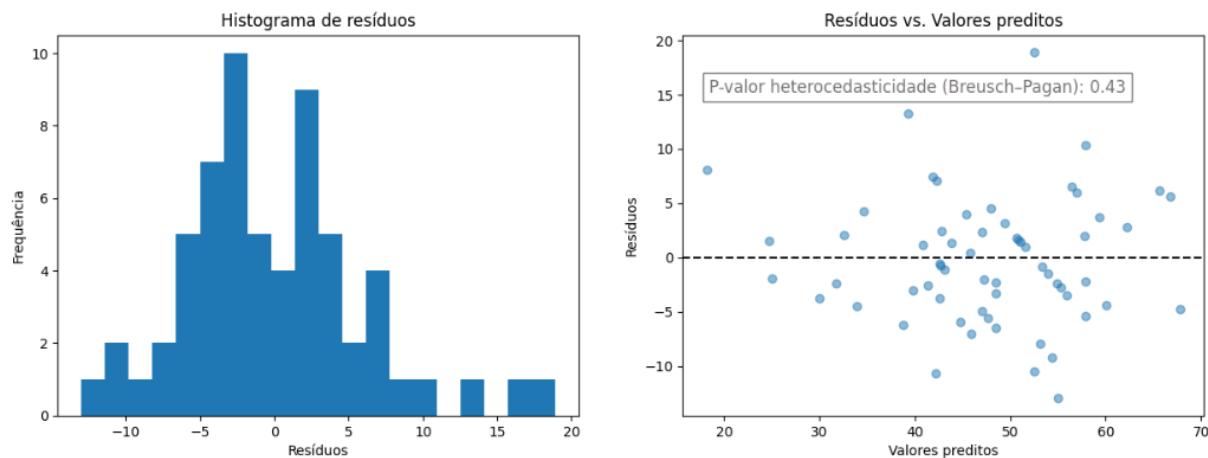


Figura 20 – Gráficos de diagnóstico da regressão linear de energia gasta em função de energia estimada sem regeneração

Fonte: autor

4.2 Coeficientes do modelo com sistema regenerativo linear

Por meio de otimização utilizando o método de Nelder-Mead, o coeficiente ajustado para o modelo de regeneração linear ($\alpha_{\text{regeneração linear}}$) foi estabelecido em 1. Fisicamente, isso significa que, para essa amostragem dos dados, o melhor valor estabelecido para tal coeficiente considera que, nos momentos de frenagem, o sistema é capaz de recuperar 100% da energia disponibilizada. Esse valor está, provavelmente, superestimado. Younes *et al.* (2013) reportou, para um carro, valores de regeneração variáveis, entre 10% a 35% da energia recuperada, a depender de fatores de direção e rota. Sterkenburg *et al.* (2011) adotou valores entre 22% e 40% para um coeficiente linear de regeneração para caminhões operando numa área urbana, em Roterdão. A hipótese mais plausível para a superestimação do coeficiente de regeneração está associada com os intervalos de integração - o que

será detalhado em seções subsequentes desse trabalho.

Nessa configuração, a regressão linear resultou em um coeficiente de determinação (R^2) de 0,613 e um valor F de 95,07, baseado em 62 observações. Adicionalmente, o teste de Breusch-Pagan revelou a ausência de heterocedasticidade nos resíduos do modelo. A figura com a regressão nos dados de treino pode ser vista na Figura 21 e os *plots* de diagnóstico dos resíduos pode ser visto na Figura 22.

Coeficiente	Desvio Padrão	Estatística t	P-valor (t)	Intervalo de Confiança a 95%
Intercepto	11.6078	3.866	3.002	0.004 [3.874, 19.341]
Energia estimada	0.6568	0.068	9.610	0.00 [0.520, 0.794]

Tabela 5 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada com regeneração linear

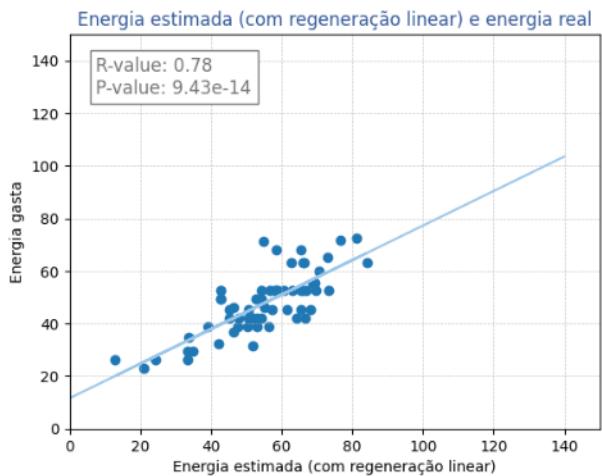


Figura 21 – Regressão linear de energia gasta em função de energia estimada com regeneração linear em dados de treino
Fonte: autor

4.3 Coeficientes de modelo com sistema regenerativo exponencial

Através do processo de otimização empregando o método de Nelder-Mead, o coeficiente ajustado para o modelo de regeneração exponencial ($\alpha_{\text{regeneração exp}}$) foi estabelecido em 0,01. O valor parece dentro de um valor aceitável, sabe-se que Fiori; Ahn; Rakha (2016) adotou o valor de 0,0411 para um veículo Nissan Leaf. No entanto, sabe-se que a estimativa desse parâmetro pode ser desafiadora, Fiori *et al.* (2021) encontrou um intervalo de confiança entre 0,005 e 1 para tal parâmetro em ônibus elétricos.

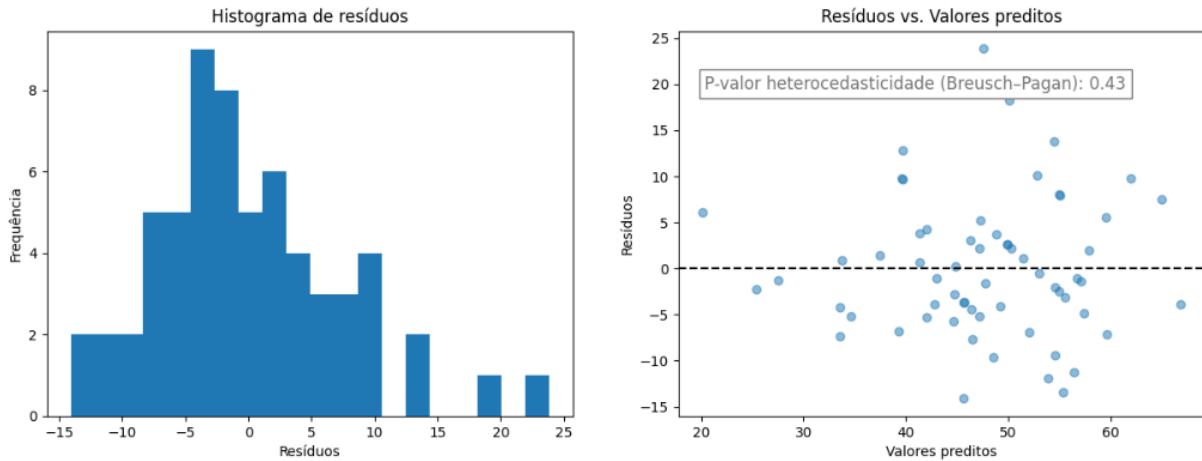


Figura 22 – Gráficos de diagnóstico da regressão linear de energia gasta em função de energia estimada com regeneração linear
Fonte: autor

Sob essa configuração, a regressão linear apresentou um coeficiente de determinação (R^2) de 0,606 e um valor F de 92,55, com base em 62 observações. Além disso, a análise de heterocedasticidade, conduzida por meio do teste de Breusch-Pagan, indicou a ausência de tal fenômeno nos resíduos do modelo.

Coeficiente	Desvio Padrão	Estatística t	P-valor (t)	Intervalo de Confiança a 95%
Intercepto	11.2226	3.850	2.915	0.005 [3.522, 18.924]
Energia estimada	0.6497	0.067	9.751	0.00 [0.516, 0.783]

Tabela 6 – Coeficientes estimados em regressão linear de energia gasta em função de energia estimada com regeneração exponencial

4.4 Derivação de parâmetros macroscópicos e mesoscópicos

Com base na filtragem de pontos que apresentam distâncias percorridas acima de 0,01 metros e velocidades estimadas (calculadas como a razão entre a variação da posição e a variação do tempo) situadas entre o percentil 10 e 90, procedeu-se ao ajuste da energia calculada para cada modelo, utilizando o coeficiente linear derivado da regressão linear. Como resultado, obtiveram-se os valores de consumo de energia em quilowatt-hora por quilômetro (kWh/km) na Tabela 7 e de consumo de energia em quilowatt-hora por quilômetro por quilo (kWh/km/kg) na Tabela 8.

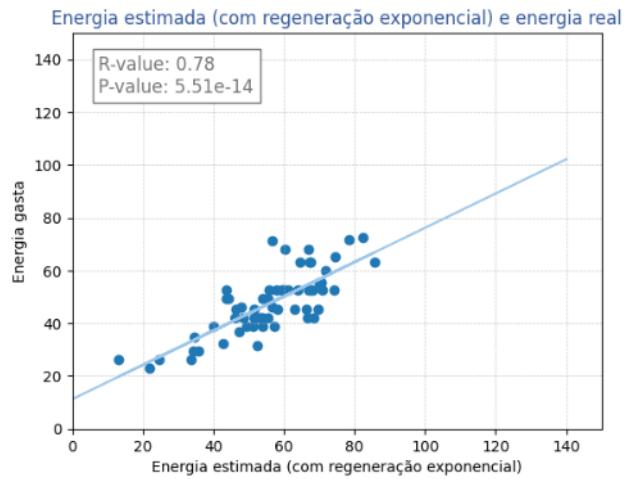


Figura 23 – Regressão linear de energia gasta em função de energia estimada com regeneração exponencial em dados de treino

Fonte: autor

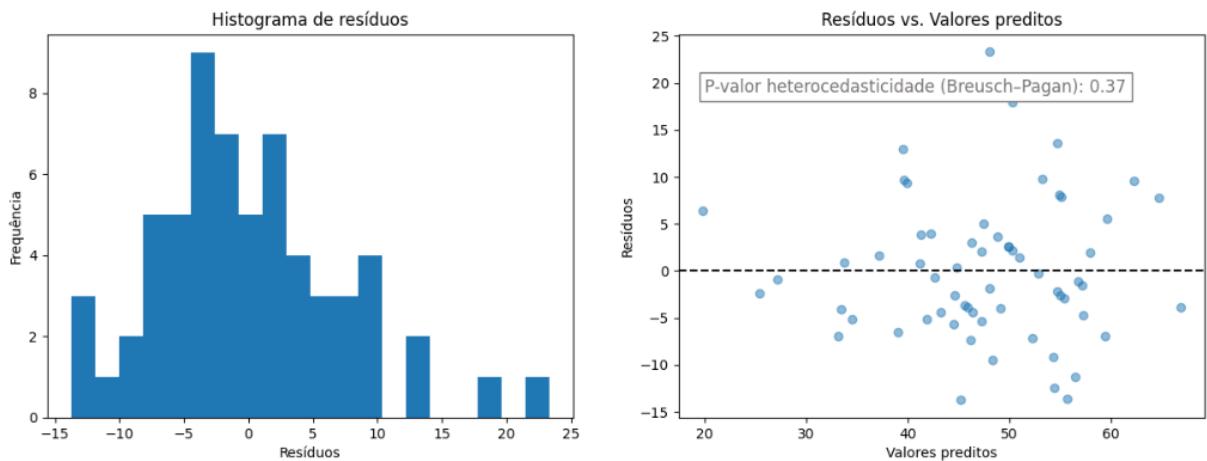


Figura 24 – Gráficos de diagnóstico da regressão exponencial de energia gasta em função de energia estimada com regeneração exponencial

Fonte: autor

Modelo	Consumo por distância ajustado (EC), em kWh/km
Sem regeneração	0,854
Regeneração linear	0,9155
Regeneração exponencial	0,950

Tabela 7 – Valores de consumo por distância ajustado (EC) para os modelos

Modelo	Consumo por distância ajustado por distância e massa, em kWh/km/kg
Sem regeneração	$9,415 \cdot 10^{-5}$
Regeneração linear	$10,461 \cdot 10^{-5}$
Regeneração exponencial	$10,076 \cdot 10^{-5}$

Tabela 8 – Valores de consumo por distância e por massa ajustado (EC/kg) para os modelos

4.5 Avaliação de erros em dados de teste

Os modelos que fornecem estimativas de gasto de energia por distância, baseados no EC (kWh/km), foram categorizados como "macroscópicos". Por outro lado, os modelos que consideram gasto de energia por distância e massa, baseados no EC/kg (kWh/kg/km), foram classificados como "mesoscópicos". Além disso, os modelos que realizam a estimativa de energia ponto a ponto com a inclusão do ajuste do coeficiente linear foram denominados "microscópicos". O parâmetro de autonomia do fabricante, de 110km para 105 kWh, leva a um valor de 0,954 kWh/km, e foi denominado com *Dummy*.

A métrica de erro quadrático médio (MSE) dos erros no conjunto de teste (16 rotas) para cada um dos modelos pode ser consultada na Tabela 9. É possível verificar que neste caso, o melhor valor foi obtido com o modelo microscópico com a modelagem exponencial da regeneração.

Com relação a dispersão dos erros no conjunto de teste, a Tabela 10 apresenta os valores médios, desvio padrão e quartis dos erros. De forma equivalente, a Tabela 11 apresenta esses valores em termos percentuais, ou seja, com relação ao *SOC*. Tais tabelas, assim como os boxplots da Figura 25, permitem verificar que apesar dos valores médios de modelos macroscópicos em alguns casos se mostrarem melhores do que os de modelos mesoscópicos e microscópicos, a variabilidade dos erros diminui conforme os modelos se tornam mais granulares.

4.6 Comparação entre os modelos

Devido à incerteza associada aos parâmetros dos modelos e à amostragem realizada a cada 10 segundos, observou-se uma tendência sistemática de superestimação do valor da energia consumida pelos modelos físicos. Essa tendência de superestimação, por sua vez, motivou a necessidade de correção, a qual foi implementada por meio de um coeficiente linear ajustado pela regressão linear. Esse coeficiente modela parâmetros que não

Modelo	Erro Quadrático Médio (MSE)
Dummy	218,42
Sem regeneração (Macroscópico)	143,55
Regeneração linear (Macroscópico)	178,59
Regeneração exponencial (Macroscópico)	213,63
Sem regeneração (Mesoscópico)	199,46
Regeneração linear (Mesoscópico)	167,9
Regeneração exponencial (Mesoscópico)	160,18
Sem regeneração (Microscópico)	186,61
Regeneração linear (Microscópico)	109,09
Regeneração exponencial (Microscópico)	106,96

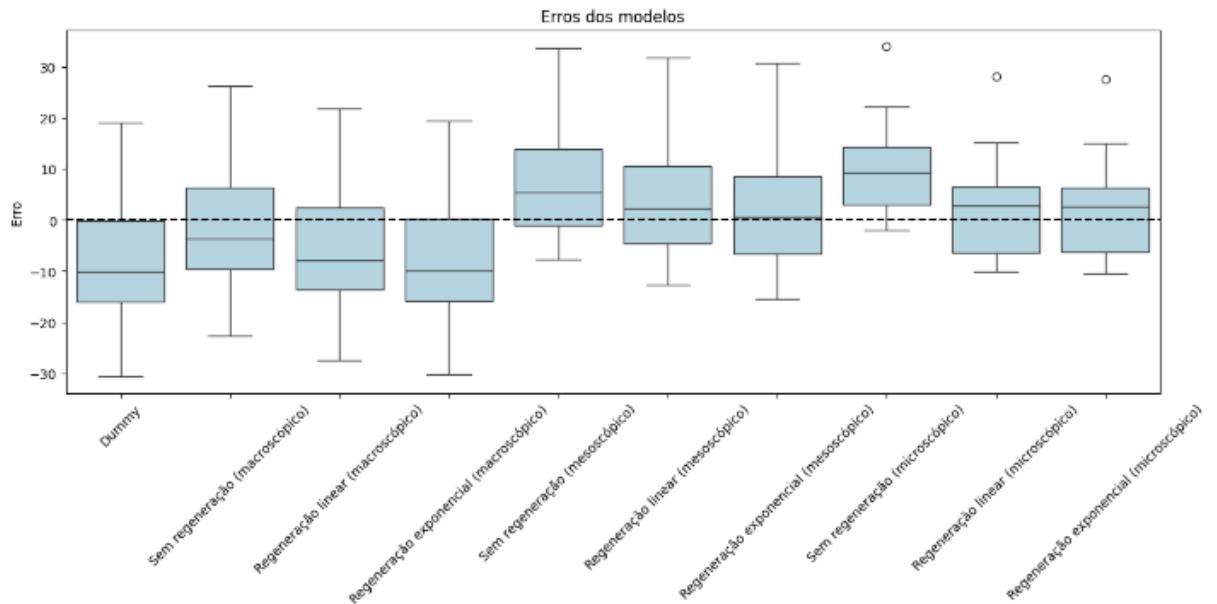
Tabela 9 – Valores de erro quadrático médio para os modelos em kWh²

Figura 25 – Distribuição de erros dos modelos mesoscópicos e macroscópicos

Fonte: autor

necessariamente foram considerados explicitamente na modelagem, assim como o erro sistemático dos parâmetros considerados e calculados. A regressão linear foi selecionada por

Modelo	Média	Desvio padrão	Quartil		
			1°	2°	3°
dummy	-8,13	12,75	-16,01	-10,19	-0,06
Sem regeneração (macroscópico)	-1,49	12,28	-9,62	-3,64	6,34
Regeneração linear (macroscópico)	-5,55	12,55	-13,52	-7,88	2,43
Regeneração exponencial (macroscópico)	-7,86	12,73	-15,75	-9,95	0,20
Sem regeneração (mesoscópico)	7,68	12,24	-1,11	5,39	13,92
Regeneração linear (mesoscópico)	4,37	12,60	-4,63	2,34	10,57
Regeneração exponencial (mesoscópico)	2,43	12,83	-6,67	0,56	8,61
Sem regeneração (microscópico)	10,01	9,60	2,96	9,30	14,33
Regeneração linear (microscópico)	2,68	10,43	-6,34	2,75	6,48
Regeneração exponencial (microscópico)	2,61	10,34	-6,15	2,65	6,39

Tabela 10 – Distribuição de erros (em kWh) dos modelos no conjunto de teste

vários fatores. Em primeiro lugar, por sua simplicidade e fácil interpretabilidade. Além disso, o modelo físico já incorporava diversas não linearidades no consumo, e, portanto, mesmo com o consumo energético tendo diversos fatores, a regressão linear mostrou um funcionamento satisfatório.

O interessante é que, em virtude desse coeficiente ser menor no caso do modelo que não considerava explicitamente a regeneração, o consumo específico de energia por quilômetro (kWh/km) desse modelo se revelou inferior em comparação aos modelos que incorporavam a regeneração de forma explícita no modelo físico. Ou seja, a regeneração não era considerada, mas o modelo estimou um consumo EC (kWh/km) inferior (mais eficiente) por conta do ajuste linear. Simplificadamente, a regeneração é um consumo de energia negativo, então, se esta não é considerada separadamente, ela pode ser indiretamente modelada por um coeficiente linear menor. Isso destaca a influência significativa da incerteza na eficácia dos modelos e ressalta a importância da correção desse viés, a fim de obter estimativas mais precisas e confiáveis do consumo de energia.

Em termos gerais, notou-se que o modelo de autonomia de fábrica (*dummy*) apresentou o pior desempenho, evidenciado por um erro quadrático Médio (MSE) mais elevado.

Modelo	Média	Desvio padrão	Quartil		
			1°	2°	3°
dummy	-18,14	24,22	-34,25	-19,15	-0,13
Sem regeneração (macroscópico)	-5,69	21,67	-20,10	-6,60	10,42
Regeneração linear (macroscópico)	-13,30	23,23	-28,75	-14,27	3,97
Regeneração exponencial (macroscópico)	-17,64	24,12	-33,68	-18,65	0,30
Sem regeneração (mesoscópico)	12,10	19,36	-2,46	11,04	24,07
Regeneração linear (mesoscópico)	5,94	20,72	-9,65	4,80	18,74
Regeneração exponencial (mesoscópico)	2,33	21,51	-13,85	1,16	15,63
Sem regeneração (microscópico)	16,44	13,09	5,81	17,75	26,43
Regeneração linear (microscópico)	2,47	16,30	-12,94	5,08	11,39
Regeneração exponencial (microscópico)	2,35	16,24	-12,60	5,11	11,44

Tabela 11 – Distribuição de erros percentuais (SOC) dos modelos no conjunto de teste

Isso ocorreu porque a autonomia modelada de 110km para 105kWh, leva a um parâmetro macroscópico de 0,9545 kWh/km - que se mostra mais conservador do que qualquer um dos resultados derivados dos parâmetros macroscópicos calculados. Nesse sentido, o valor de referência se mostrou uma superestimação de consumo mais intensa do que a dos demais parâmetros, levando a um erro quadrático médio de 218,42 kWh².

É interessante notar que, no que diz respeito aos modelos macroscópicos, houve uma tendência geral de superestimação do gasto energético, mesmo com a correção via coeficiente linear. Contrariamente, os modelos mesoscópicos tenderam a subestimar o consumo de energia. Quanto aos modelos microscópicos, o modelo sem regeneração apresentou uma inclinação para a subestimação do gasto energético, enquanto os modelos com regeneração demonstraram uma tendência mais equilibrada, com uma leve propensão à superestimação. Uma hipótese para isso é de que, no caso dos modelos mesoscópicos, com a normalização do consumo pela massa, o valor do intercepto - que foi desconsiderado - se tornaria relevante, levando a uma subestimação no valor consumido de energia. No caso do modelo macroscópico, como não há uma normalização pela massa, houve uma compensação positiva do consumo energético global, que leva a tal superestimação.

No que diz respeito aos modelos macroscópicos, ou seja, na estimativa de um parâmetro EC em kWh/km, curiosamente, observou-se que o parâmetro do modelo que não considera a regeneração foi inferior ao dos modelos que incluíam a regeneração. Essa discrepância pôde ser explicada pela forma como a energia foi ajustada, com base no coeficiente angular da regressão linear, que foi menor para o modelo sem regeneração. Além disso, é importante notar que esse modelo, sem regeneração, também foi o que demonstrou o menor erro quadrático médio (MSE).

Foi observado que o modelo macroscópico que não considerava a regeneração obteve um desempenho superior a todos os modelos mesoscópicos, inclusive teve um MSE inferior ao do modelo microscópico sem regeneração. Isso é um achado notável e sugere que, para os propósitos deste estudo em particular, a modelagem macroscópica sem regeneração ofereceu uma estimativa relativamente precisa do consumo de energia. Isso parece sugerir que a um nível macroscópico de análise, a regeneração é melhor modelada como um coeficiente linear global do que como duas componentes separadas (uma no modelo físico e uma no coeficiente linear da regressão).

Em uma análise geral, os modelos microscópicos que incorporaram a regeneração demonstraram ser os que mais se aproximaram do gasto de energia real, apresentando uma menor dispersão dos valores. Essa descoberta ressalta a eficácia dos modelos microscópicos na representação das complexas dinâmicas de consumo de energia e regeneração em níveis mais detalhados de granularidade operacional, contribuindo para estimativas mais precisas e confiáveis do consumo energético. Esses modelos incorporam mais variáveis e situações em sua modelagem, o que dá a possibilidade de um cálculo mais preciso do consumo energético.

4.7 Fontes de ruído e erro no modelo

A presença de erros de magnitude considerável nos modelos desenvolvidos decorre da complexa interação de diversos fatores de incerteza intrínseca a essa análise. Em primeiro lugar, o alto intervalo de integração (10s) se mostra excessivamente elevado para estimativas precisas. Outro fator reside nas medições de velocidade obtidas por meio do Sistema de Posicionamento Global (GPS), cuja precisão intrínseca frequentemente é afetada por variabilidades ambientais e técnicas. Além disso, as medições de posição do GPS, mesmo após correção por meio de técnicas de *map-matching*, ainda subsistem como fonte de incerteza. Outro elemento que gera erros é a incerteza associada à massa individual de cada pacote transportado, que foi estimado em 25kg, porém não é um valor padronizado. Adicionalmente, a utilização de sistemas auxiliares, como o ar condicionado, não foi considerada, o que também pode induzir erros. Além disso, os coeficientes da literatura, como arraste e atrito, também podem induzir erros. Por fim, os próprios dados da variá-

vel dependente estão sujeitos a erros decorrentes da imprecisão de medição de SOC e da leitura do painel na fotografia do *checklist* de retorno.

4.7.1 Energia consumida

Medir com precisão a carga nas baterias, particularmente em baterias de veículos elétricos, é um desafio complexo. A precisão na medição do estado de carga (*SOC*) é essencial para garantir a confiabilidade da estimativa da autonomia e para otimizar o funcionamento do veículo elétrico. No entanto, a medição da carga nas baterias está inherentemente associada a erros. Como dito na seção de revisão de literatura, segundo Zheng *et al.* (2018), os fabricantes de veículos elétricos costumam estabelecer um erro máximo de 5% no *SOC*. No entanto, apenas alguns dias sem uma recalibragem do sistema pode levar a um erro a um nível maior do que este.

Além disso, a leitura do valor do *SOC* no painel foi feito via um mostrador de ponteiro em uma foto tirada no momento de retorno do caminhão ao centro de distribuição. Não obstante, as circunstâncias em que essas imagens são obtidas não obedecem a uma padronização, resultando em ângulos variáveis que induzem o efeito de paralaxe de maneira não uniforme. Tal cenário, por si só, pode suscitar leituras imprecisas. Adicionalmente, uma série de desafios adicionais se apresentam, como, por exemplo, condições de iluminação insuficientes ou a presença de reflexos na superfície do mostrador, os quais podem comprometer a precisão das leituras. De forma complementar, é relevante mencionar que os marcadores no mostrador do ponteiro são discretizados em intervalos de 3,125%, inviabilizando, desse modo, a obtenção de valores de SOC com maior precisão do que 1,5625%.

4.7.2 Energia estimada

A energia estimada utilizou primariamente o modelo de energia baseado na potência necessária para promover tração do veículo. Todas as variáveis de entrada desse modelo têm incertezas associadas, tanto as diretamente medidas como os coeficientes utilizados. Em específico, destacamos os erros associados à estimativa de massa, velocidade e aceleração.

4.7.2.1 Estimação de massa

No cálculo da massa do veículo, uma média de 25 kg por pacote foi adotada como um valor de referência. No entanto, ao examinarmos a amostra disponível, notou-se que, em algumas instâncias, esse valor pode apresentar desvios significativos em relação a massa real dos pacotes. Apesar do desvio padrão ser relativamente baixo, com apenas 2

kg, foram identificados casos extremos nos quais os pacotes pesavam tanto quanto 40 kg ou tão pouco quanto 700 gramas.

4.7.2.2 Estimação de velocidade e aceleração e associados ao intervalo de integração

Como já mencionado na seção de metodologia, existe um erro associado a medição de velocidades com efeito Doppler pelo sistema de GPS.

Outro fator digno de nota é que o cálculo da aceleração foi efetuado numericamente a partir dos dados de velocidade, em vez de ser realizado através de um sensor fisicamente acoplado ao caminhão. Isso resulta na utilização de uma aceleração média em vez de uma aceleração instantânea.

De fato, é reconhecido que as acelerações em veículos geralmente seguem um padrão caracterizado por picos e vales. Segundo Bokare; Maurya (2017), para caminhões em velocidades entre 20 a 30 km/h, o tempo médio de aceleração é de 11 segundos e o de desaceleração, 16 segundos. Uma amostragem com latência média de 10 segundos, parece estar dentro do tempo médio esperado para acelerações e desacelerações em velocidades urbanas.

No entanto, o fator que parece induzir o maior erro na modelagem é a alta latência dos dados, que foi de, em média, 10 segundos. No trabalho de Zhang *et al.* (2020), foram utilizados dados amostrados com uma latência de 1s (1Hz), ou seja, 10× mais frequente e, ainda assim, foram observados erros percentuais médios (MAPE) de 12% na energia consumida. Com uma amostragem também de 1Hz, como feita por Fiori *et al.* (2021), o erro percentual médio foi de apenas cerca de 1%. O problema principal seria considerar a potência compatível com a velocidade inicial como constante durante todo o intervalo de integração.

4.8 Análises derivadas dos modelos de energia

4.8.1 Dimensionamento de frotas com autonomia fixa (parâmetro macroscópico)

Foi considerado um modelo simplificado de dimensionamento de frota, em que o número de veículos necessários é calculado como a demanda diária (em km) dividido pela capacidade de cada veículo (em km), como na equação 4.1. A capacidade de cada veículo é definida como a capacidade da bateria (em kWh) dividida pelo consumo médio de energia (em kWh/km) (equação 4.2).

Este modelo pressupõe, em primeiro lugar, que a demanda diária de quilômetros é constante ao longo do tempo, implicando que a frota é dimensionada para atender a essa demanda média diária. Nesse sentido, não são consideradas variações na demanda ao longo

do dia ou da semana, o que pode levar a sub ou superutilização da frota em diferentes momentos. A falta de consideração de tais variações podem ter implicações significativas em termos de impacto ambiental e econômico, uma vez que a frota pode ser subutilizada em muitos momentos, resultando em maior consumo de recursos e custos mais elevados. Além disso, o modelo considera o consumo EC (kWh/km) como base para determinar a autonomia dos veículos, sem levar em consideração fatores adicionais que podem afetar de maneira significativa a operação de uma frota. Dentre as omissões notáveis, estão a falta de consideração das restrições associadas à velocidade média do veículo e à duração dos turnos de trabalho dos motoristas e ajudantes, aspectos cruciais para o funcionamento eficiente e adequado de uma frota de veículos.

$$N_{\text{veículos}} = \frac{\text{Demanda}}{\text{Autonomia}} \quad (4.1)$$

$$\text{Autonomia} = \frac{\text{Capacidade bateria}}{EC} \quad (4.2)$$

Como enunciado nas equações, o principal aspecto avaliado é o impacto de consumo fixo no dimensionamento de uma frota. No entanto, como é sabido haver uma grande variação na autonomia esperada de um veículo elétrico, analisamos a relação entre a probabilidade de uma dada autonomia ser ultrapassada, o que levaria à parada do caminhão em rota, e o tamanho da frota dimensionada com essa autonomia. Nesse sentido, é introduzido o conceito de um erro do tipo 1, o qual denota a probabilidade de o consumo efetivo de energia por quilômetro superar um valor preestabelecido, em outras palavras, a probabilidade de o veículo esgotar a bateria quando se assume bateria com carga. O erro do tipo 1 pode ser compreendido como a incerteza associada à possibilidade de os veículos requererem uma quantidade de energia superior à prevista, o que, operacionalmente, acarretaria em guincho ou na não entrega de todos os pacotes. A probabilidade deste erro pode ser denotada como α . Além deste erro, também existe o erro do tipo 2, que denotaria a probabilidade de se assumir um consumo superior ao que foi de fato executado, em outras palavras, quando se assume que a bateria estaria esgotada, mas ainda há carga. O erro do tipo 2 pode levar a ineficiências, mas seu impacto em relação a imprevistos na operação é menor. Nesse sentido, seguiu-se um dimensionamento tendo em vista apenas o erro do tipo 1.

Sabendo-se que o consumo EC em kWh/km segue uma determinada distribuição, podemos estabelecer um valor de probabilidade de erro do tipo 1 (α) e derivar um limite (*threshold*) a ser considerado para EC e, com a equação 4.2, calcular a autonomia do veículo. Esse relacionamento entre α e EC pode ser visto na Figura 26.

A partir de tal autonomia, procede-se ao dimensionamento da frota, mesmo em cenários onde o consumo efetivo pode, ocasionalmente, exceder ligeiramente as estimativas

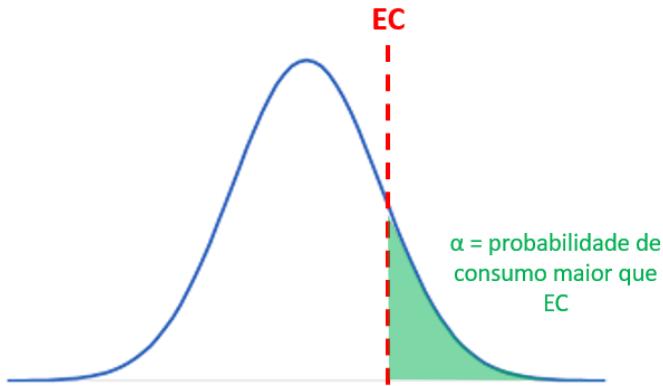


Figura 26 – Ilustração de relação entre EC e α

Fonte: autor

iniciais. Um valor maior de α torna o valor de EC mais agressivo, aumentando a autonomia esperada. Isso pode levar a altos custos operacionais relativos à parada do veículo em rota. Por outro lado, um valor pequeno de α pode levar a uma estimativa de consumo mais cautelosa, o que por sua vez, diminui a autonomia esperada e poderia resultar em uma frota superdimensionada.

A distribuição dos consumos reais em kWh/km nos dados de teste pode ser visualizada na Figura 27. Para avaliar a normalidade desses dados, foi conduzido o teste de Shapiro-Wilk, resultando em um p-valor de 0,785. Portanto, com base nesse valor de p , considerou-se que os dados seguem uma distribuição normal. Além disso, a distribuição dos dados, conforme estimada via *Kernel Density Estimation* (KDE), apresenta uma notável semelhança com uma distribuição normal, como pode ser observado na Figura 28. Na figura do *kernel* estimado, destacam-se linhas representando os valores de EC estimados pelos modelos macroscópicos.

Foi calculada o consumo EC em kWh/km compatível com diferentes probabilidades de erro do tipo 1 (α). Para tal, foi calculada a média e desvio padrão de tal consumo na amostra de teste, obtendo-se os valores de 0.84 kWh/km e 0.18 kWh/km respectivamente. Considerando que os consumos médios de energia por distância (EC) seguem uma distribuição t com 15 graus de liberdade, dada a normalidade da amostra, foi calculado o consumo EC compatível com um dado α . Para tal, foi calculado o valor t correspondente a α com 15 graus de liberdade, e depois esse valor foi multiplicado pelo desvio padrão de EC e somado com sua média, tal como descrito na equação 4.3.

$$EC = (\text{Student-}t(\alpha, 15) * s_{EC}) + \bar{EC} \quad (4.3)$$

Procedeu-se ao dimensionamento de frotas para um valor fixo de quilômetros diá-

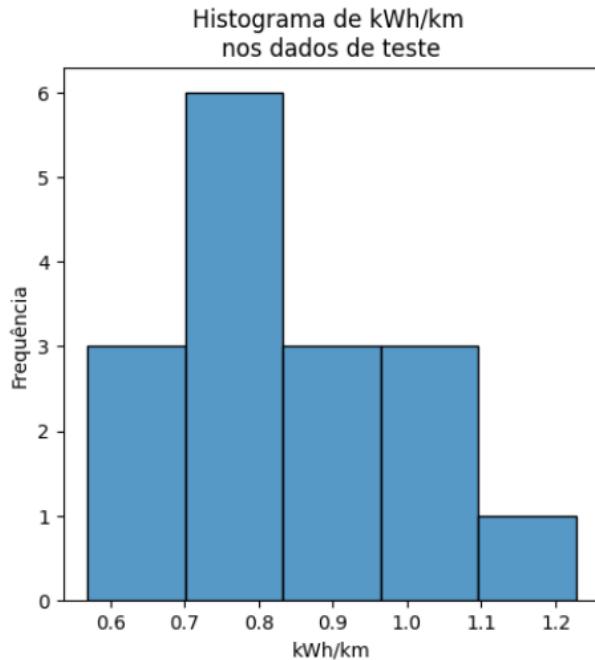


Figura 27 – Histograma de consumo $\frac{kWh}{km}$ em dados de teste
Fonte: autor

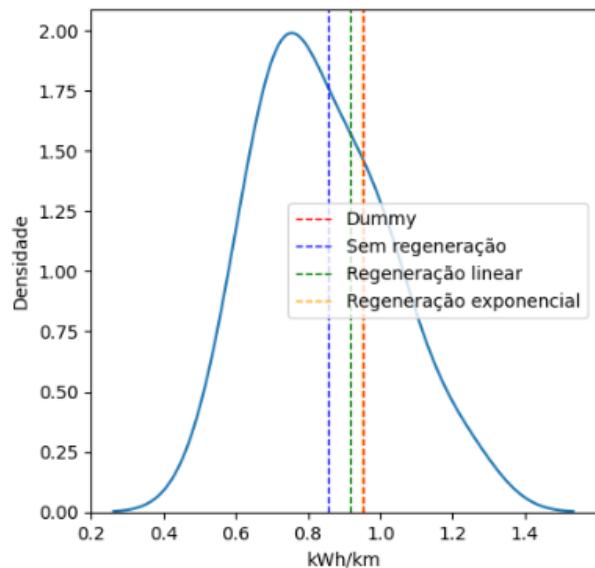


Figura 28 – KDE (Kernel Density Estimation) de consumo $\frac{kWh}{km}$ em dados de teste
Fonte: autor

rios. Foram estimadas frotas para os seguintes valores de α : 0,5; 0,4; 0,35; 0,3; 0,47 (α correspondente a EC sem regeneração); 0,34 (α correspondente a EC regeneração linear); 0,27 (α correspondente a EC regeneração exponencial); 0,263 (α correspondente ao modelo Dummy); 0,2; 0,15; 0,1; 0,05; 0,01; 0,005; 0,001. O valor relativo à frota para α de 0,001 foi estabelecido como 100%, e as frotas relativas aos outros valores de α foram representadas proporcionalmente a essa frota (α de 0,001). O gráfico que ilustra essa distribuição pode ser visualizado na Figura 29, também é possível verificar os dados na tabela 12.

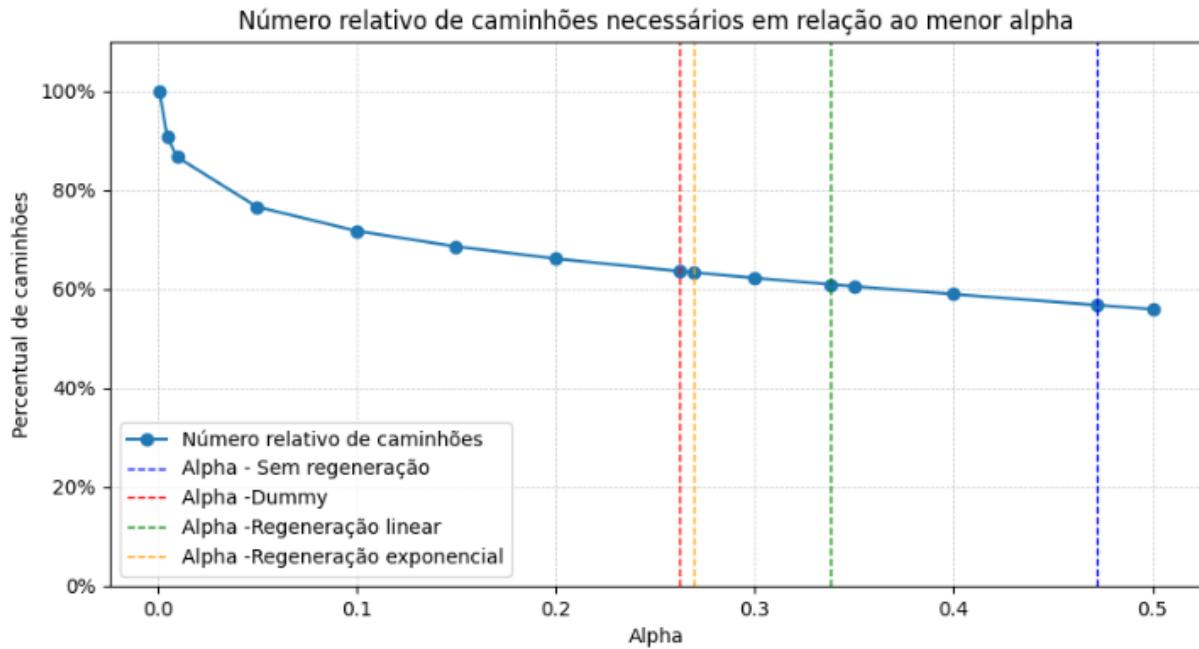


Figura 29 – Percentual (%) de caminhões dimensionados para cada α em relação ao dimensionamento do menor α avaliado (α_{min}) - $\alpha_{min} = 0.001$
Fonte: autor

α	Consumo (kWh/km)	Número relativo de caminhões (%)
0.001	1.51	100.0
0.005	1.37	90.7
0.010	1.30	86.6
0.050	1.15	76.6
0.100	1.08	71.7
0.150	1.03	68.6
0.200	1.00	66.1
0.262	0.96	63.6
0.270	0.95	63.3
0.300	0.94	62.2
0.338	0.92	60.9
0.350	0.91	60.5
0.400	0.89	58.9
0.472	0.85	56.7
0.500	0.84	55.9

Tabela 12 – Resultado do dimensionamento de frota com base no erro do tipo 1

Dada a alta variabilidade do consumo EC de energia por distância, em kWh/km, observado nas rotas, é notável que a variação na tolerância ao erro do tipo 1 leva a um dimensionamento muito diferente da autonomia do caminhão e, consequentemente, no dimensionamento da frota.

No caso de assumir uma autonomia média de 1.86 kWh/km, ou seja, uma autonomia de 56,43 km, compatível com a operação atual do CD, a probabilidade de erro do tipo 1 seria inferior a 0,1 % segundo a distribuição da amostra de teste.

Segundo o modelo, uma erro do tipo 1 de 0,1 % presume uma autonomia de 69 km, ao passo que um erro de 5% presume uma autonomia de 91 km. Essa diferença pode

levar a um impacto de 23% no tamanho dimensionamento da frota.

De fato, o dimensionamento da frota com base nos modelos macroscópicos de autonomia fixa não é a opção ideal. Isso se deve ao fato de que as chances de incorrer em erros do tipo 1 são significativamente altas, resultando em na necessidade de um parâmetro demasiadamente conservador, que pode levar a uma frota superdimensionada.

Nesse contexto, considerar modelos mais precisos, em que a probabilidade de erro do tipo 1 é menor, como os modelos microscópicos, pode ser uma abordagem vantajosa. Especificamente, a inclusão de uma margem de segurança, chamada de "*buffer*", nas estimativas dos modelos microscópicos pode ser benéfica.

No entanto, para que essa abordagem seja viável, é fundamental que o planejamento de rotas utilize esses modelos microscópicos em vez de depender de um parâmetro de autonomia fixa, como é comum. Incorporar esses modelos no planejamento de rotas é um desafio computacional complexo e oneroso, mas já foi realizado em estudos anteriores, exemplificados por pesquisas como a de Xiao *et al.* (2021).

4.8.2 Clusterização de rotas

Apesar da alta dispersão do consumo (EC) das rotas, uma estratégia possível para mitigar a alta dispersão do erro de modelos macroscópicos poderia envolver uma modelagem regional desses parâmetros. Isto é, delimitando áreas geográficas e considerando variáveis específicas, como declividade e velocidade média seria possível ter valores médios variáveis de consumo, que seriam utilizados a depender da região de entrega de uma dada rota. Nesse contexto, uma tentativa de abordagem semelhante ao que foi feito no trabalho de Velázquez-Martínez *et al.* (2016) foi implementada para agrupar (*clusterizar*) as rotas a partir dos dados de treino, buscando identificar valores médios de consumo. Posteriormente, essa modelagem seria validada em rotas de teste, permitindo a avaliação da eficácia da consideração regional na redução da dispersão dos parâmetros macroscópicos e, consequentemente, aprimorando a precisão das estimativas de consumo. No entanto, para os dados do presente trabalho, essa segmentação não se mostrou válida, dada a falta de variabilidade em locais de entrega.

Em primeiro lugar, foram consideradas algumas variáveis para clusterização de rotas, como número de paradas, ponto de maior distância até o CD, coeficiente de regeneração exponencial médio, variação no grade e massa de entrega em cada uma das rotas de treino do modelo. Foram avaliadas diversas combinações de tais variáveis para clusterização utilizando o algoritmo K-means, que organiza dados em grupos (*clusters*) com base em centroides (James *et al.*, 2013). Posteriormente, os *clusters* eram agregados conforme a metodologia proposta em Velázquez-Martínez *et al.* (2016), em que era feito um teste de Tukey e *clusters* sem diferença significativa de consumo eram agregados. No entanto,

ao final do procedimento, os *clusters* colapsavam sempre em um mesmo *cluster*. Isso provavelmente ocorreu devido a uma baixa variação de localização de entrega e condições de operação. Uma das tentativas de clusterização pode ser vista na Figura 30, onde pode ser vista a sobreposição das distribuições de consumo de energia pelos *clusters* e, portanto, a não separabilidade destes.

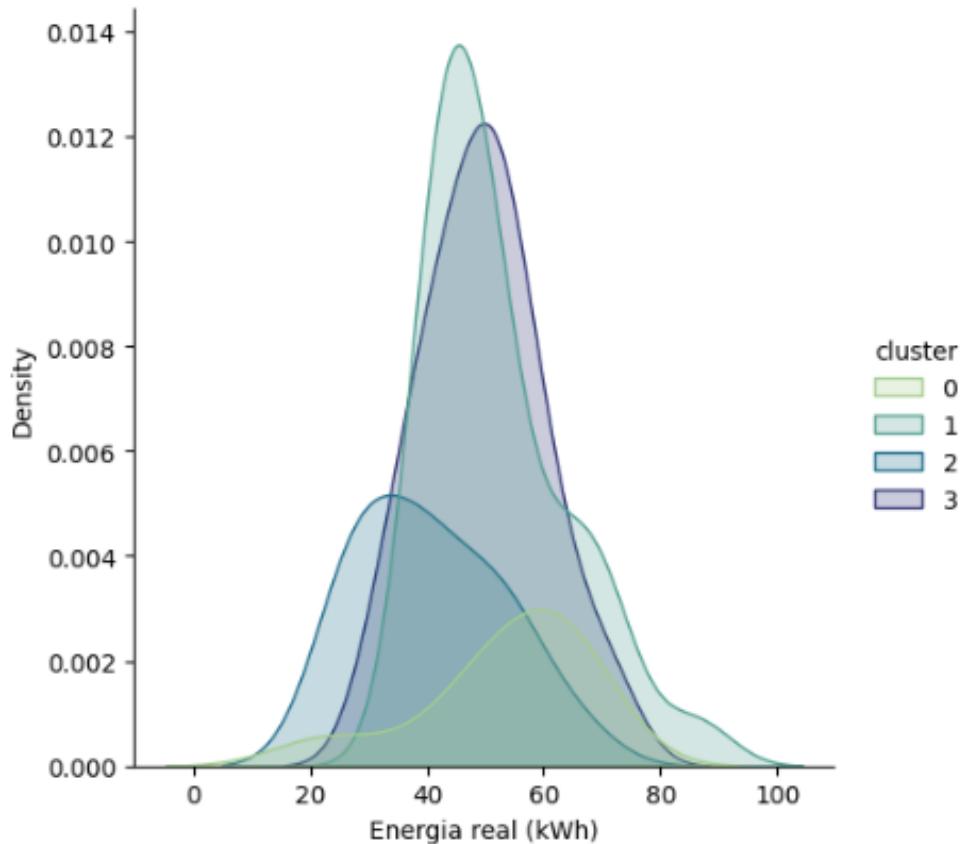


Figura 30 – Tentativa de clusterização de rotas
Fonte: autor

Apesar de esta metodologia não ter produzido os resultados desejados, ela ainda poderia ser aplicada caso mais rotas e com maior variabilidade de região de entrega pudessem ser incorporadas.

4.9 Síntese de aprendizados

Com os dados obtidos durante a realização desse trabalho, foi verificado que conforme a granularidade dos modelos é refinada, eles tendem a ter uma dispersão de erro menor. Para termos comparativos, dentre os melhores modelos de cada granularidade - isto é, o microscópico e mesoscópico com regeneração exponencial e o macroscópico sem regeneração - o modelo microscópico obteve um intervalo interquartil dos erros 18% menor do que o modelo mesoscópico e 22% menor do que o modelo macroscópico.

Nesse sentido, pode-se afirmar modelos microscópicos tem uma **confiabilidade** maior e seu uso precederia uma carga de segurança (*buffer*) menor e, para um mesmo *buffer*, apresentaria uma probabilidade de falha menor do que os modelos das demais granularidades.

No entanto, o uso de tais modelos impõe dificuldades tanto do ponto de vista operacional como do ponto de vista computacional. Tais dificuldades dizem respeito à **complexidade** de sua aplicação. Computacionalmente, seria necessário reformular os algoritmos de roteirização de modo a incluir estimativas com granularidade mais refinada por meio de simuladores. Além disso, pouco adiantaria realizar tais simulações caso a operação diferisse em demasia do que foi simulado. Nesse sentido, seria necessário controlar rigorosamente a ordem das entregas e as rotas realizadas. Sabe-se que tal controle operacional se mostra um grande desafio por si só.

Além disso, para planejamentos de nível mais estratégico, como localização de CDs e dimensionamento de frotas é ainda mais difícil incluir modelos microscópicos, dadas as incertezas inerentes desse tipo de planejamento, em que, frequentemente, não se possui *a priori* os locais de entrega e rotas a serem realizadas de forma detalhada. Para esses casos de uso, uma estimativa macroscópica com agrupamentos, tal como foi tentado neste trabalho, poderia se mostrar benéfica.

A síntese do *trade-off* entre confiabilidade e complexidade dos modelos de estimativa de energia em veículos elétricos (*BEVs*) pode ser vista na Figura 31.

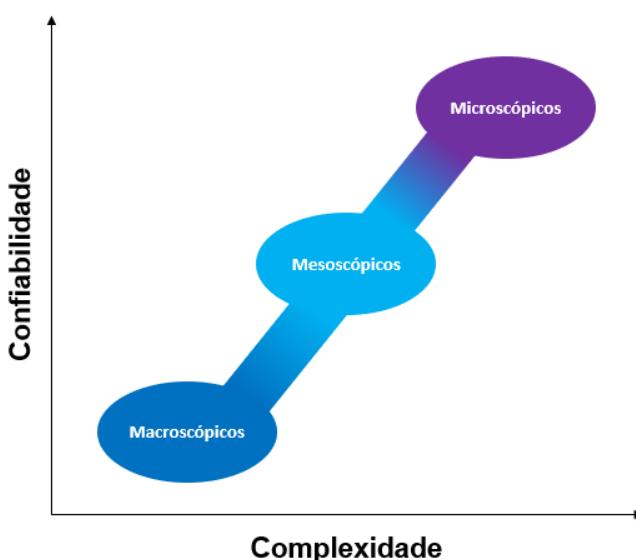


Figura 31 – Ilustração sobre o *trade-off* entre confiabilidade e complexidade de modelos de energia.

Fonte: autor

Resumindo, tal como apresentado na introdução, este trabalho teve como objeti-

vos a aplicação de modelos físicos microscópicos de energia com diferentes modelagens de regeneração, corrigidos por um coeficiente linear derivado estatisticamente. Além disso, derivaram-se parâmetros mesoscópicos e macroscópicos a partir da aplicação desses diferentes modelos microscópicos. Analisaram-se os erros, limitações e aplicações desses modelos neste capítulo. As conclusões finais e sugestões para futuras pesquisas serão abordadas no próximo capítulo.

5 Conclusões e próximos desenvolvimentos

5.1 Conclusão

A transição para veículos elétricos representa um avanço significativo em direção a uma logística mais sustentável. No entanto, é importante reconhecer que ainda persistem desafios significativos em relação ao uso desse tipo de veículo, sendo a restrição de autonomia uma das questões mais proeminentes. A autonomia limitada das baterias em veículos elétricos pode gerar preocupações em relação a possíveis interrupções na rota, especialmente em cenários em que não há infraestrutura adequada para recarga. As consequências associadas ao descarregamento da bateria durante uma rota podem variar desde atrasos operacionais até a necessidade de resgates, impactando negativamente a eficiência e a confiabilidade das operações.

A mitigação dessas dificuldades muitas vezes requer um planejamento rigoroso da rota e uma estimativa precisa da energia necessária para a viagem. Nesse sentido, o uso de modelos macroscópicos, ou baseados numa autonomia fixa, tem um erro consideravelmente maior do que modelos microscópicos. Os modelos desenvolvidos nesse trabalho comprovam essa realidade, com o erro quadrático médio do modelo microscópico com regeneração exponencial de 106,96 kWh², ao passo que o mesmo modelo em escala macroscópica obteve um erro de 213,63 kWh². De forma a mitigar o impacto operacional do erro de tais modelos, podem ser adotados *buffers* de energia reserva. Tais *buffers* endereçam o problema da probabilidade de subestimação da energia gasta pelos modelos (erros do tipo 1), mas acarretam em custos operacionais e subutilização da frota.

A incorporação de modelos com maior precisão pode diminuir o impacto econômico dos *buffers*, mas sua implementação é desafiadora. Na literatura, podem ser encontrados exemplos de implementação algoritmos de roteamento que incorporam modelos de estimativa precisos, como microscópicos e mesoscópicos, no roteamento com o uso de simulações, que consideram fatores como topografia, carga, velocidade e condições ambientais para prever o consumo de energia.

No entanto, mesmo com um roteamento que tenha uma precisão e exatidão alta para o consumo de energia, as incertezas operacionais, como ordem em que serão feitas as entregas, distâncias entre os nós de entrega e condições de trânsito, ainda podem gerar uma variabilidade considerável no consumo de energia. Até que uma infraestrutura mais abrangente esteja disponível, que inclua postos de recarga, veículos de resgate e mecanismos de troca de bateria emergencial, a operação segura de veículos elétricos pode depender da implementação de estratégias de superdimensionamento de frotas e subdimensionamento

de distâncias por rota. Embora essas estratégias possam fornecer uma solução temporária, elas também acarretam custos financeiros significativos para as operações.

Ainda que fosse atingido um cenário em que todos esses aspectos de infraestrutura estejam devidamente implementados para dar suporte aos veículos elétricos, é inegável que a operação desses veículos introduz uma complexidade que não necessariamente encontra um paralelo direto com os veículos a combustão. A gestão da autonomia, o carregamento e a manutenção das baterias, as flutuações nas condições de energia são elementos intrínsecos à operação de veículos elétricos que demandam abordagens distintas de modelagem.

Nesse contexto, é fundamental que os modelos econômicos e ambientais que avaliam o impacto das operações com veículos elétricos incluam todos esses fatores. Em específico, tal como apontado nesse trabalho, é importante considerar as incertezas e parâmetros de segurança associados a tais incertezas na modelagem financeira e ambiental da operação eletrificada. Além disso, a consideração de tais elementos é importante para a adaptação de práticas de gerenciamento para promover uma transição bem-sucedida para veículos elétricos em uma variedade de contextos operacionais. A análise completa e holística desses fatores é um passo fundamental em direção a uma logística mais sustentável e eficiente, permitindo a tomada de decisões informadas e estratégicas na adoção de veículos elétricos.

5.2 Próximos desenvolvimentos

Os futuros avanços seguintes a esse trabalho podem envolver a implementação dos modelos microscópico híbridos físico-estatísticos que foram desenvolvidos neste trabalho no contexto de simulação de rotas, com sua posterior integração em modelos de roteirização e tomada de decisões sobre a localização de Centros de Distribuição (CDs) e infraestrutura de carregamento.

Adicionalmente, seria vantajoso conduzir experimentos fatoriais com uma ampla variação operacional e a coleta de dados de alta frequência para a validação das entradas do modelo. Dentre esses dados capturados com alta frequência, preferencialmente constariam o perfil de velocidades assim como o SOC (nível da bateria) ao longo das rotas. Com tais dados, também seria possível conduzir a análise de clusterização de rotas que não foi possível viabilizar de forma satisfatória nesse estudo. Tal coleta também poderia seguir com a validação dos coeficientes de regeneração exponencial e linear que foram obtidos neste trabalho.

Referências

- 1 ABOUSLEIMAN, Rami; RAWASHDEH, Osamah. Energy consumption model of an electric vehicle. In: 2015 IEEE Transportation Electrification Conference and Expo (ITEC). [S.l.]: IEEE, jun. 2015. DOI: [10.1109/itec.2015.7165773](https://doi.org/10.1109/itec.2015.7165773). Disponível em: <<https://doi.org/10.1109/itec.2015.7165773>>.
- 2 AHMED, Moin *et al.* Electric Vehicle Range Estimation Using Regression Techniques. **World Electric Vehicle Journal**, MDPI AG, v. 13, n. 6, p. 105, jun. 2022. DOI: [10.3390/wevj13060105](https://doi.org/10.3390/wevj13060105). Disponível em: <<https://doi.org/10.3390/wevj13060105>>.
- 3 ANP - AGÊNCIA NACIONAL DE PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. Série histórica do levantamento de preços. [S.l.: s.n.], 2023. <https://www.gov.br/anp/pt-br/assuntos/precos-e-defesa-da-concorrencia/precos/precos-revenda-e-de-distribuicao-combustiveis/serie-historica-do-levantamento-de-precos>. Accessed: 2023-10-22.
- 4 ANUÁRIO DA INDÚSTRIA AUTOMOBILÍSTICA BRASILEIRA. [S.l.], 2023. Disponível em: <https://anfavea.com.br/site/wp-content/uploads/2023/05/anuario-ATUALIZADO-2023-ALTA_compressed.pdf>.
- 5 BARNITT, Robb. **Fedex express gasoline hybrid electric delivery truck evaluation: 12-month report**. [S.l.], 2011.
- 6 BARTH, Matthew; SCORA, George; YOUNGLOVE, Theodore. Modal emissions model for heavy-duty diesel vehicles. **Transportation Research Record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1880, n. 1, p. 10–20, 2004.
- 7 BASSO, Rafael *et al.* Energy consumption estimation integrated into the Electric Vehicle Routing Problem. **Transportation Research Part D: Transport and Environment**, Elsevier BV, v. 69, p. 141–167, abr. 2019. DOI: [10.1016/j.trd.2019.01.006](https://doi.org/10.1016/j.trd.2019.01.006). Disponível em: <<https://doi.org/10.1016/j.trd.2019.01.006>>.
- 8 BEHNKE, Martin; KIRSCHSTEIN, Thomas. The impact of path selection on GHG emissions in city logistics. **Transportation Research Part E: Logistics and Transportation Review**, v. 106, p. 320–336, 2017. ISSN 1366-5545. DOI: <https://doi.org/10.1016/j.tre.2017.08.011>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1366554517300388>>.

- 9 BHARDWAJ, Shishir; MOSTOFI, Hamid. Technical and Business Aspects of Battery Electric Trucks — A Systematic Review. **Future Transportation**, v. 2, n. 2, p. 382–401, 2022. ISSN 2673-7590. DOI: [10.3390/futuretransp2020021](https://doi.org/10.3390/futuretransp2020021). Disponível em: <<https://www.mdpi.com/2673-7590/2/2/21>>.
- 10 BOKARE, P.S.; MAURYA, A.K. Acceleration-Deceleration Behaviour of Various Vehicle Types. **Transportation Research Procedia**, Elsevier BV, v. 25, p. 4733–4749, 2017. DOI: [10.1016/j.trpro.2017.05.486](https://doi.org/10.1016/j.trpro.2017.05.486). Disponível em: <<https://doi.org/10.1016/j.trpro.2017.05.486>>.
- 11 BROOKER, Aaron *et al.* **FASTSim: A model to estimate vehicle efficiency, cost and performance**. [S.l.], 2015.
- 12 CARVALHO, Carlos Henrique Ribeiro de. Emissões relativas de poluentes do transporte urbano. Instituto de Pesquisa Econômica Aplicada (Ipea), 2011.
- 13 CETESB. **Proconve**. [S.l.: s.n.], 2023. [Accessed 24-10-2023]. Disponível em: <<https://cetesb.sp.gov.br/veicular/proconve/>>.
- 14 CHANG, Wen-Yeau. The state of charge estimating methods for battery: A review. **International Scholarly Research Notices**, Hindawi, v. 2013, 2013.
- 15 COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO (CETESB). **Relatório de Emissões Veiculares 2020**. [S.l.], 2022. Disponível em: <<https://cetesb.sp.gov.br/veicular/wp-content/uploads/sites/6/2022/03/Relatorio-Emissoes-Veiculares-2020.pdf>>.
- 16 DEMIR, Emrah; BEKTAS, Tolga; LAPORTE, Gilbert. A comparative analysis of several vehicle emission models for road freight transportation. **Transportation Research Part D: Transport and Environment**, Elsevier BV, v. 16, n. 5, p. 347–357, jul. 2011. DOI: [10.1016/j.trd.2011.01.011](https://doi.org/10.1016/j.trd.2011.01.011). Disponível em: <<https://doi.org/10.1016/j.trd.2011.01.011>>.
- 17 DENG, Jie *et al.* Electric Vehicles Batteries: Requirements and Challenges. **Joule**, v. 4, n. 3, p. 511–515, 2020. ISSN 2542-4351. DOI: <https://doi.org/10.1016/j.joule.2020.01.013>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S254243512030043X>>.
- 18 D'ESTE, Glen M.; ZITO, Rocco; TAYLOR, Michael A. P. Using GPS to Measure Traffic System Performance. **Computer-Aided Civil and Infrastructure Engineering**, Wiley, v. 14, n. 4, p. 255–265, jul. 1999. DOI: [10.1111/0885-9507.00146](https://doi.org/10.1111/0885-9507.00146). Disponível em: <<https://doi.org/10.1111/0885-9507.00146>>.
- 19 DEVORE, Jay L. **Probabilidade E Estatística Para Engenharia E Ciências**. [S.l.: s.n.], 2018.

- 20 DOUCETTE, Reed T.; MCCULLOCH, Malcolm D. Modeling the CO₂ emissions from battery electric vehicles given the power generation mixes of different countries. **Energy Policy**, Elsevier BV, v. 39, n. 2, p. 803–811, fev. 2011. DOI: [10.1016/j.enpol.2010.10.054](https://doi.org/10.1016/j.enpol.2010.10.054). Disponível em: <<https://doi.org/10.1016/j.enpol.2010.10.054>>.
- 21 ENERGIA ELÉTRICA, CCEE Câmara de Comercialização de. **Painel de preços**. [S.l.: s.n.], 2023. <https://www.ccee.org.br/precos/painel-precos>. Accessed: 2023-10-22.
- 22 EPA (UNITED STATES ENVIRONMENTAL PROTECTION AGENCY). **Learn About Impacts of Diesel Exhaust and the Diesel Emissions Reduction Act (DERA)**. [S.l.: s.n.], 2023. <https://www.epa.gov/dera/learn-about-impacts-diesel-exhaust-and-diesel-emissions-reduction-act-dera>. [Accessed 25-11-2023].
- 23 FENABRAVE. **Relatório de Emplacamentos Setembro de 2023**. [S.l.], 2023.
- 24 FIORI, Chiara; AHN, Kyoungho; RAKHA, Hesham A. Power-based electric vehicle energy consumption model: Model development and validation. **Applied Energy**, Elsevier BV, v. 168, p. 257–268, abr. 2016. DOI: [10.1016/j.apenergy.2016.01.097](https://doi.org/10.1016/j.apenergy.2016.01.097). Disponível em: <<https://doi.org/10.1016/j.apenergy.2016.01.097>>.
- 25 FIORI, Chiara *et al.* Microscopic energy consumption modelling of electric buses: model development, calibration, and validation. **Transportation Research Part D: Transport and Environment**, Elsevier BV, v. 98, p. 102978, set. 2021. DOI: [10.1016/j.trd.2021.102978](https://doi.org/10.1016/j.trd.2021.102978). Disponível em: <<https://doi.org/10.1016/j.trd.2021.102978>>.
- 26 FIPE - FUNDAÇÃO INSTITUTO DE PESQUISAS ECONÔMICAS. **Tabela FIPE**. [S.l.: s.n.], 2023. <https://veiculos.fipe.org.br/>. [Accessed 21-10-2023].
- 27 GENIKOMSAKIS, Konstantinos N.; MITRENTSIS, Georgios. A computationally efficient simulation model for estimating energy consumption of electric vehicles in the context of route planning applications. **Transportation Research Part D: Transport and Environment**, Elsevier BV, v. 50, p. 98–118, jan. 2017. DOI: [10.1016/j.trd.2016.10.014](https://doi.org/10.1016/j.trd.2016.10.014). Disponível em: <<https://doi.org/10.1016/j.trd.2016.10.014>>.
- 28 GOUVEIA, Nelson *et al.* Hospitalizações por causas respiratórias e cardiovasculares associadas à contaminação atmosférica no Município de São Paulo, Brasil. **Cadernos de Saúde Pública**, SciELO Brasil, v. 22, p. 2669–2677, 2006.

- 29 HAYES, John G.; DAVIS, Kevin. Simplified electric vehicle powertrain model for range and energy consumption based on EPA coast-down parameters and test validation by Argonne National Lab data on the Nissan Leaf. In: 2014 IEEE Transportation Electrification Conference and Expo (ITEC). [S.l.]: IEEE, jun. 2014. DOI: [10.1109/itec.2014.6861831](https://doi.org/10.1109/itec.2014.6861831). Disponível em: <<https://doi.org/10.1109/itec.2014.6861831>>.
- 30 HELLGREN, Jonas. Life cycle cost analysis of a car, a city bus and an intercity bus powertrain for year 2005 and 2020. **Energy policy**, Elsevier, v. 35, n. 1, p. 39–49, 2007.
- 31 HORE-LACY. Future Energy Demand and Supply. In: NUCLEAR Energy in the 21st Century. 2nd. London, UK: WNUP, 2011. cap. 1, p. 9.
- 32 JAC MOTORS. **Jac Motors - iEV1200T**. [S.l.: s.n.], 2023. <https://www.jacmotors.com.br/veiculos/electricos-detalhes/iev1200t>. [Accessed 21-10-2023].
- 33 JAMES, Gareth *et al.* **An Introduction to Statistical Learning: with Applications in R**. [S.l.]: Springer, 2013. Disponível em: <<https://faculty.marshall.usc.edu/gareth-james/ISL/>>.
- 34 KAWAMOTO, Ryuji *et al.* Estimation of CO₂ Emissions of Internal Combustion Engine Vehicle and Battery Electric Vehicle Using LCA. **Sustainability**, MDPI AG, v. 11, n. 9, p. 2690, mai. 2019. DOI: [10.3390/su11092690](https://doi.org/10.3390/su11092690). Disponível em: <<https://doi.org/10.3390/su11092690>>.
- 35 KOUPAL, John *et al.* Design and implementation of MOVES: EPAs new generation mobile source emission model. **Ann Arbor**, v. 1001, n. 48, p. 105, 2003.
- 36 LARANJEIRO, Patrícia F. *et al.* Using GPS data to explore speed patterns and temporal fluctuations in urban logistics: The case of São Paulo, Brazil. **Journal of Transport Geography**, Elsevier BV, v. 76, p. 114–129, abr. 2019. DOI: [10.1016/j.jtrangeo.2019.03.003](https://doi.org/10.1016/j.jtrangeo.2019.03.003). Disponível em: <<https://doi.org/10.1016/j.jtrangeo.2019.03.003>>.
- 37 LEE, Dong-Yeon; THOMAS, Valerie M.; BROWN, Marilyn A. Electric Urban Delivery Trucks: Energy Use, Greenhouse Gas Emissions, and Cost-Effectiveness. **Environmental Science & Technology**, American Chemical Society (ACS), v. 47, n. 14, p. 8022–8030, jul. 2013. DOI: [10.1021/es400179w](https://doi.org/10.1021/es400179w). Disponível em: <<https://doi.org/10.1021/es400179w>>.
- 38 MERA ET AL. **Comparison of the Life-Cycle Greenhouse Gas Emissions of Combustion Engine and Electric Passenger Cars in Brazil**. [S.l.], 2023.

- 39 MOREIRA, Jose R.; PACCA, Sergio A.; GOLDEMBERG, Jose. The reduction of CO₂e emissions in the transportation sector: Plug-in electric vehicles and biofuels. **Renewable and Sustainable Energy Transition**, Elsevier BV, v. 2, p. 100032, ago. 2022. DOI: [10.1016/j.rset.2022.100032](https://doi.org/10.1016/j.rset.2022.100032). Disponível em: <<https://doi.org/10.1016/j.rset.2022.100032>>.
- 40 NEWSON, Paul; KRUMM, John. Hidden Markov map matching through noise and sparseness. In: PROCEEDINGS of the 17th ACM SIGSPATIAL international conference on advances in geographic information systems. [S.l.: s.n.], 2009. P. 336–343.
- 41 NIST. **Physical Measurement Laboratory**. [S.l.: s.n.], 2023. <https://physics.nist.gov/>. [Accessed 21-10-2023].
- 42 NTZIACHRISTOS, Leonidas *et al.* COPERT: a European road transport emission inventory model. In: SPRINGER. INFORMATION Technologies in Environmental Engineering: Proceedings of the 4th International ICSC Symposium Thessaloniki, Greece, May 28-29, 2009. [S.l.: s.n.], 2009. P. 491–504.
- 43 OUR WORLD IN DATA. **Brazil: CO₂ Country Profile**. [S.l.: s.n.], 2021. <https://ourworldindata.org/co2/country/brazil>. Accessed: 2023-05-28.
- 44 PAMUŁA, Teresa; PAMUŁA, Wiesław. Estimation of the Energy Consumption of Battery Electric Buses for Public Transport Networks Using Real-World Data and Deep Learning. **Energies**, MDPI AG, v. 13, n. 9, p. 2340, mai. 2020. DOI: [10.3390/en13092340](https://doi.org/10.3390/en13092340). Disponível em: <<https://doi.org/10.3390/en13092340>>.
- 45 PASCHOAL, Anderson *et al.* Emissão de gases de efeito estufa (GEE) no transporte de cargas: modelos e aplicações no Brasil. In: [s.l.]: Editora Atlas Ltda, 2017. cap. 3.
- 46 PELLETIER, Samuel; JABALI, Ola; LAPORTE, Gilbert. The electric vehicle routing problem with energy consumption uncertainty. **Transportation Research Part B: Methodological**, Elsevier BV, v. 126, p. 225–255, ago. 2019. DOI: [10.1016/j.trb.2019.06.006](https://doi.org/10.1016/j.trb.2019.06.006). Disponível em: <<https://doi.org/10.1016/j.trb.2019.06.006>>.
- 47 PICARD, A *et al.* Revised formula for the density of moist air (CIPM-2007). **Metrologia**, IOP Publishing, v. 45, n. 2, p. 149–155, fev. 2008. DOI: [10.1088/0026-1394/45/2/004](https://doi.org/10.1088/0026-1394/45/2/004). Disponível em: <<https://doi.org/10.1088/0026-1394/45/2/004>>.
- 48 PLAUDIS, Matthew *et al.* An Algorithmic Approach to Quantifying GPS Trajectory Error. In: PROCEEDINGS of the IEEE/CVF International Conference on Computer Vision. [S.l.: s.n.], 2021. P. 3909–3916.

- 49 QI, Xuewei *et al.* 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**, Elsevier BV, v. 64, p. 36–52, out. 2018. DOI: [10.1016/j.trd.2017.08.008](https://doi.org/10.1016/j.trd.2017.08.008). Disponível em: <<https://doi.org/10.1016/j.trd.2017.08.008>>.
- 50 ROGGE, Matthias *et al.* Electric bus fleet size and mix problem with optimization of charging infrastructure. **Applied Energy**, Elsevier BV, v. 211, p. 282–295, fev. 2018. DOI: [10.1016/j.apenergy.2017.11.051](https://doi.org/10.1016/j.apenergy.2017.11.051). Disponível em: <<https://doi.org/10.1016/j.apenergy.2017.11.051>>.
- 51 SAKI, Siavash; HAGEN, Tobias. A Practical Guide to an Open-Source Map-Matching Approach for Big GPS Data. **SN Computer Science**, Springer Science e Business Media LLC, v. 3, n. 5, ago. 2022. DOI: [10.1007/s42979-022-01340-5](https://doi.org/10.1007/s42979-022-01340-5). Disponível em: <<https://doi.org/10.1007/s42979-022-01340-5>>.
- 52 SATHRE, Roger; GUSTAVSSON, Leif. Lifecycle climate impact and primary energy use of electric and biofuel cargo trucks. **GCB Bioenergy**, Wiley Online Library, v. 15, n. 4, p. 508–531, 2023.
- 53 SCHÜSSLER, Nadine; AXHAUSEN, Kay W. Identifying trips and activities and their characteristics from GPS raw data without further information. **Arbeitsberichte Verkehrs- und Raumplanung**, ETH, Eidgenössische Technische Hochschule Zürich, IVT, v. 502, 2008.
- 54 SEABOLD, Skipper; PERKTOLD, Josef. statsmodels: Econometric and statistical modeling with python. In: 9TH Python in Science Conference. [S.l.: s.n.], 2010.
- 55 SHAMMA, Zarin Subah *et al.* Electric vehicle range prediction estimator (EVPRE). **Software Impacts**, v. 13, p. 100369, 2022. ISSN 2665-9638. DOI: <https://doi.org/10.1016/j.simpa.2022.100369>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S266596382200077X>>.
- 56 SHIBATA, Seishiro; NAKAGAWA, Tsuguhiro. Mathematical Model of Electric Vehicle Power Consumption for Traveling and Air-Conditioning. **Journal of Energy and Power Engineering**, David Publishing Company, v. 9, n. 3, mar. 2015. DOI: [10.17265/1934-8975/2015.03.006](https://doi.org/10.17265/1934-8975/2015.03.006). Disponível em: <<https://doi.org/10.17265/1934-8975/2015.03.006>>.
- 57 STERKENBURG, S. Van *et al.* Analysis of regenerative braking efficiency & A case study of two electric vehicles operating in the Rotterdam area. In: 2011 IEEE Vehicle Power and Propulsion Conference. [S.l.]: IEEE, set. 2011. DOI: [10.1109/vppc.2011.6043109](https://doi.org/10.1109/vppc.2011.6043109). Disponível em: <<https://doi.org/10.1109/vppc.2011.6043109>>.

- 58 U. S. ENVIRONMENTAL PROTECTION AGENCY. User's guide to MOBILE, 2003. Disponível em: <<https://nepis.epa.gov/>>.
- 59 U. S. ENVIRONMENTAL PROTECTION AGENCY. Advanced Technology Vehicle Modeling In PERE, 2004. Disponível em: <<https://nepis.epa.gov/>>.
- 60 UOL - UNIVERSO ONLINE. **VW e-Delivery, desenvolvido no Brasil, será lançado na Argentina em 2023.** [S.l.: s.n.], 2022.
<https://insideevs.uol.com.br/news/610324/volkswagen-edelivery-caminhao-eletrico-argentina/>. [Accessed 21-10-2023].
- 61 VELÁZQUEZ-MARTÍNEZ, Josué C. *et al.* A new statistical method of assigning vehicles to delivery areas for CO₂ emissions reduction. **Transportation Research Part D: Transport and Environment**, Elsevier BV, v. 43, p. 133–144, mar. 2016. DOI: [10.1016/j.trd.2015.12.009](https://doi.org/10.1016/j.trd.2015.12.009). Disponível em: <<https://doi.org/10.1016/j.trd.2015.12.009>>.
- 62 VIRTANEN, Pauli *et al.* SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. **Nature Methods**, v. 17, p. 261–272, 2020. DOI: [10.1038/s41592-019-0686-2](https://doi.org/10.1038/s41592-019-0686-2).
- 63 VOLKSWAGEN. **Catálogo de veículos.** [S.l.: s.n.], 2023.
<https://www.vwco.com.br/caminhoes>. Accessed: 2023-10-21.
- 64 XIAO, Yiyong *et al.* Electric vehicle routing problem: A systematic review and a new comprehensive model with nonlinear energy recharging and consumption. **Renewable and Sustainable Energy Reviews**, Elsevier BV, v. 151, p. 111567, nov. 2021. DOI: [10.1016/j.rser.2021.111567](https://doi.org/10.1016/j.rser.2021.111567). Disponível em: <<https://doi.org/10.1016/j.rser.2021.111567>>.
- 65 YANG, S.C. *et al.* Electric vehicle's electricity consumption on a road with different slope. **Physica A: Statistical Mechanics and its Applications**, Elsevier BV, v. 402, p. 41–48, mai. 2014. DOI: [10.1016/j.physa.2014.01.062](https://doi.org/10.1016/j.physa.2014.01.062). Disponível em: <<https://doi.org/10.1016/j.physa.2014.01.062>>.
- 66 YOUNES, Zoulficar *et al.* Analysis of the main factors influencing the energy consumption of electric vehicles. In: 2013 International Electric Machines & Drives Conference. [S.l.]: IEEE, mai. 2013. DOI: [10.1109/иемдс.2013.6556260](https://doi.org/10.1109/иемдс.2013.6556260). Disponível em: <<https://doi.org/10.1109/иемдс.2013.6556260>>.
- 67 ZHANG, Jason *et al.* Short Note: On the Relativistic Doppler Effect for Precise Velocity Determination using GPS. **Journal of Geodesy**, Springer Science e Business Media LLC, v. 80, n. 2, p. 104–110, mar. 2006. DOI: [10.1007/s00190-006-0038-8](https://doi.org/10.1007/s00190-006-0038-8). Disponível em: <<https://doi.org/10.1007/s00190-006-0038-8>>.

- 68 ZHANG, Jin *et al.* Energy consumption analysis and prediction of electric vehicles based on real-world driving data. **Applied Energy**, Elsevier BV, v. 275, p. 115408, out. 2020. DOI: [10.1016/j.apenergy.2020.115408](https://doi.org/10.1016/j.apenergy.2020.115408). Disponível em: <<https://doi.org/10.1016/j.apenergy.2020.115408>>.
- 69 ZHANG, Rui; YAO, Enjian. Mesoscopic model framework for estimating electric vehicles' energy consumption. **Sustainable Cities and Society**, Elsevier BV, v. 47, p. 101478, mai. 2019. DOI: [10.1016/j.scs.2019.101478](https://doi.org/10.1016/j.scs.2019.101478). Disponível em: <<https://doi.org/10.1016/j.scs.2019.101478>>.
- 70 ZHENG, Yuejiu *et al.* Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. **Journal of Power Sources**, Elsevier BV, v. 377, p. 161–188, fev. 2018. DOI: [10.1016/j.jpowsour.2017.11.094](https://doi.org/10.1016/j.jpowsour.2017.11.094). Disponível em: <<https://doi.org/10.1016/j.jpowsour.2017.11.094>>.

Apêndice A - Ambiente e código

Código Python de tratamento dos dados de GPS

Utilizando a biblioteca GeoPandas do Python, foi aplicado o seguinte tratamento nos dados:

```

locations_valid = (
    locations_valid .query( "distribution_center_id == 401" )
    .assign(
        location_timestamp=pd.to_datetime( locations[ "
            location_timestamp" ] ),
    )
    .sort_values( by=[ "tour_id" , "location_timestamp" ] ,
        ascending=True )
    .assign(
        dspeed=lambda dfa: dfa[ "speed" ].diff() ,
        dtime=lambda dfa: dfa[ "location_timestamp" ].diff() .
            dt.total_seconds() ,
        frequency=lambda dfa: 1 / dfa[ "dtime" ] ,
        day=lambda dfa: dfa[ "location_timestamp" ].dt.date ,
        weekday=lambda dfa: dfa[ "location_timestamp" ].dt .
            day_name() ,
        geometry=lambda dfa: dfa .apply(
            lambda row: Point( row[ "longitude" ] , row[ "
                latitude" ] ) , axis=1
        ) ,
        previous_geometry=lambda dfa: dfa .groupby( "tour_id" )
            [ "geometry" ].shift(1) ,
        previous_latitude=lambda dfa: dfa .groupby( "tour_id" )
            [ "latitude" ].shift(1) ,
        previous_longitude=lambda dfa: dfa .groupby( "tour_id" )
            [ "longitude" ].shift(1) ,
        distance=lambda dfa: apply_haversine_distance( dfa ) ,
        inferred_speed_ms=lambda dfa: ( dfa[ "distance" ] / dfa
            [ "dtime" ] ) .mask(
            dfa[ "dtime" ].isna() | dfa[ "dtime" ] == 0 , 0
        ) ,
)

```

```

inferred_speed_kmh=lambda dfa: dfa[ "
    inferred_speed_ms" ] * 3.6 ,
mass_id=lambda dfa: (
    dfa[ "location_timestamp" ].dt.strftime( "%Y%m%d" )
).astype( str )
+ "_"
+ (dfa[ "license_plate" ]).astype( str ) ,
inferred_dspeed_ms=lambda dfa: (
    dfa[ "inferred_speed_ms" ] - dfa.groupby( "tour_id" )
)[ "inferred_speed_ms" ].shift(1)
),
inferred_acceleration_ms2=lambda dfa: (
    dfa[ "inferred_dspeed_ms" ] / dfa[ "dtime" ]
).mask( dfa[ "dtime" ].isna() | dfa[ "dtime" ] == 0, 0) ,
inferred_acceleration_kmh2=lambda dfa: dfa[ "
    inferred_acceleration_ms2" ] * 3.6 ,
)
.query( "inferred_speed_kmh < 150 and
    inferred_acceleration_kmh2 < 10" )
.drop( columns=[ "geometry" , "previous_geometry" ] )
)

def apply_haversine_distance( df ):
    lon1 , lat1 , lon2 , lat2 = (
        df[ "previous_longitude" ].values ,
        df[ "previous_latitude" ].values ,
        df[ "longitude" ].values ,
        df[ "latitude" ].values ,
    )
    lon1 , lat1 , lon2 , lat2 = map( np.radians , [ lon1 , lat1 , lon2 ,
        lat2 ] )
    dlon = lon2 - lon1
    dlat = lat2 - lat1
    a = np.sin( dlat / 2.0 ) ** 2 + np.cos( lat1 ) * np.cos( lat2 ) *
        np.sin( dlon / 2.0 ) ** 2

    c = 2 * np.arcsin( np.sqrt( a ) )
    km = 6367 * c
    m = km * 1000

```

```
    return m
```

Código Python para designar pontos de parada nas rotas

```
def get_route_delivery_points_matches(stop_points, route):
    stop_points_3857 = stop_points.to_crs(crs=3857)
    route_3857 = route.copy().to_crs(crs=3857)
    last_ts = "1990-01-01 10:41:11+00:00"
    matches = []
    for i in range(stop_points_3857.shape[0]):
        route_3857 = route_3857.query("location_timestamp >
            @last_ts")
        stop_point = stop_points_3857.iloc[i : i + 1]
        match = stop_point.sjoin_nearest(
            route_3857, distance_col="d_point", how="left",
            max_distance=100
        )
        match = match.sort_values(by=["location_timestamp"],
            ascending=True)
        last_index_right = match.iloc[0]["index_right"]
        last_ts = match.iloc[0]["location_timestamp"]
        matches.append(last_ts)
    return matches

def add_mass_to_route(stop_points, route):
    last_ts = get_route_delivery_points_matches(stop_points,
        route)
    route = (
        route.merge(
            stop_points.assign(location_timestamp=pd.to_datetime(
                last_ts)).reindex(
                columns=["location_timestamp", "volume_packages"
            ]
        ),
        how="left",
        on="location_timestamp",
        validate="1:1",
    )
    .sort_values(by="location_timestamp")
```

```

    . assign(
        delta_mass=lambda dfa: dfa[ "volume_packages" ].fillna
        (0) * 5,
        total_loaded_mass=lambda dfa: dfa[ "delta_mass" ].sum
        (),
        current_truck_mass=lambda dfa: (6380 + dfa[ "
            total_loaded_mass" ])
        - dfa[ "delta_mass" ].cumsum() ,
    )
)
return route

```

Instalação do servidor Valhalla

Para execução do serviço Valhalla, foi utilizado um ambiente Docker. O Docker é uma plataforma de código aberto que simplifica a implantação de aplicativos dentro de contêineres. Uma vez instalado, o seguinte comando deve ser instalado, no caso de se ter interesse no map-matching da região em questão.

```
docker run -dt --name valhalla_gis-ops-2 -p 8002:8002 -v $PWD/
    custom_files:/custom_files -e tile_urls=https://download.
    geofabrik.de/south-america/brazil/sudeste-latest.osm.pbf -e
    build_elevation=True -e max_x=-44 -e min_x=-47 -e min_y=-25 -
    e max_y=-21 -e ghcr.io/gis-ops/docker-valhalla/valhalla:
    latest
```

Após a execução bem-sucedida, o servidor Valhalla GIS estará disponível em <http://localhost:8002>.

Código Python para chamada do servidor Valhalla

```

def make_valhalla_request(route):
    begin_time = route[ "location_timestamp" ].iloc [0]
    meili_coordinates = (
        route . assign(
            time=lambda dfa: (dfa[ "location_timestamp" ] -
            begin_time) . dt . seconds
        )
        . reindex(columns=[ "time" , "latitude" , "longitude" ])
        . rename(columns={ "latitude" : "lat" , "longitude" : "lon" })
    )

```

```

        . to_json( orient="records" )
    )
#meili_accuracy = str(route["accuracy"].tolist())
meili_head = '{"shape":'
# Those are parameters that you can change according to the
# Meili's documentation
meili_tail = (
    """, "use_timestamps": true, "search_radius": 300, "
    "costing": "bus", "format": "osrm", "filters": {
        "attributes": ["shape", "edge.names", "edge.way_id", "
            "edge.speed", "edge.lane_count", "edge.speed_limit", "
            "edge.speed", "edge.length", "edge.road_class", "shape",
            "matched.point", "matched.distance_along_edge", "
            "matched.edge_index", "edge.weighted_grade", "edge.id",
            "node.elapsed_time"], "action": "include"} } """
) # f",gps_accuracy:{meili_accuracy}" +
# Combining all the string into a single request
meili_request_body = meili_head + meili_coordinates +
    meili_tail
url = "http://localhost:8002/trace_attributes"
# Providing headers to the request
headers = {"Content-type": "application/json"}
# We need to send our JSON as a string
data = str(meili_request_body)
# Sending a request
r = requests.post(url, data=data, headers=headers)
return r.json()

def _get_matched_edges(response):
    matched_edges = pd.DataFrame(response[ "edges" ]).reset_index(
        names="edge_index")
    return matched_edges

def _get_matches_and_distances(response):
    edge_match = []
    edge_distance = []
    for match in response[ "matched_points" ]:
        edge_match.append(match.get( "edge_index" ))

```

```

        edge_distance.append(match.get("distance_along_edge"))
    return edge_match, edge_distance

def __mapmatching2points(route, response):
    if len(route) > 50:
        assert len(response["edges"]) > 0, "No edges matched for long route"
    matched_edges = __get_matched_edges(response)
    edge_match, edge_distance = __get_matches_and_distances(
        response)
    route = (
        route.assign(edge_index=edge_match, edge_distance=
                    edge_distance)
        .merge(
            matched_edges.assign(
                edge_index=lambda dfa: dfa["edge_index"].astype(
                    float))
        ),
        on="edge_index",
        how="left",
        validate="m:1",
        suffixes=(" ", "__mapmatch"),
    )
)
return route

def get_route_info(route):
    response = make_valhala_request(route)
    route = route.pipe(__mapmatching2points, response=response)
    return route

```

Código Python para estimar coeficientes de regeneração

```

def calculate_energy_exponential(routes_geo, params):
    alpha = params[0]
    mass_column="current_truck_mass"
    speed_col="speed"

```

```

    tours = routes_geo.assign(
        dspeed = lambda dfa: dfa[speed_col].diff(),
        accel = lambda dfa: dfa["dspeed"] / dfa["dtime"],
        angle = lambda dfa: np.radians(dfa["weighted_grade"]
            ].fillna(0)),
        ptraction_1 = lambda dfa: dfa[mass_column]*dfa[
            "accel"]*dfa[speed_col]/1000,
        ptraction_2 = lambda dfa: dfa[mass_column]*g*np.sin(
            dfa["angle"])*dfa[speed_col]/1000,
        ptraction_3 = lambda dfa: 0.5*C_d*area*rho_air*(dfa[
            speed_col]**3)/1000,
        ptraction_4 = lambda dfa: dfa[mass_column]*g*np.cos(
            dfa["angle"].fillna(0))*C_r*dfa[speed_col]/1000,
        ptraction_total = lambda dfa: (dfa["ptraction_1"] +
            dfa["ptraction_2"]+ dfa["ptraction_3"]+ dfa[
            "ptraction_4"]),
        regen_coeff = lambda dfa: np.where(
            (dfa["ptraction_total"] < 0) & (dfa["accel"] <
            -0.001),
            np.exp(-alpha/dfa["accel"].abs()),
            0
        ),
        total_p = lambda dfa: np.where(
            dfa["ptraction_total"] > 0, (dfa[
                "ptraction_total"]),
            dfa["ptraction_total"]*dfa["regen_coeff"]
        ),
        dtime_hour = lambda dfa: dfa["dtime"]/3600,
        energy = lambda dfa: dfa["total_p"]*dfa["dtime_hour"]
    ),
)
return tours

def calculate_energy_linear(routes_geo, params):
    alpha = params[0]
    mass_column="current_truck_mass"
    speed_col="speed"
    tours = routes_geo.assign(
        dspeed = lambda dfa: dfa[speed_col].diff(),

```

```

accel = lambda dfa: dfa[ "dspeed "]/dfa[ "dtime "],
angle = lambda dfa: np.radians(dfa[ "weighted_grade "
].fillna(0)),
ptraction_1 = lambda dfa: dfa[ mass_column]*dfa[ "
accel "]*dfa[ speed_col]/1000,
ptraction_2 = lambda dfa: dfa[ mass_column]*g*np.sin(
    dfa[ "angle "])*dfa[ speed_col]/1000,
ptraction_3 = lambda dfa: 0.5*C_d*area*rho_air*(dfa[
    speed_col]**3)/1000,
ptraction_4 = lambda dfa: dfa[ mass_column]*g*np.cos(
    dfa[ "angle "].fillna(0))*C_r*dfa[ speed_col]/1000,
ptraction_total = lambda dfa: (dfa[ "ptraction_1 "] +
    dfa[ "ptraction_2 "]+ dfa[ "ptraction_3 "]+ dfa[ "
ptraction_4 "]),
regen_coeff = lambda dfa: np.where(
    (dfa[ "ptraction_total "] < 0) & (dfa[ "accel "] <
        -0.001),
    alpha ,
    0
),
total_p = lambda dfa: np.where(
    dfa[ "ptraction_total "] > 0, dfa[ "ptraction_total "
], dfa[ "ptraction_total "]*dfa[ "regen_coeff "]
),
dtime_hour = lambda dfa: dfa[ "dtime "]/3600,
energy = lambda dfa: dfa[ "total_p "]*dfa[ "dtime_hour "
],
)
return tours

def merge_with_validation(tours, validation):
    tours_agg = (
        tours.groupby([ "actual_id "], as_index=False)
        .agg(
            estimated_energy = ( "energy " , "sum" )
        )
        .merge(
            validation , on="actual_id " , how="left " , validate="
            1:1 "
        )
    )
    return tours

```

```
        )
        .assign(
            error = lambda dfa: (dfa[ "true_energy" ] - dfa[ "estimated_energy" ]) .abs() ,
            error_squared = lambda dfa: dfa[ "error" ]**2
        )
    )
return tours_agg

def goodness_of_fit_exponential(params):
    tours = calculate_energy_exponential(energy_train , params)
    tours_agg = merge_with_validation(tours ,
        validation_likelihood)
    return tours_agg[ "error_squared" ].mean()

def goodness_of_fit_linear(params):
    tours = calculate_energy_linear(energy_train , params)
    tours_agg = merge_with_validation(tours ,
        validation_likelihood)
    return tours_agg[ "error_squared" ].mean()

def get_regen_coeff(func , initial_value):
    result = minimize(func , [0.0411] ,
        bounds=[(0.01 , 1)] ,
        method='Nelder-Mead')

    return result .x
```

Apêndice B - Dados

Considerando a elevada volumetria dos dados de GPS, serão disponibilizados apenas os dados agregados por rota.

Dados de treino (com modelo físico microscópico) para ajuste da regressão linear.

Tabela 13: Dados de treino agregados - para regressão

Energia estimada pelo modelo físico sem regeneração	Nível de bateria (SOC)	Energia real (calculada via SOC) (kWh)	Energia estimada pelo modelo físico com regeneração exponencial (kWh)	Energia estimada pelo modelo físico com regeneração linear (kWh)
90.990448	0.570000	45.150000	69.617165	68.175051
69.699487	0.600000	42.000000	52.942439	51.843252
87.467255	0.320000	71.400000	56.715366	54.724233
101.692542	0.470000	55.650000	70.691476	69.217707
112.350404	0.316000	71.820000	78.561635	76.725962
68.691018	0.630000	38.850000	49.312012	47.434389
114.581391	0.310000	72.450000	82.256530	81.208110
48.157651	0.720000	29.400000	34.250257	33.472363
63.399954	0.650000	36.750000	47.264331	46.346092
79.903585	0.600000	42.000000	53.359693	51.875788
68.619888	0.600000	42.000000	51.424809	50.497886
67.862717	0.700000	31.500000	52.375845	51.740205
35.356172	0.780000	23.100000	21.901897	20.927740
100.412243	0.400000	63.000000	67.209030	66.049413
22.331680	0.750000	26.250000	13.240187	12.933529
84.318098	0.500000	52.500000	57.945535	56.646722
66.408653	0.630000	38.850000	51.261654	50.266559
91.962793	0.500000	52.500000	66.896698	65.347038

Continuado na próxima página

Tabela 13: Dados de treino agregados - para regressão (Continuado)

Energia estimada pelo modelo físico sem regeneração	Nível de bateria (SOC)	Energia real (calculada via SOC) (kWh)	Energia estimada pelo modelo físico com regeneração exponencial (kWh)	Energia estimada pelo modelo físico com regeneração linear (kWh)
61.375851	0.690000	32.550000	42.828607	42.185784
52.245147	0.720000	29.400000	35.906582	34.993003
105.972418	0.380000	65.100000	74.454042	72.905964
87.454302	0.600000	42.000000	68.398661	66.647056
92.154118	0.600000	42.000000	66.509849	64.368003
76.998761	0.600000	42.000000	54.071012	53.004583
97.560975	0.430000	59.850000	71.882499	70.429158
65.281302	0.600000	42.000000	48.441806	47.804028
74.903829	0.630000	38.850000	53.869433	53.136900
49.608749	0.670000	34.650000	34.623894	33.717910
62.331991	0.500000	52.500000	43.617518	42.694031
85.648366	0.500000	52.500000	59.553845	58.240725
84.029636	0.500000	52.500000	59.514740	58.337110
88.998874	0.500000	52.500000	64.023855	63.091733
84.747363	0.500000	52.500000	60.190688	58.910877
70.935281	0.570000	45.150000	51.658936	50.663580
78.837026	0.500000	52.500000	55.769074	54.369760
68.970990	0.570000	45.150000	46.230850	45.210111
94.027534	0.500000	52.500000	74.195559	73.140115
73.965469	0.530000	49.350000	55.461323	54.147302
94.997291	0.400000	63.000000	67.597807	66.184826
67.344466	0.530000	49.350000	43.803954	42.791552
77.402333	0.570000	45.150000	58.293345	57.224365
68.113148	0.530000	49.350000	44.206356	42.595089
97.660774	0.470000	55.650000	70.040664	68.625070

Continuado na próxima página

Tabela 13: Dados de treino agregados - para regressão (Continuado)

Energia estimada pelo modelo físico sem regeneração	Nível de bateria (SOC)	Energia real (calculada via SOC) (kWh)	Energia estimada pelo modelo físico com regeneração exponencial (kWh)	Energia estimada pelo modelo físico com regeneração linear (kWh)
53.492070	0.630000	38.850000	39.983163	39.267503
116.447813	0.400000	63.000000	85.663284	84.092077
88.590557	0.570000	45.150000	66.370840	65.340408
74.768757	0.560000	46.200000	47.777390	46.240972
90.305701	0.500000	52.500000	67.998786	66.953273
77.082374	0.530000	49.350000	54.018175	52.830063
44.798016	0.750000	26.250000	33.782816	33.436204
92.689841	0.500000	52.500000	67.461478	65.995517
78.210316	0.600000	42.000000	55.543904	54.221127
68.911326	0.600000	42.000000	46.118055	45.264396
72.870175	0.630000	38.850000	57.154124	56.204279
81.541570	0.500000	52.500000	61.283221	60.620697
79.772936	0.570000	45.150000	63.159297	61.590767
95.985239	0.400000	63.000000	64.645253	62.813626
34.859723	0.750000	26.250000	24.595124	24.203567
97.682462	0.350000	68.250000	66.904963	65.289588
79.846616	0.560000	46.200000	56.674796	55.038060
97.613596	0.500000	52.500000	70.800239	69.718468
86.318911	0.350000	68.250000	60.186404	58.533846

E, por fim, dados de teste para validação dos modelos:

Tabela 14: Dados de teste - para cálculo de erros

Nível de bateria (SOC)	Energia real (calculada via SOC) (kWh)	Energia estimada pelo modelo físico-estatístico sem regeneração (kWh)	Energia estimada pelo modelo físico-estatístico com regeneração linear (kWh)	Energia estimada pelo modelo físico-estatístico com regeneração exponencial (kWh)
0.590000	43.050000	37.834208	44.121310	44.317317
0.400000	63.000000	44.751133	51.082866	51.238533
0.570000	45.150000	40.435382	47.551830	47.412222
0.180000	86.100000	52.107866	58.063440	58.519032
0.570000	45.150000	44.985096	52.380181	52.518125
0.380000	65.100000	47.028900	52.055536	52.325651
0.400000	63.000000	62.630398	73.079586	73.103801
0.380000	65.100000	42.967770	49.958850	50.191960
0.560000	46.200000	48.266232	56.272801	56.607048
0.430000	59.850000	47.688743	55.350872	55.250046
0.610000	40.950000	30.310870	37.371861	37.251651
0.440000	58.800000	45.714854	54.980954	54.580863
0.500000	52.500000	48.879226	58.757631	58.512298
0.500000	52.500000	44.533931	50.579530	50.904110
0.630000	38.850000	37.862323	45.448929	45.432412
0.500000	52.500000	41.675161	47.835292	47.937041