



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA

DÁRIO MACEDO SOBRINHO

**GERENCIAMENTO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS EM
ESTAÇÃO PÚBLICA USANDO CONTROLE CONSENSO DISTRIBUÍDO**

FORTALEZA

2021

DÁRIO MACEDO SOBRINHO

GERENCIAMENTO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS EM ESTAÇÃO
PÚBLICA USANDO CONTROLE CONSENSO DISTRIBUÍDO

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Orientadora: Profa. Ph.D. Ruth Pastôra Saraiva Leão

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- M12g Macedo Sobrinho, Dário.
Gerenciamento de carregamento de veículos elétricos em estação pública usando controle consenso distribuído / Dário Macedo Sobrinho. – 2021.
75 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2021.
Orientação: Profa. Dra. Ruth Pastora Saraiva Leão.
1. Veículos elétricos. 2. Algoritmo de consenso. 3. Controle distribuído. 4. Otimização. 5. Posto de abastecimento elétrico. I. Título.

CDD 621.3

DÁRIO MACEDO SOBRINHO

GERENCIAMENTO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS EM ESTAÇÃO
PÚBLICA USANDO CONTROLE CONSENSO DISTRIBUÍDO

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Aprovada em: 02 de Dezembro de 2021

BANCA EXAMINADORA

Profa. Ph.D. Ruth Pastôra Saraiva
Leão (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Raimundo Furtado Sampaio
Universidade Federal do Ceará (UFC)

Prof. Prof. Dr. Giovanni Cordeiro Barroso
Universidade Federal do Ceará (UFC)

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

A Deus. A minha mãe, Célia. Ao meu pai,
Darsio. A todos que me apoiaram.

AGRADECIMENTOS

A Deus, por todas as coisas boas e más que aconteceram na minha vida. Cada uma delas, ao seu modo, me fizeram chegar aonde eu cheguei, enfrentando dificuldades e superando barreiras, que foram decisivos para minha formação profissional e, principalmente, pessoal.

Aos meus pais e toda a minha família, por toda força e suporte que me deram durante toda minha vida e, especialmente, durante essa trajetória acadêmica.

À professora Ruth, pelo apoio, orientação, compreensão e disponibilidade durante a realização deste trabalho. Aos professores da banca pelas considerações feitas com o intuito de melhorar o trabalho desenvolvido.

A todos os amigos que tive o prazer de conhecer durante a graduação e pós graduação, no GREI, GPEC, GPAR e DETI. Obrigado pelos momentos de discussões, troca de conhecimentos e descontração. Essa caminhada não teria sido a mesma sem vocês.

E à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo financiamento da pesquisa de mestrado via bolsa de estudos.

“Deus é o nome pelo qual designo tudo que se atravessa no caminho de minha obstinação de forma violenta e atrevida, tudo que atrapalha minhas opiniões, meus planos e intenções subjetivos e muda o curso da minha vida para o bem ou para o mal.”

(Carl Gustav Jung)

RESUMO

O crescente uso de Veículos Elétricos (VEs) nos últimos anos tem suscitado novos desafios à operação das redes elétricas de distribuição dado o acréscimo de carga e a natureza aleatória dos VEs. Neste contexto, muitos trabalhos têm destacado a técnica de multiagentes baseada em algoritmo de consenso distribuído para agregar ação coordenada e cooperativa de agentes no gerenciamento de VEs. Nesta dissertação é apresentado um algoritmo de consenso distribuído, cujo objetivo é controlar e otimizar o carregamento de múltiplos VEs em um posto de abastecimento elétrico. O algoritmo proposto faz uso das informações trocadas entre agentes vizinhos para otimizar o uso da potência elétrica do posto por meio da redução de perdas elétricas durante o carregamento. O controle distribuído, se comparado ao centralizado e descentralizado, é potencialmente mais eficiente e flexível no que se refere ao custo computacional e ao custo de comunicação. No trabalho são demonstradas a escalabilidade do método proposto quanto ao número de estações de carga de VEs do posto de abastecimento, a eficiência do carregamento quanto ao uso de potência de suprimento do posto e de atendimento ao cliente e a adaptabilidade do modelo a saídas e entradas aleatórias de VEs. Para tanto são apresentados três estudos de caso que demonstram a funcionalidade do método aplicado. São avaliados a convergência do algoritmo de consenso, o aproveitamento da potência utilizada em relação à potência fornecida, o nível de carregamento das baterias através do *State of Charge* (SOC) dos VEs. Os resultados obtidos evidenciam a adaptabilidade e escalabilidade do algoritmo, além de provar a efetividade da aplicação do método na coordenação do carregamento eficiente de VEs.

Palavras-chave: Veículos elétricos. Algoritmo de consenso. Controle distribuído. Otimização. Posto de abastecimento elétrico.

ABSTRACT

This dissertation aims to control and optimize the charging of multiple EVs in an electrical supply station, using the distributed consensus algorithm. The proposed algorithm uses the information exchanged between neighboring EVs to optimize the use of the station's electrical power by reducing electrical losses during charging. The proposed algorithm makes use of the information exchanged between neighboring VEs to carry out the charging process efficiently. The distributed control, when compared to centralized and decentralized, is potentially more efficient and flexible with regard to computational cost and communication cost. The work demonstrates the scalability of the proposed method regarding the number of EV charging stations at the station of supply, the efficiency of the charging in terms of the use of power supply from the station and customer service and the adaptability of the model to random outputs and inputs of EVs. For that, three case studies are presented that aim to demonstrate the functionality of the applied method. The convergence of the consensus algorithm, the utilization of the used power in relation to the supplied power, the battery charging level through the SOC of the are evaluated. The results obtained show the adaptability and scalability of the algorithm, in addition to proving the effectiveness of applying the method in coordinating the efficient charging of VEs.

Keywords: Electric vehicles. Consensus algorithm. Distributed control. Optimization. Electric Charging Station.

LISTA DE FIGURAS

Figura 1 – Linha temporal das referências base desta dissertação.	21
Figura 2 – Grafo não direcionado.	24
Figura 3 – Caminho.	24
Figura 4 – Conectividade.	25
Figura 5 – Matriz de adjacência.	26
Figura 6 – Matriz de graus.	27
Figura 7 – Matriz laplaciana.	28
Figura 8 – Estrutura de agentes e algoritmo de consenso.	30
Figura 9 – Camada de conexão física.	37
Figura 10 – Arquitetura de comunicação da Estação Pública de Carregamento.	38
Figura 11 – Saída do VE 3.	41
Figura 12 – Entrada do VE 11.	41
Figura 13 – Modelo da bateria em carregamento.	43
Figura 14 – Troca de informações entre agentes vizinhos.	54
Figura 15 – Custo incremental inicial para o Estudo de Caso 1.	58
Figura 16 – Desvio de potência para o Estudo de Caso 1.	59
Figura 17 – Corrente de referência e corrente de carregamento para o Estudo de Caso 1.	59
Figura 18 – Potência de carga dos VEs para o Estudo de Caso 1.	60
Figura 19 – SOC dos VEs para o Estudo de Caso 1.	61
Figura 20 – Potência total disponível e potência total consumida para o Estudo de Caso 1.	61
Figura 21 – Custo incremental inicial para o Estudo de Caso 2.	63
Figura 22 – Desvio de potência para o Estudo de Caso 1.	63
Figura 23 – Corrente de referência e corrente de carregamento para o Estudo de Caso 2.	64
Figura 24 – Potência de carga dos VEs para o Estudo de Caso 2.	64
Figura 25 – SOC dos VEs para o segundo caso.	65
Figura 26 – Potência total disponível e potência total consumida para o segundo caso.	65
Figura 27 – Custo incremental para 100 VEs.	67
Figura 28 – Desvio de potência para 100 VEs.	67
Figura 29 – Potência total disponível e potência total consumida para 100 VEs.	68
Figura 30 – SOC dos 30 VEs que saem e dos 10 VEs que entram.	68

LISTA DE TABELAS

Tabela 1 – Padrões de carregamento.	39
Tabela 2 – Fabricantes de VEs e padrões de carregamento.	40
Tabela 3 – Parâmetros iniciais utilizados.	47
Tabela 4 – Tempo de permanência.	47
Tabela 5 – Parâmetros e informações computacionais do Estudo de Caso 1.	58
Tabela 6 – Parâmetros e informações computacionais do Estudo de Caso 2.	62
Tabela 7 – Parâmetros e informações computacionais do Estudo de Caso 3.	66

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo de consenso padrão.	31
Algoritmo 2 – Algoritmo de consenso desenvolvido.	55

LISTA DE ABREVIATURAS E SIGLAS

VEs	Veículos Elétricos
SOC	<i>State of Charge</i>
TWh	Terawatt-hora
CVX	Biblioteca de Programação Convexa
PLI	Programação Linear Inteira
PLB	Programação Linear Binária
G2V	<i>Grid-To-Vehicle</i>
V2G	<i>Vehicle-To-Grid</i>
JADE	<i>Java Agent DEvelopment</i>
AIMD	<i>Additive-Increase-Multiplicative-Decrease</i>
ADMM	Método de Direção Alternada de Multiplicadores
KKT	Karush-Kuhn-Tucker
UEC	Unidade de Estação de Carregamento
ISO	<i>International Organization for Standardization</i>
IEEE	<i>International Electrotechnical Commission</i>
SAE	<i>Society of Automotive Engineers</i>
IWC	<i>Infrastructure Working Council</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Revisão bibliográfica	15
1.2	Objetivos	20
1.3	Contribuição	20
1.4	Artigo publicado	20
1.5	Estrutura do trabalho	21
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Teoria dos grafos	23
2.1.1	Conceitos sobre grafos	23
2.1.1.1	<i>Grafo não direcionado</i>	23
2.1.1.2	<i>Caminho</i>	24
2.1.1.3	<i>Número de vizinhos e grau</i>	24
2.1.1.4	<i>Conectividade</i>	25
2.1.2	Matriz de adjacência	25
2.1.3	Matriz de Graus	26
2.1.4	Matriz laplaciana	26
2.1.5	Teoremas usados	28
2.1.5.1	<i>Teorema do círculo de Gershgorin</i>	28
2.1.5.2	<i>Teorema de Perron-Frobenius</i>	28
2.2	Algoritmo de consenso	29
2.2.1	Modelagem do algoritmo de consenso	30
2.2.2	Algoritmo de consenso em tempo discreto	30
2.2.2.1	<i>Convergência do algoritmo de consenso</i>	31
2.2.3	Algoritmo de consenso com variável de feedback	33
2.2.4	Matriz de peso	33
2.2.4.1	<i>Método uniforme</i>	34
2.2.4.2	<i>Método de metropolis</i>	34
2.2.4.3	<i>Método da metrópolis média</i>	34
2.3	Multiplicadores de Lagrange	35
2.4	Considerações finais	35

3	DEFINIÇÃO E MODELAGEM DO PROBLEMA DE CARREGAMENTO EFICIENTE DE VEÍCULOS ELÉTRICOS	37
3.1	Definição do problema	37
3.1.1	<i>Padrão de carregamento</i>	38
3.1.1.1	<i>Normas relacionadas ao carregamento de VEs</i>	39
3.1.2	<i>Alteração da rede de comunicação</i>	41
3.2	Modelagem matemática do problema	42
3.3	Parâmetros iniciais dos VEs	46
3.3.1	<i>Tempo de permanência dos VEs</i>	47
3.4	Algoritmo utilizado	48
3.4.1	<i>Inicialização do algoritmo de consenso</i>	48
3.4.2	<i>Regra de iteração do algoritmo de consenso</i>	49
3.4.3	<i>Análise da convergência do algoritmo</i>	50
3.4.4	<i>Critério de parada para o algoritmo de consenso</i>	51
3.4.5	<i>Alteração do coeficiente de ganho</i>	52
3.4.6	<i>Restrições de potência</i>	52
3.4.7	<i>Troca de informação entre os agentes vizinhos</i>	53
3.4.8	<i>Implementação do algoritmo desenvolvido</i>	55
3.4.9	<i>Descrição do algoritmo desenvolvido</i>	56
3.5	Hardware e Software Utilizados	56
3.6	Considerações finais	56
4	RESULTADOS E DISCUSSÕES DO PROBLEMA DE CARREGAMENTO EFICIENTE DE VEÍCULOS ELÉTRICOS	57
4.1	Estudo de caso 1	57
4.2	Estudo de caso 2	61
4.3	Estudo de caso 3	65
5	CONCLUSÃO E TRABALHOS FUTUROS	69
5.1	Trabalhos futuros	70
	REFERÊNCIAS	71

1 INTRODUÇÃO

Descarbonização, descentralização, digitalização e democratização são quatro vetores que podem acelerar o ritmo de transição energética global e mudando a forma como vivemos. Dentre os diferentes setores da economia, o transporte é um dos principais contribuintes para as emissões de gases de efeito estufa e a mobilidade urbana tem apresentado uma expansão considerável nos últimos anos (KUMAR; ALOK, 2020; TAYARANI *et al.*, 2018; ENERGIA, 2021).

Alguns países já apresentam um crescimento considerável na quantidade de VEs, se considerada a porcentagem de novos VEs adquiridos. De acordo com Richter (2021), mais de 50% dos novos veículos adquiridos na Noruega em 2020 foram VEs em resposta à política governamental do país. Considerando projeções futuras a nível global, o número de VEs deverá expandir de 8 milhões em 2019 para 50 milhões em 2025 e 140 milhões em 2030 a nível mundial, excluindo-se dessa análise VEs de duas e três rodas, correspondendo a um crescimento anual médio de 30%. De forma concomitante, a demanda de energia referente aos VEs é projetada para alcançar quase 550 Terawatt-hora (TWh) em 2030 (OUTLOOK, 2020).

Essas projeções sugerem que os VEs irão desempenhar um importante papel no sistema de potência nos próximos anos. Tendo isso em vista, há a necessidade de torná-los mais competitivos em relação aos veículos de combustão e, conseqüentemente, há também a necessidade de se adequar a novos desafios que a inserção do transporte elétrico na vida cotidiana irá causar (DAS *et al.*, 2020).

Diversos estudos relacionam os principais impactos que a inserção do transporte elétrico no mercado pode causar. Estudos em relação à infraestrutura de carregamento (CHEN *et al.*, 2017; DORCEC *et al.*, 2019), políticas e incentivos (SIERZCHULA *et al.*, 2014; BJERKAN *et al.*, 2016; MELTON *et al.*, 2017), modelo de negócio (WU, 2019; NIAN *et al.*, 2019; YOON *et al.*, 2019), previsão de demanda (LEE *et al.*, 2019; JAHANGIR *et al.*, 2019), gerenciamento de baterias (LIU *et al.*, 2022), integração dos VEs à rede (WENZEL *et al.*, 2017; TENG *et al.*, 2016), entre outros.

A integração dos VEs à rede elétrica de distribuição traz como principal desafio ao sistema elétrico a forma em como se dará o carregamento desses VEs. O carregamento de VEs pode ser não gerenciado ou gerenciado através de uma estratégia de carregamento. O não gerenciamento funciona de forma independente à oferta e à demanda de energia elétrica e, portanto, é mais susceptível a causar impactos significativos à rede elétrica quando um grande

número de VEs está envolvido no carregamento. Aumento de perdas elétricas, queda de tensão, sobrecarga, circulação de correntes harmônicas, aumento de temperatura e de aceleração do envelhecimento de transformadores estão entre os principais impactos (ZHENG *et al.*, 2019).

Já as estratégias que utilizam gerenciamento de carregamento são utilizadas com o propósito de carregar uma grande quantidade de VEs a fim de não causar estresse no sistema de distribuição. Além disso, se bem gerenciados por uma estratégia eficiente de carregamento, os VEs podem beneficiar o sistema de distribuição (XU, 2014).

1.1 Revisão bibliográfica

Com o intuito de mitigar o impacto causado pelo carregamento de VEs nas redes elétricas de distribuição, diferentes estratégias de controle de carregamento vêm sendo propostas na literatura. Em relação à arquitetura de controle utilizada, as estratégias de coordenação de carregamento são classificadas em centralizada, descentralizada e distribuída (DAS *et al.*, 2020).

No controle centralizado de carregamento, tem-se uma única unidade central de controle, responsável por gerenciar a potência e o tempo de carregamento dos VEs através da otimização de uma dada função objetivo.

Qi *et al.* (2020) utilizam um método de modelagem denominado equação diferencial parcial para regular a potência de um grupo de VEs centralizados. O método desenvolvido é executado através de uma divisão do SOC da bateria dos VEs em intervalos finitos. Através dessa divisão do SOC, os VEs são então agrupados e a equação diferencial parcial é utilizada para realizar essa modelagem e realizar a regulação de potência dos VEs. Todas as simulações são realizadas através do MATLAB.

Sortomme *et al.* (2010) relacionam fator de carga e variação de carga em um problema de otimização, que minimiza as perdas em alimentadores enquanto realiza o carregamento de VEs. Em He *et al.* (2012), os autores propõem a minimização dos custos de carregamento de VEs através de um controlador central responsável por gerenciar informações de diferentes grupos de VEs. Ambos os trabalhos utilizam a Biblioteca de Programação Convexa (CVX) do MATLAB para otimização.

Os autores em Nguyen *et al.* (2014) propõem uma estratégia de coordenação de carregamento que utiliza Programação Linear Inteira (PLI) e Programação Linear Binária (PLB) para minimizar os custos com eletricidade de uma estação de carregamento.

Vagropoulos e Bakirtzis (2013) desenvolveram uma estratégia ótima para agregadores

de VEs que participam do mercado do dia seguinte e mercados de regulação. Para isso, utilizam um método de programação linear estocástica.

Os autores em Soares *et al.* (2014) desenvolveram uma estratégia de gerenciamento de carregamento em tempo real de VEs, que combina um método de otimização heurístico e otimização linear. Kang *et al.* (2013) utilizam o algoritmo *Earliest Deadline First* em uma estratégia de carregamento global em tempo real.

Em Tikka *et al.* (2016), os autores propõem uma metodologia para carregamento de VEs que minimiza a emissão de CO₂ de forma concomitante à minimização do custo de carregamento, utilizando o método Simplex para otimização.

Embora de fácil aplicação prática, o controle centralizado lida com diversas variáveis e sua aplicação para uma larga escala de VEs resulta em um elevado custo computacional e de comunicação, além de baixa tolerância à falha em caso de perda da unidade central (ZHENG *et al.*, 2019).

O controle descentralizado de carregamento de VEs, em sua maioria é caracterizado pela hierarquização da estrutura de controle, requerendo determinado nível de comunicação entre os diferentes dispositivos do sistema.

Munoz e Jabbari (2020) propõem um protocolo de carregamento para um local de trabalho, no qual cada VE gera seu próprio perfil de carregamento através de uma estratégia descentralizada. Utilizando programação linear, os autores conseguem reduzir os custos de eletricidade, a quantidade de picos de carregamento e o número de soquetes de carregamento necessários no local de trabalho.

Lakshminarayanan *et al.* (2018) propõem a utilização de um gerenciador inteligente para a realização de um agendamento ótimo das operações de *Grid-To-Vehicle* (G2V) e *Vehicle-To-Grid* (V2G) de uma microrrede. Para tanto, os autores utilizam o algoritmo *Random Forest* e a plataforma de sistema multiagente *Java Agent DEvelopment* (JADE). Os autores obtêm resultados satisfatórios e os validam, utilizando dois *hardware-in-the-loop*.

Moschella *et al.* (2020) desenvolvem um algoritmo denominado *Additive-Increase-Multiplicative-Decrease* (AIMD) de forma descentralizada para coordenar a taxa de carregamento de VEs. O algoritmo utilizado pelos autores não utiliza as estações de carregamento para comunicar nenhuma informação. As simulações descritas no trabalho são baseadas em um sistema de potência com 39 barras.

Em Teng *et al.* (2016), um controlador descentralizado é desenvolvido para mitigar

os impactos de carregamento em redes de distribuição. O controlador utiliza lógica *fuzzy* para integrar as medidas realizadas e ajustar a corrente de carregamento a fim de alcançar o seu objetivo. Simulações e experimentos são realizados, comprovando a aplicabilidade do método desenvolvido.

Cortés e Martínez (2016) desenvolveram um algoritmo descentralizado de controle de carregamento orientado pelo preço de energia, que obtém estratégias de carregamento, conforme os VEs ajustam sua estratégia em relação a uma informação de preço. O algoritmo proposto obtém soluções ótimas no que concerne à minimização de custos de energia consumida por VEs e outras cargas.

Ma *et al.* (2016) desenvolveram um algoritmo descentralizado que visa criar uma relação entre os custos de geração e o custo de carregamento dos VEs. Para isso, os VEs determinam suas estratégias de carregamento com base em um perfil de preço comum a todos os participantes do algoritmo, posteriormente esse perfil de preço é atualizado e o algoritmo obtém uma estratégia de carregamento eficiente (socialmente ótima).

Zhan *et al.* (2015) propõem um algoritmo que utiliza o conceito de matriz de transição de probabilidade para preencher a curva de carga de determinado agregador em um período noturno. Os resultados evidenciam que o algoritmo consegue criar estratégias de carregamento adequadas para os VEs com poucas iterações, demonstrando que pode ser implementado em aplicações em tempo real.

A estratégia de controle distribuído não requer a existência de controlador central, como a estratégia centralizada, e também não requer hierarquização na estrutura de controle, como a estratégia descentralizada. A comunicação é local e acontece entre agentes próximos uns aos outros de acordo com a camada de conexão que interliga os agentes a seus vizinhos. Por sua vez, o custo computacional e o custo de comunicação é mais flexível e eficiente, caso comparado às estratégias centralizada e descentralizada.

Khaki *et al.* (2018) desenvolveram uma estratégia de carregamento utilizando um algoritmo baseado no Método de Direção Alternada de Multiplicadores (ADMM) cujo objetivo é minimizar a variação de carga e os custos de carregamentos de VEs. Os autores validam seus resultados em um estudo de caso com 4 alimentadores e 60 VEs.

Xu *et al.* (2021) propõem uma estratégia baseada em *blockchain* para carregamento de veículos elétricos. A utilização do *blockchain* assegura que informações não sejam acessadas por terceiras partes, protegendo assim dados privados dos usuários de VEs, assim como eliminar

a dependência dos equipamentos responsáveis por realizar o carregamento de VEs no que se refere à troca de informações.

Através do controle exercido pelas estações de carregamento nos perfis de carregamento e descarregamento de VEs, Chen e Cheng (2014) conseguiram minimizar a diferença entre geração e carga (composta por VEs e outras cargas). Para isso, utilizam um algoritmo baseado no ADMM estocástico. Os resultados demonstraram que o método desenvolvido ajuda na regulação de frequência .

Hu *et al.* (2016) apresentam um algoritmo distribuído que utiliza um método subgradiente para minimizar os custos de carregamento de VEs em agregadores e responder às requisições individuais de energia para VEs em um período de 24 horas. Em Fan *et al.* (2017), os autores propõem um algoritmo distribuído baseado no ADMM, usado para decompor o múltiplo fluxo de carga otimizado em duas etapas resolvidas de forma alternativa e iterativa.

Apesar de ser bastante utilizada na literatura mais recente, a família de algoritmos derivado do ADMM possui um custo computacional alto, pois eles precisam de uma solução para problemas sub-ótimos a cada iteração. Algumas variantes do ADMM podem aliviar esse custo computacional, mas, ainda assim, apresentam dificuldades na implementação dos algoritmos em relação a outros algoritmos distribuídos (YUAN *et al.*, 2018).

Dentre os algoritmos distribuídos, o algoritmo de consenso vem se destacando nos últimos anos com pesquisas em diversas áreas (computação científica, fusão de sensores distribuídos, por exemplo) (OLFATI-SABER *et al.*, 2007).

Em seu trabalho, Zou *et al.* (2017) exploram a coordenação do comportamento do carregamento de VEs sobre um horizonte de tempo finito, usando um protocolo completamente distribuído. Para tanto, é realizada uma estratégia descentralizada motivada por um modelo em tempo real de preço, no qual os VEs participantes simultaneamente determinam a sua estratégia ótima de carregamento em relação a uma informação de preço prevista. Essas estratégias de carregamento propostas são usadas para estimar a demanda total do sistema, que, por sua vez, é utilizada para atualizar o perfil de preço.

Mohammadi *et al.* (2016) utilizam o algoritmo de consenso para chegar a uma decisão em grupo referente a um sinal de preço incremental para a energia fornecida, o qual é transmitido entre os VEs. Além disso, os autores levam em consideração restrições locais referentes aos VEs. O algoritmo desenvolvido também se destaca por: apresentar uma solução factível a cada iteração; não há a necessidade de atualizar todos os multiplicadores de Lagrange;

solução “escalável”, podendo ser aplicada a um grande número de VEs.

Os autores em Rahbari-Asr e Chow (2014) desenvolvem um trabalho que utiliza o algoritmo de consenso, visando realizar o carregamento de VEs através da maximização do SOC de cada VE. A função objetivo é simplificada em uma função não linear e resolvida pelo método de Karush-Kuhn-Tucker (KKT). Simulações de Monte Carlo são realizadas demonstrando a escalabilidade do método.

Gusrialdi *et al.* (2017) desenvolveram um algoritmo de consenso cujo objetivo é otimizar a operação de uma rede com vários postos de carregamento, fazendo com que a potência de todas as estações de carregamento ao longo de uma rodovia sejam utilizadas de maneira uniforme. O trabalho ainda minimiza o tempo total de espera por postos de carregamento.

Yang *et al.* (2012) desenvolveram um algoritmo distribuído baseado no protocolo de consenso. O algoritmo controla a potência fornecida a subestações e a VEs, objetivando regular a frequência nas barras das subestações. Os resultados são validados por meio de simulações em diferentes estruturas de comunicação não resistentes a falhas de comunicação.

Em Xu (2014) e Wang e Chen (2019), o algoritmo de consenso é utilizado de forma a alocar uma quantidade de potência para o carregamento de VEs. O carregamento acontece através da troca de informações entre os agentes em relação ao custo incremental da função objetivo, responsável por minimizar as perdas de potência causadas pela resistência interna da bateria através do compartilhamento da variável de Lagrange entre os agentes do problema. Em Wang e Chen (2019), os autores ampliam o trabalho ao considerar aleatoriedade na definição do problema e realizar além do carregamento, o fornecimento de potência dos VEs para a rede. Ambos os trabalhos testam e validam seus resultados em simulações e os validam em diferentes estudos de caso, demonstrando a escalabilidade do algoritmo para grandes quantidades de VEs. Os trabalhos também se caracterizam por permitir a alteração da rede de comunicação que interliga os VEs, provando serem adaptáveis a saídas aleatórias de VEs.

Diversas estratégias de carregamento vêm sendo propostas na literatura. Neste trabalho, é proposta uma estratégia de carregamento eficiente de VEs que utiliza um algoritmo distribuído de consenso e permite a saída e entrada aleatória de VEs de uma estação de carregamento.

1.2 Objetivos

Esta Dissertação tem por objetivo geral apresentar a aplicação de algoritmo de consenso distribuído como estratégia de controle e otimização para gerenciar o carregamento de VEs, visando a redução de perdas elétricas em uma estação pública de carregamento.

Os objetivos específicos consistem em demonstrar a escalabilidade do método proposto quanto ao número de VEs, realizar eficientemente o carregamento dos VEs, além de aproveitar integralmente a quantidade de potência fornecida pela estação de carregamento e possuir adaptabilidade a saídas e entradas aleatórias de VEs.

1.3 Contribuição

Tomando como principais referências os trabalhos de Xu (2014) e Wang e Chen (2019), neste trabalho é proposto um sistema de carregamento de VEs que permite a entrada e a saída aleatória de VEs durante o processo de carregamento, sendo a entrada aleatória de VEs um diferencial não abordado nas referências citadas. Além disso, ainda que não seja utilizado um coeficiente de ganho ótimo devido ao caráter aleatório do problema, uma metodologia de mudança do coeficiente de ganho inspirada em Wang *et al.* (2018) foi utilizada. Como resultado da pesquisa feita inicialmente, considerando carregamento e saídas aleatórias, os resultados foram expostos em (SOBRINHO *et al.*, 2020) que se refere a uma publicação em congresso de resultados dessa dissertação.

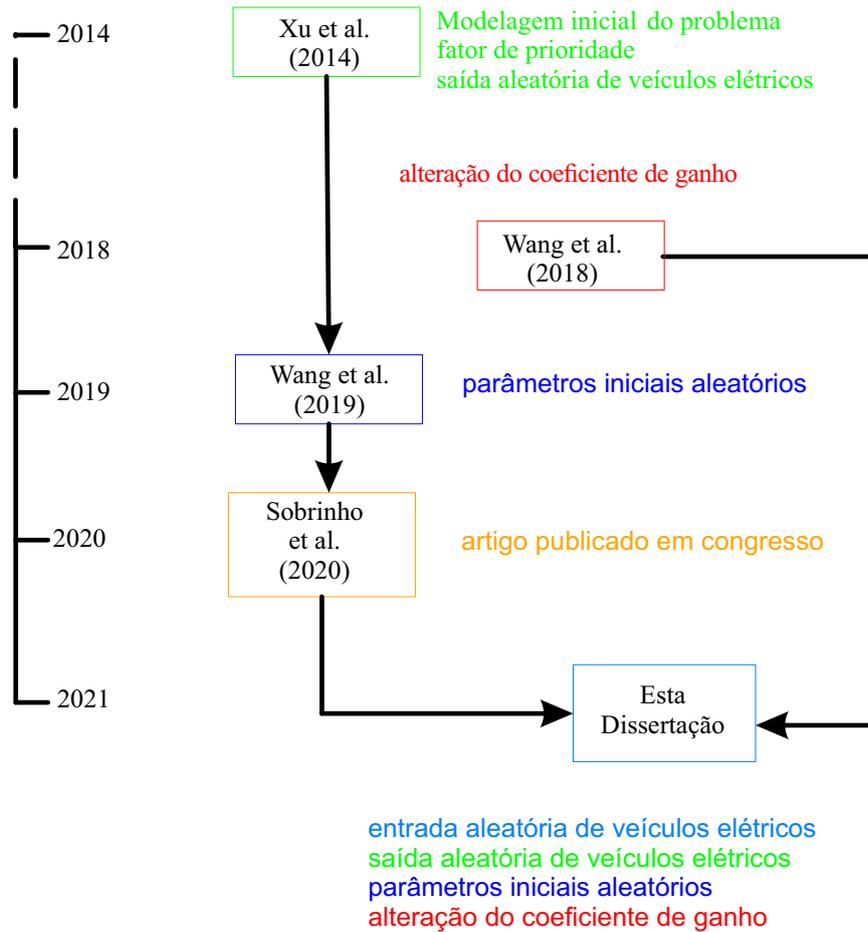
Na Figura 1 é apresentada uma linha do tempo das principais inspirações para o desenvolvimento desta dissertação.

1.4 Artigo publicado

Publicação originária desta pesquisa:

SOBRINHO, D. M.; ALMADA, J. B.; LEÃO, R. P.; SAMPAIO, R. F. Carregamento Eficiente de Veículos Elétricos usando Algoritmo de Consenso. In: Congresso Brasileiro de Automática-CBA. 2020.

Figura 1 – Linha temporal das referências base desta dissertação.



Fonte: Autoria própria.

1.5 Estrutura do trabalho

Esta dissertação está dividida em cinco capítulos, conforme apresentado nos parágrafos a seguir.

No Capítulo 1 foi apresentada uma introdução sobre o tema, levando em consideração aspectos importantes que evidenciam o crescimento da frota de VEs e a necessidade de adequação da rede de distribuição para atender com confiabilidade a nova carga elétrica emergente. Ainda no Capítulo 1 foi apresentada a revisão bibliográfica de trabalhos relacionados ao carregamento de VEs utilizando diferentes estratégias de solução, bem como a principal contribuição deste trabalho e o artigo publicado em congresso originário do estágio inicial dessa pesquisa.

No Capítulo 2 são apresentados os fundamentos teóricos que permeiam a realização dessa pesquisa. Sendo assim, são apresentadas noções básicas sobre o algoritmo de consenso e o seu funcionamento; também são apresentados conceitos básicos de teoria dos grafos e de variável de Lagrange.

No Capítulo 3, o problema a ser investigado nessa dissertação é apresentado, assim como a modelagem matemática do problema, a definição dos parâmetros iniciais do problema. Detalhes da implementação do algoritmo desenvolvido também são discutidos, assim como o funcionamento do algoritmo.

No Capítulo 4 são apresentados os resultados obtidos com a aplicação do algoritmo. Três estudos de caso são apresentados e visam mostrar a efetividade do algoritmo de consenso na resolução do problema. As características de adaptabilidade e a eficiência do método são discutidas.

No Capítulo 5 são apresentadas as principais conclusões obtidas a partir dos estudos de caso apresentados, assim como perspectivas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os principais fundamentos teóricos que regem a realização deste trabalho. São eles: teoria dos grafos, uma breve introdução sobre os algoritmos de consenso e o seu uso, e multiplicadores de Lagrange.

2.1 Teoria dos grafos

Um grafo é um conjunto de nós e arestas. As arestas indicam a quantidade de possíveis caminhos para a chegada de um nó ao outro. Nesse trabalho, o grafo é utilizado para representar a conectividade de uma rede de comunicação (MIRALLES, 2014).

A Equação (2.1) define um grafo G como

$$G = (V, E) \quad (2.1)$$

em que

- V representa um conjunto de nós;
- E representa um conjunto de arestas;

O conjunto de nós $V = \{1, 2, \dots, n\}$ representa os elementos contidos no grafo, enquanto o conjunto de arestas $E = (i, j) \subseteq V \times V$ representa a conexão do nó i com o nó j .

2.1.1 Conceitos sobre grafos

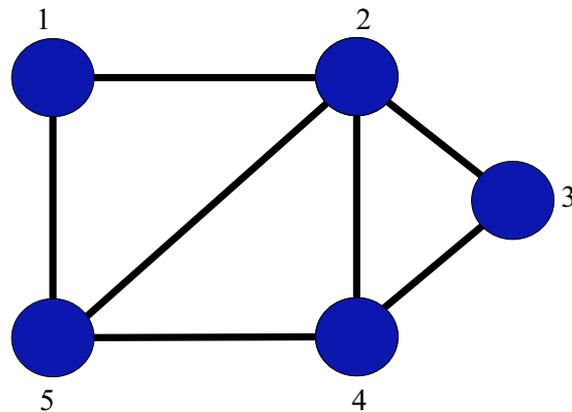
2.1.1.1 Grafo não direcionado

Um grafo não direcionado se caracteriza por ter seus nós conectados por arestas de modo que a informação que é transmitida entre os nós não possui direção fixa, ou seja, o nó i consegue alcançar o nó j e eles conseguem obter informação um do outro (MIRALLES, 2014). Isso pode ser definido pela Equação (2.2)

$$e_{ij} = e_{ji} \quad (2.2)$$

Utilizando como exemplo o grafo da Figura 2 que contém $V = 1, 2, 3, 4, 5$ e $E = (1, 2), (1, 5), (2, 3), (2, 4), (2, 5), (3, 4)$, pode-se ver que o nó 1 é conectado ao nó 2 e ao nó 5, sendo possível estabelecer uma conexão entre os dois nós.

Figura 2 – Grafo não direcionado.

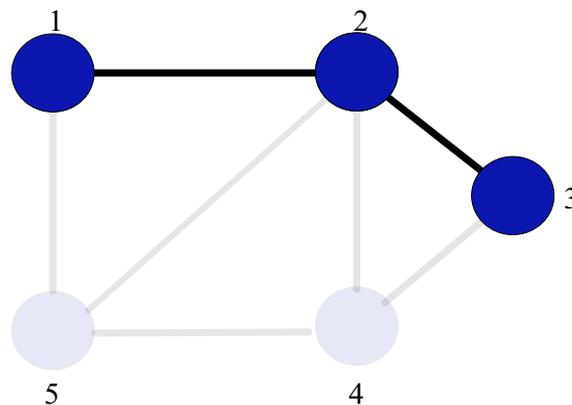


Fonte: Autoria própria.

2.1.1.2 Caminho

Um caminho é uma sequência finita ou infinita de vértices e arestas alternados um dos outros, começando e terminando por vértices (MIRALLES, 2014). Na Figura 3 é mostrado um caminho unindo o nó 1 ao nó 3.

Figura 3 – Caminho.



Fonte: Autoria própria.

2.1.1.3 Número de vizinhos e grau

O conjunto de vizinhos de um nó i , Ω_i , contém os nós que estão a seu alcance. O conjunto de vizinhos para um grafo não direcionado pode ser definido pela Equação (2.3)

$$\Omega_i = \{j \in V | (i, j) \in E\} \quad (2.3)$$

em que a Equação (2.3) significa que o nó j pertence ao conjunto de vizinhos do nó i se e somente se existe uma aresta os conectando.

O número de elementos no conjunto de vizinhos de i é o grau do nó i , d_i , que está representado na Equação (2.4)

$$d_i = \|\Omega_i\| \quad (2.4)$$

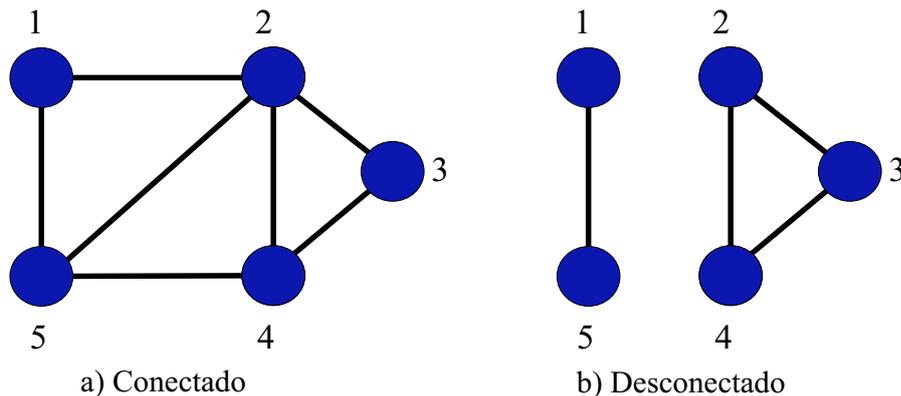
No exemplo da Figura 4a, o conjunto de vizinhos do nó 1, Ω_1 , é (2,5) e o seu grau é igual a 2.

2.1.1.4 Conectividade

Dois nós estão conectados, caso exista, no mínimo, um caminho os unindo. Assim sendo, um grafo G é conectado se existe ao menos um caminho conectando cada nó a todos os outros. Em qualquer outro caso, o grafo G está desconectado (MIRALLES, 2014).

Na Figura 4 é apresentada uma comparação entre um grafo conectado e um grafo desconectado. É válido observar como a partir de qualquer nó do grafo apresentado na Figura 4a é possível chegar em qualquer outro nó, já no grafo apresentado na Figura 4b isso não é possível.

Figura 4 – Conectividade.



Fonte: Autoria própria.

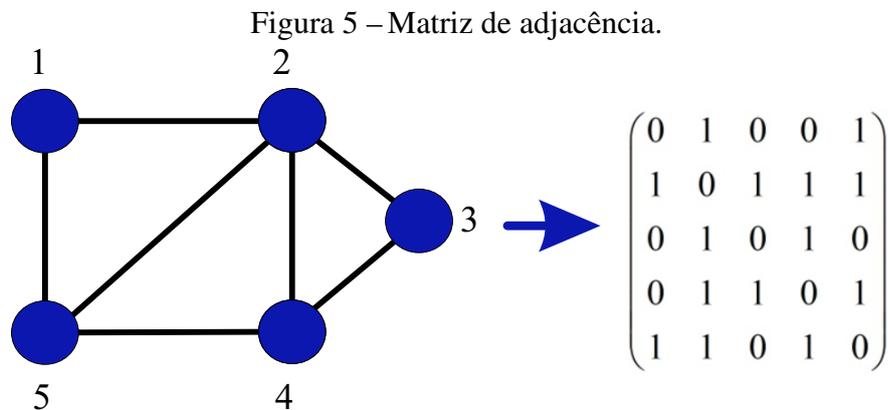
2.1.2 Matriz de adjacência

Uma matriz de adjacência A é uma forma de definir um grafo G pelas entradas de uma matriz. As arestas conectadas são iguais a um e arestas não conectadas iguais a zero. A

dimensão da matriz A tem $I \times I$, em que $I = |V|$ é o número de nós do grafo (MIRALLES, 2014). A Equação (2.5) define a construção da matriz A como

$$A_{ij} = \begin{cases} 1, & \text{para } (i, j) \in E \\ 0, & \text{caso contrário} \end{cases} \quad (2.5)$$

Já que o grafo é não direcionado, a matriz A é sempre simétrica. Com o exemplo utilizado, a matriz de adjacência do pode ser definida por meio do grafo na Figura 5.



Fonte: Autoria própria.

2.1.3 Matriz de Graus

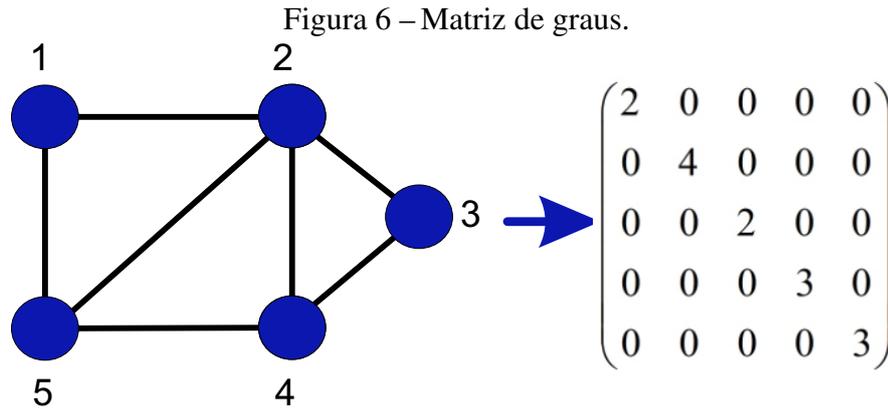
A matriz de graus D consiste em uma matriz diagonal contendo o número de vizinhos Ω_i . Os elementos da matriz de graus podem ser calculados através do somatório das linhas ou colunas da matriz de adjacência. Dessa forma, a matriz de graus pode ser definida através da Equação (2.6)

$$D_{ij} = \begin{cases} \Omega_i, & \text{para } i = j \\ 0, & \text{caso contrário} \end{cases} \quad (2.6)$$

Pode-se representar a matriz de graus do grafo na Figura 6.

2.1.4 Matriz laplaciana

No campo matemático da teoria dos grafos, a matriz laplaciana, às vezes chamada matriz de admitância, matriz Kirchhoff ou laplaciano discreto, é uma representação matricial de



Fonte: Autoria própria.

um grafo. É definida através da Equação (2.7)

$$L_{ij} = \begin{cases} d_i, & \text{para } i = j \\ -1, & \text{para } i \neq j \text{ e } (i, j) \in E \\ 0, & \text{caso contrário} \end{cases} \quad (2.7)$$

A Equação (2.7) também pode ser representada de forma matricial através da Equação (2.8)

$$L = D - A \quad (2.8)$$

em que

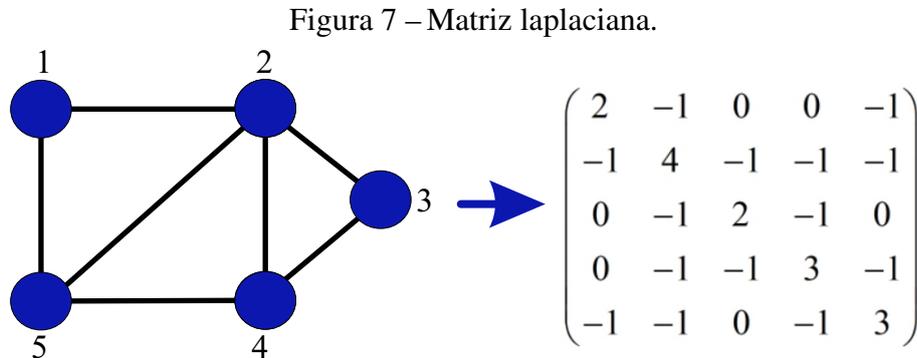
- D é a matriz de graus;
- A é a matriz de adjacência.

A matriz Laplaciana, L , possui algumas propriedades em relação a grafos não direcionados, que são importantes para aplicações que utilizam agentes (MIRALLES, 2014).

São essas as propriedades:

- L é simétrica;
- L é semi-definida positiva;
- L possui n autovalores reais não negativos, em que o autovalor mínimo é igual a zero;
- Para grafos não direcionados conectados, a soma das linhas e das colunas da matriz laplaciana é igual a 0;
- Todos os autovalores de L no plano complexo são localizados em um disco centralizado no ponto $\delta + 0j$ com raio de $\delta = \max(d_i)$, isto é, o grau máximo do grafo.

Na Figura 7 é apresentada a matriz laplaciana do grafo que vem sendo usado como exemplo.



Fonte: Autoria própria.

2.1.5 Teoremas usados

Os teoremas a seguir são apresentados uma vez que são usados para validar o algoritmo de consenso desenvolvido na sequência.

2.1.5.1 Teorema do círculo de Gershgorin

De acordo com Shalimoon (2018), o teorema do círculo de Gershgorin se refere a um disco no qual todos os autovalores da matriz A estão incluídos.

Teorema 2.1.1 *Se a_{ij} representa os coeficientes da matriz A de dimensão $n \times n$, e R_i é definido para cada linha de A por $R_i = \sum_{j \neq i} |a_{ij}|$, $1 \leq i \leq n$, todo autovalor de A pertence a pelo menos um dos discos centralizados em a_{ii} com um raio de R_i , ou seja, os autovalores da matriz A são representados pela união dos círculos de Gershgorin.*

A Equação (2.9) ilustra a união dos círculos de Gershgorin,

$$G(A) = \bigcup_{i=1}^n \{z \in \mathbb{C} : |z - a_{ii}| \leq R_i(A)\}. \quad (2.9)$$

2.1.5.2 Teorema de Perron-Frobenius

De acordo com Mårtensson e Sjövall (2011), o teorema de Perron-Frobenius garante que o autovalor de uma matriz A com o maior módulo tenha multiplicidade algébrica unitária.

Teorema 2.1.2 Sendo $S \geq 0$ uma matriz irredutível, existe um único número real positivo λ_1 com as seguintes propriedades:

- Existe um único vetor de valores reais, $u > 0$, tal que $Au = \lambda_1 u$;
- λ_1 tem multiplicidade algébrica e geométrica igual a 1;
- $\lim_{k \rightarrow \infty} \frac{1}{\lambda_1^k} S^k = uv^T$, em que u e v são os autovetores direito e esquerdo, correspondendo a λ_1 tal que $v^T u = 1$.

2.2 Algoritmo de consenso

Os problemas de consenso vêm sendo estudados, de maneira formal, desde a década de 1960, formando inclusive um novo campo de estudo denominado computação distribuída. Em uma rede de comunicação, consenso é definido como um acordo entre múltiplos agentes em relação a determinada variável compartilhada. Quando essa condição é satisfeita, é dito que os agentes alcançaram o consenso. Para tanto, os agentes negociam entre si através de métodos denominados algoritmo (protocolo) de consenso (OLFATI-SABER *et al.*, 2007).

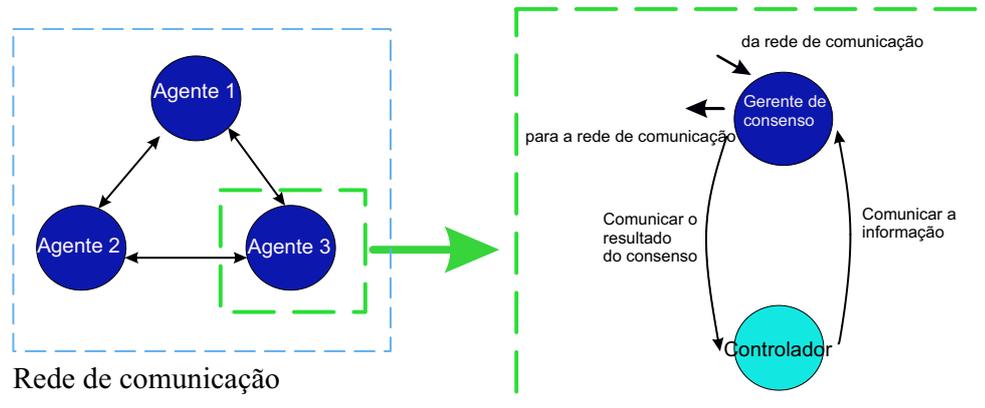
Em um exemplo cotidiano de um problema de consenso, pode-se imaginar uma reunião para jantar de um grupo de amigos. Há, portanto, a necessidade de se definir um horário para que esse grupo de amigos possa vir a se encontrar. Os amigos (agentes) devem então compartilhar entre si o horário no qual devem se encontrar (informação a ser compartilhada).

Enquanto uma solução centralizada iria precisar de uma chamada de conferência entre os amigos, uma solução distribuída para o problema seria a realização de uma chamada por cada indivíduo para um subconjunto do grupo (REN; BEARD, 2008).

Dessa forma, a informação compartilhada entre os amigos é atualizada de forma ponderada com a sua própria informação e a informação de quem o agente está conversando.

Na Figura 8 é apresentada uma estrutura simplificada de agentes integrados por meio do algoritmo de consenso. Nessa estrutura, cada agente possui um controlador local e um gerente de consenso. O controlador envia a informação a ser compartilhada ao gerente de consenso; Este último, por sua vez, é responsável por negociar com os agentes vizinhos através da rede de comunicação, utilizando um algoritmo de consenso. Com isso, o gerente de consenso obtém o resultado do consenso e informa essa decisão ao controlador que, por sua vez, ajusta sua ação em relação à informação recebida (ZHANG; CHOW, 2011).

Figura 8 – Estrutura de agentes e algoritmo de consenso.



Fonte: Adaptado de (ZHANG; CHOW, 2011).

2.2.1 Modelagem do algoritmo de consenso

O algoritmo de consenso pode ser modelado por um modelo em tempo contínuo ou por um modelo em tempo discreto. Quando a informação compartilhada está disponível de maneira instantânea, o modelo em tempo contínuo é utilizado; por outro lado, quando a informação está disponível através de pacotes de dados discretos, o modelo em tempo discreto é utilizado (REN; BEARD, 2008).

O algoritmo de consenso em tempo discreto é utilizado nesta dissertação. A sua característica de envio de informações em tempo discreto se adequa ao problema do carregamento eficiente de VEs.

2.2.2 Algoritmo de consenso em tempo discreto

O algoritmo de consenso pode ser definido, de forma matemática, por meio da Equação (2.10):

$$x_i[t + 1] = \sum_{j=1}^N w_{ij}[t]x_j[t], \quad i = 1, \dots, N, \quad (2.10)$$

Ou de forma matricial por meio da Equação (2.11):

$$x_i[t + 1] = W[t]x[t] \quad (2.11)$$

em que, nas equações (2.10) e (2.11) tem-se:

- $x[t] = (x_1[t], x_2[t], \dots, x_N[t])$ é o vetor de informação de todos os agentes $x_i[t]$ na iteração t ;
- $x_i[t + 1]$ é a informação atualizada na iteração $t + 1$;
- $W[t] \in \mathbb{R}^{N \times N}$ é denominada de matriz de pesos e se caracteriza por descrever a rede de comunicação na qual os agentes estão presentes. Informações sobre a matriz de pesos são apresentadas na seção 2.2.4.

O algoritmo de consenso é utilizado nessa dissertação para ser executado durante t iterações em k instantes de tempo. Dessa forma há uma relação entre o tempo de discretização do problema de carregamento eficiente de VEs e as iterações do algoritmo de consenso. Em cada instante de tempo, k , há a execução de t vezes o algoritmo de consenso.

O Algoritmo 1 descreve o processo padrão de funcionamento do algoritmo de consenso.

Algoritmo 1: Algoritmo de consenso padrão.

Na iteração t , cada agente obtém determinada informação inicial, $x_i[0]$;

Para as iterações $t = 1, 2, \dots$;

Passo 1: Cada agente recebe a informação de seus vizinhos, isto é, cada agente x_i recebe informação de $x_j[t] \forall j \in \Omega_i$, conjunto de vizinhos do agente i ;

Passo 2: O agente i multiplica a informação recebida de seus vizinhos com determinado peso, w_{ij} , e a sua própria informação, w_{ii} ;

Passo 3: O agente i combina a informação recebida com a sua própria informação, ou seja, $x_i[t + 1] = w[t]_{ii}x_i[t] + \sum_{j \in \Omega_i} w[t]_{ij}x_j[t]$;

Passo 4: O agente i envia a informação $x_i[t + 1]$ e o processo se repete.

2.2.2.1 Convergência do algoritmo de consenso

Em Slučiak (2013), é fornecida uma prova da convergência do algoritmo de consenso da Equação (2.10). A sua convergência implica que $\lim_{t \rightarrow \infty} x[t]$ existe, $\forall x[0] < \infty$, ou seja,

$$\lim_{t \rightarrow \infty} x[t] = \lim_{t \rightarrow \infty} W^t x[0] = x^*. \quad (2.12)$$

em que x^* representa a convergência do algoritmo de consenso para um dado valor de x .

Sendo assim, a convergência do algoritmo depende apenas das propriedades da matriz de peso, W . A convergência pode ser provada através do teorema de Perron-Frobenius.

Realizando a decomposição espectral da matriz W , como parte da demonstração da Equação (2.10) tem-se

$$W^t = U\Lambda^t U^{-1}, \quad (2.13)$$

em que

- U é uma matriz de autovetores;
- Λ é uma matriz de autovalores.

A matriz de autovalores é responsável por influenciar todo o comportamento do algoritmo do consenso. Além disso, pode ser concluído que o valor absoluto do maior autovalor não deve ser maior que 1 para que o limite $\lim_{t \rightarrow \infty} A^t$ exista. A matriz de pesos, W , descreve a topologia da rede de comunicação e, por conta disso, deve-se basear na matriz de adjacência.

A matriz W pode ser representada através da Equação (2.14), pois satisfaz as propriedades da matriz laplaciana e do teorema de Perron-Frobenius.

$$W = I - \varepsilon L, \quad 0 < \varepsilon < \frac{1}{\delta} \quad (2.14)$$

em que δ é o grau máximo da rede de comunicação. É dito que a matriz W é duplamente estocástica por a soma das suas linhas e colunas serem iguais a 1. Além disso, de acordo com o teorema do círculo de Gershgorin, todos os autovalores de L estão dentro de um círculo unitário. A convergência do algoritmo de consenso pode ser demonstrada através da Equação (2.15):

$$\begin{aligned} \lim_{t \rightarrow \infty} x(t) &= \lim_{t \rightarrow \infty} U\Lambda U^{-1}x[0] = \lim_{t \rightarrow \infty} \begin{pmatrix} \frac{1}{\sqrt{N}} & 1 & u_2 & \dots \end{pmatrix} \begin{pmatrix} 1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_N \end{pmatrix}^t \begin{pmatrix} \frac{1}{\sqrt{N}} 1^T \\ v_2^T \\ \vdots \end{pmatrix} x(0) \\ &= \frac{1}{N} \cdot 1 \cdot 1^T x(0) \equiv \bar{x}(0) \cdot 1 \end{aligned} \quad (2.15)$$

Sendo assim, cada agente converge para um valor médio dos valores iniciais.

2.2.3 Algoritmo de consenso com variável de feedback

A representação mais comum do algoritmo de consenso em tempo discreto é a definida na Equação (2.10). Levando em consideração a estimativa de erro de rastreamento, de acordo com o proposto em Lewis *et al.* (2013), o algoritmo de consenso pode ser representado através da Equação (2.16).

$$x_i[t + 1] = \sum_{j=1}^N w_{ij}x_j[t] + \varepsilon\Delta[t], \quad i = 1, \dots, N \quad (2.16)$$

em que

- $x_i[t + 1]$ representa a informação atualizada do i -ésimo agente na iteração $t + 1$;
- $x_j[t]$ representa a informação do j -ésimo agente na iteração t ;
- ε representa o coeficiente de ganho;
- Δ representa a variável de *feedback*;
- w_{ij} representa o coeficiente da matriz de pesos estocástica, a qual influencia a velocidade de convergência do algoritmo.

Em (2.10), o termo principal de consenso, $\sum_{j=1}^n w_{ij}[t]x_j[t]$, garante que x_i convirja para uma constante, enquanto a adição do outro termo, $\varepsilon\Delta(t)$, proporciona um *feedback* da diferença representada pela variável de *feedback*, Δ . Essa variável de *feedback* garante que x_i convirja para um valor ótimo (WANG *et al.*, 2018).

2.2.4 Matriz de peso

Existem diferentes métodos para se determinar a matriz de peso de uma rede de comunicação. Como requisito para que o algoritmo de consenso alcance a convergência, a matriz de pesos deve ter as seguintes propriedades:

- A matriz deve ser duplamente estocástica, isto é, a soma das suas linhas deve ser igual a 1, assim como a soma das suas colunas;
- O valor absoluto de todos os autovalores da matriz de peso deve ser ≤ 1 , de acordo com o teorema do círculo de Gershgorin.

Na literatura, são encontrados diversos tipos de matrizes de pesos. Alguns dos métodos mais utilizados e suas principais características são citados a seguir.

2.2.4.1 Método uniforme

Os coeficientes de peso possuem valores fixos, sendo computados através da Equação (2.17). Não possui adaptabilidade devido aos coeficientes fixos e também tem uma convergência lenta em comparação a outros métodos (ALFAGEE, 2013).

$$w_{ij} = \begin{cases} \frac{1}{N}, & j \in \Omega_i \\ 1 - \sum_{j \in N_i} \frac{1}{N} & i = j \\ 0, & \text{caso contrário} \end{cases} \quad (2.17)$$

em que

- w_{ij} é um elemento da matriz de pesos W ;
- N é o número de agentes.

2.2.4.2 Método de metropolis

Diferentemente do método uniforme, o método de metrópolis já apresenta uma melhoria por ter os seus coeficientes definidos de uma maneira não fixa. Apresenta melhoria de estabilidade e adaptabilidade no processo de convergência do algoritmo de consenso (ALFAGEE, 2013). Os coeficientes são definidos de acordo com a Equação (2.18):

$$w_{ij} = \begin{cases} \frac{1}{[\max(\Omega_i, \Omega_j) + 1]}, & j \in \Omega_i \\ 1 - \sum_{j \in \Omega_i} \frac{1}{[\max(\Omega_i, \Omega_j) + 1]} & i = j \\ 0, & \text{caso contrário,} \end{cases} \quad (2.18)$$

em que

- w_{ij} é um elemento da matriz de pesos W ;
- Ω_i é o número de vizinhos do i -ésimo agente;
- Ω_j é o número de vizinhos do j -ésimo agente.

2.2.4.3 Método da metrópolis média

Conforme Alfagee (2013) e Wang e Chen (2019), o Método da Metropolis Média provê estabilidade e adaptabilidade ao processo de convergência do algoritmo de consenso,

apresentando uma melhoria se comparado a outros métodos. Os coeficientes de pesos são definidos através da Equação (2.19):

$$w_{ij} = \begin{cases} \frac{2}{[\Omega_i + \Omega_j + \varepsilon]}, & j \in \Omega_i \\ 1 - \sum_{j \in \Omega_i} \frac{2}{[\Omega_i + \Omega_j + \varepsilon]} & i = j \\ 0, & \text{caso contrário,} \end{cases} \quad (2.19)$$

em que

- w_{ij} é um elemento da matriz de pesos W ;
- Ω_i é o número de vizinhos do i -ésimo agente;
- Ω_j é o número de vizinhos do j -ésimo agente;
- ε é um pequeno número que pode variar entre 0 e 1.

2.3 Multiplicadores de Lagrange

O método dos multiplicadores de Lagrange foi desenvolvido pelo matemático Joseph L. Lagrange e é utilizado, usualmente, para determinar os pontos críticos de uma função (STEWART, 2007). Nessa dissertação, a variável de Lagrange da função objetivo que define o problema é usada como uma das informações a serem compartilhadas entre os agentes, tendo em vista que a minimização da função objetivo pode ser realizada por meio do método dos multiplicadores de Lagrange.

A Equação de Lagrange pode ser representada por (2.20)

$$\nabla f(x) = \lambda \nabla g(x) \quad (2.20)$$

em que:

- $\nabla f(x)$ é o gradiente de uma função $f(x)$;
- λ é o multiplicador de Lagrange;
- $\nabla g(x)$ é o gradiente de uma função de restrição $g(x)$.

2.4 Considerações finais

Neste capítulo foram apresentados os principais conceitos teóricos que embasam o desenvolvimento deste trabalho, como: definição sobre teoria dos grafos, método de consenso e multiplicadores de lagrange.

No próximo capítulo é apresentada a modelagem do gerenciamento de carregamento de veículos elétricos em um estacionamento com múltiplos pontos de recarga. Os conceitos estabelecidos neste capítulo de fundamentação teórica são aplicados ao modelo baseado no algoritmo de consenso distribuído, discreto, que usa matriz de peso, calculada pelo método Metrópolis Média, e variável de realimentação, com otimização do custo incremental de recarga baseado nos multiplicadores de Lagrange.

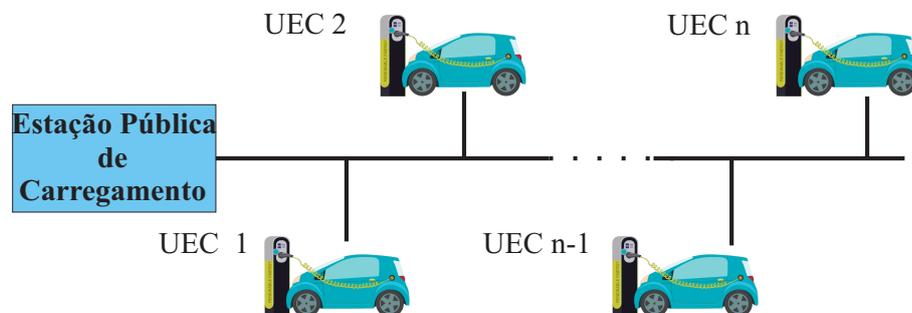
3 DEFINIÇÃO E MODELAGEM DO PROBLEMA DE CARREGAMENTO EFICIENTE DE VEÍCULOS ELÉTRICOS

Neste capítulo define-se o problema de carregamento eficiente de VEs, apresenta-se a modelagem matemática do problema, os parâmetros iniciais do problema e o algoritmo desenvolvido.

3.1 Definição do problema

Em problemas envolvendo o algoritmo de consenso, há como definição um grupo de agentes que se comunicam entre si para chegar em um acordo em relação a um objetivo global. Nesta dissertação, um agente é representado por uma Unidade de Estação de Carregamento (UEC). Assim sendo, cada UEC está localizada em um ponto de carga de um estacionamento público de carregamento de VEs. A UEC é uma estrutura de hardware e *software*, com soquete de carregamento, por meio do qual o VE se conecta, e *software* para gerenciamento do carregamento dos VEs. O objetivo global entre os agentes é o carregamento eficiente dos VEs realizado por meio do algoritmo de consenso, com troca de informação através de uma arquitetura de comunicação. Dessa forma, as UECs são responsáveis por executar o algoritmo de consenso entre si, realizando a troca de informações necessárias à resolução do problema através de uma arquitetura de comunicação. Na Figura 9 é apresentada uma ilustração da estação pública de carregamento. Como observado na figura, cada VE conecta-se a uma UEC (camada física) que se comunica (arquitetura de comunicação) com as unidades vizinhas visando carregar de forma eficiente os VEs, segundo o tempo de permanência e a quantidade de autonomia necessária de cada VE.

Figura 9 – Camada de conexão física.



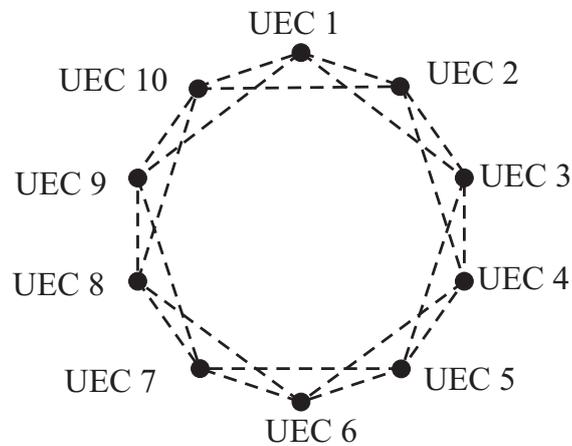
Fonte: Autoria própria.

A estação pública de carregamento possui um valor de potência contratada pré-

definida para carregar todos os VEs. Além disso, a localização física da estação de carregamento e, conseqüentemente, de toda a estrutura necessária ao carregamento de VEs se refere a espaços públicos como, por exemplo, *shoppings*, campus universitário, etc. É assumido que os usuários dos VEs informam o tempo de permanência e a autonomia desejada, que por sua vez é vista através do estado de carga do VE.

Na Figura 10 é apresentada a arquitetura de comunicação entre as UACs (agentes) da estação pública de carregamento, modelada por meio de grafo. Assim sendo, os vértices representam os agentes (UECs) e as arestas representam a comunicação entre os agentes.

Figura 10 – Arquitetura de comunicação da Estação Pública de Carregamento.



Fonte: Autoria própria.

3.1.1 Padrão de carregamento

Analisando os três maiores mercados de VEs (estadunidense, europeu e asiático), pode-se notar uma predominância de cinco diferentes padrões de carregamento: SAE J1772, Mennekes, CHAdeMO, GB/T e Tesla (KNEZ *et al.*, 2019). Cada padrão apresenta características próprias e maiores predominâncias nos três diferentes mercados. Na Tabela 1 são apresentadas as principais características desses padrões de carregamento: o seu tipo de carregamento em corrente contínua ou alternada; o tempo aproximado de carregamento; os seus pontos fortes e fracos, que estão relacionados à velocidade de carregamento e ao estabelecimento do padrão em países e continentes, assim como a outros fatores, como a exclusividade dos carregadores da Tesla apenas para veículos da própria fabricante.

No mercado estadunidense, há uma predominância do padrão de carregamento J1772 de cerca de 50% do total do mercado norte-americano, enquanto os padrões de carregamento

Tabela 1 – Padrões de carregamento.

Padrão de Carregamento	AC/DC	Tempo de Carregamento	Pontos Fortes	Pontos Fracos
CHAdEMO	AC/DC	20 minutos	Carregamento Rápido	Corrente muito alta
GB/T	AC/DC	Aproximadamente 1,3 hora	Trifásico	Apenas na China
J1772	AC	Aproximadamente 3,5 horas	Bem estabelecido nos EUA e no Japão	Monofásico; Carregamento pode ser lento.
Mennekes	AC	Aproximadamente 1,3 hora	Trifásico Formalizado como carregador oficial na União Europeia	Relativamente novo
Tesla	DC	20 minutos	Carregamento Rápido	Apenas para carros da Tesla; Corrente muito alta

Fonte: Adaptado de (KNEZ *et al.*, 2019)

Mennekes e CHAdEMO possuem 20% cada do total desse mercado. No mercado europeu, o padrão de carregamento Mennekes é o mais utilizado, seguido pelos padrões de carregamento CHAdEMO, Tesla e J1772. Já no mercado asiático, os padrões de carregamento CHAdEMO e GB/T são responsáveis por quase 90% do total do mercado asiático (KNEZ *et al.*, 2019). A Tabela 2 relaciona os padrões de carregamentos nos três mercados analisados em relação a alguns fabricantes de VEs.

A não uniformização de um padrão de carregamento é uma das principais barreiras ao crescimento de estações de carregamento de VEs. Os VEs fabricados pela Tesla, por exemplo, só podem ser carregados com o padrão de carregamento específico produzido pela sua própria fabricante (KNEZ *et al.*, 2019).

É assumido nesse estudo a utilização do padrão de carregamento SAE J1772 tipo 2 com a potência máxima de carregamento de 3,3 kW, assim como utilizado em Wang e Chen (2019). Dessa forma, todas as UECs obedecem a esse padrão de carregamento.

3.1.1.1 Normas relacionadas ao carregamento de VEs

Devido ao crescimento cada vez mais constante dos VEs, organizações internacionais como *International Organization for Standardization (ISO)*, *International Electrotechnical Commission (IEEE)*, *Society of Automotive Engineers (SAE)* e *Infrastructure Working Council*

Tabela 2 – Fabricantes de VEs e padrões de carregamento.

Estados Unidos		Europa		Asia	
Fabricantes	Padrão de Carregamento	Fabricantes	Padrão de Carregamento	Fabricantes	Padrão de Carregamento
Chevrolet	J1772	Audi	Mennekes	BYD	GB/T
Cadillac	J1772	BMW	Mennekes	GM Korea	J1772
Fisker	J1772	Bolloré	J1772	Honda	J1772
Ford	J1772	Citroën	CHAdEMO	Kia	J1772
Tesla	Tesla	Fiat	J1772	Mitsubishi	CHAdEMO
		Mercedes Benz	Mennekes	Nissan	CHAdEMO
		Opel	J1772	Hyundai	J1772
		Peugeot	CHAdEMO	TATA	J1772
		Porsche	Mennekes	Toyota	J1772
		Renault	Mennekes		
		Daimler	Mennekes		
		Volvo	Mennekes		
		Volkswagen	Mennekes		

Fonte: Adaptado de (KNEZ *et al.*, 2019)

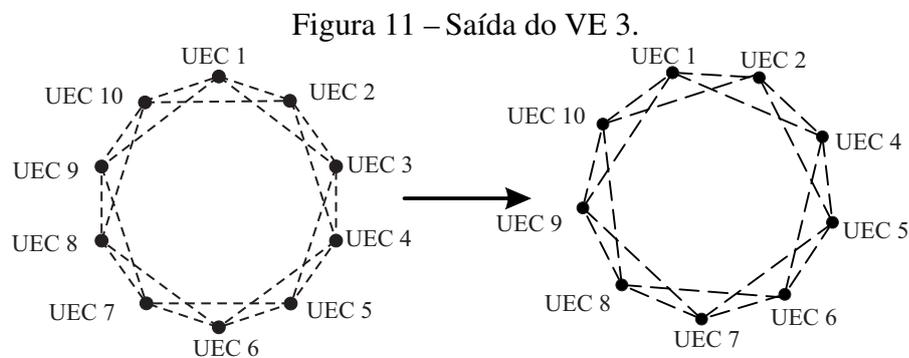
(IWC) vêm elaborando normas relacionadas à utilização de VEs de forma geral (REIS, 2020).

Dentre as principais normas relacionadas aos carregadores de VEs destacam-se:

- UL 2202: Equipamento de sistema de carregamento de VE;
- IEC 60950: Segurança do equipamento de tecnologia da informação;
- IEC 61851-21: Sistema de carregamento elétrico do veículo elétrico – Parte 21: requisitos do VE para conexão condutora a uma fonte de corrente alternada;
- IEC 61000: Compatibilidade eletromagnética (EMC);
- IEC62196-1: Conectores, tomadas, acopladores e entradas dos veículos – Carregamento condutivo de VEs;
- ECE R100: Proteção contra choque elétrico;
- ISO 6469-3: Veículos rodoviários elétricos – Especificações de segurança – Parte 3: Proteção de pessoas contra riscos elétricos;
- ISO 26262: Veículos rodoviários – Segurança funcional;
- SAE J2929: Padrão de segurança do sistema de bateria de propulsão elétrica e híbrida do veículo;
- SAE J1772: Norma norte-americana para conectores elétricos de VEs.

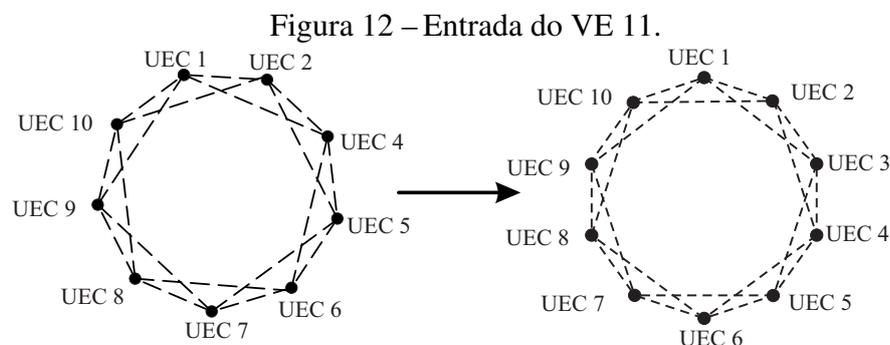
3.1.2 Alteração da rede de comunicação

O algoritmo para carregamento deve apresentar adaptabilidade a saídas e entradas aleatórias de VEs. Para que essa adaptabilidade do algoritmo exista, é necessário que a rede de comunicação seja alterada a cada nova mudança de topologia. A entrada ou a saída de VEs implica na alteração da rede de comunicação existente, e para cada nova configuração o algoritmo deve convergir para uma condição de carregamento eficiente para os VEs conectados. Na Figura 11 é apresentada a reconfiguração da arquitetura de comunicação no processo de saída do VE 3 que estava conectado à UEC 3. Observa-se com a saída de VE 3 que as UECs vizinhas anteriores à UEC 3 passam a conectar-se com as UECs vizinhas posteriores à UEC 3.



Fonte: Autoria própria.

De forma análoga, a entrada de um VE também irá alterar a topologia da arquitetura de comunicação adicionando mais um agente e, conseqüentemente, a arquitetura de comunicação também será reconfigurada. Utilizando a rede de comunicação apresentada na Figura 11 como exemplo, pode-se mostrar na Figura 12 o processo de entrada de um novo VE conectado à UEC 3 que estava sem veículos.



Fonte: Autoria própria.

É importante ressaltar que com a mudança da topologia da arquitetura de comuni-

cação, a matriz de adjacência que a representa também deve ser atualizada, de acordo com a Equação (2.5). Conseqüentemente, a matriz de pesos utilizada também irá ser atualizada a partir da mudança da matriz de adjacência.

3.2 Modelagem matemática do problema

O problema é modelado a partir da bateria de um VE, a qual é considerada por seu circuito equivalente que consiste em uma tensão de circuito aberto em série com uma resistência. O objetivo do problema é minimizar as perdas de potência causadas no carregamento, devido à resistência interna da bateria. A potência disponível para carregamento de VEs é maximizada, enquanto satisfaz aos requisitos de carregamentos de cada VE.

Na Figura 13 é apresentado o modelo de bateria utilizado no processo de carregamento de VEs. O modelo de bateria em carregamento pode ser formulado em tempo discreto, com base na Equação (3.1)

$$V_{b,i} = V_{oc,i} + R_i \cdot I_{br,i}(k) \quad (3.1)$$

em que

- $V_{b,i}$ é a tensão nos terminais da bateria referente ao i -ésimo VE;
- $V_{oc,i}$ é a tensão de circuito aberto referente ao i -ésimo VE;
- $I_{br,i}(k)$ é a corrente real de carregamento da bateria referente ao i -ésimo VE;
- R_i é a resistência interna da bateria referente ao i -ésimo VE;
- k representa o k -ésimo instante do tempo da simulação.

A potência de carregamento do i -ésimo VE é obtida com

$$P_i(k) = V_{oc,i} \times I_{br,i}(k) + R_i \times I_{br,i}^2(k) \quad (3.2)$$

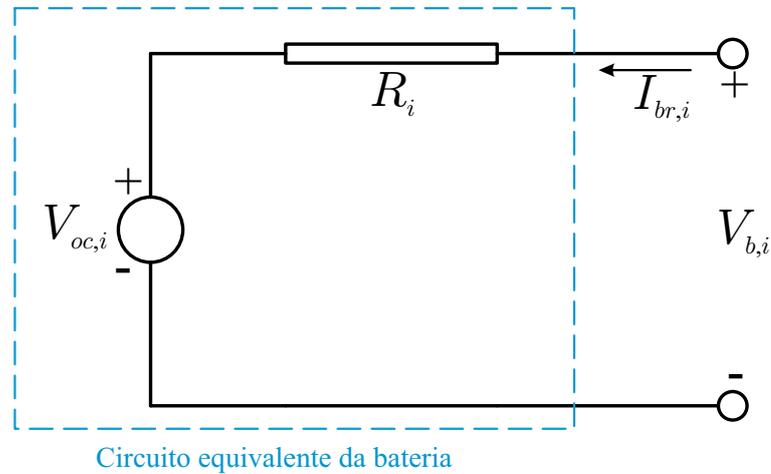
Através da Equação (3.2), é possível obter a corrente de carregamento da bateria para o i -ésimo VE

$$I_{br,i}(k) = \frac{1}{2 \times R_i} \times (-V_{oc,i} + \sqrt{V_{oc,i}^2 + 4 \times R_i \times P_i(k)}) \quad (3.3)$$

A equação (3.3) é sujeita à seguinte restrição

$$0 \leq I_{br,i}(k) \leq I_{br,i}^{max}(k) \quad (3.4)$$

Figura 13 – Modelo da bateria em carregamento.



Fonte: Adaptado de (XU, 2014).

O SOC de cada VE é calculado através de (3.5), cuja restrição é expressa em (3.6).

O SOC de cada VE no momento de saída do estacionamento é calculado por (3.7).

$$SOC_i(k+1) = SOC_i(k) + \frac{\Delta T}{Q_i} \times I_{br,i}(k) \quad (3.5)$$

$$SOC_{i,o} \leq SOC_i(k) \leq SOC_i(K_i) \quad (3.6)$$

$$SOC_i(K_i) = SOC_{i,o} + \sum_{k=1}^{K_i} \frac{\Delta T}{Q_i} \times I_{br,i}(k) \quad (3.7)$$

em que, nas equações (3.5)-(3.7):

- ΔT é o passo de tempo da simulação em horas;
- Q_i é a capacidade da bateria em Ah referente ao i -ésimo VE;
- $SOC_{i,o}$ é o SOC inicial do i -ésimo VE;
- $SOC_i(K_i)$ é o SOC final do i -ésimo VE;
- $K_i = T_i/\Delta T$, em que T_i representa o tempo de permanência do i -ésimo VE no estacionamento.

As perdas de potência causadas pela resistência interna da bateria podem ser minimizadas com

$$\min \sum_{k=1}^{K_i} I_{br,i}^2(k) \cdot R_i \quad (3.8)$$

Equação (3.8) pode ser representada através de (3.9), de acordo com propriedades de inequação (GWANYAMA, 2004).

$$\sum_{k=1}^{K_i} I_{br,i}^2(k) \cdot R_i \geq \left(\frac{(\sum_{k=1}^{K_i} I_{br,i}(k))^2}{K_i} \right) \cdot R_i \quad (3.9)$$

Em (3.9), de acordo com uma das propriedades de inequações, a igualdade entre os dois lados da expressão é mantida quando a corrente da bateria do i -ésimo VE mantém um valor constante durante todo o tempo. Caso essa corrente se mantenha constante, o lado direito de (3.9) atinge seu maior valor, enquanto produz o menor valor no lado esquerdo. Ou seja, as perdas de potência causadas pela resistência interna da bateria são minimizadas. A corrente ideal que produz esse efeito pode ser representada como

$$I_i^{ideal}(k) = \frac{Q_i \times (SOC_i(K_i) - SOC_{i,o})}{K_i \times \Delta T} \quad (3.10)$$

Assim sendo, cada VE, para minimizar as perdas causadas pelo carregamento, deseja manter essa corrente constante, como foi definido em (3.9). Entretanto, não é possível realizar isso de forma prática por causa das diferenças da capacidade de potência disponível para cada VE em cada passo de simulação. Além disso, o algoritmo é executado em tempo real, por conseguinte, a corrente de referência do k -ésimo passo de simulação é atualizada de acordo com o tempo de carregamento restante e a capacidade de bateria que necessita ser carregada, através de (3.11).

$$I_i^{ref}(k) = \frac{(SOC_i(K_i) - SOC_i(k)) \times Q_i}{(K_i - k) \times \Delta T} \quad (3.11)$$

Também é necessário a utilização de um fator de prioridade de carregamento para cada um dos VEs, o qual varia de acordo com o tempo restante no local de carregamento e a capacidade de bateria que falta ser carregada (XU, 2014). Esse fator é definido por (3.12).

$$\rho_i(k) = \frac{1}{SOC_i(k) \times (T_i - k \times \Delta T)} \quad (3.12)$$

Com a análise feita, a minimização das perdas de potência causadas pela resistência interna da bateria é equivalente a forçar a corrente real de carregamento da bateria $I_{br,i}(k)$ a

seguir a corrente de referência $I_i^{ref}(k)$. Ou seja, o problema de otimização pode ser modelado da seguinte forma

$$\begin{aligned}
C &= \min \sum_{i=1}^{N_{VE}} (\rho_i(k) \times (I_i^{ref}(k) - I_{br,i}(k))^2) \\
&= \sum_{i=1}^{N_{VE}} (\rho_i(k) \times (I_i^{ref}(k))^2 - \frac{I_i^{ref}(k) \times V_{oc,i}}{R_i} + \frac{V_{oc,i}^2}{2 \times R_i^2} + \frac{P_i(k)}{R_i} - (\frac{I_i^{ref}(k)}{R_i} + \frac{V_{oc,i}}{2 \times R_i^2}) \times \\
&\quad \sqrt{V_{oc,i}^2 + 4 \times R_i \times P_i(k)})
\end{aligned} \tag{3.13}$$

em que N_{VE} se refere ao número total de VEs.

O problema formulado possui as seguintes equações de restrições

$$P_i^{min} \leq P_i(k) \leq P_i^{max} \tag{3.14}$$

$$\sum_{i=1}^{N_{ve}} P_i(k) \leq P_{disp.}(k) \tag{3.15}$$

em que $P_{disp.}(k)$ é a potência total de carregamento disponível da estação de carregamento. Equação (3.14) representa a restrição de potência que pode ser carregada, em cada instante de tempo, no i -ésimo VE. Equação (3.15) representa a restrição de carregamento de potência para todos os VE.

O desvio de potência para o i -ésimo VE é calculado por (3.16).

$$P_{D,i}(k) = P_i(k) - P_{rede,i}(k) \tag{3.16}$$

A análise realizada leva em consideração uma função objetivo, a qual será minimizada utilizando no algoritmo de consenso o custo incremental dessa função. O custo incremental é a variável de Lagrange da função objetivo, podendo ser obtido para o i -ésimo VE com

$$r_i = \frac{\partial C_i}{\partial P_i(k)} = \rho_i(k) \times \left(\frac{1}{R_i} - \frac{V_{o,i} + 2R_i I_i^{ref}(k)}{R_i \sqrt{V_{o,i}^2 + 4R_i P_i(k)}} \right) \tag{3.17}$$

O custo incremental é limitado de acordo com os limites de potência, conforme definido por (WOOD *et al.*, 2013).

$$\begin{cases} r_i^* = \frac{\partial C_i}{\partial P_i(k)}, & \text{para } P_i^{\min} < P_i(k) < P_i^{\max} \\ r_i^* > \frac{\partial C_i}{\partial P_i(k)}, & \text{para } P_i(k) = P_i^{\max} \\ r_i^* < \frac{\partial C_i}{\partial P_i(k)}, & \text{para } P_i(k) = P_i^{\min} \end{cases} \quad (3.18)$$

em que r_i^* representa o custo incremental ótimo para o algoritmo de consenso.

Durante o processo iterativo de cálculo do algoritmo de consenso, há a possibilidade de o algoritmo definir a potência de carregamento do i -ésimo VE em valor acima ($P_i > P_i^{\max}$) ou abaixo das restrições ($P_i < P_i^{\min}$) de carregamento definidos pela Equação (3.14). Dessa forma, o algoritmo de consenso calcula a potência de carregamento do i -ésimo VE de acordo com a Equação (3.19).

$$P_i(k) = \begin{cases} \frac{(V_{oc,i} + 2R_i I_i^{\text{ref}}(k))^2}{4R_i (1 - R_i^2)^2} - \frac{V_{o,i}^2}{4R_i}, & \text{para } 0 \leq P_i(k) \leq P_i^{\max} \\ P_i^{\max}, & \text{para } P_i(k) > P_i^{\max} \\ P_i^{\min}, & \text{para } P_i(k) < P_i^{\min} \end{cases} \quad (3.19)$$

em que $P_i(k)$ representa o carregamento eficiente de potência para os VEs. As potências P_i^{\max} e P_i^{\min} são definidas como sendo 3,3 kW e 0, respectivamente. Esses valores estão de acordo com o padrão de carregamento J1772 tipo 2 (WANG; CHEN, 2019).

3.3 Parâmetros iniciais dos VEs

Os parâmetros utilizados nesse trabalho foram retirados de (WANG; CHEN, 2019). Cada parâmetro inicial é selecionado de forma aleatória, dentro de um intervalo selecionado, através de uma distribuição uniforme. Para tanto, a função *randi* do MATLAB é utilizada para realizar a distribuição uniforme entre um intervalo de valores pré-selecionados, de acordo com a equação (3.20).

$$X = \text{randi}([imin, imax], n, m) \quad (3.20)$$

em que *randi* retorna uma matriz de dimensão $n \times m$ contendo inteiros retirados da distribuição uniforme discreta no intervalo $[imin, imax]$ (MATHWORKS, 2021).

Na Tabela 3 são dados todos os parâmetros iniciais que são utilizados no modelo e como eles são obtidos, todos possuindo a função *randi* como um de seus argumentos. Ou seja, todos os parâmetros irão variar de acordo com uma faixa de valores inteiros retirados de uma distribuição uniforme discreta. Dessa forma, os VEs poderão ter diferentes capacidades de bateria, assim como tensão de circuito aberto, resistência interna, SOC inicial e SOC desejado.

Tabela 3 – Parâmetros iniciais utilizados.

Tensão de circuito aberto (V)	$V_{oc,i} = 300 + 0,1 \times randi([-100\ 100], 1, 1)$
Resistência interna (ohm)	$R_i = 1 + 0.01 \times randi([-10\ 30], 1, 1)$
Capacidade da bateria (Ah)	$Q_i = 25 + randi([-2\ 8], 1, 1)$
SOC inicial	$SOC_i = 0,3 + 0,01 \times randi([-5\ 10], 1, 1)$
SOC desejado	$SOC_i(K_i) = 0,85 + 0,01 \times randi([-5\ 5], 1, 1)$

Fonte: Adaptado de (WANG; CHEN, 2019).

3.3.1 Tempo de permanência dos VEs

Para demonstrar a prioridade no carregamento de VEs com menores tempos de permanência, através do fator de prioridade ρ_i definido em (3.12), assim como para evidenciar a adaptabilidade do algoritmo em relação a saídas e entradas de VEs, o tempo de permanência é segmentado em três diferentes grupos: VEs que permanecem, VEs que saem e VEs que entram no estacionamento, conforme mostrado na Tabela 4, em que

- k denota o k -ésimo instante de tempo do algoritmo;
- ΔT é o passo de tempo da simulação em horas.

Das expressões na Tabela 4 obtém-se:

- percentual da quantidade total inicial de VEs definido para permanecer no estacionamento;
- percentual da quantidade total inicial de VEs definido para entrar no estacionamento;
- percentual da quantidade total inicial de VEs definido para sair do estacionamento.

Foram obtidos os percentuais de 70%, 30% e 10% para VEs que permanecem, VEs que saem e VEs que entram no estacionamento, respectivamente.

Tabela 4 – Tempo de permanência.

	Tempo de permanência (h)
VEs que saem	$T_i = 3.5 + \Delta T \times randi([-5\ 5], 1, 1)$
VEs que permanecem	$T_i = 5 + \Delta T \times randi([-5\ 10], 1, 1)$
VEs que entram	$T_i = k \times \Delta T + \Delta T \times randi([12\ 36], 1, 1)$

Fonte: Autoria própria.

A diferenciação que cada um dos grupos possui na parametrização da função *randi* está relacionado à característica de cada um dos grupos. O tempo de permanência para os VEs que irão sair do estacionamento é menor se comparado ao dos VEs que permanecem no estacionamento. Já os VEs que entram no estacionamento têm o seu tempo de permanência definido conforme a k -ésima iteração em execução do algoritmo.

3.4 Algoritmo utilizado

Como apresentado na seção 2.2.3, o algoritmo de consenso é definido em (3.21), em que a variável de *feedback* é o seu o desvio de potência.

$$x_i[t+1] = \sum_{j=1}^N w_{ij}[t]x_j[t] + \varepsilon\Delta P, \quad i = 1, \dots, N \quad (3.21)$$

sendo

- ΔP representa o desvio de potência entre a potência de carregamento de um VE e a potência total disponível da estação de carregamento;
- w_{ij} é o coeficiente da matriz de pesos;
- $x_i[t+1]$ é a atualização da informação a ser compartilhada entre os agentes na iteração $t+1$;
- $x_j[t]$ é a informação a ser compartilhada entre os agentes na iteração t ;
- ε é o coeficiente de ganho.

Nesse estudo, a matriz de pesos utilizada é a matriz metrópolis média, devido a sua característica de adaptabilidade à saída e entrada de novos agentes. A matriz foi definida na Equação (2.19).

3.4.1 Inicialização do algoritmo de consenso

Inicialmente, é assumido que apenas o primeiro VE conhece a potência total disponível da estação de carregamento. Sendo assim, o algoritmo de consenso é inicializado na iteração $t = 1$ através das equações (3.22)-(3.25).

$$P_{rede,i}[1] = \begin{cases} P_{rede}(k), & \text{para } i = 1 \\ 0, & \text{caso contrário} \end{cases} \quad (3.22)$$

$$P_i = \left\{ \begin{array}{ll} P_{rede,i}[1], & \text{se } P_i^{min} \leq P_{rede}(k) \leq P_i^{max} \\ P_i^{max}, & \text{se } P_{rede}(k) \geq P_i^{max} \\ P_i^{min}, & \text{se } P_{rede}(k) \leq P_i^{min} \\ 0, & \text{para } i \neq 1 \end{array} \right\} \text{ para } i = 1 \quad (3.23)$$

$$P_{D,i}[1] = P_i[1] - P_{rede,i}[1] \quad (3.24)$$

$$r_i = \rho_i(k) \times \left(\frac{1}{R_i} - \frac{V_{o,i} + 2R_i I_i^{ref}(k)}{R_i \sqrt{V_{o,i}^2 + 4R_i P_i(k)}} \right) \quad (3.25)$$

3.4.2 Regra de iteraç o do algoritmo de consenso

O algoritmo de consenso utilizado nessa disserta o funciona a partir das equa es (3.26)-(3.29) que s o executadas iterativamente:

$$r_i[t+1] = \sum_{j=1} w_{ij} r_j[t] - \varepsilon P_{D,i}[t] \quad (3.26)$$

$$P_i[t+1] = \frac{(V_{oc,i} + 2R_i I_i^{ref}(k))^2}{4R_i \left(\frac{1 - R_i r_i[t+1]}{\rho_i(k)} \right)^2} - \frac{V_{oc,i}^2}{4R_i} \quad (3.27)$$

$$P'_{D,i}[t] = P_{D,i}[t] + (P_i[t+1] - P_i[t]) \quad (3.28)$$

$$P_{D,i}[t+1] = \sum_{j=1} w_{ij} P'_{D,j}[t] \quad (3.29)$$

em que, nas equa es (3.26)-(3.29):

- t   a vari vel de itera o do algoritmo de consenso;
- $r_i[t+1]$   o custo incremental da troca de informa es entre o i - simo VE e o seus vizinhos;
- $P_i[t+1]$   a pot ncia de carregamento do i - simo VE na itera o $t+1$;
- $P_{D,i}[t+1]$   o desvio de pot ncia, isto  , a diferen a entre a pot ncia de carregamento do i - simo VE e a pot ncia dispon vel para carregamento do i - simo VE.

3.4.3 Análise da convergência do algoritmo

Para analisar a convergência do algoritmo de consenso, as Equações (3.26)-(3.29) podem ser escritas na seguinte forma matricial:

$$R_i[t + 1] = WR_i[t] - \varepsilon P_{Di}[t] \quad (3.30)$$

$$P_i[t + 1] = BR_i[t + 1] \quad (3.31)$$

$$P_{Di}[t + 1] = WP_{Di}[t] + W(P_{Di}[t + 1] - P_i[t]) \quad (3.32)$$

em que, nas equações (3.30)-(3.33):

- R_i é o vetor coluna dos valores de r_i ;
- P_{Di} é o vetor coluna dos valores de P_{Di} ;
- P_i é o vetor coluna dos valores de P_i ;
- B é a expressão algébrica para derivar P_i a partir de r_i ;
- W é uma matriz duplamente estocástica.

$$P_{Di}[t + 1] = WP_{Di}[t] + W(P_{Di}[t + 1] - P_i[t]) \quad (3.33)$$

Combinando as Equações (3.30)-(3.33), o custo incremental e o desvio de potência atualizados podem ser expressos por:

$$\begin{bmatrix} R_i[t + 1] \\ P_{Di}[t + 1] \end{bmatrix} = \begin{bmatrix} W & -\varepsilon I_N \\ WBW - WB & W - \varepsilon WB \end{bmatrix} \cdot \begin{bmatrix} R_i[t] \\ P_{Di}[t] \end{bmatrix} \quad (3.34)$$

em que I_N é uma matriz identidade de dimensão N . Por motivos de simplificação, uma matriz M pode ser definida por meio da Equação (3.35):

$$M = \begin{bmatrix} W & -\varepsilon I_N \\ WBW - WB & W - \varepsilon WB \end{bmatrix} \quad (3.35)$$

Sabendo que o valor do coeficiente de ganho, representado por ε , é um valor muito pequeno, pode-se admitir que M tenha os mesmos autovalores de W . Assim sendo, pode-se chegar à expressão da Equação (3.36):

$$|M - \lambda I_N| = \left| \begin{bmatrix} W - \lambda I_N & -\varepsilon I_N \\ WBW - WB & W - \varepsilon WB - \lambda I_N \end{bmatrix} \right| \approx |W - \lambda I_N|^2 \quad (3.36)$$

Por ser uma matriz duplamente estocástica, a soma das linhas e colunas da matriz W é igual a 1 e, além disso, a matriz apresenta como seu autovalor máximo $\lambda = 1$. Sendo assim, o autovetor da matriz W em relação a $\lambda = 1$ deve ser igual a $\begin{bmatrix} 1_N & 0_N \end{bmatrix}^T$, em que 1_N é um vetor coluna de 1 com dimensão N e 0_N é um vetor coluna de 0 com dimensão N . Essas propriedades satisfazem a Equação (3.37).

$$M \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} = \lambda \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} \Rightarrow \begin{bmatrix} W & -\varepsilon I_N \\ WBW - WB & W - \varepsilon WB \end{bmatrix} \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} = \lambda \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} = \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} \quad (3.37)$$

Já que M converge para $\begin{bmatrix} 1_N & 0_N \end{bmatrix}^T$ à medida que o tempo se aproxima do infinito, o custo incremental irá convergir para um valor comum r_1^* e o desvio de potência irá convergir para 0, conforme exposto matematicamente na Equação (3.38).

$$\begin{bmatrix} R_i[\infty] \\ P_{Di}[\infty] \end{bmatrix} = r_i^* \begin{bmatrix} 1_N \\ 0_N \end{bmatrix} \quad (3.38)$$

3.4.4 Critério de parada para o algoritmo de consenso

A variável *diff* é calculada através da Equação (3.39)

$$diff = r_1[t + 1] - r_1[t] \quad (3.39)$$

Através dessa variável o algoritmo de consenso introduz um critério de parada relacionado à convergência do custo incremental. Caso *diff* seja menor que um valor de tolerância pré-definido, $diff_{min}$, o algoritmo de consenso será finalizado e, conseqüentemente, não irá executar o seu número máximo de iterações, t_{max} , resultando em um menor custo computacional.

3.4.5 Alteração do coeficiente de ganho

Devido ao caráter aleatório da modelagem do problema (parâmetros dos VEs, variáveis locais) e a característica de adaptabilidade da rede de comunicação em relação a saídas e entradas de VEs, pode ser necessário que o coeficiente de ganho, ε , do algoritmo de consenso sofra alguma alteração para garantir a convergência do algoritmo.

De acordo com Wang *et al.* (2018), valores pequenos de ε garantem a convergência do algoritmo, enquanto maiores valores de ε podem levar a alguma instabilidade. Dessa forma, uma lógica de alteração do coeficiente de ganho, ε , é utilizada.

Após a execução do algoritmo é checado se em sua iteração final, $t = t_{max}$, o algoritmo chega a sua convergência. Caso o algoritmo não atinga a convergência, o coeficiente de ganho é então alterado através da Equação (3.40) e o algoritmo de consenso é reinicializado com um coeficiente de ganho menor, providenciando uma maior estabilidade ao processo em contrapartida ao benefício que um coeficiente de ganho maior pode oferecer.

$$\varepsilon = \varepsilon/5. \quad (3.40)$$

3.4.6 Restrições de potência

As restrições do algoritmo desenvolvido são formuladas de acordo com as Equações (3.14) e (3.15). No entanto, para aplicar essas restrições ao algoritmo de consenso é necessário desenvolver uma lógica específica, pois o algoritmo de consenso pode calcular valores que ultrapassem as restrições impostas pelo problema.

Em Wang *et al.* (2018), é proposta a execução do algoritmo de consenso em duas partes, caso seja necessário. São elas:

- Execução do algoritmo de consenso sem levar em consideração as restrições de potência;
- Caso a execução sem restrições leve a algum valor que ultrapasse os limites de potência, o algoritmo de consenso é executado uma segunda vez aplicando as restrições aos agentes que ultrapassaram os limites na primeira execução.

Tomando como base essa metodologia desenvolvida por Wang *et al.* (2018), um método parecido é aplicado nesse trabalho objetivando manter todos os valores de P_i dos VEs dentro dos limites impostos pela Equação de restrição (3.14) e utilizar completamente a potência disponível da estação de carregamento, obedecendo a Equação de restrição (3.15).

O algoritmo de consenso é executado, primeiramente, sem levar em consideração as restrições de potência. Caso algum VE ultrapasse as restrições de potência da Equação (3.14), uma *flag* é acionada e o VE é adicionado a uma lista de violação de restrição. Os VEs que não ultrapassaram nenhuma das restrições são adicionados a outra lista.

Caso exista alguma *flag* acionada, o algoritmo de consenso é executado mais uma vez utilizando as listas para fazer com que os VEs que ultrapassaram as restrições tenham o seu valor de potência definidos conforme (3.14). Mesmo com a execução dos dois algoritmos de consenso conforme a metodologia de Wang *et al.* (2018), ainda pode existir uma nova ultrapassagem dos limites impostos em (3.14) na segunda execução do algoritmo de consenso. Com isso, o algoritmo de consenso será executado até que todos os VEs estejam de acordo com as restrições de (3.14)

No entanto, caso o número de VEs que ultrapasse o limite superior de potência ($P_i > P_{max}$) seja muito grande, é possível que a Equação de restrição (3.15) não seja obedecida, pois o somatório das potências dos VEs conectados será maior que a potência disponível. Sendo assim, uma *flag* será acionada e o segundo algoritmo de consenso será executado apenas entre os VEs que ultrapassaram o limite superior de potência, enquanto os VEs restantes terão seus valores de potência definidos de acordo com (3.14).

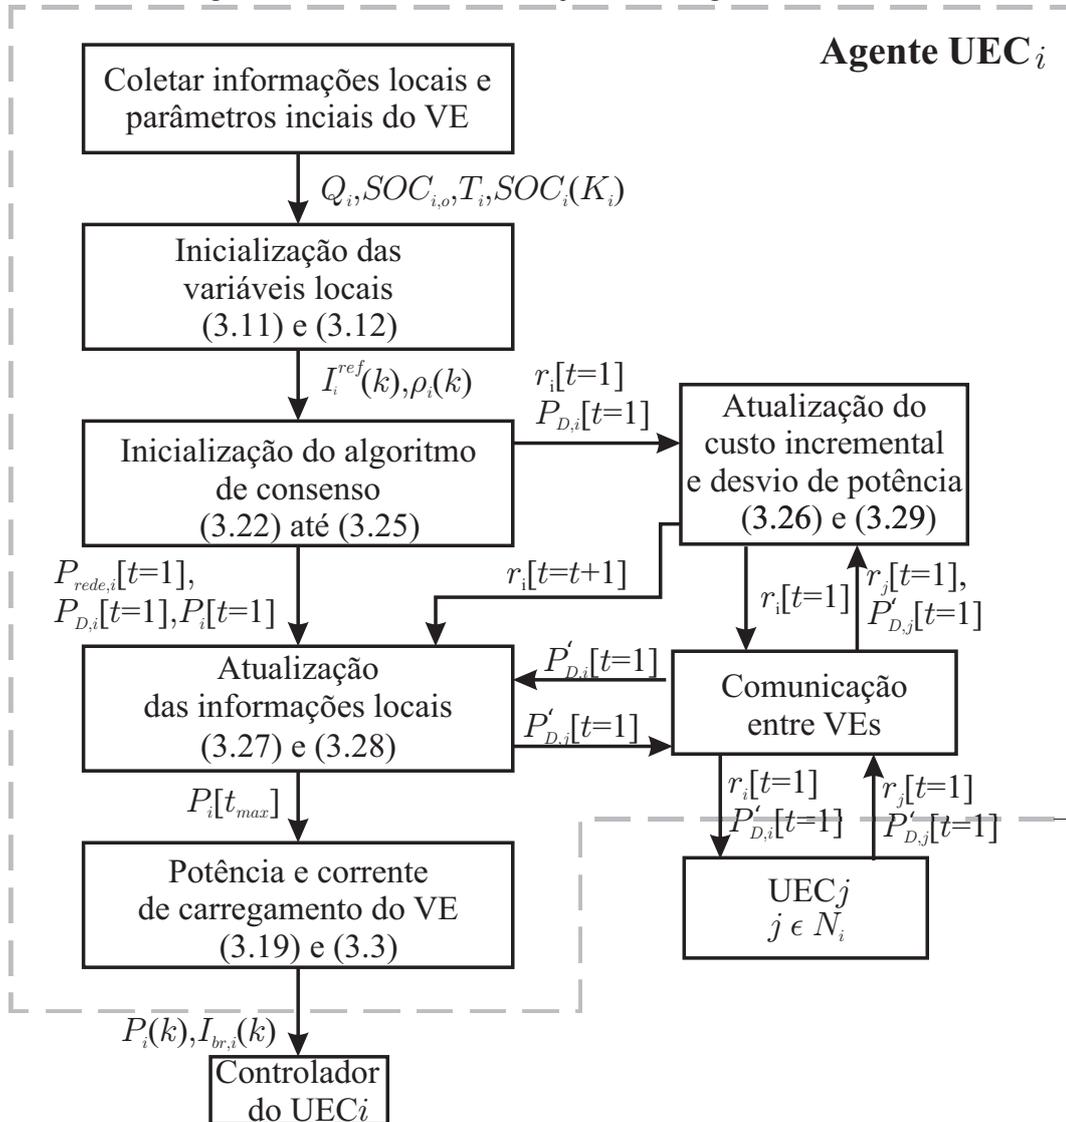
Assim como pode-se ter muitos VEs com valores de potência acima do limite superior, também pode-se ter muitos VEs com valores de potência abaixo do limite inferior ($P_i < P_{min}$) e, conseqüentemente, a potência total disponível não irá ser aproveitada mesmo tendo VEs que ainda não estão completamente carregados. Sendo assim, uma *flag* diferente será acionada e o segundo algoritmo de consenso será executado apenas entre os VEs que ficaram abaixo do limite inferior de potência, enquanto os VEs restantes terão seus valores de potência definidos de acordo com (3.14).

3.4.7 Troca de informação entre os agentes vizinhos

Inicialmente, o *i*-ésimo agente (UEC) coleta as informações referentes à capacidade de bateria, ao SOC atual, ao SOC final desejado e ao tempo de carregamento do *i*-ésimo VE. Após isso, a corrente de referência e o fator de prioridade do VE são inicializados através de (3.11) e (3.12), respectivamente. O algoritmo de consenso é inicializado com as equações (3.22)-(3.25). Com isso, as informações locais P_i e $P'_{D,i}$ são atualizadas através de (3.27) e (3.28). O custo incremental r_i e o desvio de potência $P_{D,i}$ são atualizados através de (3.26) e (3.29).

As informações $P'_{D,i}$ e r_i são compartilhadas com os vizinhos do i -ésimo VE. Simultaneamente, o i -ésimo VE recebe as informações $P'_{D,j}$ e r_j dos VEs vizinhos. Finalmente, a potência e a corrente de carregamento finais são obtidas através de (3.19) e (3.3).

Figura 14 – Troca de informações entre agentes vizinhos.



Fonte: Autoria própria.

Na Figura 14 é apresentado o processo de troca de informação que acontece entre os VEs.

3.4.8 Implementação do algoritmo desenvolvido

A implementação do algoritmo desenvolvido é mostrada no Algoritmo 2.

Algoritmo 2: Algoritmo de consenso desenvolvido.

1: Inicialização de parâmetros e variáveis;

$N_{UECS}, \Delta t, \varepsilon, t_{max}, P_{rede,i}, diff_min, A;$

Cálculo de $V_{oc,i}, R_i, Q_i, SOC_i, SOC_i(K_i), T_i$, de acordo com Tabela 3 e 4;

2: while $k \leq N_{kmax}$ **do**

3: Atualização da rede de comunicação;

determinar se há saída ou entrada de VEs;

atualizar a matriz de peso, de acordo com (2.19);

4: Inicialização de variáveis locais;

Cálculo de $I_i^{ref}(k)$ e $\rho_i(k)$, de acordo com (3.11) e (3.12), respectivamente;

5: Inicialização de flags e listas;

6: while $sum(flag) \neq 0$ & $n_algorit == 0$ **do**

7: Inicialização das variáveis de iteração;

$P_{rede,i}, P_i, P_{D,i}, r_i$, de acordo com (3.22)-(3.25);

8: while $t \leq t_{max}$ & $diff > diff_min$ **do**

$r_i[t], P_i[t], P_d[t], P_d[t+1]$, de acordo com (3.26), (3.27), (3.28), (3.29);

9: Cálculo do critério de parada, diff, de acordo com a equação (3.39);

10: Lógica de mudança do coeficiente de ganho;

end

11: Verificação da ultrapassagem dos limites de potência;

end

12: Obtenção dos valores finais.;

$P_i(k) = P_i[t];$

Cálculo de $I_{br,i}(k)$, de acordo com (3.3);

Cálculo de $SOC_i(k)$, de acordo com (3.5);

13: Voltar para o passo 2

end

3.4.9 Descrição do algoritmo desenvolvido

Parâmetros e variáveis do algoritmo de consenso são inicializados: Número de UECS (N_{UECS}), passo de tempo do algoritmo (Δt), coeficiente de ganho (ϵ), potência disponibilizada pela rede à estação de carregamento (P_{rede}), valor de tolerância usado na lógica do critério de parada ($diff_{min}$), matriz de adjacência (A), além dos parâmetros das Tabelas 3 e 4.

Posteriormente, o algoritmo entra no primeiro *loop while* de repetição que é responsável por executar o restante do algoritmo durante k instantes de tempos. A rede de comunicação é atualizada, as variáveis locais são inicializadas, assim como as flags e listas.

O algoritmo entra em um segundo *loop while*, responsável por executar o consenso e as lógicas do critério de parada e a mudança do coeficiente de ganho. Após finalizar o segundo *loop while* o algoritmo verifica a ultrapassagem dos limites de potência. Posteriormente, o algoritmo obtém seus valores finais de potência, corrente real de carregamento e SOC_i para cada veículo.

3.5 Hardware e Software Utilizados

Para implementação do algoritmo, o software MATLAB foi utilizado. O algoritmo desenvolvido foi executado em um *hardware* com as seguintes especificações: processador Intel Core i5-8265U, com 8 GB de memória RAM.

3.6 Considerações finais

Neste capítulo foi definido o problema de carregamento eficiente de VEs. A modelagem matemática do problema e a sua parametrização foi apresentada, além do algoritmo desenvolvido. O algoritmo é desenvolvido visando obter um resultado favorável em relação à característica de aleatoriedade do problema. Portanto, lógicas que auxiliam a execução do algoritmo são desenvolvidas como alteração do coeficiente de ganho, restrições de potência, critério de parada. Uma análise de convergência do algoritmo também é apresentada, assim como um funcionamento geral do algoritmo desenvolvido. Além disso, as configurações de software e *hardware* utilizados no problema também são dadas.

4 RESULTADOS E DISCUSSÕES DO PROBLEMA DE CARREGAMENTO EFICIENTE DE VEÍCULOS ELÉTRICOS

Neste capítulo, são apresentados três estudos de caso que visam demonstrar e validar o algoritmo desenvolvido para o problema de minimização da redução de perdas do carregamento de VEs. Nos três estudos de caso, a janela de apresentação da resposta é de 4 horas. A potência recebida pelos VEs está representada através da potência de carga P_i .

4.1 Estudo de caso 1

Nesse estudo de caso, é assumido que a estação de carregamento composta de 10 UECs inicia o processo de carregamento com todas as UECs ocupadas. Três VEs são selecionados de forma aleatória para deixarem a estação de carregamento e, posteriormente, um VE entra de maneira aleatória no estacionamento. A potência de carga disponível é definida como sendo de 9 kW e o passo de tempo da simulação como sendo de 5 minutos.

Durante a execução do algoritmo, o tempo de execução foi medido para cada um dos instantes de tempos simulados. Dessa forma, foi possível estimar o tempo médio de cada iteração em segundos para que o algoritmo de consenso fosse executado, utilizando a Equação (4.1)

$$T_M = \frac{T_T}{N_{iter}} \quad (4.1)$$

em que

- T_M é o tempo médio por iteração;
- T_T é o tempo total de execução do algoritmo;
- N_{iter} é número de iterações do algoritmo de consenso.

A troca de informações entre os agentes possui um tempo médio por iteração de 0,00024 segundos a cada iteração. O coeficiente de ganho é definido como sendo 5×10^{-6} , conforme utilizado em Wang e Chen (2019). Além disso, é especificado um erro mínimo permitido de 10×10^{-6} em relação ao processo de convergência do algoritmo de consenso. Na configuração de rede de comunicação definida, cada UEC possui 4 vizinhos e se comunica com seus vizinhos adjacentes, conforme foi apresentado na Figura 10. Na Tabela 5 são mostrados os principais parâmetros e informações computacionais desse estudo de caso.

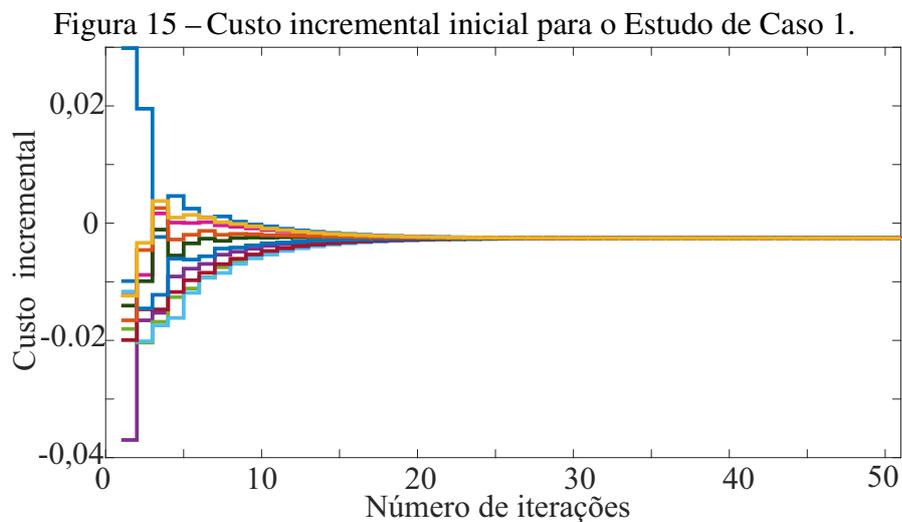
Tabela 5 – Parâmetros e informações computacionais do Estudo de Caso 1.

Caso	1
Potência de carga disponível	9 kW
Passo de tempo	5 minutos
Tempo médio por iteração	0,24 ms
Coefficiente de ganho	5×10^{-6}
Erro permitido	10×10^{-6}
Quantidade de Vizinhos por VE	4
Quantidade de VEs inicialmente	10
Quantidade de VEs saindo	3
Quantidade de VEs entrando	1

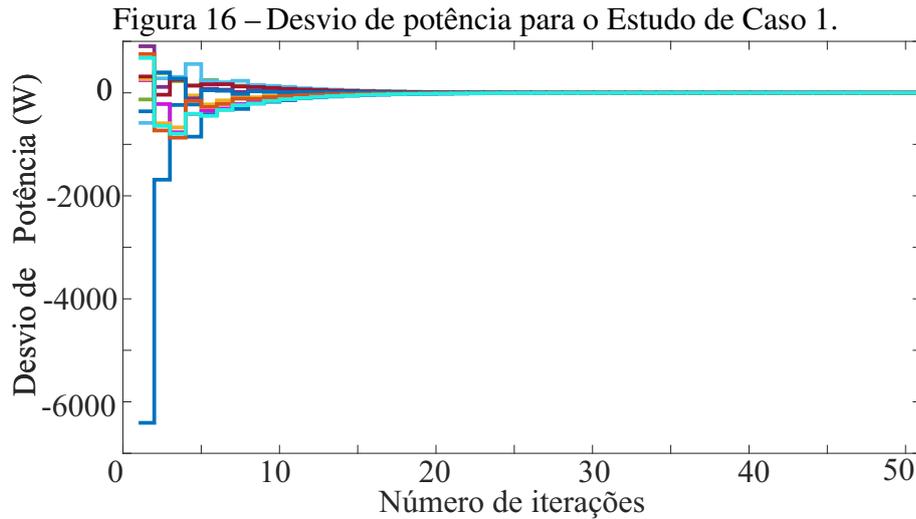
Fonte: Autoria própria.

Na Figura 15 e na Figura 16 é apresentada a convergência do algoritmo de consenso em relação às informações de custo incremental e desvio de potência para o primeiro instante de tempo, $k = 1$. Em ambas as figuras a convergência do algoritmo acontece na iteração 51. Em termos de tempo, o algoritmo precisou de 0,1224 segundos ($51 \times 0,00024$ segundos) para convergir, demonstrando funcionalidade para um sistema em tempo real.

A convergência do custo incremental em um valor próximo de zero indica que os agentes conseguem chegar a um acordo em relação ao valor de potência que será distribuída entre eles. Por outro lado, a convergência do desvio de potência em um valor próximo de zero indica que os VEs conseguem utilizar completamente a potência disponibilizada pela estação de carregamento. Sendo assim, ambas as informações compartilhadas apresentam uma boa convergência com valores bem próximos de 0.



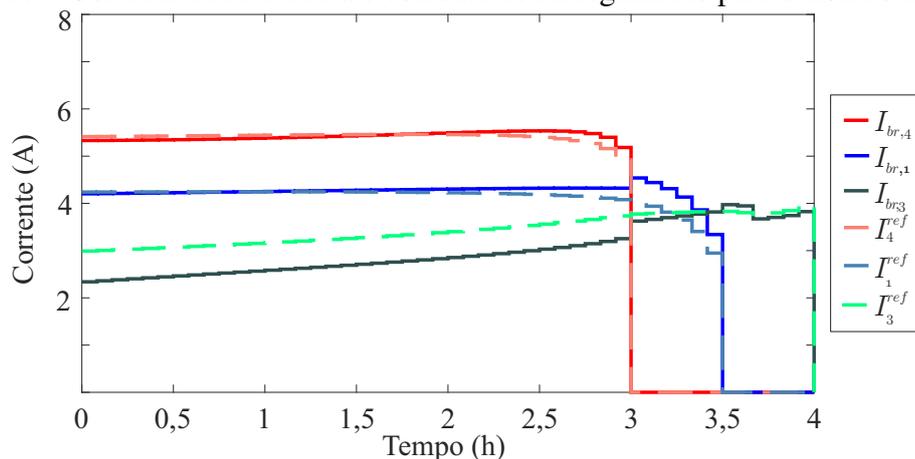
Na Figura 17, as correntes de referência e de carregamento das baterias são mostradas.



Fonte: Autoria própria.

Essas correntes são representadas para os VEs 4, 1 e 3 com saída do estacionamento às 3,0h, 3,5h e 4h, respectivamente. À medida que o tempo de partida de cada um dos VEs se aproxima, a sua corrente de carregamento tende a se aproximar da corrente de referência. Há um pequeno erro referente à diferença entre a potência disponível para carregar cada VE individualmente e a potência necessária para carregar o VE. Por exemplo, observa-se que a corrente de carregamento do VE 3 no início apresenta uma maior diferença para a sua corrente de referência e à medida que o tempo de saída do VE 3 vai se aproximando, a corrente de carregamento da bateria se aproxima mais da corrente de referência.

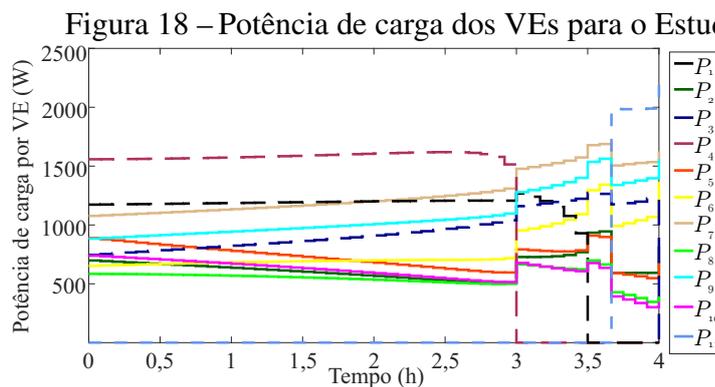
Figura 17 – Corrente de referência e corrente de carregamento para o Estudo de Caso 1.



Fonte: Autoria própria.

Na Figura 18 é apresentada a potência de carga de cada um dos VEs. Os VEs 4, 1 e 3 tendem a utilizar uma maior quantidade de potência de carga, pois possuem um tempo de permanência menor que os outros VEs. Isso acontece por causa do fator de prioridade de

carregamento, que é maior para o VE com menor tempo de permanência no estacionamento e que possui o maior SOC restante necessário para o carregamento. No momento de saída dos VEs, ocorre uma redistribuição de potência para os VEs restantes. O mesmo comportamento pode ser observado no momento de entrada do VE 11, em um período de tempo entre 3,5h e 4,0h, pois, com sua entrada, parte da potência que estava sendo usada para carregar os outros VEs é redirecionada para o VE que acaba de entrar. Isso evidencia a adaptabilidade do algoritmo a saídas e entradas aleatórias.

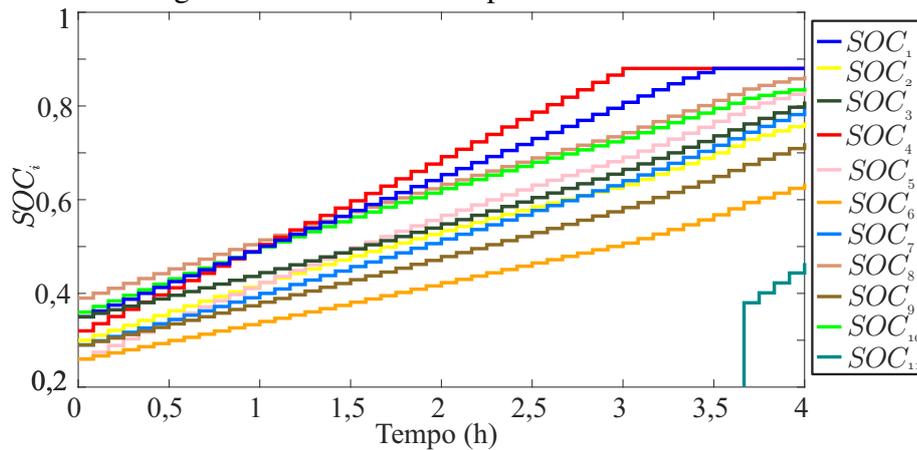


Fonte: Autoria própria.

Na Figura 19 é apresentado o comportamento do SOC de cada um dos VEs presentes no estacionamento. Pode-se observar que os VEs se aproximam do seu SOC desejado à medida que seu tempo de saída está se aproximando, com maior prioridade para os VEs 4, 1 e 3 que possuem um menor tempo de permanência em relação aos outros VEs. Também pode-se notar a entrada do VE 11 no estacionamento, através desta figura, e o início do seu processo de carregamento, que é mais lento em relação aos outros VEs por possuir um fator de prioridade baixo se comparado aos VEs restantes.

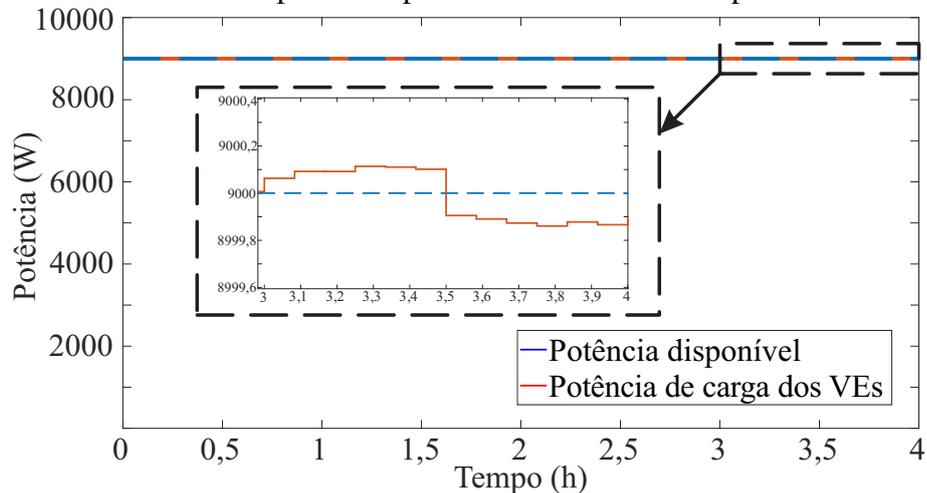
Na Figura 20 é apresentada a relação entre a potência total de carga dos VEs e a potência disponível. Pode-se observar uma grande precisão no aproveitamento total da potência disponível. A partir das 3h, o algoritmo desenvolvido passa por algumas modificações na sua camada de comunicação em relação às entradas e saídas de VEs, conforme é mostrado na área ampliada da Figura. Ainda assim, o algoritmo desenvolvido consegue realizar um bom aproveitamento da potência disponibilizada pela estação de carregamento.

Figura 19 – SOC dos VEs para o Estudo de Caso 1.



Fonte: Autoria própria.

Figura 20 – Potência total disponível e potência total consumida para o Estudo de Caso 1.



Fonte: Autoria própria.

4.2 Estudo de caso 2

Nesse estudo de caso são utilizadas as mesmas características dos VEs que iniciam o processo de carregamento no estudo de caso 1. A diferença entre esse estudo e o anterior, reside no VE que entra na estação de carregamento, pois, nesse estudo, é assumido que o VE tem um tempo de permanência demasiadamente curto que faz com que o VE entre na estação de carregamento e saia da estação de carregamento 0,5h após a sua entrada. O objetivo desse estudo é realizar essa comparação com o primeiro estudo de caso e verificar se mesmo com um tempo de permanência mais curto, o VE que entra na estação de carregamento consegue atingir o seu SOC desejado.

Dessa forma, a estação de carregamento possui 10 UECs que iniciam o processo de carregamento ocupadas por 10 VEs. Posteriormente há a saída de três VEs e a entrada de um VE

de forma aleatória. A potência de carga é definida como sendo de 9 kW e o passo de tempo da simulação como sendo de 5 minutos.

O tempo médio por iteração foi calculado através da Equação (4.1). A troca de informações entre os agentes possui um custo médio de 0,36 ms a cada iteração. O coeficiente de ganho é definido como 5×10^{-6} . Cada VE possui 10 vizinhos e a comunicação se dá de forma semelhante ao estudo de caso 1. A Tabela 6 dispõe os principais parâmetros e informações computacionais desse estudo de caso.

Tabela 6 – Parâmetros e informações computacionais do Estudo de Caso 2.

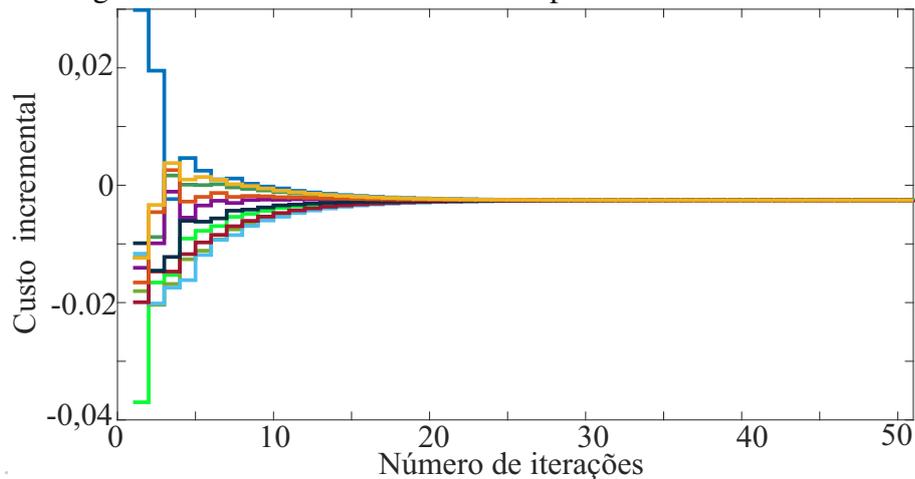
Caso	2
Potência de carga disponível	9 kW
Passo de tempo	5 minutos
Tempo médio por iteração	0,36 ms
Coefficiente de ganho	5×10^{-6}
Erro permitido	10×10^{-6}
Quantidade de Vizinhos por VE	4
Quantidade de VEs inicialmente	10
Quantidade de VEs saindo	1
Quantidade de VEs entrando	3

Fonte: Autoria própria.

Na Figura 21 e na Figura 22 é apresentada a convergência do algoritmo de consenso em relação às informações de custo incremental e desvio para o primeiro instante de tempo, $k = 1$. Em ambas as figuras a convergência do algoritmo acontece na iteração 51. Em termos de tempo, o algoritmo precisou de 0,1836 segundos ($51 \times 0,00036$ segundos) para convergir. Assim como o resultado obtido no estudo de caso 1, a convergência do custo incremental e do desvio de potência em um valor próximo de zero indicam uma boa convergência em relação às informações que são trocadas entre os agentes.

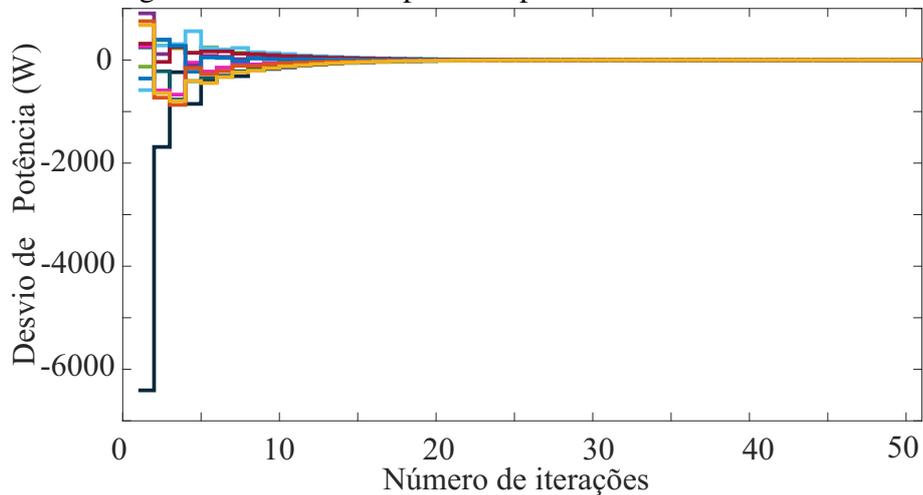
Na Figura 23, as correntes de referência e de carregamento da bateria são mostradas. Essas correntes são representadas para os VEs 4, 1 e 3 com saída do estacionamento às 3,0h, 3,5h e 4h, respectivamente, assim como para o VE 11 que entra na estação de carregamento um pouco depois das 3,0h e tem a sua saída 0,5h depois. O comportamento das correntes dos VEs 4, 1 e 3 funciona de forma similar ao primeiro caso, com a corrente de referência do VE se aproximando cada vez mais da corrente de carregamento à medida que o tempo de permanência diminui, conforme é mostrado na ampliação presente na Figura 23. O VE 11 tem sua corrente de referência em um valor muito alto que, conforme o seu tempo de permanência se aproxima do

Figura 21 – Custo incremental inicial para o Estudo de Caso 2.



Fonte: Autoria própria.

Figura 22 – Desvio de potência para o Estudo de Caso 1.

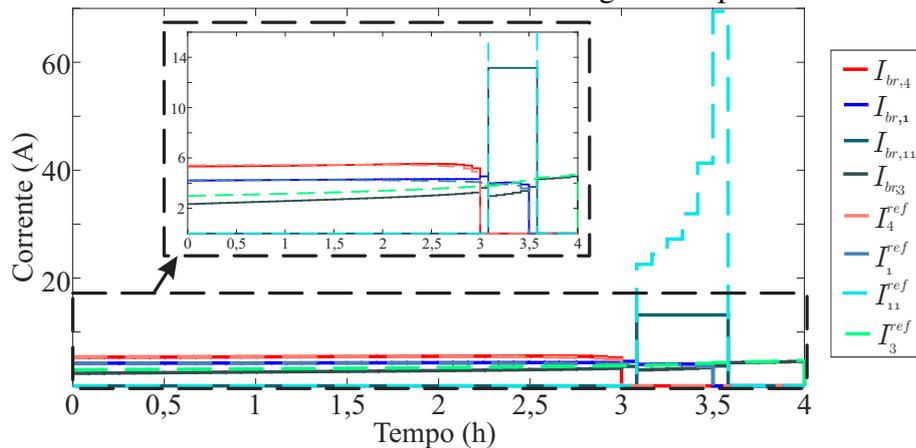


Fonte: Autoria própria.

final a corrente tende a crescer mais, enquanto enquanto a corrente de carregamento da bateria se mantém em um nível constante, não alcançando o valor ideal da corrente de referência devido a potência máxima de carregamento já está sendo alocada ao VE.

Na Figura 24 é apresentada a potência de carga dos VEs. VEs que possuem um tempo de permanência menor e uma quantidade maior de SOC para ser carregado possuem um fator de prioridade maior e, por conta disso, podem ter a sua potência de carga maior que outros VEs com um fator de prioridade menor. Assim como no primeiro caso, a saída de um VE implica na redistribuição da potência que estava sendo utilizada para esse VE. Dessa forma, a saída dos VEs 4, 1 e 3 resultam nessa redistribuição da potência de carga para outros VEs que permanecem no estacionamento. O VE 11 permanece no estacionamento apenas 0,5h e por conta disso possui um fator de prioridade mais elevado que os outros VEs. Dessa forma a potência de carga do

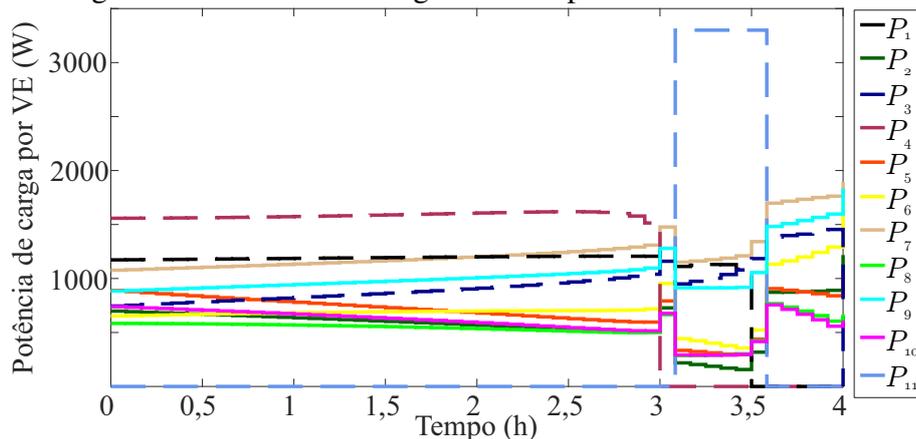
Figura 23 – Corrente de referência e corrente de carregamento para o Estudo de Caso 2.



Fonte: Autoria própria.

VE 11 permanece em 3300 W durante todo o seu período de carregamento com o intuito de se aproximar do seu SOC final.

Figura 24 – Potência de carga dos VEs para o Estudo de Caso 2.

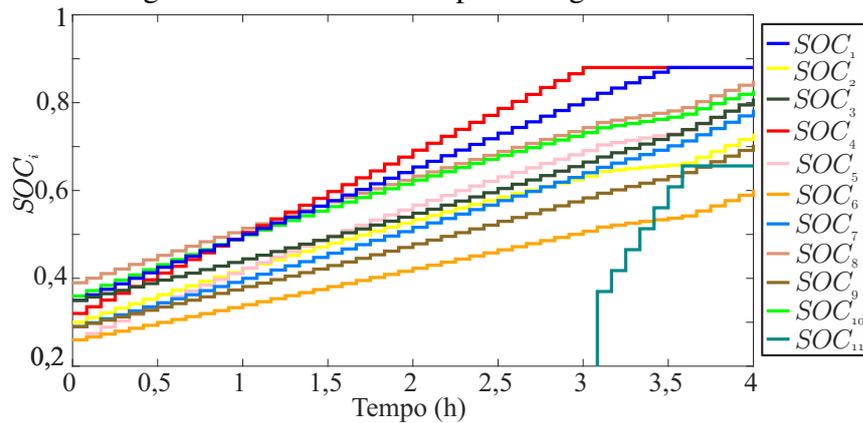


Fonte: Autoria própria.

Na Figura 25 é apresentado o SOC de cada um dos VEs presentes no estacionamento. À medida que o tempo de permanência de cada VE se aproxima do final, há uma tendência de o seu SOC ser carregado mais rapidamente devido ao fator de prioridade. Dessa forma, os VEs 4, 1 e 3 alcançam o seu SOC desejado por terem um tempo de permanência menor e, conseqüentemente, um maior fator de prioridade. O VE 11 alcança 0,6560 de nível de SOC, quando o seu SOC desejado era de 0,86. Mesmo com o máximo de potência de carga sendo alocada ao VE 11, o seu tempo de permanência no estacionamento de apenas 0,5h não possibilitou o carregamento necessário para alcançar o nível de SOC desejado.

Na Figura 26 é apresentada a relação entre a potência total de carga dos VEs e a potência disponível. Pode-se observar uma grande precisão no aproveitamento total da potência

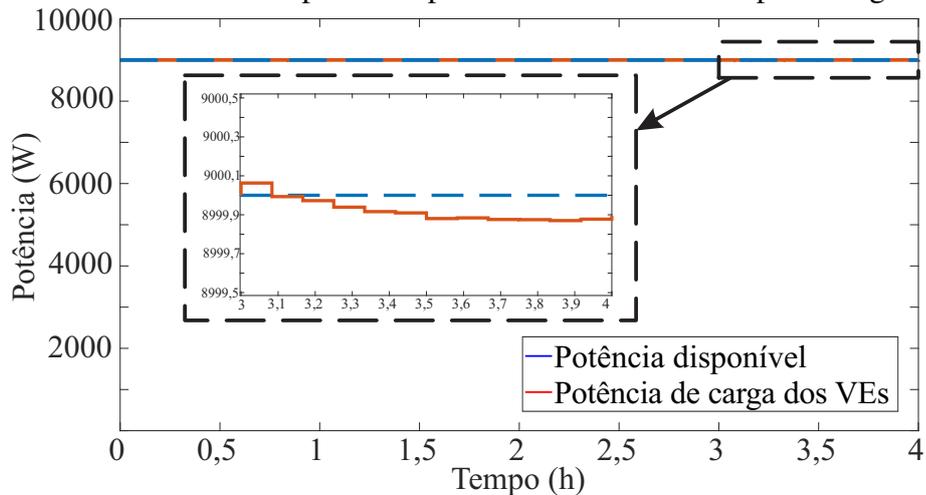
Figura 25 – SOC dos VEs para o segundo caso.



Fonte: Autoria própria.

disponível. A partir das 3h, o algoritmo desenvolvido passa por algumas modificações na sua camada de comunicação em relação às entradas e saídas de VEs, conforme é ilustrado na área ampliada da Figura.

Figura 26 – Potência total disponível e potência total consumida para o segundo caso.



Fonte: Autoria própria.

4.3 Estudo de caso 3

Diferentemente dos casos anteriores, nesse estudo é assumido que existem 100 UECs de carregamento na estação. Desses 100 VEs, 30 são configurados para saírem do estacionamento em horários selecionados de forma aleatória dentre os intervalos de 3,0h e 4,0h, enquanto 10 VEs chegam ao estacionamento de forma também aleatória. O objetivo é demonstrar a adaptabilidade a saídas e a entradas aleatórias e, além disso, provar a escalabilidade do algoritmo em um caso com um maior número de agentes. A potência de carga disponível é definida como sendo de 90

kW e o passo de tempo de simulação permanece em 5 minutos.

O tempo médio por iteração foi calculado através da Equação (4.1). A troca de informações entre os agentes possui um custo médio de 0,0018 segundos a cada iteração. O coeficiente de ganho é definido como 5×10^{-6} . Cada VE possui 10 vizinhos e a comunicação se dá de forma semelhante ao estudo de caso 1. A Tabela 7 dispõe os principais parâmetros e informações computacionais desse estudo de caso.

Tabela 7 – Parâmetros e informações computacionais do Estudo de Caso 3.

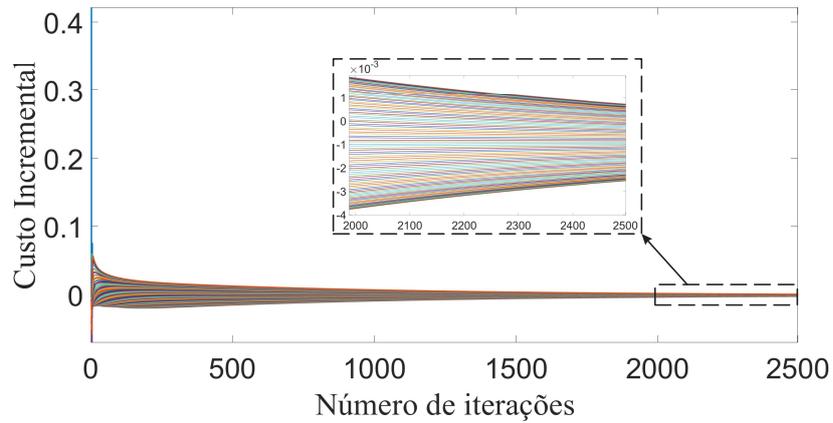
Caso	3
Potência de carga disponível	90 kW
Passo de tempo	5 minutos
Tempo médio por iteração	0,0018s
Coefficiente de ganho	5×10^{-6}
Erro permitido	10×10^{-6}
Quantidade de Vizinhos por VE	10
Quantidade de VEs inicialmente	100
Quantidade de VEs saindo	30
Quantidade de VEs entrando	10

Fonte: Autoria própria.

As Figura 27 e 28 representam a convergência do algoritmo para as informações de custo incremental e de desvio de potência. É possível ver que o algoritmo proposto convergiu para valores próximos de 0 em ambas as figuras. Foram 2501 iterações, o que representa 3 segundos em termos de tempo ($2501 \times 0,0018$) para alcançar a convergência do custo incremental e do desvio de potência. Pode-se notar que existe uma diferença significativa em número de iterações e tempo em relação aos casos anteriores. Isso acontece devido à consideração de uma grande escala de VEs. No entanto, o algoritmo continua apresentando um bom funcionamento mesmo com um grande número de VEs, provando ter escalabilidade e chegando a uma convergência próxima de 0 para as duas informações compartilhadas entre os agentes, conforme é evidenciado na área ampliada da figura.

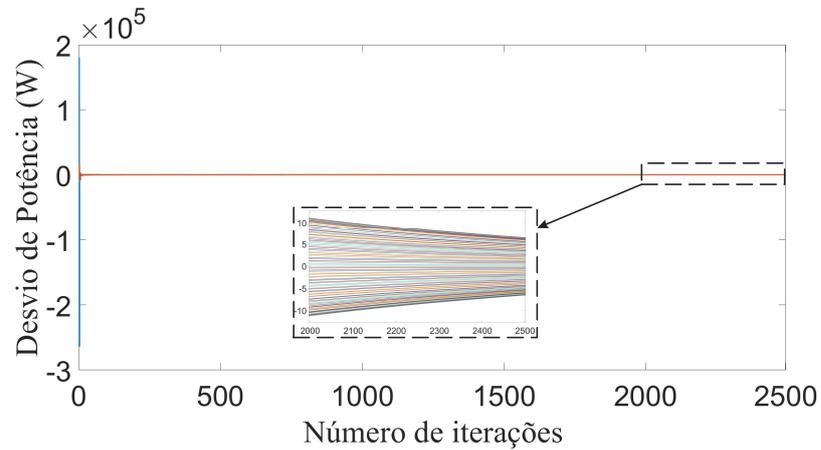
Na Figura 29, podemos ver que os VEs conseguem maximizar a utilização da potência disponibilizada pela estação de carregamento. Há também erro nos instantes finais de execução do código por conta das constantes alterações na rede de comunicação referente a saídas e entradas aleatórias, conforme é demonstrado através da área ampliada presente na figura. Ainda assim, como aconteceu nos estudos de caso anteriores, o algoritmo desenvolvido para 100 VEs apresenta uma boa precisão com as saídas e entradas aleatórias.

Figura 27 – Custo incremental para 100 VEs.



Fonte: Autoria própria.

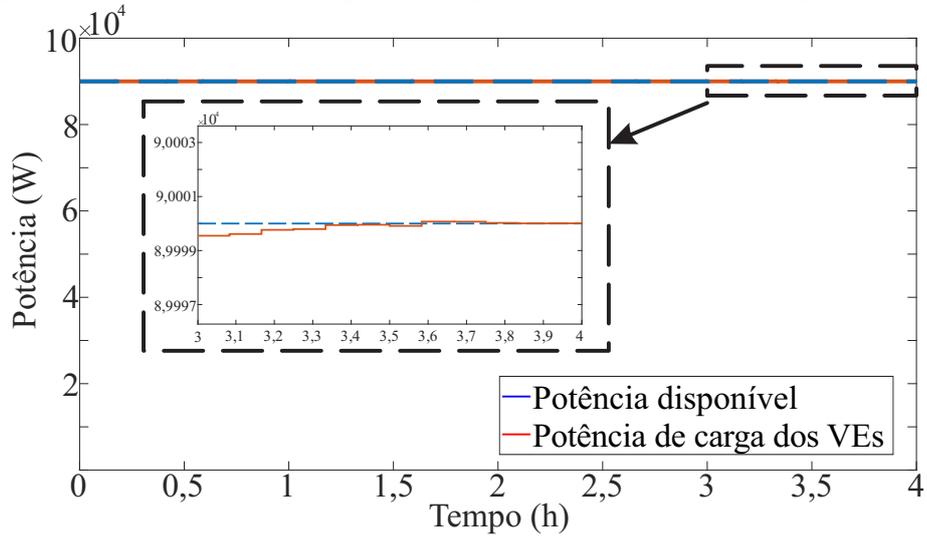
Figura 28 – Desvio de potência para 100 VEs.



Fonte: Autoria própria.

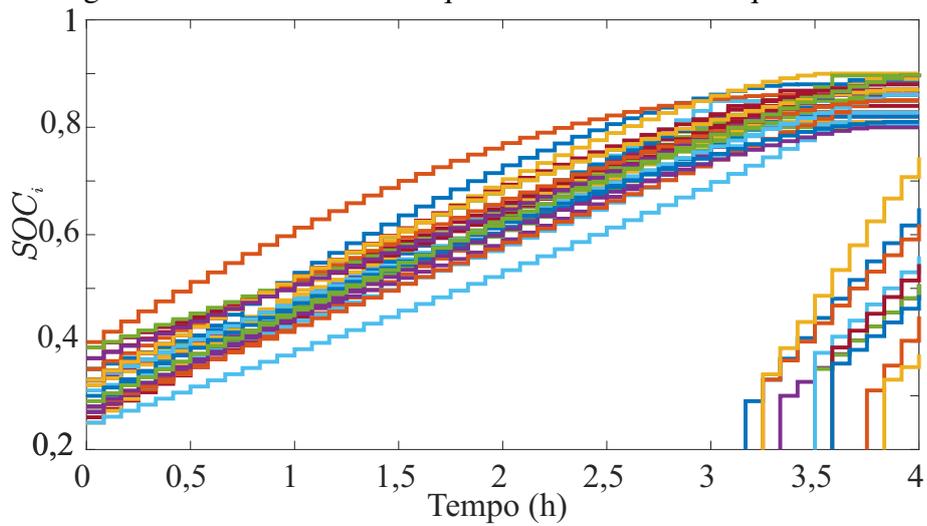
A Figura 30 mostra que os 30 VEs que saem do estacionamento conseguem atingir um nível próximo ao nível desejado de SOC, além de mostrar o início do processo de carregamento dos VEs que entram. Todos os VEs que saem do estacionamento conseguem atingir o seu nível de SOC desejado.

Figura 29 – Potência total disponível e potência total consumida para 100 VEs.



Fonte: Autoria própria.

Figura 30 – SOC dos 30 VEs que saem e dos 10 VEs que entram.



Fonte: Autoria própria.

5 CONCLUSÃO E TRABALHOS FUTUROS

Esta dissertação apresentou uma estratégia de gerenciamento de carregamento de um estacionamento de veículos elétricos com múltiplos pontos de recarga. Para coordenação e controle eficiente do carregamento dos VEs foi usado o algoritmo de consenso discreto distribuído, visando a minimização de perdas elétricas na estação de carregamento. Para isso, o custo incremental e o desvio de potência dos VEs são utilizados como as informações que são compartilhadas entre os VEs.

Os métodos distribuídos são potencialmente mais eficientes e flexíveis que os centralizados e descentralizados, pois a troca de informação é realizada nas vizinhanças adjacentes, reduzindo os requisitos de comunicação e recursos de computação. O modelo utilizado possui os seus parâmetros iniciais definidos através de uma distribuição uniforme, conferindo um caráter de aleatoriedade ao problema. Os objetivos específicos consistem em demonstrar a escalabilidade do método proposto quanto ao número de VEs, realizar eficientemente o carregamento dos VEs, além de aproveitar integralmente a quantidade de potência fornecida pela estação de carregamento e possuir adaptabilidade a saídas e entradas aleatórias de VEs.

Foram apresentados três estudos de caso, em dois deles foi considerando uma estação de carregamento para 10 VEs e no terceiro uma estação de carregamento para 100 VEs a fim de avaliar a efetividade do processo de carregamento usando o algoritmo de consenso. O algoritmo desenvolvido realizou o controle distribuído do carregamento eficiente de VEs com uma boa precisão. Os resultados apresentados para ambos os casos, demonstram uma convergência próxima de zero para o custo incremental e para o desvio de potência, as duas informações que foram compartilhadas entre os agentes. O algoritmo também se mostrou eficiente no que se refere ao aproveitamento total da potência disponibilizada pela estação de carregamento. A rede de comunicação também se mostrou adaptável a saídas e entradas aleatórias no problema, redistribuindo a potência dos VEs que saíram do estacionamento aos VEs que permaneceram no estacionamento. Em relação à entrada de VEs, o algoritmo também conseguiu redistribuir potência dos VEs que estavam na estação aos VEs que entravam no estacionamento. O algoritmo também mostrou característica de escalabilidade ao suportar uma grande quantidade de VEs.

Por conseguinte, a aplicação do algoritmo de consenso evidenciou que a comunicação local entre VEs pode ser utilizada para realizar o carregamento eficiente de VEs. O método também apresentou uma boa escalabilidade, visto que foi aplicado a uma grande quantidade de VEs no terceiro caso.

5.1 Trabalhos futuros

Visando melhorias no presente trabalho, são apresentadas as seguintes sugestões para trabalhos futuros:

- Investigar a utilização de um coeficiente de ganho ótimo;
- Investigar a utilização de outras topologias de rede de comunicação;
- Utilizar outros algoritmos distribuídos que vêm sendo utilizados na literatura mais recente como o algoritmo de difusão, por exemplo;
- Realizar o estudo para diferentes padrões de carregamento.

REFERÊNCIAS

- ALFAGEE, H. A. **Consensus algorithm in smart grid and communication networks**. Tese (Doutorado em Engenharia Elétrica) – Universidade de Colorado, Denver, 2013.
- BJERKAN, K. Y.; NØRBECH, T. E.; NORDTØMME, M. E. Incentives for promoting battery electric vehicle (bev) adoption in norway. **Transportation Research Part D: Transport and Environment**, [S. l.], v. 43, p. 169–180, 2016.
- CHEN, S.; CHENG, R. S. Distributed charging control of plug-in electric vehicles via the stochastic alternating direction method of multipliers. *In*: **2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall)**, 2014, [S. l.], p. 1–5.
- CHEN, Z.; LIU, W.; YIN, Y. Deployment of stationary and dynamic charging infrastructure for electric vehicles along traffic corridors. **Transportation Research Part C: Emerging Technologies**, [S. l.], v. 77, p. 185–206, 2017.
- CORTÉS, A.; MARTÍNEZ, S. A hierarchical algorithm for optimal plug-in electric vehicle charging with usage constraints. **Automatica**, [S. l.], v. 68, p. 119–131, 2016.
- DAS, H.; RAHMAN, M.; LI, S.; TAN, C. Electric vehicles standards, charging infrastructure, and impact on grid integration: A technological review. **Renewable and Sustainable Energy Reviews**, [S. l.], v. 120, p. 109618, 2020.
- DORCEC, L.; PEVEC, D.; VDOVIC, H.; BABIC, J.; PODOBNIK, V. How do people value electric vehicle charging service? a gamified survey approach. **Journal of cleaner production**, [S. l.], v. 210, p. 887–897, 2019.
- ENERGIA, O. **Como será a energia elétrica do futuro?** 2021. Disponível em: <https://origoenergia.com.br/blog/como-sera-a-energia-eletrica-do-futuro>. Acesso em: 14 jul. 2021.
- FAN, H.; DUAN, C.; ZHANG, C.-K.; JIANG, L.; MAO, C.; WANG, D. Admm-based multiperiod optimal power flow considering plug-in electric vehicles charging. **IEEE Transactions on Power Systems**, [S. l.], v. 33, n. 4, p. 3886–3897, 2017.
- GUSRIALDI, A.; QU, Z.; SIMAAN, M. A. Distributed scheduling and cooperative control for charging of electric vehicles at highway service stations. **IEEE Transactions on Intelligent Transportation Systems**, [S. l.], v. 18, n. 10, p. 2713–2727, 2017.
- GWANYAMA, P. W. The hm-gm-am-qm inequalities. **College Mathematics Journal**, [S. l.], p. 47–50, 2004.
- HE, Y.; VENKATESH, B.; GUAN, L. Optimal scheduling for charging and discharging of electric vehicles. **IEEE transactions on smart grid**, [S. l.], v. 3, n. 3, p. 1095–1105, 2012.
- HU, J.; YANG, G.; BINDNER, H. W.; XUE, Y. Application of network-constrained transactive control to electric vehicle charging for secure grid operation. **IEEE Transactions on Sustainable Energy**, [S. l.], v. 8, n. 2, p. 505–515, 2016.
- JAHANGIR, H.; TAYARANI, H.; AHMADIAN, A.; GOLKAR, M. A.; MIRET, J.; TAYARANI, M.; GAO, H. O. Charging demand of plug-in electric vehicles: Forecasting travel behavior based on a novel rough artificial neural network approach. **Journal of cleaner production**, [S. l.], v. 229, p. 1029–1044, 2019.

KANG, J.; DUNCAN, S. J.; MAVRIS, D. N. Real-time scheduling techniques for electric vehicle charging in support of frequency regulation. **Procedia Computer Science**, [S. l.], v. 16, p. 767–775, 2013.

KHAKI, B.; CHU, C.; GADH, R. A hierarchical admn based framework for ev charging scheduling. *In: 2018 IEEE/PES Transmission and Distribution Conference and Exposition (T&D)*, 2018, [S. l.], p. 1–9.

KNEZ, M.; ZEVNIK, G. K.; OBRECHT, M. A review of available chargers for electric vehicles: United states of america, european union, and asia. **Renewable and Sustainable Energy Reviews**, [S. l.], v. 109, p. 284–293, 2019.

KUMAR, R. R.; ALOK, K. Adoption of electric vehicle: A literature review and prospects for sustainability. **Journal of Cleaner Production**, [S. l.], v. 253, p. 119911, 2020.

LAKSHMINARAYANAN, V.; CHEMUDUPATI, V. G. S.; PRAMANICK, S. K.; RAJASHEKARA, K. Real-time optimal energy management controller for electric vehicle integration in workplace microgrid. **IEEE Transactions on Transportation Electrification**, [S. l.], v. 5, n. 1, p. 174–185, 2018.

LEE, D.-H.; KIM, M.-S.; ROH, J.-H.; YANG, J.-P.; PARK, J.-B. Forecasting of electric vehicles charging pattern using bayesians method with the convolustion. **IFAC-PapersOnLine**, [S. l.], v. 52, n. 4, p. 413–418, 2019.

LEWIS, F. L.; ZHANG, H.; HENGSTER-MOVRIC, K.; DAS, A. **Cooperative control of multi-agent systems: optimal and adaptive design approaches**. 1. ed. Londres: Springer Science & Business Media, 2013. v. 1. 23–70 p.

LIU, W.; PLACKE, T.; CHAU, K. Overview of batteries and battery management for electric vehicles. **Energy Reports**, [S. l.], v. 8, p. 4058–4084, 2022.

MA, Z.; ZOU, S.; RAN, L.; SHI, X.; HISKENS, I. A. Efficient decentralized coordination of large-scale plug-in electric vehicle charging. **Automatica**, [S. l.], v. 69, p. 35–47, 2016.

MÅRTENSSON, C.; SJÖVALL, L. **Consensus Algorithms-Flocking and Swarms**. Monografia (Monografia em Engenharia Física) – Departamento de Matemática, Otimização e Teoria dos Sistemas, Instituto Royal de Tecnologia, Estocolomo, 2011.

MATHWORKS. **Uniformly distributed pseudorandom integers**. 2021. Disponível em: <https://www.mathworks.com/help/matlab/ref/randi.html>. Acesso em: 17 jul. 2021.

MELTON, N.; AXSEN, J.; GOLDBERG, S. Evaluating plug-in electric vehicle policies in the context of long-term greenhouse gas reduction goals: Comparing 10 canadian provinces using the “pev policy report card”. **Energy Policy**, [S. l.], v. 107, p. 381–393, 2017.

MIRALLES, J. A. **Consensus Algorithms for Networked Control**. Tese (Doutorado em Engenharia Elétrica e Tecnologia da Informação) – Instituto de Engenharia de Comunicação e Sistemas de Alta Frequência, Universidade Técnica de Viena, Viena, 2014.

MOHAMMADI, J.; HUG, G.; KAR, S. A fully distributed cooperative charging approach for plug-in electric vehicles. **IEEE Transactions on Smart Grid**, [S. l.], v. 9, n. 4, p. 3507–3518, 2016.

- MOSCHELLA, M.; MURAD, M. A. A.; CRISOSTOMI, E.; MILANO, F. Decentralized charging of plug-in electric vehicles and impact on transmission system dynamics. **IEEE Transactions on Smart Grid**, [S. l.], v. 12, n. 2, p. 1772–1781, 2020.
- MUNOZ, E. R.; JABBARI, F. A decentralized, non-iterative smart protocol for workplace charging of battery electric vehicles. **Applied Energy**, [S. l.], v. 272, p. 115187, 2020.
- NGUYEN, V.-L.; TRAN-QUOC, T.; BACHA, S.; LUU, N.-A. Charging strategies to minimize the energy cost for an electric vehicle fleet. *In: IEEE PES Innovative Smart Grid Technologies, Europe*, 2014, [S. l.], p. 1–7.
- NIAN, V.; HARI, M.; YUAN, J. A new business model for encouraging the adoption of electric vehicles in the absence of policy support. **Applied Energy**, [S. l.], v. 235, p. 1106–1117, 2019.
- OLFATI-SABER, R.; FAX, J. A.; MURRAY, R. M. Consensus and cooperation in networked multi-agent systems. **Proceedings of the IEEE**, [S. l.], v. 95, n. 1, p. 215–233, 2007.
- OUTLOOK, I. G. E. Entering the decade of electric drive. **International Energy Agency**, Paris, v. 1, p. 1–16, 2020.
- QI, W.; AN, H.; WANG, M.; DONG, X.; JIANG, Q.; ZHANG, Q.; MU, Y.; JIA, H. Modeling and control of centralized electric vehicles for regulation service. *In: 2020 IEEE Power & Energy Society General Meeting (PESGM)*, 2020, [S. l.], p. 1–5.
- RAHBARI-ASR, N.; CHOW, M.-Y. Cooperative distributed demand management for community charging of phev/pevs based on kkt conditions and consensus networks. **IEEE Transactions on Industrial Informatics**, [S. l.], v. 10, n. 3, p. 1907–1916, 2014.
- REIS, F. E. U. **Estudo de conversores bidirecionais trifásicos para aplicação em estações de recarga de baterias de veículos elétricos**. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2020.
- REN, W.; BEARD, R. W. **Distributed consensus in multi-vehicle cooperative control**. 1. ed. [S. l.]: Springer, 2008. v. 27. 22 p.
- RICHTER, F. **Norway Passes Milestone in Transition to E-Mobility**. 2021. Disponível em: <https://www.statista.com/chart/23863/electric-car-share-in-norway/>. Acesso em: 29 jan. 2021.
- SHALIMOON, A. **Cooperative Control of Multi-Agent Systems: Consensus, Flocking and Formation Control**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade do Estado de Califórnia, Northridge, 2018.
- SIERZCHULA, W.; BAKKER, S.; MAAT, K.; WEE, B. V. The influence of financial incentives and other socio-economic factors on electric vehicle adoption. **Energy Policy**, [S. l.], v. 68, p. 183–194, 2014.
- SLUČIAK, O. **Convergence analysis of distributed consensus algorithms**. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Técnica de Viena, Viena, 2013.
- SOARES, F. J.; ALMEIDA, P. R.; LOPES, J. P. Quasi-real-time management of electric vehicles charging. **Electric Power Systems Research**, [S. l.], v. 108, p. 293–303, 2014.

SOBRINHO, D. M.; ALMADA, J. B.; LEÃO, R. P.; SAMPAIO, R. F. Carregamento eficiente de veículos elétricos usando algoritmo de consenso. **Anais da Sociedade Brasileira de Automática**, [S. l.], v. 2, n. 1, 2020.

SORTOMME, E.; HINDI, M. M.; MACPHERSON, S. J.; VENKATA, S. Coordinated charging of plug-in hybrid electric vehicles to minimize distribution system losses. **IEEE transactions on smart grid**, [S. l.], v. 2, n. 1, p. 198–205, 2010.

STEWART, J. **Cálculo**. 5. ed. São Paulo: Thomson, 2007. v. 5. 36 p.

TAYARANI, M.; NADAFIANSHAMABADI, R.; POORFAKHRAEI, A.; ROWANGOULD, G. Evaluating the cumulative impacts of a long range regional transportation plan: Particulate matter exposure, greenhouse gas emissions, and transportation system performance. **Transportation Research Part D: Transport and Environment**, [S. l.], v. 63, p. 261–275, 2018.

TENG, J.-H.; LIAO, S.-H.; WEN, C.-K. Design of a fully decentralized controlled electric vehicle charger for mitigating charging impact on power grids. **IEEE Transactions on Industry Applications**, [S. l.], v. 53, n. 2, p. 1497–1505, 2016.

TIKKA, V.; LASSILA, J.; HAAKANA, J.; PARTANEN, J. Electric vehicle smart charging aims for co 2 emission reduction? *In: 2016 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*, 2016, [S. l.], p. 1–6.

VAGROPOULOS, S. I.; BAKIRTZIS, A. G. Optimal bidding strategy for electric vehicle aggregators in electricity markets. **IEEE Transactions on power systems**, [S. l.], v. 28, n. 4, p. 4031–4041, 2013.

WANG, L.; CHEN, B. Distributed control for large-scale plug-in electric vehicle charging with a consensus algorithm. **International Journal of Electrical Power & Energy Systems**, [S. l.], v. 109, p. 369–383, 2019.

WANG, R.; LI, Q.; ZHANG, B.; WANG, L. Distributed consensus based algorithm for economic dispatch in a microgrid. **IEEE Transactions on Smart Grid**, [S. l.], v. 10, n. 4, 2018.

WENZEL, G.; NEGRETE-PINCETIC, M.; OLIVARES, D. E.; MACDONALD, J.; CALLAWAY, D. S. Real-time charging strategies for an electric vehicle aggregator to provide ancillary services. **IEEE Transactions on Smart Grid**, [S. l.], v. 9, n. 5, p. 5141–5151, 2017.

WOOD, A. J.; WOLLENBERG, B. F.; SHEBLÉ, G. B. **Power generation, operation, and control**. 3. ed. [S. l.]: John Wiley & Sons, 2013. 620 p.

WU, P. Which battery-charging technology and insurance contract is preferred in the electric vehicle sharing business? **Transportation Research Part A: Policy and Practice**, [S. l.], v. 124, p. 537–548, 2019.

XU, S.; CHEN, X.; HE, Y. Evchain: an anonymous blockchain-based system for charging-connected electric vehicles. **Tsinghua Science and Technology**, [S. l.], v. 26, n. 6, p. 845–856, 2021.

XU, Y. Optimal distributed charging rate control of plug-in electric vehicles for demand management. **IEEE Transactions on power Systems**, [S. l.], v. 30, n. 3, p. 1536–1545, 2014.

- YANG, H.; CHUNG, C.; ZHAO, J. Application of plug-in electric vehicles to frequency regulation based on distributed signal acquisition via limited communication. **IEEE Transactions on Power Systems**, [S. l.], v. 28, n. 2, p. 1017–1026, 2012.
- YOON, T.; CHERRY, C. R.; RYERSON, M. S.; BELL, J. E. Carsharing demand estimation and fleet simulation with ev adoption. **Journal of Cleaner Production**, [S. l.], v. 206, p. 1051–1058, 2019.
- YUAN, K.; YING, B.; ZHAO, X.; SAYED, A. H. Exact diffusion for distributed optimization and learning—part i: Algorithm development. **IEEE Transactions on Signal Processing**, [S. l.], v. 67, n. 3, p. 708–723, 2018.
- ZHAN, K.; HU, Z.; SONG, Y.; LU, N.; XU, Z.; JIA, L. A probability transition matrix based decentralized electric vehicle charging method for load valley filling. **Electric Power Systems Research**, [S. l.], v. 125, p. 1–7, 2015.
- ZHANG, Z.; CHOW, M.-Y. Incremental cost consensus algorithm in a smart grid environment. *In: 2011 IEEE Power and Energy Society General Meeting*, 2011, [S. l.], p. 1–6.
- ZHENG, Y.; NIU, S.; SHANG, Y.; SHAO, Z.; JIAN, L. Integrating plug-in electric vehicles into power grids: A comprehensive review on power interaction mode, scheduling methodology and mathematical foundation. **Renewable and Sustainable Energy Reviews**, [S. l.], v. 112, p. 424–439, 2019.
- ZOU, S.; HISKENS, I.; MA, Z.; LIU, X. Consensus-based coordination of electric vehicle charging. **IFAC-PapersOnLine**, [S. l.], v. 50, n. 1, p. 8881–8887, 2017.