



PUC
CAMPINAS
PONTIFÍCIA UNIVERSIDADE CATÓLICA

**Pontifícia Universidade Católica de
Campinas**

Programa de Pós-Graduação em Gestão de
Redes de Telecomunicações

EULER BRUNO PEREIRA DOS SANTOS

**COORDENAÇÃO DO CARREGAMENTO DE VEÍCULOS
ELÉTRICOS UTILIZANDO HEURÍSTICA E
META-HEURÍSTICA**

CAMPINAS
2023

EULER BRUNO PEREIRA DOS SANTOS

**COORDENAÇÃO DO CARREGAMENTO DE VEÍCULOS
ELÉTRICOS UTILIZANDO HEURÍSTICA E META-HEURÍSTICA**

Dissertação apresentada ao Programa de Pós-Graduação em Gestão de Redes de Telecomunicações da Escola Politécnica da Pontifícia Universidade Católica de Campinas como parte dos requisitos para a obtenção do título de Mestre em Gestão de Redes de Telecomunicações.

Orientador: Prof. Dr. Carlos Alberto de Castro Junior

Este exemplar corresponde à versão final da Dissertação defendida por EULER BRUNO PEREIRA DOS SANTOS e orientada pelo Prof. Dr. Carlos Alberto de Castro Junior.

CAMPINAS
2023

Ficha catalográfica elaborada por Fabiana Rizziolli Pires CRB 8/6920
Sistema de Bibliotecas e Informação - SBI - PUC-Campinas

629.2293 Santos, Euler Bruno Pereira dos
S237c

Coordenação do carregamento de veículos elétricos utilizando heurística e meta-
heurística / Euler Bruno Pereira dos Santos. - Campinas: PUC-Campinas, 2023.

43 f.: il.

Orientador: Carlos Alberto de Castro Junior.

Dissertação (Mestrado em Gestão de Redes de Telecomunicações) - Programa de
Pós-Graduação em Gestão de Redes de Telecomunicações, Escola Politécnica,
Pontifícia Universidade Católica de Campinas, Campinas, 2023.

Inclui bibliografia.

1. Veículos elétricos. 2. Sistemas de energia elétrica. 3. Heurística. I. Castro
Junior, Carlos Alberto de. II. Pontifícia Universidade Católica de Campinas. Escola
Politécnica. Programa de Pós-Graduação em Gestão de Redes de Telecomunicações.
III. Título.

23. ed. CDD 629.2293

EULER BRUNO PEREIRA DOS SANTOS


**COORDENAÇÃO DO CARREGAMENTO DE VEÍCULOS
ELÉTRICOS UTILIZANDO HEURÍSTICA E META-
HEURÍSTICA**

Dissertação apresentada como exigência para obtenção do título de Mestre em Gestão de Redes de Telecomunicações ao Programa de Pós-Graduação em Gestão de Redes de Telecomunicações da Escola Politécnica.


Área de Concentração: Gestão de Redes e Serviços.

Orientador (a): Prof. Dr. Carlos Alberto de Castro Junior.


Dissertação defendida e aprovada em 30 de junho de 2023 pela Comissão Examinadora constituída dos seguintes professores:



Prof. Dr. Carlos Alberto de Castro Junior
Orientador da Dissertação e Presidente da Comissão Examinadora
Pontifícia Universidade Católica de Campinas



Profa. Dra. Marina Lavorato de Oliveira
Pontifícia Universidade Católica de Campinas



Prof. Dr. Tiago de Moraes Barbosa
Universidade Estadual de Campinas - UNICAMP

Agradecimentos

Agradeço ao meu orientador pelos valiosos conselhos, à minha esposa Adielly pelo grande apoio e à reitoria da PUC-Campinas pela bolsa de 50% para a realização de mestrado.

Resumo

O mercado automotivo está se movendo rapidamente em direção aos veículos elétricos (VEs). As mudanças no sentimento do consumidor, nas políticas, regulamentações e outros fatores estão impulsionando a aceitação dos usuários e, por fim, o crescimento das vendas de veículos elétricos. As barreiras existentes para a expansão das vendas de veículos elétricos tendem a desaparecer com o tempo e a expectativa é que até 2030, os veículos elétricos representem 32% das vendas de carros novos globalmente. As participações regionais, no entanto, devem variar muito de acordo com o país, e um dos motivos que restringirá a adoção mais ampla de VEs é a infraestrutura de carregamento insuficiente ou inadequada. A demanda adicional de eletricidade e a imprevisibilidade do comportamento dos proprietários de VEs, poderão resultar em um impacto significativo nos sistemas de distribuição de energia elétrica e podem resultar em instabilidades e falhas. Este trabalho propõe soluções baseadas na meta-heurística Teaching-Learning-Based Optimization (TLBO), e em uma heurística especializada para coordenar o carregamento de um grupo de veículos elétricos. Os métodos propostos buscam entregar o máximo de energia possível às baterias dos veículos sem violar as restrições e os limites do sistema elétrico. A meta-heurística TLBO é um algoritmo eficiente, que demanda poucos parâmetros de ajuste e não depende de dados históricos para obter uma resposta ótima para uma tomada de decisão. A heurística especializada faz uso das características específicas do problema para obter uma solução de qualidade. Serão apresentados os resultados de simulações, utilizando a heurística e o TLBO, com as devidas comparações de desempenho.

Palavras-chave: Otimização; Recarga de Veículos Elétricos; Gerenciamento; Sistemas de Energia Elétrica; TLBO; Heurística.

Abstract

The automotive market is moving fast towards electric vehicles (EV). Changes in consumer sentiment, policies, regulations, and other factors are driving the user's acceptance and ultimately the growth of EV sales. The existing barriers to the expansion of EV sales tend to disappear over time and the expectation is that by 2030, EVs will represent 32 percent of the new car sales globally. Regional shares, however, are expected to vary widely according to country, and one of the reasons that will restrain broader adoption of EV is the insufficient or unsuitable charging infrastructure. The additional electricity demand and the unpredictability of EV owners' behavior will make a significant impact on the electricity distribution systems and may result in instabilities and failures. This work proposes solutions based on the Teaching-Learning-Based Optimization (TLBO) meta-heuristic, and on specialized heuristics to coordinate the charging of a group of electric vehicles. The proposed methods seek to deliver as much energy as possible to vehicle batteries without violating the constraints and limits of the electrical system. The TLBO meta-heuristic is an efficient algorithm that requires few tuning parameters and does not depend on historical data to obtain an optimal solution for the problem. On the other hand, the specialized heuristic makes use of the specific characteristics of the problem to obtain a good solution. Simulation results will be presented using heuristics and TLBO, along with performance comparisons.

Keywords: Optimization; EV charging; Coordination; Electrical Systems; TLBO; Heuristics

Lista de Figuras

1.1	Previsão da fatia de mercado de VEs por região.	12
1.2	Demanda de eletricidade residencial com 10% e 50% de PEVs.	13
3.1	Ilustração do problema. Fonte: o autor	17
3.2	Distribuição das notas obtidas pelos estudantes nas turmas dos professores P_1 e P_2 . Adaptado de (RAO; SAVSANI; VAKHARIA, 2012)	25
3.3	Modelo de distribuição para as notas obtidas de um grupo de estudantes. Adaptado de (RAO; SAVSANI; VAKHARIA, 2012)	25
3.4	Fluxograma do TLBO	27
4.1	Evolução do SOC(%) dos veículos: Caso 1	29
4.2	Evolução do SOC(%) dos veículos: cenário com limitação de potência disponível e de capacidade de carga das baterias	30
4.3	Evolução do carregamento no TLBO Sequencial (Modelo 1)	31
4.4	Evolução do carregamento no TLBO Sequencial (Modelo 2)	32
4.5	Evolução do carregamento no TLBO Simultâneo (Modelo 1)	32
4.6	Evolução do carregamento no TLBO Simultâneo (Modelo 2)	32
4.8	Evolução do carregamento no TLBO Sequencial (Modelo 1)	32
4.7	Evolução do carregamento na Heurística	33
4.9	Evolução do carregamento no TLBO Sequencial (Modelo 2)	34
4.10	Evolução do carregamento no TLBO Simultâneo (Modelo 1)	35
4.11	Evolução do carregamento no TLBO Simultâneo (Modelo 2)	35
4.12	Evolução do carregamento na Heurística	36

Lista de Tabelas

4.1	Caso 1: Cenário de testes	29
4.2	Configuração do Caso 2	31
4.3	Configuração do Caso 3	34
4.4	Tempo de cálculo [s]	36
4.5	Número de iterações para a convergência	37
4.6	Notas do caso 2	39
4.7	Notas do caso 3	39

Sumário

1	Introdução	11
1.1	Motivação	11
1.2	Objetivos	13
2	Revisão Bibliográfica	14
3	Metodologia	16
3.1	Descrição do Problema	16
3.2	Modelos matemáticos	17
3.2.1	Modelo 1	17
3.2.2	Modelo 2	19
3.3	Soluções propostas	20
3.3.1	TLBO Simultâneo	21
3.3.2	TLBO Sequencial	21
3.3.3	Heurística	21
3.4	Teaching-Learning-Based Optimization (TLBO)	24
3.4.1	Etapa do Professor	26
3.4.2	Etapa dos Estudantes	26
4	Resultados das simulações	28
4.1	Condições de simulação	28
4.2	Caso 1	28
4.3	Caso 2	30
4.3.1	Descrição do caso	30
4.4	Caso 3	31
4.4.1	Descrição do caso	31
4.5	Discussão dos resultados	37
4.5.1	Critérios de comparação	37
4.5.2	Avaliação dos resultados	39
5	Considerações finais	41

Capítulo 1

Introdução

Os veículos elétricos (VE) passaram a ser produzidos em massa nos últimos anos, impulsionados principalmente por incentivos governamentais e regulamentações que visam à redução das emissões de poluentes e de gases de efeito estufa. Em 2019, a venda de veículos elétricos representou cerca de 3% do mercado mundial e deve alcançar uma fatia de 32% em 2030 (INSIGHTS, 2020). O usuário que trocar o seu veículo a combustão por um elétrico deixará de abastecer nos postos de combustíveis e passará a abastecer seu novo veículo elétrico em eletropostos dedicados, estacionamentos, shoppings e principalmente, na sua residência.

A demanda de energia referente ao carregamento dos veículos elétricos mudará aspectos de planejamento e operação das redes elétricas. Será necessário adotar mecanismos que atuem na proteção das redes elétricas e no controle dos custos de energia sem impor restrições de fornecimento de energia elétrica aos consumidores.

O cenário de controle de consumo torna-se ainda mais desafiador nas regiões de maior concentração de veículos elétricos. Por exemplo, a expectativa de participação de veículos elétricos nas vendas de automóveis em 2030 na China está próxima de 50%, seguida da Europa com mais de 40%, conforme mostra a Figura 1.1.


1.1 Motivação

Com as vendas de veículos elétricos podendo atingir até 50% do número de veículos vendidos em alguns mercados, é questão de tempo para que algumas regiões alcancem grandes concentrações de veículos elétricos. Em (SUN et al., 2021) os autores avaliaram dados reais de mais de 76 mil VEs viajando por um mês na cidade de Beijing e observaram que a maioria dos usuários carrega os seus veículos durante a noite. Os usuários que estão em trânsito durante o dia, carregam seus veículos em estacionamentos e estações de recarga e tendem a procurar uma estação de recarga quando o estado de carga das baterias está entre 20% e 90%.

O carregamento de veículos elétricos sem uma coordenação adequada pode influenciar significativamente a operação da rede elétrica, aumentando as perdas de potência e impactando a qualidade da energia fornecida. Segundo (CLEMENT-NYNS; HAESSEN; DRIESEN, 2009), as perdas podem atingir 6% e a queda de tensão 10,3% em um ambiente com penetração de 30% de veículos elétricos utilizando carregadores de 4 kW, principalmente nos período entre 18h e 21h.

Figura 1.1: Previsão da fatia de mercado de VEs por região.

Participação dos VEs nas vendas de automóveis por região



Adaptado de (WOODWARD et al., 2020).

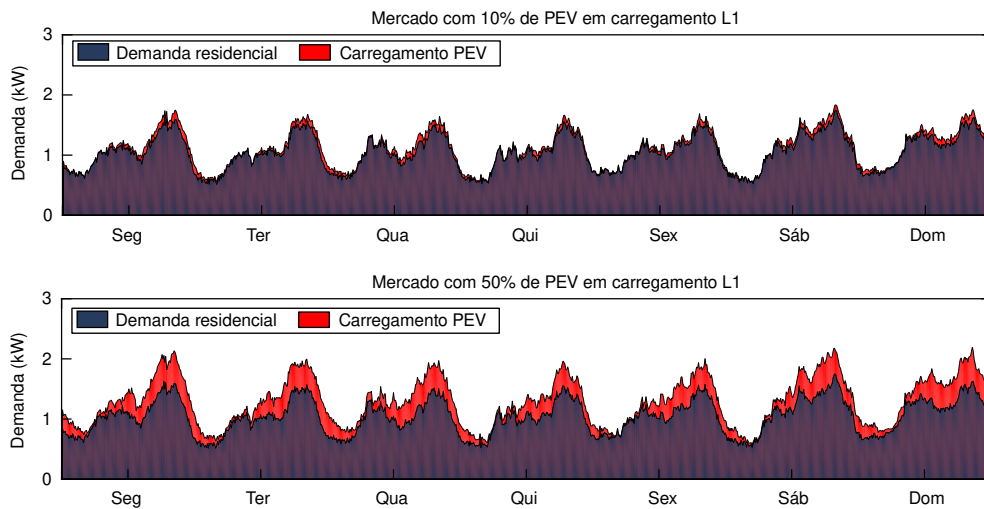
Em (MURATORI, 2018), mostra-se que o impacto dos VEs no consumo total das residências é limitado, porém, os picos de demanda provocados por eles são consideráveis. A presença de apenas um veículo elétrico em carregamento nível 2 (6,6 kW) já seria capaz de fazer o transformador de uma região residencial trabalhar cerca de 15% acima de sua capacidade nominal por uma hora, reduzindo sua vida útil. Ao considerar uma concentração de 50% de veículos elétricos, observou-se um aumento significativo nos picos de consumo e um potencial deslocamento do perfil de consumo de energia, amplificando a criticidade dos horários de pico. É possível observar este efeito na Figura 1.2, que ilustra a demanda residencial e a demanda extra causada pelos VEs.

Muitas redes elétricas não estão preparadas para esta demanda adicional. Em (VERZIJB- BERGH et al., 2012) foi apresentado um estudo que investigou os impactos do carregamento dos veículos elétricos nas redes de distribuição, considerando várias redes na Holanda. Os autores observaram que o carregamento não controlado dos veículos elétricos aumenta a sobrecarga nos equipamentos que compõem a rede elétrica. Essa sobrecarga reduz a vida útil desses equipamentos de forma significativa e nas estimativas econômicas foi considerada a substituição antecipada dos equipamentos e a perda de energia, e apresentam uma diferença de 20% de perda de energia entre os cenários com carregamento controlado e não controlado.

A sobrecarga reduz a vida útil e resulta na troca de diversos equipamentos antes do fim da vida útil planejada. Nos cenários de carregamento sem nenhum tipo de controle foi identificada a necessidade de trocar os equipamentos de rede com frequência duas vezes maior que nos cenários de carregamento controlado. A análise econômica identificou que o cenário de carregamento controlado representa uma economia em valor presente líquido de 20% quando comparado com o cenário de carregamento não controlado.

O efeito do carregamento dos veículos elétricos nas redes elétricas e no perfil de consumo não pode ser ignorado. A ausência de planejamento e controle tanto do lado de fornecimento

Figura 1.2: Demanda de eletricidade residencial com 10% e 50% de PEVs.



Adaptado de (MURATORI, 2018)

quando do lado da demanda pode resultar em problemas graves na infraestrutura de energia elétrica e para a economia dependente de mobilidade com base em veículos elétricos plug-in.

De forma a contribuir para o preenchimento de lacunas no conhecimento e os desafios que a popularização dos veículos elétricos têm apresentado, este trabalho apresenta métodos para organizar e coordenar o carregamento de veículos elétricos de forma a atender aos objetivos dos usuários, preservando as condições de operação das redes elétricas e a vida útil dos equipamentos de distribuição.

1.2 Objetivos

O objetivo deste trabalho é implementar e avaliar soluções para a coordenação do carregamento dos veículos elétricos de forma otimizada para atender às necessidades de energia dos veículos sem gerar sobrecarga nos equipamentos da rede elétrica. Os objetivos específicos deste trabalho são:

- Revisar a bibliografia que aborda este tema de pesquisa,
- Desenvolver uma solução com a meta-heurística TLBO que atenda da melhor forma possível aos níveis de carregamento dos VEs sem ultrapassar os limites operacionais dos equipamentos da rede elétrica,
- Desenvolver uma solução heurística que controle o carregamento e comparar com o TLBO (Teaching-Learning-Based Optimization).
- Aplicar as soluções propostas em situações que apresentem desafios para carregar os veículos.

Capítulo 2

Revisão Bibliográfica

Em (CLEMENT-NYNS; HAESSEN; DRIESEN, 2009) os autores avaliaram o impacto dos veículos elétricos plug-in (PHEV) na rede de distribuição residencial e verificaram que o carregamento dos veículos sem uma coordenação adequada leva a problemas na rede elétrica em uma escala local, como perdas de potência, e influencia também características de qualidade de energia, como o perfil de tensão, o desbalanceamento de cargas e as componentes harmônicas. Os autores verificaram que uma rede com 30% das residências com veículos elétricos conectados já seria capaz de, em alguns cenários, provocar desvios de tensão de mais de 10% na rede elétrica. Os autores sugerem o uso de medidores inteligentes para aplicar o controle de carga aos veículos, e aumento nas capacidades dos transformadores e condutores para suportar a demanda adicional imposta pelos veículos. Os autores aplicaram programação determinística e estocástica e minimizaram as perdas no carregamento, porém, assumiram baterias de apenas 11 kWh de capacidade e carregadores de 4 kW.

Em (ALAHYARI; POZO; SADRI, 2020) foi proposta uma solução que visa diminuir os custos de energia elétrica de estacionamentos que oferecem o serviço de carregamento de veículos elétricos. No problema avaliado, o custo da energia elétrica é variável e o operador precisa decidir a quantidade de energia que irá comprar no início de cada período de cinco minutos sem conhecer o preço que será cobrado. Os autores desenvolveram uma solução de aprendizado de máquina cuja função é determinar a quantidade de energia a ser comprada a partir de uma pequena quantidade de dados históricos.

Em (SÁ; PEREIRA; FRANCO, 2020) foram implementados e comparados um modelo de programação cônica de segunda ordem, um modelo linear e o carregamento sem controle ao processo de carregamento dos veículos elétricos conectados a uma rede elétrica de teste de 32 barras e em um sistema de distribuição real de 136 barras. Os modelos foram aplicados com o objetivo de minimizar a quantidade de energia não fornecida e o tempo de carregamento dos veículos. Os autores identificaram que quando operam sem o gerenciamento do carregamento, ambos os sistemas experimentam violações de seus limites operacionais de tensão e corrente. Quando o gerenciamento de carregamento foi aplicado, todos os veículos atingiram a carga completa com tempo maior, porém, nenhum limite do sistema foi ultrapassado.

Em (SHIBL; ISMAIL; MASSOUD, 2020) foi considerado o histórico de uso de cada veículo para tentar estimar o horário de saída do veículo e determinar o tipo de carregamento, se rápido, normal ou mesmo se o veículo fornecerá energia à rede elétrica. Os autores aplicaram algumas técnicas de aprendizado de máquina e classificação para resolver o problema e

compararam os seus resultados. Os autores encontraram que o modelo desenvolvido em Redes Neurais Recorrentes de Memória de Longo Prazo (Long short-term memory, LSTM) obteve o melhor resultado, prevendo a melhor distribuição de potência corretamente em 95% dos casos, com taxa de erro de $\pm 0.71\%$. Contrariando a expectativa dos autores, o modelo desenvolvido em Redes Neurais Artificiais Profundas (Deep Neural Networks, DNN) não apresentou boa precisão nos resultados, prevendo corretamente a distribuição de potência em 88.2% dos casos, com uma taxa de erro de $\pm 20.2\%$.

Em (TUCHNITZ et al., 2021) os autores propõem um modelo de coordenação de carregamento de veículos elétricos com a aplicação de aprendizado reforçado para simular o carregamento de 50 veículos elétricos em uma região com 250 residências. O modelo proposto pelos autores prepara uma agenda de carregamento dos veículos ao longo do tempo disponível e desconsidera o horário de chegada e saída dos veículos. Os autores observaram que no cenário proposto não houve eventos em que a demanda de energia excedeu o limite permitido ao longo dos dias simulados e a variância total da carga da região diminuiu 65% em comparação com um cenário sem coordenação.

Em (VERZIILBERGH et al., 2012) os autores avaliaram os impactos do carregamento residencial de veículos elétricos em redes de distribuição na Holanda. Os autores consideraram diversos perfis de carregamento de EVs para entender os impactos em diversos níveis das redes de distribuição e encontraram que os cenários de carregamento sem controle levam a até duas vezes mais substituições de equipamentos em comparação com um cenário de carregamento controlado e sugerem a implementação de uma rede de distribuição inteligente para acomodar grandes penetrações de veículos elétricos.

Em (LOPEZ, 2019) a autora apresentou um modelo de programação dinâmica para decidir se o veículo deve ser carregado ou não a partir da consideração do preço da eletricidade, do SOC das baterias e de uma viagem pré-determinada. No modelo, a autora considera os preços como fatores relevantes para a decisão de recarga e o modelo propõe um cronograma de carregamento como forma de minimizar os custos com carregamento e compara com os custos de operação com veículos apenas a combustão. A autora conclui que do ponto de vista de custo de energia, o carregamento não controlado é a pior estratégia, resultando em custos maiores do que uma operação apenas com veículos a combustão interna.

Capítulo 3

Metodologia

3.1 Descrição do Problema

Para o entendimento e a delimitação do problema, este trabalho considera que uma determinada quantidade de veículos elétricos é conectada a uma estação de recarga. A Figura 3.1 representa o modelo considerado. Nele, a estação de recarga é alimentada por um transformador de distribuição que, por sua vez está conectado à rede de distribuição. Assume-se que existe um dispositivo de medição conectado à rede de distribuição que envia as informações sobre a demanda de energia da estação de recarga e nível de carga disponível às estações de recarga.

O problema do gerenciamento da recarga de veículos elétricos surge quando a rede elétrica que alimenta os carregadores de um posto de recarga possui restrições para o atendimento de todos os carregadores simultaneamente em capacidade máxima. Esta restrição pode ser a capacidade de operação da rede elétrica ou uma limitação de demanda estabelecida pelo operador da estação de recarga. A violação dessa restrição ou limite pode de forma direta oferecer risco à integridade e à vida útil dos equipamentos da rede elétrica. De forma indireta, a unidade consumidora pode incorrer em elevados custos de operação devido ao consumo de energia elevado em horários de pico e até mesmo em sanções do fornecedor de energia elétrica se exceder a demanda contratada.

Por outro lado, assume-se que o usuário que conecta o veículo à estação tem a expectativa que o veículo será carregado. Assim, os interesses do usuário final conflitam com as limitações de rede e equipamentos. Dessa forma, surge a oportunidade de aplicar um sistema de gerenciamento inteligente que atenda às expectativas do usuário e proteja os equipamentos e os interesses do operador da estação de recarga.

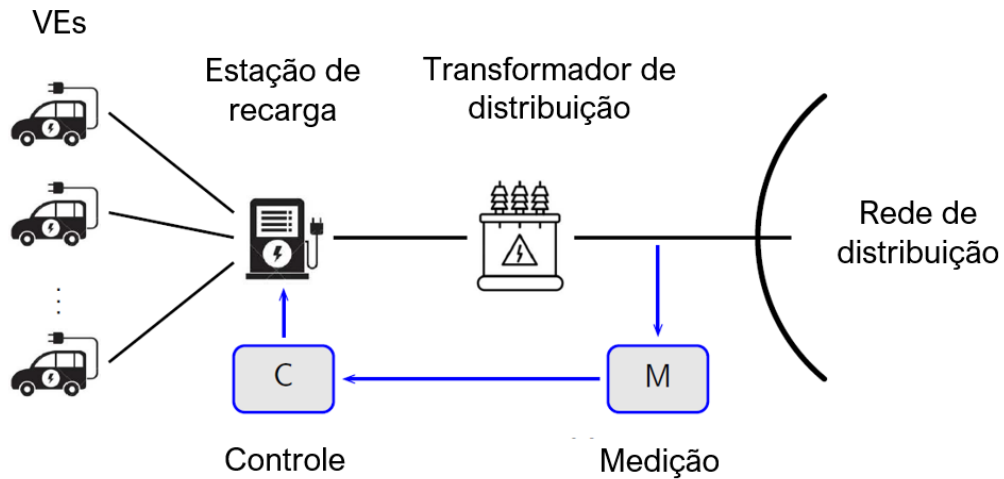


Figura 3.1: Ilustração do problema. Fonte: o autor

3.2 Modelos matemáticos

Para representar o problema descrito na Seção 3.1, neste trabalho foram desenvolvidos dois modelos matemáticos, que serão descritos em detalhe a seguir.

3.2.1 Modelo 1

O Modelo 1 é dado por:

$$\min_P P = \sum_{v=1}^{NV} [SOC_v^{max} - SOC_{v,T}]^2 - \sum_{t=1}^T \sum_{v=1}^{NV} x_{v,t} \cdot 2^{(T-t)} \quad (3.1)$$

sujeito a:

$$P_{d,t} \geq \sum_{v=1}^{NV} P_v \cdot x_{v,t}, \quad t = 1, \dots, T \quad (3.2)$$

$$SOC_{v,t} = SOC_v^0 + \eta \cdot \Delta t \cdot P_v \cdot x_{v,t}, \quad v = 1, \dots, NV, \quad t = 1 \quad (3.3)$$

$$SOC_{v,t} = SOC_{v,(t-1)} + \eta \cdot \Delta t \cdot P_v \cdot x_{v,t} - \beta \cdot SOC_{v,(t-1)}, \quad (3.4)$$

$$v = 1, \dots, NV, \quad t = 2, \dots, T$$

$$SOC_{v,(t-1)} \leq SOC_{v,t} \leq SOC_v^{max}, \quad v = 1, \dots, NV \quad (3.5)$$

$$0 \leq x_{v,t} \leq 1 \quad (3.6)$$

onde: t	=	período de tempo
T	=	número de períodos de tempo
NV	=	número de veículos elétricos
SOC_v^{max}	=	estado de carga máximo do veículo v / capacidade total da bateria
$SOC_{v,T}$	=	estado de carga do veículo v no último período T
P_v	=	potência de carregamento do veículo elétrico v
$x_{v,t}$	=	parcela da potência P_v do veículo elétrico v entregue no período t
$P_{d,t}$	=	potência disponível da instalação no período t
SOC_v^0	=	estado de carga inicial do veículo v
η	=	eficiência de carregamento da bateria do veículo elétrico
Δt	=	duração do período t
β	=	taxa de autodescarga da bateria do veículo elétrico

Este modelo é inspirado no trabalho desenvolvido em (SÁ; PEREIRA; FRANCO, 2020), e sua função objetivo busca garantir o máximo carregamento das baterias após o último período de um intervalo de tempo predefinido. Além disso, o segundo termo da função objetivo busca a priorização do carregamento nos primeiros períodos de tempo para garantir um carregamento mais rápido.

A Equação 3.1 representa a função objetivo do Modelo 1, que tem dois termos. O primeiro faz com que o modelo procure carregar os veículos o máximo possível. O segundo termo visa fazer com que os veículos recebam a maior quantidade de carga possível nos períodos iniciais do carregamento, evitando assim que seja considerada a situação onde o veículo é carregado mas não recebe quantidade relevante de carga por um longo período de tempo.

A Equação 3.2 é uma restrição que tem a função de limitar a potência entregue aos veículos respeitando o limite máximo de potência disponível para a instalação. Esta restrição garante que os transformadores e equipamentos da rede elétrica trabalharão dentro dos seus respectivos limites de operação.

A Equação 3.3 impõe que o estado de carga das baterias SOC_v ao final do período t seja o estado de carga inicial mais a parcela de carga adquirida durante o carregamento, levando em conta a eficiência de carregamento das baterias. Esta restrição é válida para o primeiro período de carregamento.

A Equação 3.4, de forma semelhante à Equação 3.3, impõe que o estado de carga das baterias ao final do período t seja o estado de carga no instante $t - 1$, anterior ao instante atual, mais a parcela de carga adquirida desde o início do carregamento, descontada de uma taxa de autodescarga β , que representa o quanto a bateria do veículo elétrico consome e perde internamente da energia a ela entregue. Esta restrição é válida para todos os períodos de tempo exceto o primeiro.

A expressão 3.5 impõe que ao final do período t o estado de carga das baterias SOC_v seja

maior ou igual ao SOC_v do período anterior e menor ou igual ao SOC_v máximo do veículo.

A expressão 3.6 impõe que a parcela $x_{v,t}$ da potência de carregamento P_d esteja entre 0 e 1, inclusive, porque ela representa a fração de potência disponível em cada instante entregue a cada veículo e, portanto, não pode ser menor que zero ou maior que um.

O modelo apresentado em (SÁ; PEREIRA; FRANCO, 2020) inclui em suas restrições o modelo mais preciso da rede, enquanto que o modelo desenvolvido neste trabalho apenas inclui o parâmetro P_d , que representa a disponibilidade da rede (do transformador que alimenta o posto de recarga) para cada período de tempo.

Embora o modelo deste trabalho seja mais simples, representa uma situação prática de maior relevância ou utilizada do ponto de vista do posto de recarga, em outras palavras, a coordenação de carregamento deve levar em conta a potência disponível para realizar o carregamento sem provocar oscilações na rede.

Já o modelo de (SÁ; PEREIRA; FRANCO, 2020) pode ser útil do ponto de vista da empresa distribuidora de energia elétrica, pois, ao ser aplicado a caso mais desafiadores, como por exemplo, situações em que há vários veículos com pouca carga solicitando carregamento, poderá indicar limitações da rede, que poderão ser resolvidas com, por exemplo, reforços na rede, troca de transformadores etc.

3.2.2 Modelo 2

Este modelo difere do Modelo 1 somente com relação à função objetivo, tendo portanto as mesmas restrições. A função objetivo possui algumas modificações em relação a 3.1 para que seja feita a busca de soluções que forneçam a maior carga possível às baterias dos veículos desde o primeiro período de tempo.

$$\min_P P = \sum_{v=1}^{NV} \sum_{t=1}^T [SOC_v^{max} - SOC_{v,t}]^2 \quad (3.7)$$

sujeito a:

$$P_{d,t} \geq \sum_{v=1}^{NV} P_v \cdot x_{v,t}, \quad t = 1, \dots, T \quad (3.8)$$

$$SOC_{v,t} = SOC_v^0 + \eta \cdot \Delta t \cdot P_v \cdot x_{v,t}, \quad v = 1, \dots, NV, \quad t = 1 \quad (3.9)$$

$$SOC_{v,t} = SOC_{v,(t-1)} + \eta \cdot \Delta t \cdot P_v \cdot x_{v,t} - \beta \cdot SOC_{v,(t-1)}, \quad (3.10)$$

$$v = 1, \dots, NV, \quad t = 2, \dots, T$$

$$SOC_{v,(t-1)} \leq SOC_{v,t} \leq SOC_v^{max}, \quad v = 1, \dots, NV \quad (3.11)$$

$$0 \leq x_{v,t} \leq 1 \quad (3.12)$$

onde: t	=	período de tempo
T	=	número de períodos de tempo
NV	=	número de veículos elétricos
SOC_v^{max}	=	estado de carga máximo do veículo v / capacidade total da bateria
$SOC_{v,T}$	=	estado de carga do veículo v no último período T
P_v	=	potência de carregamento do veículo elétrico v
$x_{v,t}$	=	parcela da potência P_v do veículo elétrico v entregue no período t
$P_{d,t}$	=	potência disponível da instalação no período t
SOC_v^0	=	estado de carga inicial do veículo v
η	=	eficiência de carregamento da bateria do veículo elétrico
Δt	=	duração do período t
β	=	taxa de autodescarga da bateria do veículo elétrico

A Equação 3.7 representa a função objetivo do Modelo 2. Neste modelo, a função objetivo busca soluções que transfiram a maior quantidade de energia às baterias desde o primeiro período de tempo. A Equação 3.7 é mais concisa e elegante que a Equação 3.1 em sua representação porque é composta de um único termo, o que facilita a leitura e entendimento.

As restrições 3.8 a 3.12 são idênticas a 3.2 a 3.6 tendo, portanto, os mesmos significados já descritos.

3.3 Soluções propostas

Para resolver os modelos propostos na Seção 3.2, serão apresentadas três abordagens para o gerenciamento da recarga de veículos elétricos. A primeira abordagem está descrita na seção 3.3.1. Nela, o algoritmo baseado na meta-heurística Teaching-Learning-Based Optimization (TLBO) resolve o modelo e calcula todas as soluções de uma única vez para todos os intervalos de tempo que compõem o período de carregamento. A segunda abordagem está descrita na seção 3.3.2 e resolve os modelos também utilizando o TLBO, calculando porém as soluções de forma sequencial, para cada período de tempo. Por fim, foi desenvolvida uma heurística que calcula a solução de forma sequencial, semelhante ao Modelo 2.

O algoritmo TLBO, detalhado na seção 3.4 é fundamentado nas interações em sala de aula entre aluno-professor e aluno-aluno. Este algoritmo mimetiza as condições de aprendizado em sala de aula em busca de melhorar os resultados e alcançar um valor ótimo para um problema de otimização. As soluções propostas foram aplicadas em diversos cenários que visaram validar os algoritmos desenvolvidos e emular alguns casos de uso desafiadores para a gestão do carregamento. A heurística é baseada no conhecimento específico do problema a ser resolvido, utilizando regras particulares para a coordenação do carregamento das baterias dos veículos elétricos.

3.3.1 TLBO Simultâneo

Nesta proposta, o algoritmo TLBO calcula de uma única vez, a solução para todos os intervalos de tempo. Cada elemento da população gerada pelo algoritmo contém as parcelas de carregamento para todos os veículos em todos períodos de tempo considerados. Ou seja, o algoritmo é executado uma única vez e fornece os valores ótimos para $(NV \cdot T)$ variáveis de decisão. Esta proposta foi aplicada para os Modelos 1 e 2, descritos nas Seções 3.2.1 e 3.2.2, respectivamente.

3.3.2 TLBO Sequencial

Nesta proposta o algoritmo calcula uma solução para todos os veículos a cada período de tempo. Na primeira iteração o algoritmo calcula as soluções para os veículos no instante $t = 1$, na segunda iteração depois calcula as soluções para $t = 2$ e assim sucessivamente até calcular a última solução para $t = T$. Ou seja, neste caso o algoritmo é executado T vezes e, em cada execução, fornece os valores ótimos de NV variáveis de decisão. Esta proposta foi aplicada para os Modelos 1 e 2, descritos nas Seções 3.2.1 e 3.2.2, respectivamente.

3.3.3 Heurística

As funções heurísticas são métodos para resolver problemas que produzem boas soluções de forma mais rápida que outros métodos. A agilidade da heurística, porém, é normalmente obtida ao custo de normalmente não oferecer a melhor solução possível, a mais precisa ou a mais completa. No entanto as soluções oferecidas pelas heurísticas, em geral, são próximas o bastante das soluções ótimas como descrito por (PATNAIK; ADRIAN, 2022).

A heurística proposta neste trabalho se baseia no conhecimento específico do processo de carregamento de veículos elétricos, e leva em conta o mesmo objetivo do Modelo 2 (3.2.2), ou seja, o de carregar o máximo possível as baterias dos veículos conectados, e no menor tempo possível. De forma similar ao TLBO Sequencial (3.3.2), esta heurística calcula a cada período de tempo uma solução para cada veículo, começando em $t = 1$ até atingir o tempo final T . Esta proposta representa a mesma aplicação do Modelo 2 (3.7).

Para resolver o problema descrito na Seção 3.1, no desenvolvimento da heurística, foram considerados os seguintes princípios:

- Estabelecer porcentagens de carregamento das baterias proporcionais às suas necessidades de carregamento.
- Fornecer a máxima potência possível às baterias dos veículos, desde que permitida pelo transformador que alimenta a estação de recarga.
- Limitar a potência entregue a cada bateria a seu respectivo limite. Eventuais sobras de potência são distribuídas proporcionalmente entre as demais baterias.
- Limitar o carregamento máximo de cada bateria ao seu respectivo SOC_M . Eventuais sobras de potência são distribuídas proporcionalmente entre as demais baterias.

A heurística desenvolvida para resolver o problema de forma similar ao Modelo 2 (3.2.2) está detalhada nos Algoritmos 1 e 2 a seguir.

Algoritmo 1: Heurística

1 **para** cada período de tempo t **faça**

2 Calcular a energia necessária para cada bateria:

$$\Delta SOC_{(j,t)} = SOC_M - SOC_{(j,t-1)}, j = 1 \dots NV \quad (3.13)$$

3 Calcular a potência entregue a cada bateria:

$$\Delta P_{j,t} = \frac{\Delta SOC_{j,t}}{\Delta t}, j = 1 \dots NV \quad (3.14)$$

4 Calcular a potência demandada pelas baterias:

$$P_t = \sum_{j=1}^{NV} \Delta P_{j,t} \quad (3.15)$$

5 Calcular a potência total que será efetivamente entregue às baterias:

$$P_{eff,t} = \min [P_t, P_{d,t}] \quad (3.16)$$

6 Calcular o percentual da potência total que será entregue a cada bateria:

$$x_{j,t} = \Delta P_{j,t} / P_t, j = 1 \dots NV \quad (3.17)$$

7 Calcular as potências entregues a cada bateria:

$$P_{s_{j,t}} = x_{j,t} \cdot P_{eff,t}, j = 1 \dots NV \quad (3.18)$$

8 Rearranjar as potências de carregamento conforme o Algoritmo 2.

9 Atualizar o SOC das baterias:

$$SOC_{(j,t+1)} = \min [(SOC_{(j,t)} + P_{s_{(j,t)}} \cdot \Delta t), SOC_M] \quad (3.19)$$

10 **fim**

Algoritmo 2: Rearranjar as potências de carregamento entre os veículos, considerando as potências de carregamento P_v das baterias.

1 Compare cada potência de carregamento com seu limite:

2 **se** $Ps_{j,t} > P_{vj}$ **então**

3 |
$$Ps_{j,t} = P_{vj} \quad (3.20)$$

4 |
$$\Delta Ps_j = 0 \quad (3.21)$$

5 **fim**

6 **senão**

7 |
$$\Delta Ps_j = P_{vj} - Ps_{j,t}, j = 1 \dots NV \quad (3.22)$$

8 **fim**

9 Calcule a potência que poderia ter sido entregue às baterias:

$$\Delta P_{S_{\text{total}}} = \sum_{j=1}^{NV} \Delta Ps_j \quad (3.23)$$

10 Calcule a disponibilidade do transformador após considerar os limites de carregamento das baterias:

$$\Delta = \Delta P_{S_{\text{total}}} - P_{ef} \quad (3.24)$$

11 Calcule o excesso de potência de cada bateria em termos percentuais:

$$y_i = \frac{\Delta Ps_i}{\sum_{j=1}^{NV} \Delta Ps_j}, i = 1 \dots NV \quad (3.25)$$

12 **se** $\sum_{j=1}^{NV} \Delta Ps_j - \Delta \leq 0$ **então**

13 | Realoque as potências de carregamento entre os veículos:

13 |
$$Ps_{j,t} = Ps_{j,t} + \Delta Ps_j, j = 1 \dots NV \quad (3.26)$$

14 **fim**

15 **senão**

16 | Realoque as potências de carregamento entre os veículos proporcionalmente às suas capacidades:

17 |
$$Ps_{j,t} = Ps_{j,t} + y_j \cdot \Delta Ps_j, para j = 1 \dots NV \quad (3.27)$$

18 **fim**

3.4 Teaching-Learning-Based Optimization (TLBO)

Diversos métodos têm sido propostos para problemas não-lineares e problemas que não são facilmente solucionáveis pelos métodos de programação matemática convencionais. As meta-heurísticas buscam resolver estes problemas com uma abordagem diferente das convencionais. Já foram feitos diversos esforços nessa área nos últimos anos e diferentes algoritmos foram criados, dos quais boa parte foi inspirada a partir da observação de fenômenos e comportamentos da natureza. Exemplos de meta-heurísticas baseadas na natureza são a otimização baseada em colônias de formigas, o algoritmo de colônia de abelhas artificiais, otimização baseada em busca de comida por bactérias, algoritmo dos vaga-lumes, otimização baseada em enxames de partículas, dentre outros (SLOWIK, 2021).

Teaching-Learning-Based Optimization (TLBO) é uma meta-heurística que busca encontrar os pontos ótimos globais de funções, inspirada na dinâmica de aprendizado em sala de aula. Este algoritmo de otimização foi desenvolvido com base nas interações entre alunos e professor em sala de aula e o efeito delas no aprendizado, ou seja nas notas dos alunos. O TLBO considera que o professor é um indivíduo com muito conhecimento, e que compartilha este conhecimento com seus alunos em sala de aula. O TLBO também toma como premissa que o nível de conhecimento do professor influencia diretamente no resultado dos alunos. Os alunos aprendem com o professor e também nas interações entre si (RAO; SAVSANI; VAKHARIA, 2012).

O algoritmo é dividido em duas fases, a "Etapa do Professor", na qual os alunos aprendem com o professor e a "Etapa dos Estudantes", na qual os alunos aprendem interagindo entre si. Considere dois professores, P_1 e P_2 que ministram uma determinada disciplina com o mesmo conteúdo para estudantes de mesmo nível em duas turmas diferentes. A Figura 3.2 mostra a distribuição das notas obtidas pelos estudantes das duas turmas diferentes, avaliadas pelos professores. As curvas 1 e 2 representam as notas obtidas pelos estudantes dos professores P_1 e P_2 , respectivamente. Assume-se uma distribuição normal para as notas, porém, na realidade ela pode apresentar uma distorção. A distribuição normal é definida como:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.28)$$

onde σ representa a variância, μ a média e x representa qualquer valor do qual é requerida uma distribuição normal.

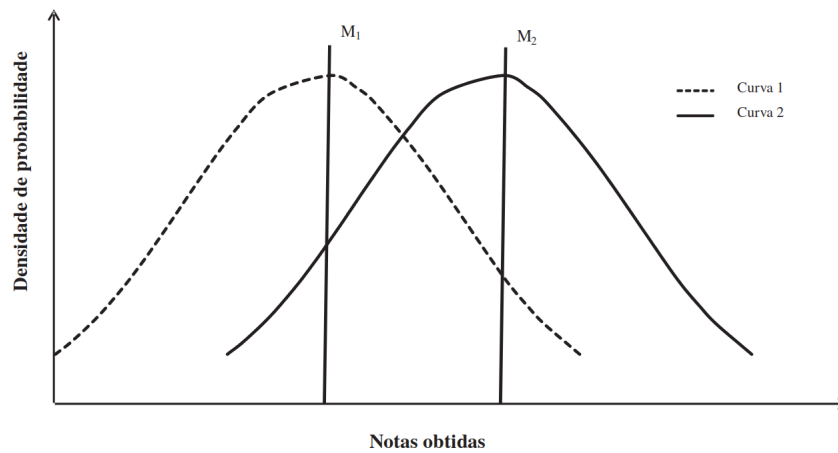


Figura 3.2: Distribuição das notas obtidas pelos estudantes nas turmas dos professores P_1 e P_2 . Adaptado de (RAO; SAVSANI; VAKHARIA, 2012)

É possível observar na Figura 3.2 que os alunos da turma do professor P_2 obtiveram melhores resultados, então pode-se concluir que o professor P_2 é melhor que P_1 no que diz respeito à transmissão de conhecimento. As principais diferenças entre ambos os resultados são as médias M_1 e M_2 , de onde se pode concluir que os melhores professores produzem os melhores resultados para os estudantes. Além disso, os estudantes aprendem das interações entre si, o que também melhora os seus resultados. A Figura 3.3 mostra um modelo das notas obtidas pelos alunos em uma turma com a curva A e média M_A . O professor é considerado a pessoa com o maior conhecimento na sociedade, então, o melhor estudante é tomado como professor, representado por P_A na Figura 3.3. O professor tenta disseminar o conhecimento para os estudantes, que aprendem e têm os seus conhecimentos aumentados de acordo com a sua capacidade. Na Figura 3.3 o professor P_A tentará mover a média M_A em direção ao seu próprio nível, de acordo com a sua própria capacidade. O professor se esforçará para transmitir todo o conhecimento e mover a média dos estudantes de M_A para M_B , a partir de onde os alunos precisarão de um novo professor com mais conhecimento, que neste caso será o professor P_B .




Figura 3.3: Modelo de distribuição para as notas obtidas de um grupo de estudantes. Adaptado de (RAO; SAVSANI; VAKHARIA, 2012)

3.4.1 Etapa do Professor

O algoritmo começa na Etapa do Professor, onde é atribuído o papel de professor ao melhor indivíduo da turma (população). A partir da escolha do professor, o algoritmo tenta melhorar os demais indivíduos X_i , aproximando-os do professor pela média atual dos indivíduos.

$$X_i^{novo} = X_i^{atual} + r \cdot [X_{professor} - (T_F \cdot X_{media})] \quad (3.29)$$

onde: r = número aleatório no intervalo [0, 1]

T_F = fator de ensino pertencente ao conjunto {1,2}, selecionado aleatoriamente

3.4.2 Etapa dos Estudantes

Na Etapa do Estudante o estudante X_i tenta melhorar seu aprendizado com um colega arbitrário X_j , onde i é diferente de j .

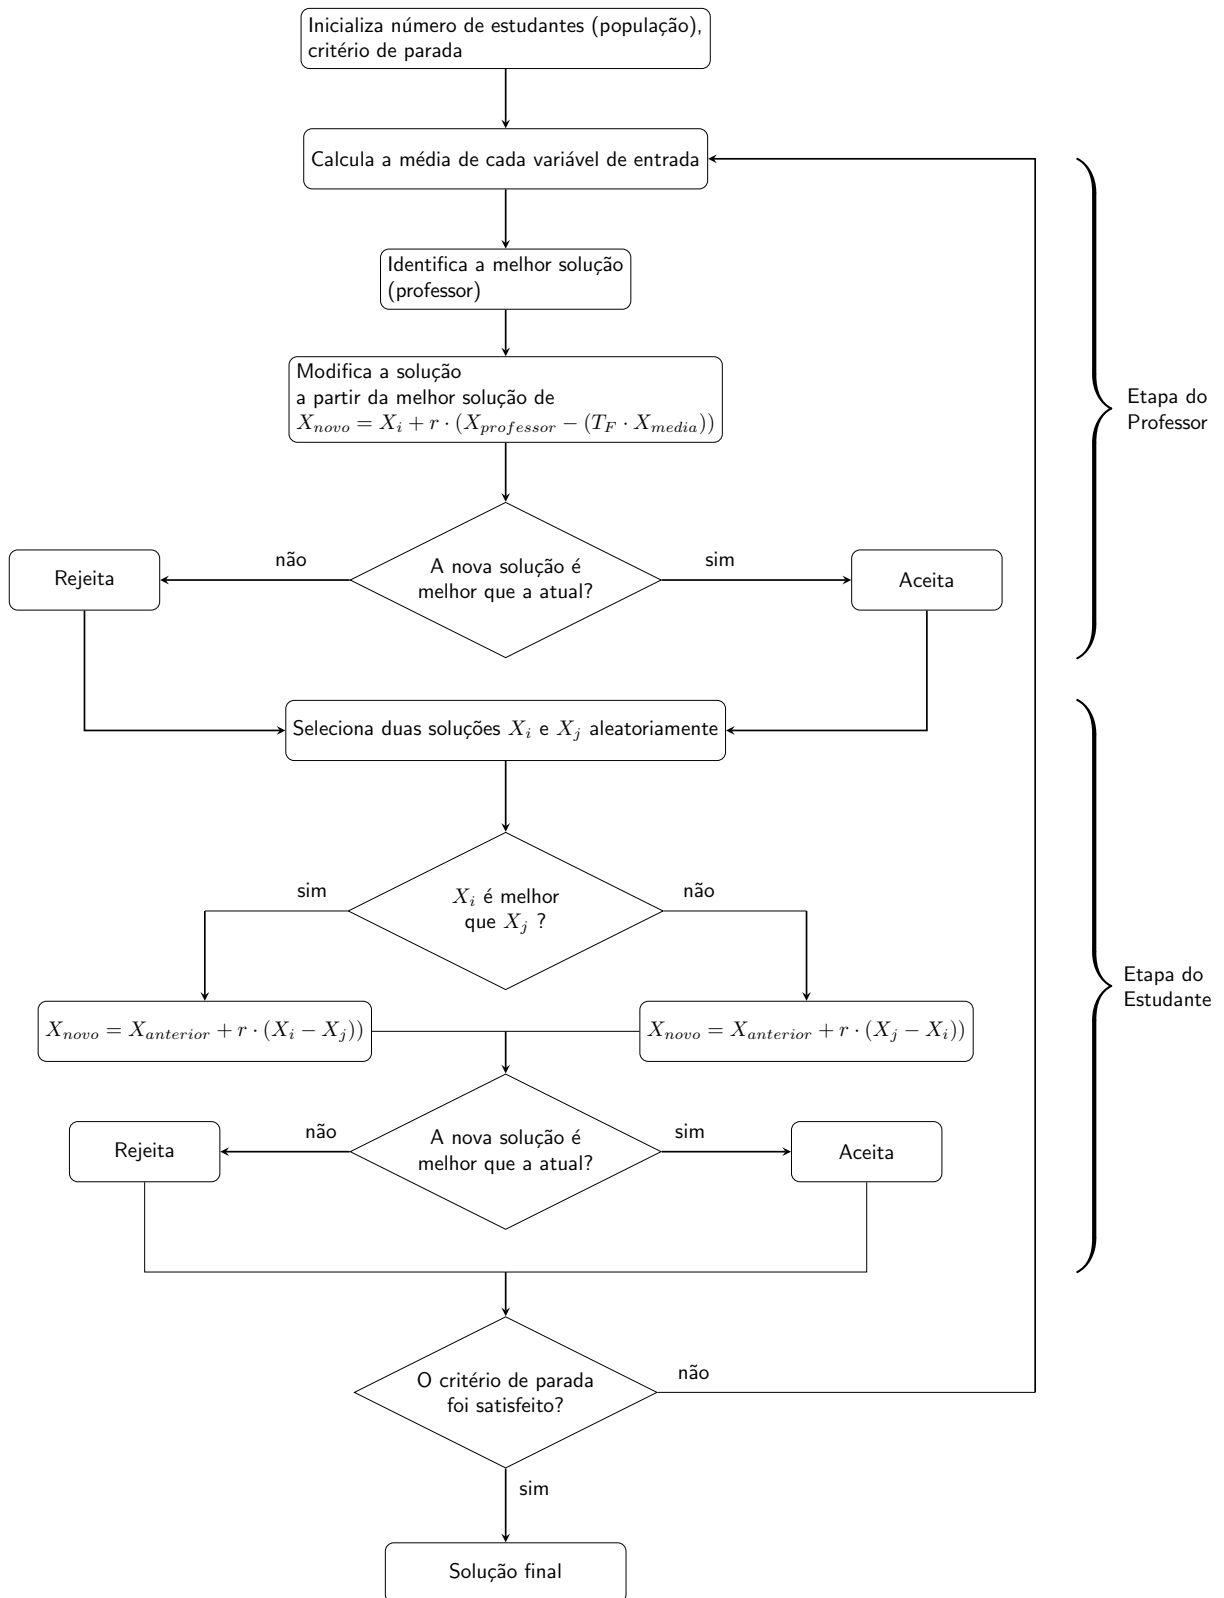
$$X_i^{novo} = X_i^{atual} + r \cdot (X_j - X_i) \quad (3.30)$$

$$X_i^{novo} = X_i^{atual} + r \cdot (X_i - X_j) \quad (3.31)$$

No caso em que X_j é melhor que X_i , X_i melhora seu conhecimento e move-se na direção de X_j (Equação 3.30). Caso contrário, X_i é movido na direção oposta a X_j (Equação 3.31). Se o estudante X_i^{novo} obtiver melhor desempenho nessa fase, será adicionado à população, substituindo X_i . As etapas do Professor e do Estudante serão repetidas até que o critério de parada pré-estabelecido seja atingido, por exemplo, um determinado número de iterações.

A Figura 3.4 mostra um fluxograma do algoritmo TLBO.

Figura 3.4: Fluxograma do TLBO



Adaptado de (RAO; SAVSANI; VAKHARIA, 2012)

Capítulo 4

Resultados das simulações

4.1 Condições de simulação

O TLBO e a heurística foram desenvolvidos utilizando a linguagem GNU Octave (EATON; BATEMAN; HAUBERG et al., 1997) e aplicados para a resolução do problema proposto na Seção 3.2. As simulações foram realizadas em um computador Dell Inspiron 7572 com Processador Intel Core i5-8250U e 8 GB de memória RAM DDR4 2400 Hz. O computador estava equipado com sistema operacional Windows 11 Pro e o GNU Octave na versão 8.2.0.

4.2 Caso 1

Após o desenvolvimento do código computacional, este foi aplicado a um problema de pequeno porte, desenhado com o objetivo de validar o seu funcionamento. Em seguida, o código foi aplicado a cenários mais complexos para avaliar a aplicação de cada modelo.

A Tabela 4.1 descreve o cenário inicial de testes que foi aplicado para obter os resultados de validação do código. Este cenário representa uma situação simples, com três veículos e suas respectivas restrições, cujos carregamentos ocorrem em 10 períodos de tempo. As restrições são especificadas na Tabela 4.1.

Neste cenário, é possível observar na Figura 4.1 que a função objetivo atinge valores relativamente estáveis a partir da 24^a iteração da execução do TLBO simultâneo. Em outros cenários de teste simulados, e que serão apresentados a seguir, o algoritmo tende a convergir entre a 8^a e a 10^a iterações. Do ponto de vista do carregamento, todos os veículos atingiram pelo menos 90% da carga máxima em até 5 períodos de recarga, sem violar o parâmetro de rede P_d (disponibilidade do transformador que alimenta o posto de carregamento). Nessa fase, a carga máxima está limitada apenas pelos limites da rede e das baterias e os períodos estão ajustados para a duração de uma hora.

No cenário da Figura 4.2 alguns parâmetros de entrada foram alterados. A variável P_d (disponibilidade da rede elétrica) foi reduzida para 20 kW e a variável P_v (capacidade de carga das baterias por período de tempo) foi diminuída para 10 kW para todos os veículos. Nesta situação todos os veículos chegaram ao último período com cargas entre 60% e 80% da carga máxima, em função das restrições impostas. O carregamento foi controlado e limitou a quantidade de potência entregue aos veículos para não ultrapassar o limite imposto pela rede elétrica.

Tabela 4.1: Caso 1: Cenário de testes

Variável	Valor	Descrição
NV	3	Número de veículos
T	10	Quantidade de períodos
P_d	70	Potência disponível [kW]
P_v	[50 50 50]	Potência máxima de carregamento [kW]
η	1	Eficiência de carregamento
β	0	Fator de autodescarga
N_{pop}	70	Tamanho da população (TLBO)
It_{max}	50	Numero máximo de iterações (TLBO)
SOC_0	[15% 16% 25%]	Estado de carga inicial
SOC_{max}	[100 100 100]	Capacidade de carga das baterias [kWh]

Figura 4.1: Evolução do SOC(%) dos veículos: Caso 1

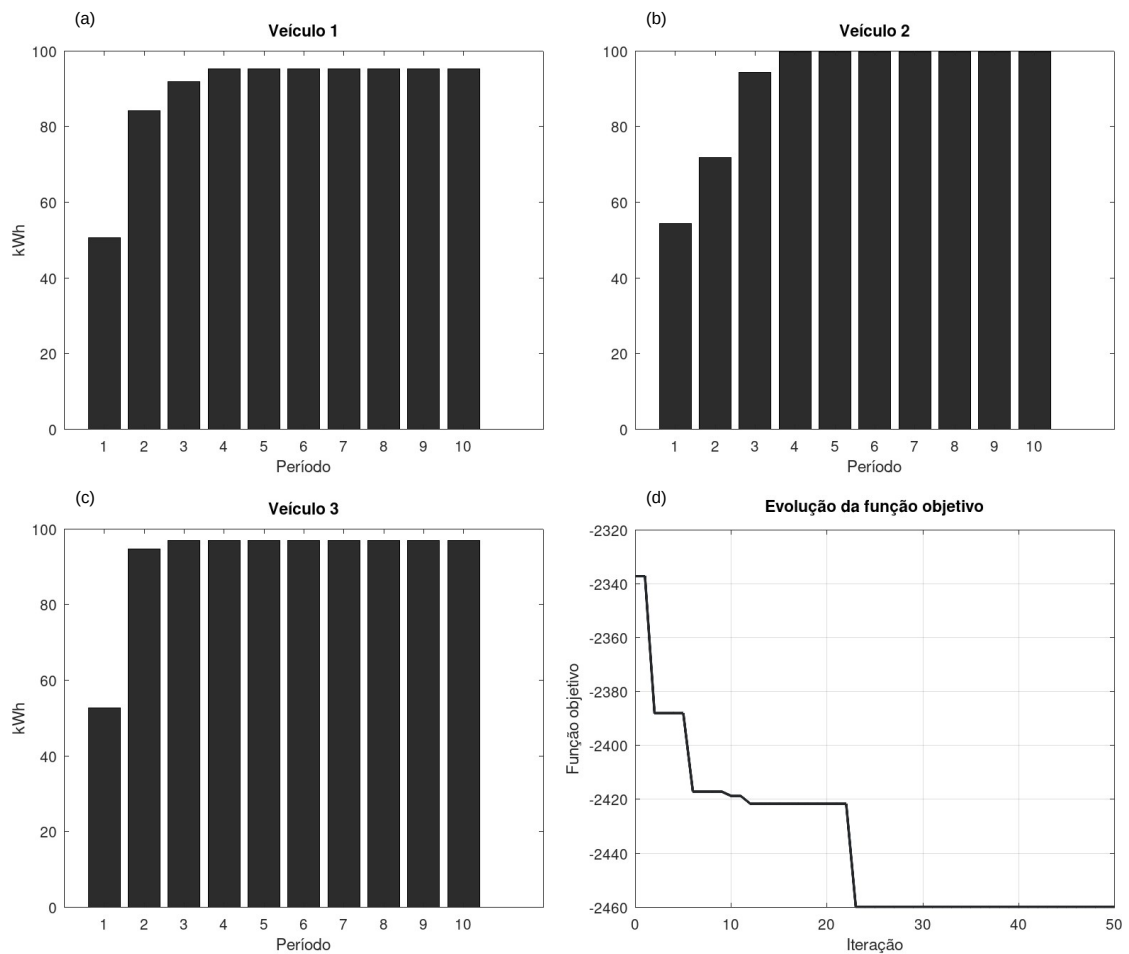
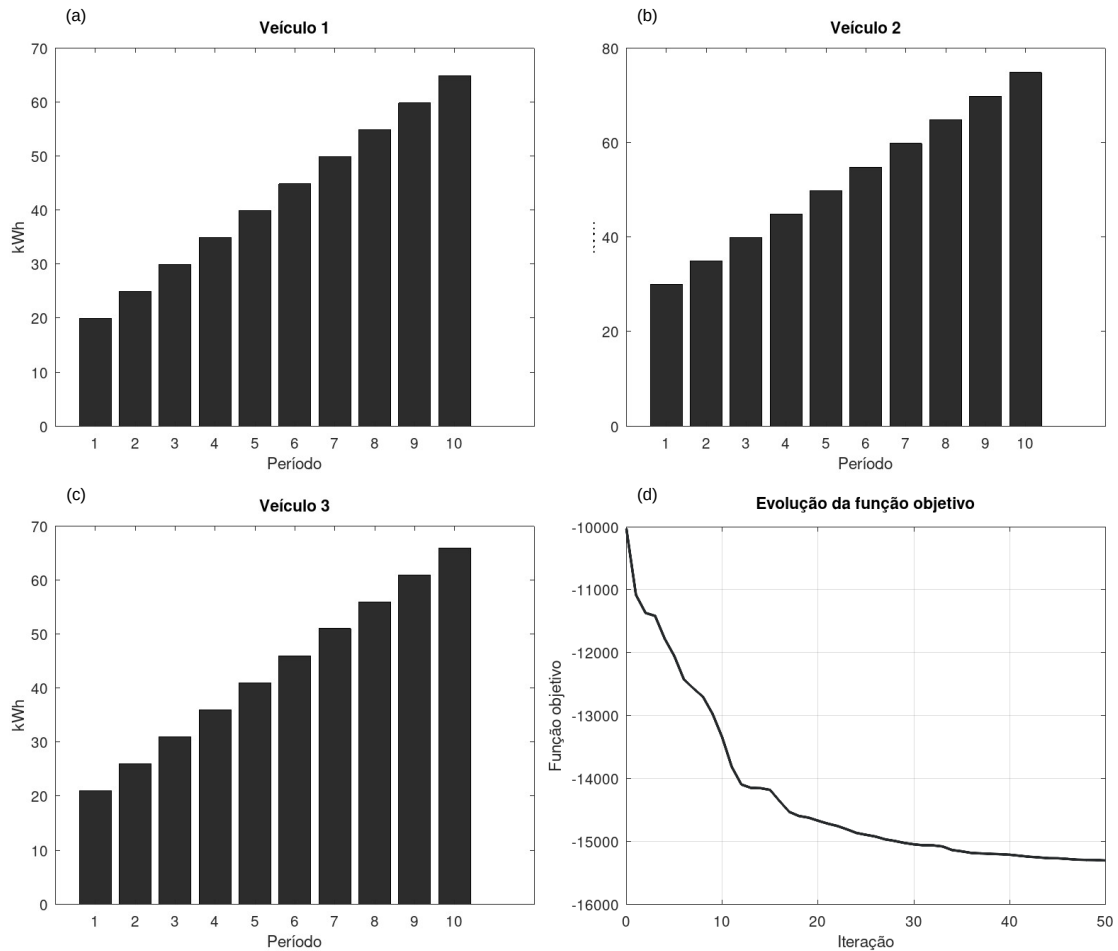


Figura 4.2: Evolução do SOC(%) dos veículos: cenário com limitação de potência disponível e de capacidade de carga das baterias



4.3 Caso 2

4.3.1 Descrição do caso

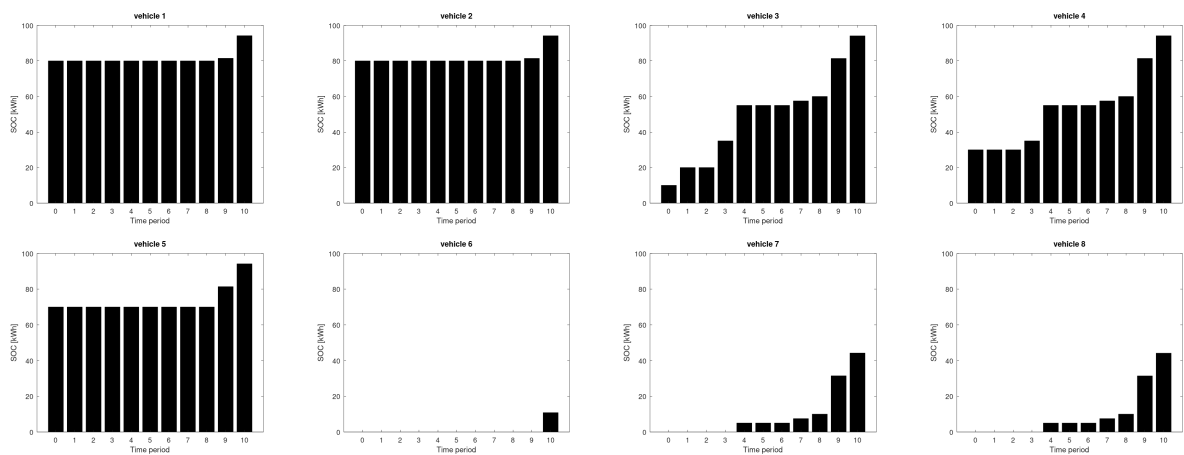
O Caso 2 corresponde a um cenário composto de 8 veículos que são conectados no instante inicial a um eletroposto. Os veículos possuem variados estados de carga (State of charge, SOC) desde 0% até 80% e capacidade de carga P_v na faixa de 50 e 300 kW. Este cenário é desafiador devido à pouca disponibilidade de carga na instalação ao longo de quase todo o período, só atingindo uma disponibilidade de 100kW nos dois últimos períodos.

As Figuras 4.3 a 4.7 mostram os resultados referentes aos carregamentos dos veículos e a evolução das funções objetivo para os dois modelos propostos e as três técnicas de solução propostas. Pode-se observar que, embora haja diferenças entre as várias evoluções de carregamento, de maneira geral elas são semelhantes. Por exemplo, os veículos com baterias mais carregadas sempre recebem uma carga menor ou nenhuma carga, enquanto que os veículos com baterias menos carregadas recebem carga maior. Verifica-se também que, em função da maior disponibilidade da rede elétrica nos últimos períodos de tempo, os carregamentos dos veículos com menor carga são bem mais significativos.

Tabela 4.2: Configuração do Caso 2

Variável	Valor	Descrição
NV	8	Número de veículos
T	10	Quantidade de períodos
P_d	[10 0 20 50 0 0 10 10 100 100]	Potência disponível [kW]
P_v	[50 50 50 50 50 300 100 100]	Potência máxima de de carregamento [kW]
η	1	Eficiência de carregamento
β	0	Fator de autodescarga
N_{pop}	70	Tamanho da população (TLBO)
It_{max}	50	Numero máximo de iterações (TLBO)
SOC_0	[80 80 10 30 70 0 0 0]	Estado de carga inicial [%]
SOC_{max}	[100 100 100 100 100 100 100 100]	Capacidade de carga das baterias [kWh]

Figura 4.3: Evolução do carregamento no TLBO Sequencial (Modelo 1)



4.4 Caso 3

4.4.1 Descrição do caso

O Caso 3 corresponde a cenário composto de 6 veículos que são conectados no instante inicial a um eletroposto. Os veículos iniciam o carregamento com estado de carga entre 10% e 50%, e capacidade de carga P_v máxima de 20 kW. Neste cenário a disponibilidade de carga na instalação oscila entre 0 e 50kW.

As Figuras 4.8 a 4.12 mostram as evoluções dos carregamentos e das funções objetivo para esses casos. Padrões de carregamento semelhantes são observados a despeito das diferentes definições de função objetivo e do método usado.

Figura 4.4: Evolução do carregamento no TLBO Sequencial (Modelo 2)

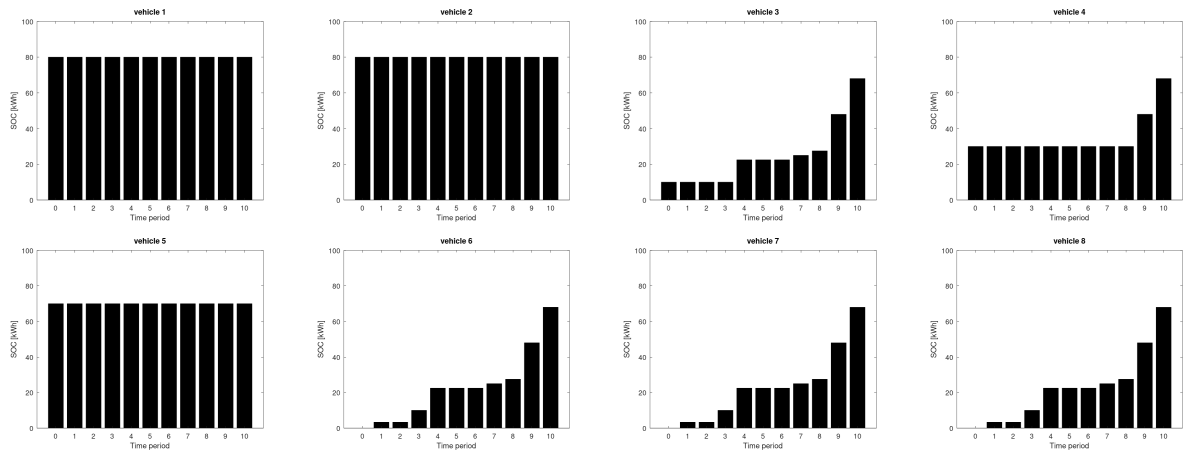


Figura 4.5: Evolução do carregamento no TLBO Simultâneo (Modelo 1)

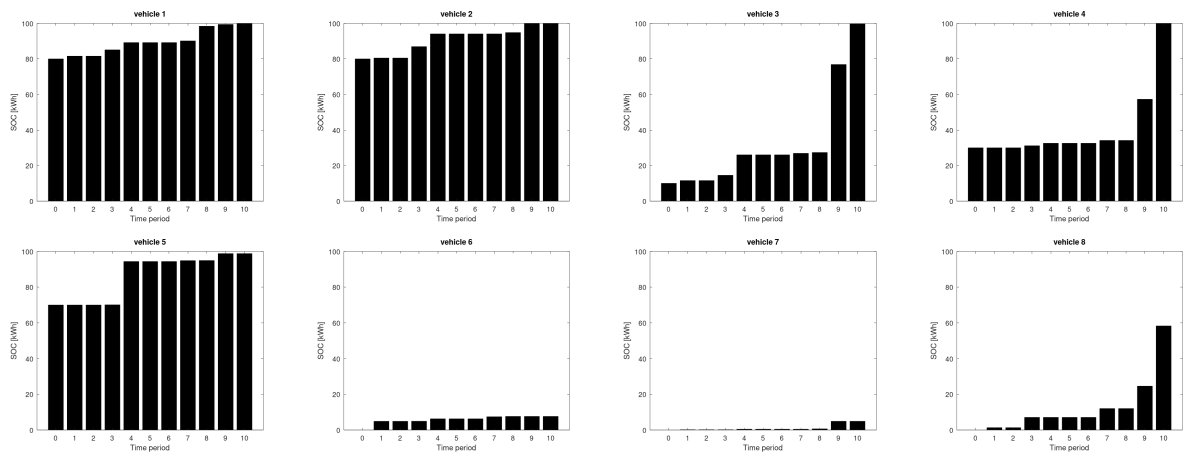


Figura 4.6: Evolução do carregamento no TLBO Simultâneo (Modelo 2)

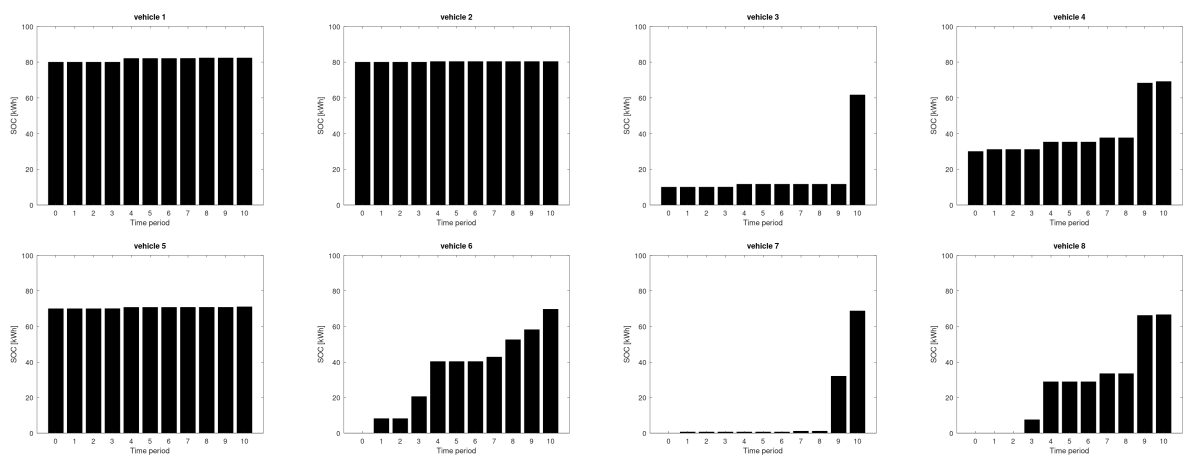


Figura 4.8: Evolução do carregamento no TLBO Sequencial (Modelo 1)

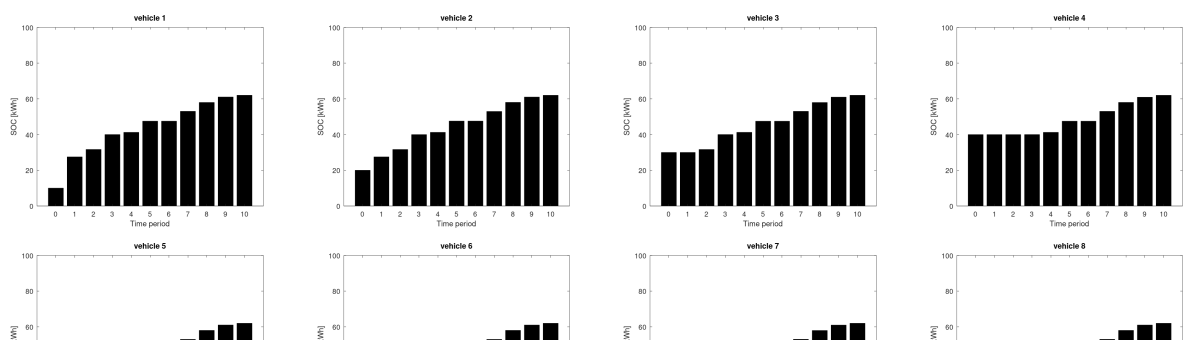


Figura 4.7: Evolução do carregamento na Heurística

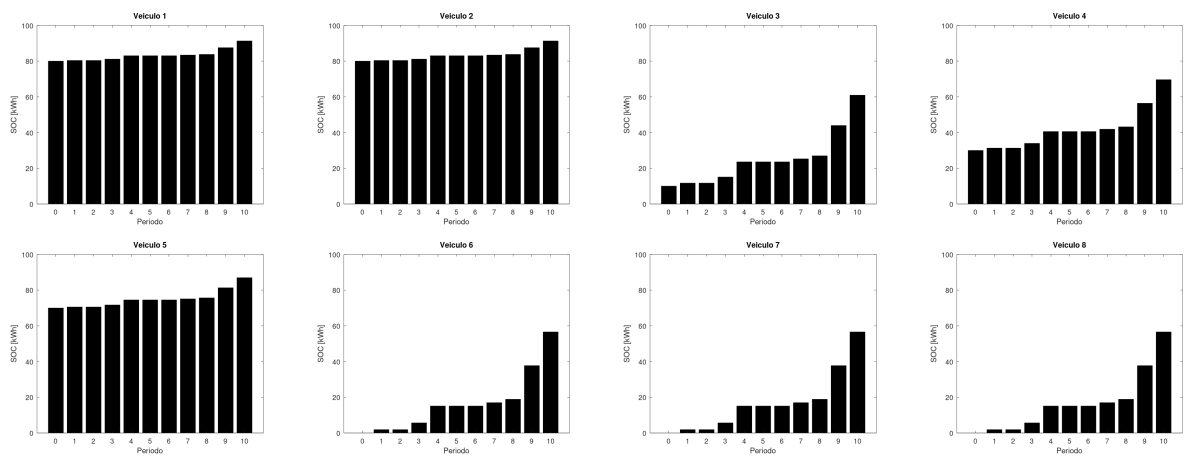


Tabela 4.3: Configuração do Caso 3

Variável	Valor	Descrição
NV	10	Número de veículos
T	10	Quantidade de períodos
P_d	[50 20 50 10 50 0 50 50 30 10]	Potência disponível [kW]
P_v	[20 20 20 20 20 20 20 20 20 20]	Potência máxima de de carregamento [kW]
η	1	Eficiência de carregamento
β	0	Fator de autodescarga
N_{pop}	70	Tamanho da população (TLBO)
It_{max}	50	Número máximo de iterações (TLBO)
SOC_0	[10 20 30 40 50 10 20 30 40 50]	Estado de carga inicial [%]
SOC_{max}	[100 100 100 100 100 100 100 100 100 100]	Capacidade de carga das baterias [kWh]

Figura 4.9: Evolução do carregamento no TLBO Sequencial (Modelo 2)

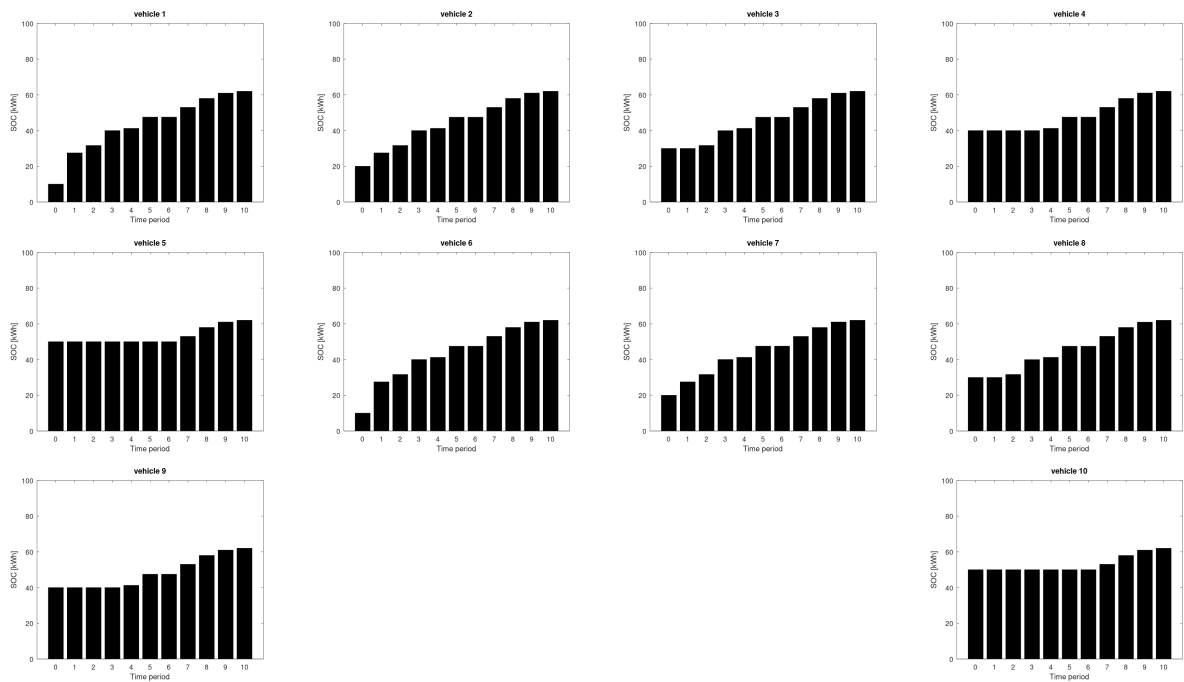


Figura 4.10: Evolução do carregamento no TLBO Simultâneo (Modelo 1)

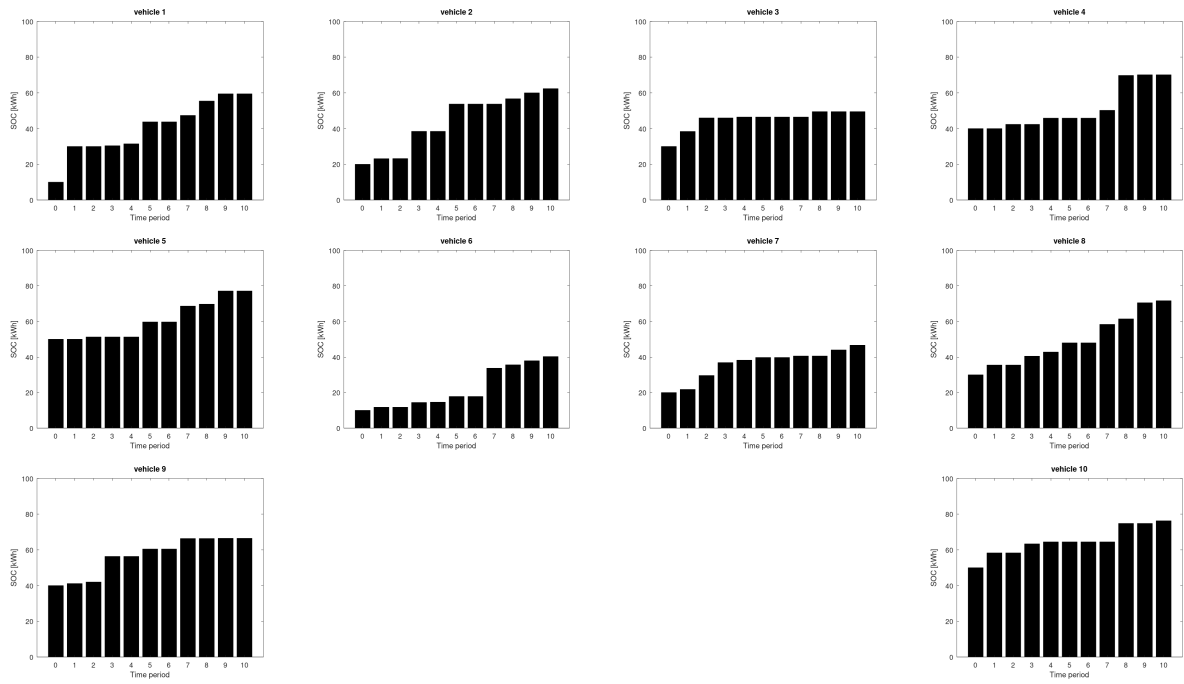


Figura 4.11: Evolução do carregamento no TLBO Simultâneo (Modelo 2)

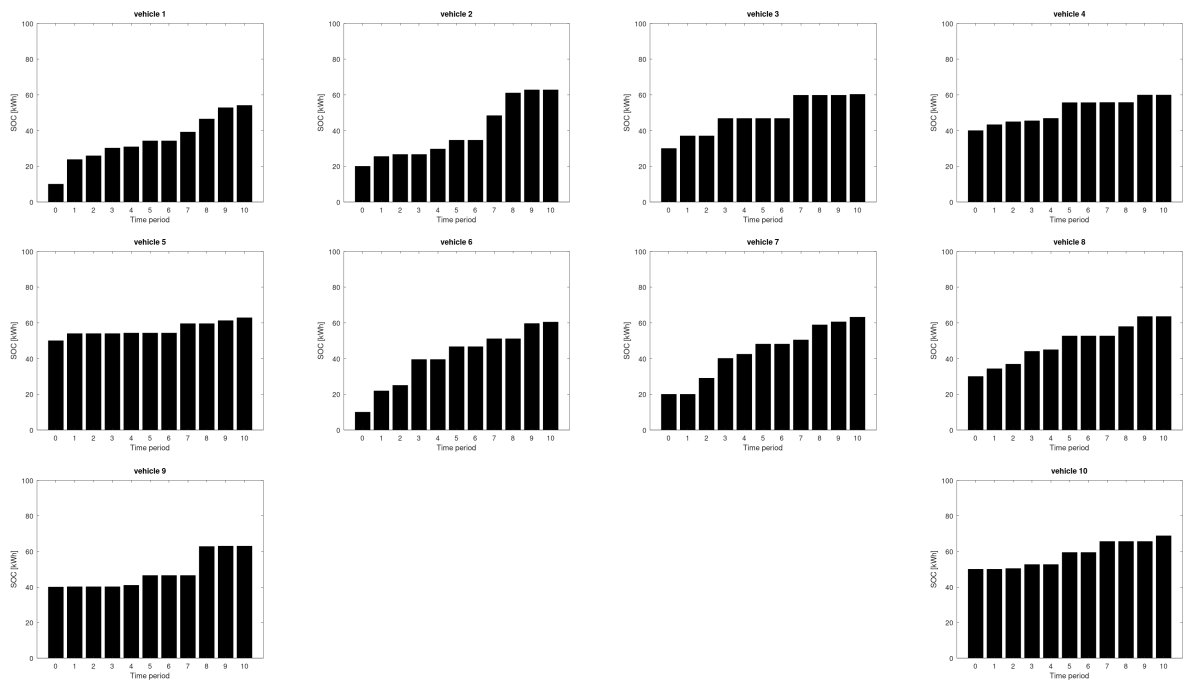
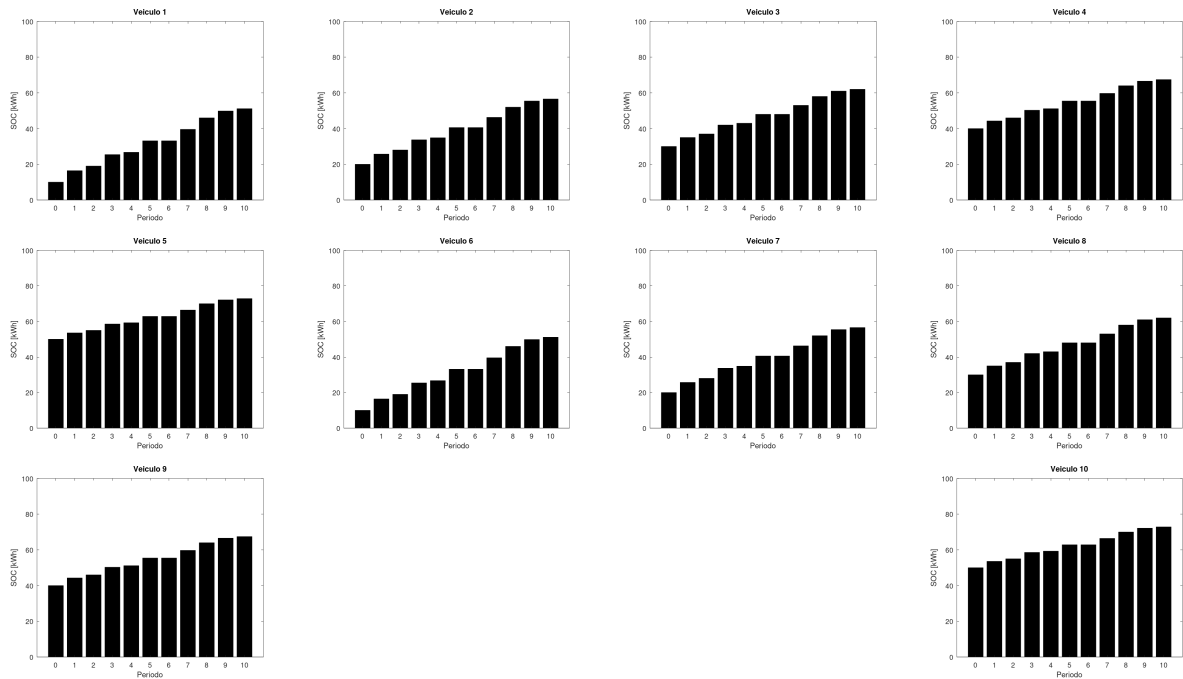


Figura 4.12: Evolução do carregamento na Heurística



A Tabela 4.4 mostra os tempos de simulação para os diferentes métodos. Verifica-se claramente que a heurística foi o método que forneceu soluções com os menores tempos de simulação. Para os casos testados, as diferenças entre os métodos TLBO simultâneo e sequencial não foram significativas.

Tabela 4.4: Tempo de cálculo [s]

	TLBO Sequencial	TLBO Sequencial	TLBO Simultâneo	TLBO Simultâneo	Heurística
	Modelo 1	Modelo 2	Modelo 1	Modelo 2	-
Caso 1	59,8	59,2	49,8	56,4	4,5
Caso 2	92,1	89,7	91,3	89,8	10,0
Caso 3	100,0	114,6	97,2	99,2	13,6

A Tabela 4.5 mostra o número de iterações associados aos métodos TLBO simultâneo e sequencial. Com relação à heurística, como o algoritmo 1 é executado uma única vez, essa informação não é relevante. Definiu-se esse número de iterações como aquele a partir do qual a função objetivo não foi mais alterada, ou seja, a solução para o problema foi obtida.

Tabela 4.5: Número de iterações para a convergência

	TLBO Sequencial	TLBO Sequencial	TLBO Simultâneo	TLBO Simultâneo	Heurística
	Modelo 1	Modelo 2	Modelo 1	Modelo 2	-
Caso 1	20	20	1	1	-
Caso 2	19	18	45	37	-
Caso 3	20	30	50	2	-

4.5 Discussão dos resultados

Nesta seção é feito um resumo da avaliação dos resultados obtidos nas seções anteriores, onde foram resolvidos os modelos descritos na seção 3.2.

4.5.1 Critérios de comparação

Os métodos apresentados neste trabalho têm características fundamentais diferentes. Os métodos 1 e 2 têm funções objetivos diferentes, logo, seus valores para solução ótima assumem valores diferentes. No caso da heurística, não há uma função objetivo formal, e sim um conjunto de princípios que são seguidos para encontrar uma solução de qualidade. Portanto, há dificuldade para comparar o desempenho dos modelos de forma direta. Então, propõe-se uma forma para realizar essa comparação da maneira mais justa possível, baseada nos seguintes pontos:

- Ponto A – priorizar os veículos que iniciaram o carregamento com os menores SOC_0 .
- Ponto B – priorizar os veículos cujas baterias ficaram mais carregadas ao final do período de carga.
- Ponto C – priorizar o carregamento nos períodos iniciais.

Os pontos são detalhados abaixo. Nos cálculos define-se o $Maior_{SOC_{max}}$ que representa o maior estado de carga máximo SOC_{max} dentre todos os veículos do caso avaliado.

$$Maior_{SOC_{max}} = \left[\max \left(SOC_{max_{v=1}}^{NV} \right) \right]_{caso} \quad (4.1)$$

Considere que a simulação envolva NV veículos. Como foram testados cinco métodos diferentes, ao final tem-se $5 \cdot NV$ carregamentos máximos. A equação 4.1 acima toma o maior dentre eles.

- **Ponto A:** Priorizar os veículos que iniciaram com menores SOC_0 . Define-se:

$$A = \frac{SOC_{max} - SOC_{0,v}}{Maior_{SOC_{max}}}, v = 1, \dots, NV \quad (4.2)$$

Esta equação calcula a diferença entre o estado de carga máximo SOC_{max} e o estado de carga inicial SOC_0 de cada veículo e depois divide pelo maior estado de carga máximo SOC_{max} do caso para normalizar os valores e permitir a comparação com os demais métodos. O objetivo é pontuar de forma normalizada cada veículo do método com relação ao estado de carga inicial relativo ao seu máximo. O resultado de A é uma matriz coluna de tamanho $[NV \times 1]$.

Ponto B: Receber a maior quantidade de carga relativa ao seu SOC_0 . Define-se:

$$B = \frac{SOC_{v, T}}{Maior_{SOC_{max}}}, v = 1, \dots, NV \quad (4.3)$$

Esta equação calcula o estado de carga final SOC_{max} de cada veículo relativo ao demais veículos do método, com o objetivo de pontuar cada veículo de forma normalizada com relação ao estado de carga máximo do método $Maior_{SOC_{max}}$. O resultado de B (4.3) é uma matriz coluna de tamanho $[NV \times 1]$.

Ponto C: Priorizar o carregamento nos períodos iniciais. Define-se, para cada veículo do método:

$$\Delta SOC_{v, t} = (SOC_{v, t} - SOC_{v, t-1}) \quad (4.4)$$

$$MC = f(\Delta SOC_{t, v}) = \begin{cases} 0, & \text{se } \Delta SOC_{v, t} \leq 0 \\ 1, & \text{se } \Delta SOC_{v, t} > 0 \end{cases} \quad (4.5)$$

$$Ps(t) = T - (t - 1) \quad (4.6)$$

$$C = \frac{\sum_{t=1}^T MC \cdot Ps}{\sum Ps} \quad (4.7)$$

A equação 4.4 calcula uma matriz de tamanho $[NV \times T]$ com o ganho de SOC de cada veículo a cada período. A equação 4.5 calcula uma matriz de tamanho $[NV \times T]$ onde cada elemento identifica com um (1) se houve carregamento no período ou com um zero (0) se não houve carregamento. A equação 4.6 determina pesos para cada período, onde o primeiro período recebe o maior peso, e a partir dele, cada período vale uma unidade menos até chegar no último período, que recebe o menor peso. Exemplo: se o vetor de períodos for $p = 1, 2, 3$, o vetor de pesos será $P = 3, 2, 1$. A equação 4.7 determina uma matriz de tamanho $[NV \times 1]$ que representa o resultado do critério C para cada veículo. Nela, cada elemento da matriz $f\Delta SOC_{t, v}$ é multiplicado pelo elemento correspondente da matriz de pesos P_v e o resultado é então dividido pela soma dos pesos de P_v para normalizar os resultados.

Por fim, é feita a unificação dos critérios A, B e C, multiplicando-os uns pelos outros. Assim, obtém-se uma única matriz de tamanho $[NV \times 1]$ com um resultado para cada veículo. Para obter um único valor que representa cada condição simulada e facilitar as comparações, toma-se o terceiro quartil (Q_3) do conjunto como o valor que representa a unificação de todos os critérios. O terceiro quartil (Q_3) é a métrica acima da qual 25% dos valores estão e foi escolhido pela sua capacidade de prover informações sobre a parte superior da distribuição de dados e por sofrer menor influência de valores extremos quando comparado com a média. A nota de cada grupo estará entre 0, que representa o pior desempenho e 1 que representa o melhor desempenho

e está descrita na equação 4.8 abaixo:

$$Nota = Q_3(A \cdot B \cdot C) \quad (4.8)$$

4.5.2 Avaliação dos resultados

As notas para cada caso foram obtidas segundo o critério descrito em 4.5.1 e estão detalhadas nas tabelas 4.6 e 4.7, bem como uma classificação em cada caso. No Caso 2, o TLBO Sequencial com o Modelo 2 foi o que apresentou o melhor desempenho, com nota 0.43. Em segundo lugar ficou a Heurística que obteve nota 0.36 e em terceira posição o TLBO Simultâneo com o Modelo 1 que obteve a nota 0.27. O TLBO Simultâneo no modelo 2 e o TLBO Sequencial Modelo 1, obtiveram as piores notas, com 0.26 e 0.18, respectivamente.

Tabela 4.6: Notas do caso 2

Modelo	Método	Nota	Classificação
Modelo 1	TLBO Simultâneo	0.27	3
Modelo 1	TLBO Sequencial	0.18	5
Modelo 2	TLBO Simultâneo	0.26	4
Modelo 2	TLBO Sequencial	0.43	1
Heurística	Heurística	0.36	2

No Caso 3, o TLBO Sequencial Modelo 1 e o TLBO Sequencial Modelo 2 obtiveram a melhor nota, com 0.45. Ambos são seguidos da Heurística que obteve nota 0.41 e, em quarta e quinta posição ficaram o TLBO Simultâneo no Modelo 2 com nota 0.37 e o TLBO Simultâneo no Modelo 1 com nota 0.35.

Tabela 4.7: Notas do caso 3

Modelo	Método	Nota	Classificação
Modelo 1	TLBO Simultâneo	0.35	5
Modelo 1	TLBO Sequencial	0.45	1
Modelo 2	TLBO Simultâneo	0.37	4
Modelo 2	TLBO Sequencial	0.45	2
Heurística	Heurística	0.41	3

De forma geral o TLBO Sequencial foi a solução que mais obteve notas altas, considerando ambos os casos, seguido da Heurística que obteve nota alta tanto no Caso 2 quanto no Caso 3. A Heurística descrita em 3.3.3 resolveu o problema mais rapidamente que os demais métodos em TLBO, conforme mostra a Tabela 4.4. Porém, todos as soluções apresentaram tempos computacionais pequenos o suficiente para realizar a atividade de forma satisfatória. A Heurística também apresentou os melhores resultados em termos de tempo de cálculo e distribuição das cargas entre os veículos. Em seguida, o TLBO Sequencial (3.3.2 com o Modelo 2 (3.2.2 também apresentou distribuição de cargas equilibrada entre os veículos porém priorizou o carregamento dos veículos que iniciaram o processo com baixo SOC, ao custo de entregar pouca ou nenhuma energia aos veículos que iniciaram o carregamento com SOC elevado.

Dentre todas as opções avaliadas, a Heurística foi a única que, quando havia potência disponível, conseguiu fornecer energia para todos os veículos em todos os períodos, mesmo que em quantidades reduzidas. Essa abordagem permitiu o carregamento gradual de todos os veículos. Da óptica dos usuários esta é a melhor opção porque nenhum veículo deixa de receber energia. Já o TLBO Sequencial, tanto no Modelo 1 (3.2.1) quanto no Modelo 2 (3.2.2) carregou os veículos de forma gradual, entregou bastante carga para os veículos e deu prioridade aos veículos que iniciaram o carregamento com baixa carga, porém deixou de entregar energia aos veículos que começaram com zero carga por vários períodos de tempos e os veículos que começaram com SOC (estado de carga da bateria) elevado ficaram sem receber carga por vários instantes de tempo. O TLBO Simultâneo foi o pior em desempenho no Modelo 1 (3.2.1) porque, apesar de atender os limites de P_d (Potência disponível na instalação), foi o que mais demorou para carregar os veículos. Já no Modelo 2 (3.2.2) ofereceu melhor distribuição de carga.

A Tabela 4.4 detalha os tempos computacionais que cada modelo apresentou no computador utilizado. As soluções em TLBO, tanto o Sequencial quanto o Simultâneo levaram tempos similares para a simulação em cada caso, com tempo mínimo de 49,8 segundos no Caso 1 e tempo máximo de 114,6 segundos no Caso 3. Já a solução em Heurística apresentou resultados melhores, com o menor tempo de 4,5 segundos no Caso 1 e o maior tempo de 13,6 segundos no Caso 3.

O código computacional considerou número fixo de 50 iterações. O TLBO Sequencial apresentou maior estabilidade no número de iterações para alcançar resultados estáveis, ficando entre 18 e 30 iterações, trazendo previsibilidade para a alocação de recurso computacional. Já o TLBO Simultâneo apresentou o menor (1) e o maior (50) número de iterações para atingir convergência, apontando possível dificuldade em prever a quantidade de recursos computacionais a serem alocados. A Heurística não é resolvida de forma iterativa, por isso não apresenta número de iterações para convergência.

Capítulo 5

Considerações finais

Neste trabalho foi desenvolvido um modelo matemático que representa os objetivos da otimização e as restrições operacionais para obter a coordenação do carregamento de baterias de veículos elétricos. Em seguida foi implementado no GNU Octave códigos para os algoritmos TLBO e heurística e os resultados das simulações realizadas atingiram o objetivo de carregar os veículos no menor tempo possível sem exceder as limitações da rede elétrica. Todas as implementações, tanto o TLBO Simultâneo (3.3.1), quanto o TLBO Sequencial (3.3.2) e a Heurística (3.3.3) respeitaram os limites P_d (Potência disponível na instalação) em todos os instantes. Os métodos foram testados para três casos com diferentes números de veículos e diferentes restrições, das baterias, da rede elétrica etc. Todos os métodos foram capazes de resolver o problema atribuindo cargas apropriadas aos veículos elétricos. Do ponto de vista técnico e prático, a Heurística consegue obter esquemas de carregamento de boa qualidade em tempos computacionais bem menores, o que pode ser conveniente do ponto de vista de software embarcado nas estações de recarga.

Conforme discutido anteriormente, uma ideia de desenvolvimento futuro é aplicar os métodos desenvolvidos neste trabalho a um problema que envolva um modelo detalhado da rede elétrica, para possibilitar às distribuidoras a realização de simulações para a verificação dos impactos do carregamento sobre a rede e a definição de ações de reforço na mesma.

Referências

- ALAHYARI, Arman; POZO, David; SADRI, Mohammad Ali. Online energy management of electric vehicle parking lots. In: IEEE. 2020 International Conference on Smart Energy Systems and Technologies (SEST). [S.l.: s.n.], 2020. P. 1–6.
- CLEMENT-NYNS, Kristien; HAESSEN, Edwin; DRIESEN, Johan. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid. **IEEE Transactions on power systems**, IEEE, v. 25, n. 1, p. 371–380, 2009.
- EATON, John Wesley; BATEMAN, David; HAUBERG, Søren et al. **GNU Octave**. [S.l.]: Network Theory London, 1997.
- INSIGHTS, Deloitte. Electric Vehicles—Setting a course for 2030. **Deloitte University EMEA CVBA: Berkenlaan, The Netherlands**, 2020.
- LOPEZ, Karol Lina. **A machine learning approach for the smart charging of electric vehicles**. 2019. Tese (Doutorado) – Université Laval.
- MURATORI, Matteo. Impact of uncoordinated plug-in electric vehicle charging on residential power demand. **Nature Energy**, Nature Publishing Group, v. 3, n. 3, p. 193–201, 2018.
- PATNAIK, Moushita; ADRIAN, Angelia Melani. Chapter 4 - A perspective depiction of heuristics in virtual reality. In: MISHRA, Sushruta et al. (Ed.). **Cognitive Big Data Intelligence with a Metaheuristic Approach**. [S.l.]: Academic Press, 2022. (Cognitive Data Science in Sustainable Computing). P. 101–116. ISBN 978-0-323-85117-6. DOI: <https://doi.org/10.1016/B978-0-323-85117-6.00006-6>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780323851176000066>>.
- RAO, R Venkata; SAVSANI, Vimal J; VAKHARIA, DP. Teaching–learning-based optimization: an optimization method for continuous non-linear large scale problems. **Information sciences**, Elsevier, v. 183, n. 1, p. 1–15, 2012.
- SÁ, Sarah M de; PEREIRA, Michael Douglas L; FRANCO, John F. Programação Linear Aplicada ao Carregamento Coordenado de Veículos Elétricos em Redes de Distribuição. In: CONGRESSO Brasileiro de Automática-CBA. [S.l.: s.n.], 2020. v. 2.
- SHIBL, Mostafa; ISMAIL, Loay; MASSOUD, Ahmed. Machine learning-based management of electric vehicles charging: Towards highly-dispersed fast chargers. **Energies**, Multidisciplinary Digital Publishing Institute, v. 13, n. 20, p. 5429, 2020.
- SLOWIK, Adam. **Swarm intelligence algorithms (Two volume set)**. [S.l.]: CRC press, 2021.

SUN, Mingdong et al. Uncovering travel and charging patterns of private electric vehicles with trajectory data: evidence and policy implications. **Transportation**, Springer, p. 1–31, 2021.

TUCHNITZ, Felix et al. Development and evaluation of a smart charging strategy for an electric vehicle fleet based on reinforcement learning. **Applied Energy**, Elsevier, v. 285, p. 116382, 2021.

VERZIILBERGH, Remco A et al. Network impacts and cost savings of controlled EV charging. **IEEE transactions on Smart Grid**, IEEE, v. 3, n. 3, p. 1203–1212, 2012.

WOODWARD, Michael et al. **Electric vehicle trends | Deloitte Insights**. English. [S.l.: s.n.], 2020. Disponível em:

<<https://www2.deloitte.com/uk/en/insights/focus/future-of-mobility/electric-vehicle-trends-2030.html>>. Acesso em: 3 mar. 2022.