



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

Carregamento Probabilístico de Veículos Elétricos em Redes de Distribuição de Energia

Leonardo Verçosa de Oliveira Valle

João Monlevade, MG
2023

Leonardo Verçosa de Oliveira Valle

Carregamento Probabilístico de Veículos Elétricos em Redes de Distribuição de Energia

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.

Orientador: Dr. Juan Carlos Galvis Manso

Universidade Federal de Ouro Preto
João Monlevade
2023

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

V181c Valle, Leonardo Verçosa de Oliveira.
Carregamento probabilístico de veículos elétricos em redes de
distribuição de energia. [manuscrito] / Leonardo Verçosa de Oliveira
Valle. - 2023.

58 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Juan Carlos Galvis Manso.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia
Elétrica .

1. Energia elétrica - Distribuição. 2. Monte Carlo, Método de. 3.
Otimização combinatória. 4. Sistemas de energia elétrica. 5. Veículos
elétricos. I. Manso, Juan Carlos Galvis. II. Universidade Federal de Ouro
Preto. III. Título.

CDU 621.313

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



FOLHA DE APROVAÇÃO

Leonardo Verçosa de Oliveira Valle

Carregamento Probabilístico de Veículos Elétricos em Redes de Distribuição de Energia

Monografia apresentada ao Curso de Engenharia Elétrica da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica

Aprovada em 15 de março de 2023

Membros da banca

Dr. Juan Carlos Galvis Manso - Orientador - Universidade Federal de Ouro Preto
Dr. Carlos Henrique Nogueira de Resende Barbosa - Universidade Federal de Ouro Preto
Dr. Felipe Eduardo Moreira Cota - Universidade Federal de Ouro Preto

Juan Carlos Galvis Manso, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 04/04/2023



Documento assinado eletronicamente por **Juan Carlos Galvis Manso, PROFESSOR DE MAGISTERIO SUPERIOR**, em 04/04/2023, às 13:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0503955** e o código CRC **28258024**.

Resumo

A queima de combustível fóssil é uma grande preocupação atualmente, e uma parte dos gases emitidos pela queima de combustível são emitidos por veículos a combustão. Atualmente, os veículos elétricos vêm ganhando mais espaço no mercado, já que são considerados uma alternativa menos poluente. Com o aumento de veículos elétricos, os sistemas de energia elétrica podem sofrer de alguns problemas, por exemplo, sobrecarga de transformadores, se o carregamento não for feito controladamente. Para realizar o carregamento controladamente e considerar a aleatoriedade do problema, o seguinte trabalho utiliza o método de Monte Carlo e um algoritmo (algoritmo genético ou algoritmo colônia de formigas) de carregamento ótimo de veículos elétricos. O modelo utilizado aplica-se no cenário de um estacionamento padrão que fornece a possibilidade de um usuário carregar ou descarregar seu veículo no local visando manter a curva de carga do estacionamento o mais constante possível. Os resultados obtidos mostram que o algoritmo genético teve uma resposta melhor no processo de otimização do carregamento de veículos elétricos do que o algoritmo colônia de formigas. Apresentou um melhor cronograma de carregamento, o qual reduziu a demanda máxima da curva de carga do estacionamento em 10%, enquanto o algoritmo colônia de formigas em somente 8,82%.

Palavras-chave: Veículos elétricos, Carregamento, Otimização, Probabilístico, Monte Carlo.

Abstract

Fossil fuel burning is a major concern today, and some of the gases released by fuel burning are emitted by combustion vehicles. Currently, electric vehicles are gaining more space in the market as they are considered a renewable and clean source. Due to the increase in electric vehicles, power systems can be damaged, for example overloading transformers, if charging is not done in a controlled manner. To perform charging in a controlled manner and incorporate randomness into the problem, the following work uses the Monte Carlo method and an optimal electric vehicle charging algorithm. The model used applies in the scenario of a standard parking lot which provides the possibility for a user to load or unload their vehicle on site. Two optimization algorithms were used, genetic algorithm and ant colony optimization algorithm. The results obtained show that the genetic algorithm had a better response than the ant colony optimization algorithm in the process of optimizing the charging of electric vehicles. It presented a better loading schedule, which reduced the maximum demand of the parking lot load curve by 10%, while the ant colony Optimization algorithm by only 8.82%.

Keywords: Electric vehicles, Charging, Optimization, Probabilistic, Monte Carlo.

Lista de ilustrações

| | |
|--|----|
| Figura 1 – Comparação entre a taxa de emissão de gases poluentes por VEs e VCs. | 1 |
| Figura 2 – Processo químico de uma célula de bateria. | 7 |
| Figura 3 – Motor elétrico de um BEV. | 10 |
| Figura 4 – V2G e G2V. | 11 |
| Figura 5 – Modelo de negócios entre consumidor, concessionaria e companhias de veículos. | 12 |
| Figura 6 – Exemplo de Histograma. | 14 |
| Figura 7 – Exemplo de uma função densidade de probabilidade. | 15 |
| Figura 8 – Exemplo distribuição normal. | 15 |
| Figura 9 – Teorema do limite central. | 16 |
| Figura 10 – Distância total (D). | 17 |
| Figura 11 – Distribuição de probabilidade para d_1 e d_2 . | 18 |
| Figura 12 – Tempo de entrada (t_{in}). | 18 |
| Figura 13 – Tempo de saída (t_{out}). | 19 |
| Figura 14 – Cenário do Problema. | 20 |
| Figura 15 – Curva de carga do estacionamento. | 23 |
| Figura 16 – Caminho da formiga | 26 |
| Figura 17 – Fluxograma do Problema de VEs. | 30 |
| Figura 18 – Cromossomo. | 31 |
| Figura 19 – Criação de um cromossomo. | 32 |
| Figura 20 – Roleta para a seleção dos pais. | 32 |
| Figura 21 – Cruzamento. | 33 |
| Figura 22 – Mutação. | 34 |
| Figura 23 – Fluxograma do Algoritmo Genético. | 35 |
| Figura 24 – Caminho da formiga para o problema de VEs | 36 |
| Figura 25 – Matriz de feromônios. | 37 |
| Figura 26 – Matriz de Atração do ACO e curva de carga do estacionamento. | 38 |
| Figura 27 – Fluxograma do Algoritmo colônia de Formigas. | 40 |
| Figura 28 – Fluxograma da simulação de Monte Carlo. | 42 |
| Figura 29 – Valores do PAR durante a otimização pelo AG e ACO. | 45 |
| Figura 30 – curva de carga do estacionamento para o AG e ACO. | 46 |
| Figura 31 – Gráfico comparando o valor da média do PAR para o AG e o ACO na simulação de MC. | 48 |
| Figura 32 – Gráfico comparando o valor do desvio padrão do PAR para o AG e o ACO. | 48 |

| | |
|---|----|
| Figura 33 – Gráfico comparando o valor da média da curva de carga para o AG e o ACO na simulação de MC. | 49 |
| Figura 34 – Gráfico comparando o valor do desvio padrão da curva de carga para o AG e o ACO. | 50 |
| Figura 35 – Seleção. | 55 |
| Figura 36 – Cruzamento. | 55 |
| Figura 37 – Mutação. | 56 |
| Figura 38 – Convergência do algoritmo. | 58 |

Lista de tabelas

| | |
|---|----|
| Tabela 1 – Trabalhos Correlatos. | 4 |
| Tabela 2 – Veículos Elétricos. | 8 |
| Tabela 3 – Dados de entrada para validação determinística. | 43 |
| Tabela 4 – Redução percentual por iteração para o AG e ACO no caso determinístico. | 44 |
| Tabela 5 – Redução percentual da curva de carga do estacionamento para o AG e o ACO. | 46 |
| Tabela 6 – Dados de entrada determinísticos. | 46 |
| Tabela 7 – Dados de entrada estocásticos. | 47 |
| Tabela 8 – Redução percentual da curva de carga do estacionamento para o AG e o ACO na simulação de MC. | 49 |

Lista de abreviaturas e siglas

| | |
|------|---|
| VE | Veículo Elétrico |
| VC | Veículo à Combustão |
| G2V | Grid-to-Vehicle |
| V2G | Vehicle-to-Grid |
| PHEV | Plug-in Hybrid Electric Vehicles |
| HEV | Hybrid Electric Vehicles |
| BEV | Battery Electric Vehicle |
| EREV | Extended Range Electric Vehicle |
| FCEV | Fuel Cell Electric Vehicle |
| SOC | State of Charge |
| GD | Geração Distribuída |
| AG | Algoritmo Genético |
| ICE | Internal Combustion Engine |
| MC | Monte Carlo |
| ACO | Ant Colony Optimization |
| PAR | Peak-to-average ratio of industrial load after integrating N PEVs |

Sumário

| | | |
|------------|--|-----------|
| 1 | INTRODUÇÃO | 1 |
| 1.1 | Justificativa | 2 |
| 1.2 | Revisão bibliográfica | 2 |
| 1.3 | Objetivos | 6 |
| 1.3.1 | Objetivo geral | 6 |
| 1.3.2 | Objetivos específicos | 6 |
| 2 | CONCEITOS TEÓRICOS | 7 |
| 2.1 | Baterias | 7 |
| 2.2 | Veículos elétricos | 8 |
| 2.2.1 | Veículo elétrico híbrido | 9 |
| 2.2.2 | Veículo elétrico híbrido do tipo Plug In | 9 |
| 2.2.3 | Veículo elétrico à bateria | 9 |
| 2.3 | Vehicle to Grid-V2G e Grid to Vehicle-G2V | 10 |
| 2.4 | Conceitos de estatística e probabilidade | 12 |
| 2.4.1 | Valor médio e desvio padrão | 12 |
| 2.4.2 | Histograma | 13 |
| 2.4.3 | Função densidade de probabilidade | 14 |
| 2.4.4 | Distribuição normal | 15 |
| 2.4.5 | Teorema do limite central | 16 |
| 2.5 | Modelo estocástico do perfil de viagem de um VE | 16 |
| 2.5.1 | Distância total percorrida pelo veículo (D) | 17 |
| 2.5.2 | Partes da distância viajadas ($d_1 - d_3$) | 17 |
| 2.5.3 | Tempo de entrada do veículo no estacionamento (t_{in}) | 18 |
| 2.5.4 | Tempo de saída do veículo do estacionamento (t_{out}) | 19 |
| 2.6 | Cenário de carregamento de VEs | 19 |
| 2.6.1 | Características do veículo | 20 |
| 2.6.2 | Restrições dos veículos | 20 |
| 2.6.3 | Função objetivo para o problema de carregamento | 22 |
| 2.6.4 | Curva de carga do estacionamento | 23 |
| 3 | DESCRIÇÃO DOS ALGORITMOS E MC | 24 |
| 3.1 | Algoritmo genético | 24 |
| 3.1.1 | indivíduo | 24 |
| 3.1.2 | Seleção | 24 |
| 3.1.3 | Cruzamento | 24 |

| | | |
|------------|---|-----------|
| 3.1.4 | Mutação | 25 |
| 3.1.5 | Elitismo | 25 |
| 3.2 | Algoritmo colônia de formigas | 25 |
| 3.2.1 | Indivíduo | 25 |
| 3.2.2 | Caminho | 25 |
| 3.2.3 | Feromônios | 26 |
| 3.2.4 | Matriz de Atração | 27 |
| 3.3 | Simulação de MC | 27 |
| 4 | METODOLOGIA | 29 |
| 4.1 | Algoritmo genético aplicado ao problema de carregamento de veículos | 31 |
| 4.1.1 | Cronograma de carregamento | 31 |
| 4.1.2 | Seleção | 32 |
| 4.1.3 | Cruzamento | 33 |
| 4.1.4 | Mutação | 33 |
| 4.1.5 | Elitismo | 34 |
| 4.1.6 | Rotina AG | 34 |
| 4.2 | Algoritmo colônia de formigas aplicado ao problema de carregamento de veículos | 35 |
| 4.2.1 | Cronograma de carregamento | 36 |
| 4.2.2 | Caminho | 36 |
| 4.2.3 | Matriz de feromônios | 37 |
| 4.2.4 | Matriz de atração | 37 |
| 4.2.5 | Rotina ACO | 39 |
| 4.3 | Simulação de MC para o problema de VEs | 40 |
| 5 | RESULTADOS | 43 |
| 5.1 | Validação do AG e do ACO | 43 |
| 5.2 | Simulações MC | 46 |
| 6 | CONCLUSÕES | 51 |
| 6.1 | Trabalhos futuros | 51 |
| | REFERÊNCIAS | 52 |
| A | VALIDAÇÃO DO AG E ACO PELO PROBLEMA DO CAIXEIRO VIAJANTE | 54 |
| A.1 | Caixeiro viajante | 54 |
| A.2 | AG | 54 |
| A.2.1 | Cromossomo | 54 |

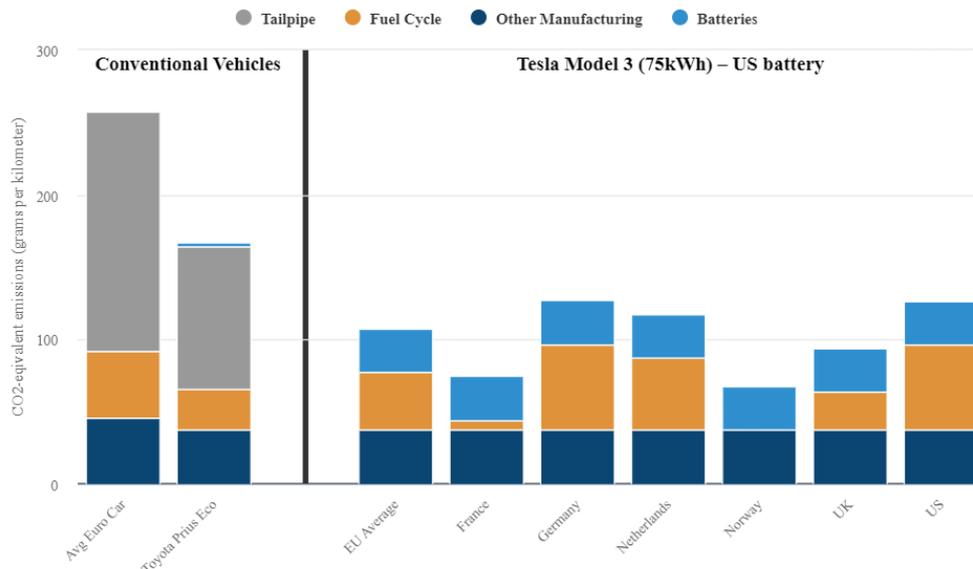
| | | |
|------------|-----------------------------|-----------|
| A.2.2 | Seleção | 54 |
| A.2.3 | Cruzamento | 55 |
| A.2.4 | Mutação | 56 |
| A.2.5 | Elitismo | 56 |
| A.3 | ACO | 56 |
| A.3.1 | Formiga | 56 |
| A.3.2 | Feromônios | 56 |
| A.3.3 | Matriz de atração | 57 |
| A.3.4 | Caminho | 57 |
| A.4 | Resultados | 57 |

1 Introdução

A queima do combustível fóssil emite gases tais como: dióxido de carbono (CO₂), óxidos de nitrogênio (NO_x), entre outros. Esses gases trazem problemas de saúde, em grandes centros urbanos, têm ligação direta com doenças cardiorrespiratórias e são cancerígenos (FELIPE et al., 2015). Na cidade de São Paulo, por exemplo, foi estimado que problemas causados pela poluição do ar, gera custos de US\$ 1,5 bilhão ao estado (FELIPE et al., 2015). Além de problemas de saúde, esses gases são fontes de problemas ambientais, assim, são responsáveis pela redução da camada de ozônio e emissão de gases nocivos ao ambiente.

Os veículos à combustão (VCs) são responsáveis por 25% da emissão de gases nocivos e como alternativa aos VCs, os veículos elétricos (VEs) vem ganhando espaço no mercado, visto que são considerados uma alternativa menos poluente, uma vez que não emitem gases nocivos. Contudo, não possuem impacto zero sobre o meio ambiente, o descarte de suas baterias corretamente é essencial, apesar disso a emissão de gases é menor que a de um VC, como mostrado na Figura 1. Portanto, os incentivos para a utilização de VEs está em constante crescimento (BARAN et al., 2011).

Figura 1 – Comparação entre a taxa de emissão de gases poluentes por VEs e VCs.



Fonte: Adaptado de Brief (2020)

Devido a esse incentivo, alguns problemas que podem aparecer pelo aumento da utilização de VEs podem ser, por exemplo, a sobrecarga de transformadores e linhas de distribuição (MEHTA et al., 2018). Contudo, o carregamento de VEs, se feito controlada-

mente, pode trazer benefícios para a rede de distribuição, assim, diminuindo os possíveis danos. Para realizar o controle do carregamento, são utilizadas várias estratégias com objetivos diferentes, tais como: diminuir o custo de carregamento, reduzir o pico de carga, e assim, achatar a curva de carga (MEHTA et al., 2018) e utilizar VEs como um sistema armazenador de energia (KUMAR et al., 2014).

1.1 Justificativa

Devido ao aumento do uso de VEs, a frota aumentará em grande escala nos próximos anos e, conseqüentemente, existirá um impacto relevante no planejamento e operação da rede de distribuição. O impacto, devido à sobrecarga do sistema de distribuição, poderá ser minimizado pelo controle do carregamento desses VEs (MEHTA et al., 2018).

Futuramente poderão existir postos de carregamento em grandes centros comerciais, nos quais a carga é elevada. Em um shopping, por exemplo, o estacionamento poderá ser utilizado como posto de carregamento, portanto aumentará a carga no local, e para evitar que o sistema elétrico seja sobrecarregado é fundamental realizar o controle do carregamento de VEs. Para elaborar o controle é necessário o estudo do carregamento ótimo de veículos.

A otimização do carregamento de automóveis será realizado por dois algoritmos, Algoritmo Genético (AG) e algoritmo de colônia de formigas (Ant colony Optimization (ACO)). O AG e o ACO já foram aplicados com sucesso neste tipo de problema de carregamento ótimo de VEs, utilizados nos trabalhos de Mehta et al. (2018) e Mavrouniotis, Ellinas e Polycarpou (2019) respectivamente. Além disso, tanto o AG quanto o ACO são de fácil implementação computacional.

Estatística é uma ferramenta chave nos negócios e na industrialização. Essa ferramenta matemática é utilizada a fim de entender sistemas variáveis, controle de processos, custos financeiros e de qualidade e para sumarização de dados e também tomada de decisão baseada em dados. Nessas funções, a estatística é uma técnica chave para a simulação de estudo do carregamento de VE se aproximar da realidade.

1.2 Revisão bibliográfica

A seção a seguir resume as principais referências utilizadas durante o trabalho, onde primeiro são apresentados os trabalhos relativos ao impacto do carregamento dos automóveis, tecnologias utilizadas e suas conclusões. Em sequência são apresentados os trabalhos que analisaram o carregamento de forma probabilística, as técnicas utilizadas e suas conclusões. A Tabela 1 mostra a revisão bibliográfica resumidamente de cada autor.

O carregamento de VEs considera dois tipos de modos: o fornecimento de energia elétrica da rede para o veículo (Grid-to-vehicle (G2V)) e do veículo para a rede (Vehicle

to Grid (V2G)). Os trabalhos de Mehta et al. (2018), Li, Bai e Tan (2012), Kumar et al. (2014), Raghavan e Khaligh (2012), Oliveira (2012) e Mavrouniotis, Ellinas e Polycarpou (2019), utilizaram do modo V2G. De acordo com Mehta et al. (2018), a maior limitação dos estudos relacionados à operação de VEs é a de utilizar somente um modo (G2V ou V2G). Entretanto, os algoritmos utilizados foram distintos para realizar a otimização do carregamento.

Mehta et al. (2018) usa algoritmo genético, Oliveira (2012) aplica algoritmo de sistemas imunológicos artificiais, Li, Bai e Tan (2012) utilizam um algoritmo de carregamento inteligente (Smart charging) e Mavrouniotis, Ellinas e Polycarpou (2019) aplicaram o algoritmo colônia de formigas. Mehta et al. (2018) analisa duas estratégias de carregamento, a primeira reduz o custo diário para o proprietário do veículo, a segunda atenua a curva de carga.

Li, Bai e Tan (2012) destacaram que para sistemas de pequeno porte, o carregamento de VEs ajuda a melhorar a eficiência da rede. Kumar et al. (2014) constata que para prédios arranha-céus, um grupo de VEs pode ser utilizado como armazenamento de energia inteligente (Smart Energy Storage) ou pode ser utilizado para melhorar a eficiência da rede nos prédios. Raghavan e Khaligh (2012) concluíram que durante a noite o carregamento do veículo elétrico híbrido plug-in (Plug-in Hybrid Electric Vehicles (PHEV)) é mais vantajoso para o sistema de distribuição e para o dono do veículo.

Oliveira (2012) confirma que a recarga controlada de VEs mantém os níveis de tensão adequados nas redes de distribuição, evita sobrecargas em circuitos, condutores e transformadores de distribuição; aumento de harmônicos e de correntes de falta. Por último, Mavrouniotis, Ellinas e Polycarpou (2019) utiliza do ACO para resolver os problemas de coordenação entre as estações de carregamento, e assim, aumentar a eficiência do carregamento. Portanto, todos os trabalhos definiram objetivos, sistemas teste e metodologias diferentes (Tabela 1). Porém, todos propõem maneiras de melhorar a rede de distribuição de energia com o carregamento de VEs.

Por outro lado, Tekdemir et al. (2017), Amini e Moghaddam (2013), Shariff, Al Essa e Cipcigan (2016) e Rezaee e Khorramdel (2013) abordam o carregamento de VEs com uma análise probabilística. Os trabalhos tratam de formas distintas essa análise considerando variáveis diferentes como objeto de estudo. Por exemplo, Amini e Moghaddam (2013) propõem dois modelos: o primeiro, propõe analisar o comportamento dos usuários de VEs em relação ao preço da energia elétrica, o segundo realiza uma análise probabilística em função da distância percorrida por um veículo via uma distribuição lognormal. Rezaee e Khorramdel (2013) projeta dois cenários: primeiro cenário a casa dos donos dos veículos possuem um carregador, enquanto o segundo cenário as casas não possuem um carregador e assim trabalha com duas variáveis de forma estocástica dentro dos dois cenários, o tempo de permanência no estacionamento e a distância percorrida pelo veículo no trajeto em estudo, utilizando uma distribuição de Rayleigh e uma distribuição normal, respectivamente, para

as variáveis.

Contudo, Tekdemir et al. (2017) utiliza uma distribuição Weibull, para modelar a carga de VEs. E, por fim, Shariff, Al Essa e Cipcigan (2016) utilizam o método de Monte Carlo (MC) para modelar o carregamento de VEs. Tekdemir et al. (2017) constata que a integração da carga dos VE ao sistema de distribuição irá afetar o sistema negativamente, prevendo um problema futuro em relação à carga dos transformadores do sistema, e um planejamento seria necessário para mitigar esse problema.

Amini e Moghaddam (2013) concluíram que o aumento da taxa de carregamento e capacidade do estacionamento levará a um incremento na cobrança da demanda de energia.

Shariff, Al Essa e Cipcigan (2016) confirma que para a integração de um grande volume de VE ao sistema de distribuição, será necessário a combinação de estratégias diferentes, como preferência os VE serem carregados por energias renováveis e utilizar o carregamento inteligente para os mesmos.

Rezaee e Khorramdel (2013) concluíram que ao utilizar estratégias de carregamento em estacionamentos com uma interface com o sistema de distribuição, irá substancialmente diminuir os problemas devido ao aumento da frota de VE.

Tabela 1 – Trabalhos Correlatos.

| Referência | Objetivos | Metodologia | Sistema teste |
|----------------------|---|--|---|
| (MEHTA et al., 2018) | Analisar duas estratégias (primeira reduz o custo diário, segunda atenua a curva de carga) de carregamento de veículos elétricos. | V2G e AG. | Estacionamento de uma indústria com 1000 vagas |
| (LI; BAI; TAN, 2012) | Analisar o impacto de PHEV na rede de distribuição de baixa tensão. | V2G, smart charging method. | Cenários diferentes de uma rede residencial de 10kV. |
| (KUMAR et al., 2014) | Analisar a viabilidade de utilizar um grupo de VEs como Smart Energy Storage | V2G, algoritmo Estimção da capacidade V2G usando programação dinâmica de VEs em tempo real | Três construções em Singapura, residencial, escritório, loja comercial. |

| | | | |
|---|---|---|---|
| (OLIVEIRA, 2012) | Otimizar a recarga de veículos em sistemas de distribuição de energia. | V2G e algoritmo de sistema imunológico artificial | Sistema de distribuição residencial IEEE 34. |
| (MAVROVOUNIOTIS; ELLINAS; POLYCARPOU, 2019) | Otimizar a recarga de veículos em sistemas de distribuição de energia. | V2G e ACO | Estacionamento. |
| (TEKDEMIR et al., 2017) | Analisar as mudanças da tensão e dos transformadores considerando mudanças futuras pela carga das estações de VEs. | Distribuição probabilística de weibull, método de amostragem por Hipercubo latino, software PSS SINCAL. | Indústrias e residências com 6960 clientes e 14 transformadores de distribuição. |
| (AMINI; MOGHADDAM, 2013) | Modelar de forma probabilística a demanda de carga de VEs em estacionamentos | Função de distribuição lognormal, modelo probabilístico de um VE. | Estacionamentos de 1000 veículos. |
| (SHARIFF; Al Essa; CIPCIGAN, 2016) | Estudar parâmetros estocásticos, como, local de carregamento e demanda de carga de VEs sem utilizar Geração Distribuída (GD). | Simulações usando software MATLAB, método MC, algoritmo de fluxo de potência Newton-Raphson. | Rede residencial urbana do Reino Unido. |
| (RAGHAVAN; KHALIGH, 2012) | Desenvolver uma Smart Grid com ênfase em gestão de demanda e interação do consumidor com o mercado de operações. | V2G, algoritmos (real time pricing e time of use). | Rede de distribuição residencial pequena consiste em quatro casas alimentadas por um transformador de 25 kVA. |

| | | | |
|----------------------------|--|--------------------------------------|---|
| (REZAEE; KHORRAMDEL, 2013) | análise estocástica do carregamento de veículos elétricos. | modelo estocástico de VE, V2G e G2V. | Sistema de distribuição residencial IEEE 34 e estacionamentos de 1000 veículos. |
|----------------------------|--|--------------------------------------|---|

Fonte: Do autor.

1.3 Objetivos

1.3.1 Objetivo geral

Definir o controle de carga para o carregamento de VEs em um grande consumidor, como, estacionamento de um centro comercial, de uma faculdade, etc., para realizar, por meio desse, uma redução da demanda máxima da curva de carga na rede de distribuição.

1.3.2 Objetivos específicos

- Implementar o modelo matemático probabilístico, considerando a aleatoriedade de algumas variáveis de entrada (distância percorrida, tempo de entrada e tempo de saída) com uma distribuição de probabilidade associada.
- Utilizar o método MC para simular os eventos aleatórios e encontrar a distribuição dos parâmetros de saída.
- Explorar e utilizar um algoritmo ótimo de carregamento de VEs baseado em AG e ACO em conjunto com o método de Monte Carlo.
- Analisar a variação das variáveis de saída do algoritmo de carregamento de VEs diante o comportamento aleatório de determinados parâmetros de entrada (distância percorrida, tempo de entrada e tempo de saída).

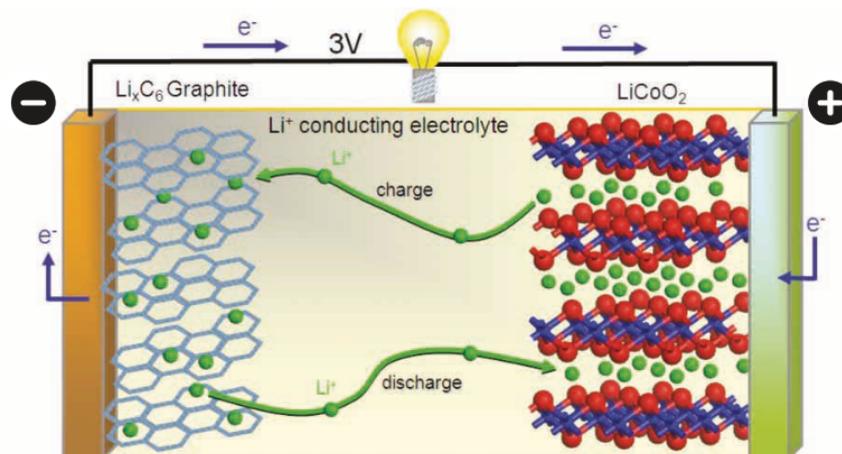
2 Conceitos teóricos

Esta seção irá descrever os conceitos teóricos utilizados no problema do carregamento ótimo de VEs. Primeiramente serão apresentadas as baterias, e suas particularidades. Em seguida apresentaremos os tipos de veículos elétricos existentes. Em terceiro retrataremos os conceitos de estatística e probabilidade envolvidos no problema do carregamento ótimo de VEs. Por último, explicaremos o modelo de otimização utilizado para o problema.

2.1 Baterias

Uma bateria típica é composta por duas ou mais células eletroquímicas unidas entre si. Cada célula de bateria é composta por um eletrodo negativo e um eletrodo positivo que estão conectados por um eletrólito, assim, a reação química entre os eletrodos e o eletrólito gera eletricidade (Figura 2). O material utilizado para os eletrodos e os eletrólitos determina as especificações da bateria (MATTHEY, 2017).

Figura 2 – Processo químico de uma célula de bateria.



Fonte: Matthey (2017).

A seguir são apresentadas algumas características das baterias (Tabela ??):

- Energia específica: consiste na quantidade de energia armazenada na bateria por unidade de massa (Wh/kg).
- Potência específica: é a potência fornecida por unidade de massa (W/kg).
- Tempo de vida útil: corresponde ao número de ciclos de carga/descarga a que pode ser sujeita.

- Capacidade da bateria: equivale na quantidade total de energia armazenada na bateria (kWh).
- Autonomia da bateria: representa o tempo de duração do funcionamento de um aparelho, no caso o VEs, sem recorrer à fonte de energia externa (km).

As baterias são implementadas nos VEs segundo suas características, pois em alguns casos é a única fonte de potência do veículo. Em automóveis puramente elétricos a densidade de energia deverá ser maior e a bateria têm um nível de descarga maior do que os PHEV ou Hybrid Electric Vehicles (HEV). Em veículos híbridos, por exemplo, podem ser implementadas baterias com menor energia específica, mas com maior potência específica, já que precisam de um nível de potência maior.

2.2 Veículos elétricos

Os primeiros VEs apareceram no início do século XX, os quais foram produzidos nos Estados Unidos da América (EUA), Grã-Bretanha e França. À medida que os VCs mostraram um melhor desempenho comparado com as limitações que tinham os VEs, principalmente com as baterias, esses últimos quase desapareceram no ano 1930 (BARAN et al., 2011). Porém, hoje em dia alguns fabricantes já oferecem VEs para a venda e aluguel (BARAN et al., 2011).

Existem diferentes tipos de VEs no mercado atual de acordo com sua evolução até o tipo de VE mais recente (Tabela 2). Serão apresentados posteriormente alguns desses tipos de veículos: HEV, PHEV e BEV.

Tabela 2 – Veículos Elétricos.

| Tipos de VEs | Combustível | Composição | Autonomia à gasolina (km) | Autonomia à bateria (km) |
|-----------------------------------|--------------------------------------|---|---------------------------|--------------------------|
| HEV | Gasolina | Motor elétrico e um motor a combustão interna | 850 | 30 |
| PHEV | Gasolina e energia elétrica | Motor elétrico e um motor a combustão interna | 850 | 80 |
| BEV | Energia elétrica | Motor elétrico | - | 150 |
| Fuel Cell Electric Vehicle (FCEV) | Células de combustível de hidrogênio | Motor elétrico | - | 500 |

| | | | | |
|--|-----------------------------|---|-----|-----|
| Extended Range Electric Vehicle (EREV) | Gasolina e energia elétrica | Motor elétrico e um motor a combustão interna | 130 | 150 |
|--|-----------------------------|---|-----|-----|

Fonte: Hermans (2013).

2.2.1 Veículo elétrico híbrido

É um veículo composto por mais de uma fonte de energia, um motor à combustão interna (Internal Combustion Engine (ICE)) que funciona em conjunto com um motor elétrico, para reduzir a emissão de poluentes e ocasionar um menor consumo de combustível. Esse tipo de veículo a bateria não precisa ser carregada externamente, em razão de ser feito pelo próprio veículo durante uma frenagem ou em momentos de desaceleração, ao converter energia cinética em elétrica para o carregamento da bateria. Neste caso, existe um sistema eletrônico que decide em que instante se deve utilizar a fonte elétrica ou a mecânica (CASTRO; FERREIRA, 2010).

2.2.2 Veículo elétrico híbrido do tipo Plug In

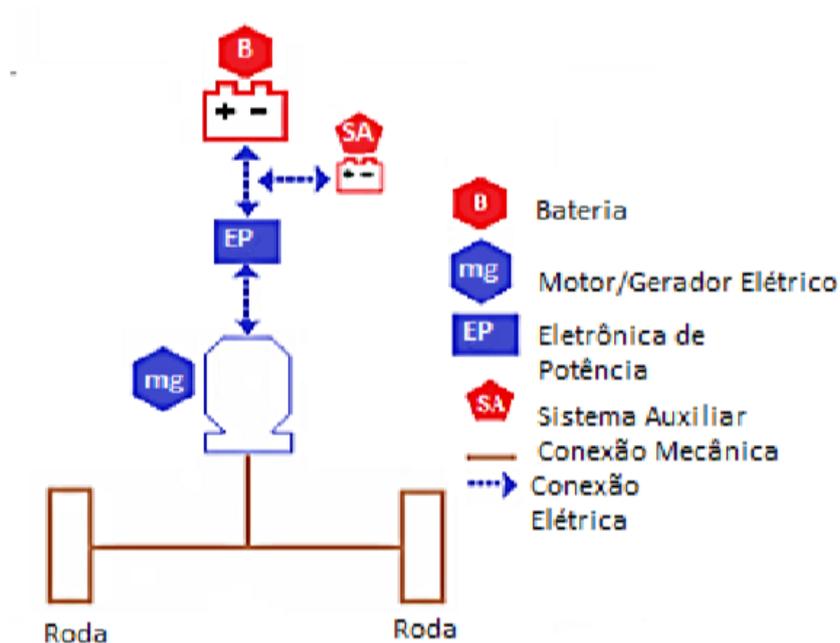
O PHEV é um veículo composto por um motor elétrico e um ICE, análogo ao HEV. A sua diferença está nas dimensões dos motores e sua conexão na rede elétrica onde carrega suas baterias. Sua bateria é um pouco maior do que a bateria do HEV e o ICE é menor comparado com o ICE do HEV ou de um veículo de combustão comum. O HEV e o PHEV tem o mesmo objetivo, o qual é aumentar a autonomia do veículo, ao combinar um motor elétrico com um ICE e uma bateria (CASTRO; FERREIRA, 2010).

Quando em funcionamento, o veículo tende a utilizar o motor mais eficiente para a situação. Em locais onde a velocidade pode ser maior, o ICE é ativado, em locais onde a velocidade deve ser menor, o motor elétrico é ativado (CASTRO; FERREIRA, 2010).

2.2.3 Veículo elétrico à bateria

O BEV diferentemente dos outros veículos citados nas seções 2.2.1 e 2.2.2, não possui um motor de combustão interna, assim, a sua configuração interna é composta apenas de uma bateria e um motor elétrico (Figura 3). Devido a sua composição ser dessa forma, o BEV necessita de estar conectado a uma tomada na rede elétrica para recarregar a bateria. A sua bateria é maior, devido à necessidade de armazenar mais energia, visto que não possui mais um ICE para ajudar na locomoção (CASTRO; FERREIRA, 2010).

Figura 3 – Motor elétrico de um BEV.



Fonte: Adaptado de Garcia Osorio (2013).

Em virtude da necessidade de um BEV de se conectar à rede de energia elétrica, surgiram formas inteligentes de utilizar as baterias dos veículos, algumas dessas são os modos G2V e V2G (MEHTA et al., 2018).

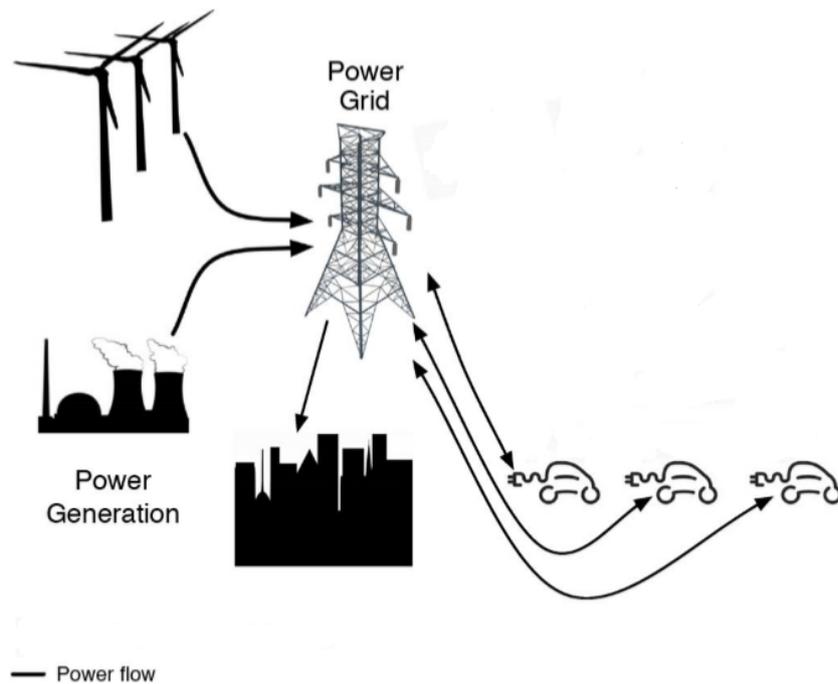
2.3 Vehicle to Grid-V2G e Grid to Vehicle-G2V

V2G descreve um sistema onde automóveis, com a necessidade de se conectar a rede elétrica, podem se comunicar com a rede elétrica para vender serviços, como, retornar eletricidade para a rede e limitar a taxa de carregamento (ROBLEDO et al., 2018).

G2V descreve um sistema onde os geradores de energia elétrica se comunicam com os consumidores, no caso os VEs, oferecendo serviços, como, fornecer energia para as demandas dos consumidores (ROBLEDO et al., 2018).

Portanto, esses modos proporcionam uma comunicação bidirecional entre os VEs e a rede de energia elétrica (Figura 4).

Figura 4 – V2G e G2V.

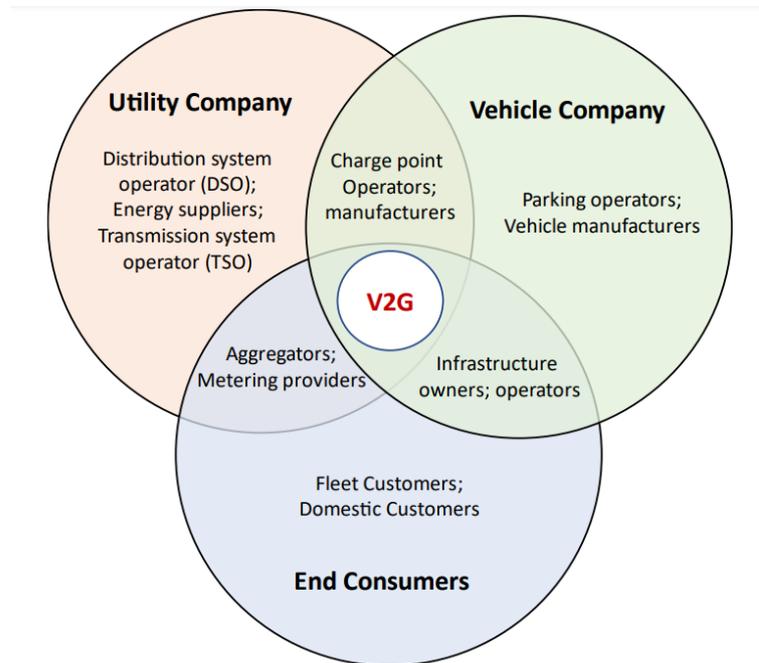


Fonte: Adaptado de Escudero-Garzas, Garcia-Armada e Seco-Granados (2012).

O sistema de carregamento de VEs irá operar no Mercado de Eletricidade como uma usina virtual que oferece uma variedade de serviços, incluindo arbitragem de preços, gerenciamento de demanda de pico e otimização de geração atrás do medidor. O V2G é visto como um divisor de águas porque permitem que geradores de energia renovável, até mesmo proprietários de residências particulares, não apenas reduzam seus próprios custos de energia, mas ganhem financeiramente com o excesso de energia gerada, (CASTRO; FERREIRA, 2010).

Os VEs oferecem um novo caminho para este recurso de integrar as companhias de veículos, concessionárias de energia e o consumidor local em um grande sistema de modelo de negócios, como mostrado na figura 5.

Figura 5 – Modelo de negócios entre consumidor, concessionária e companhias de veículos.



Fonte: Adaptado de Mojumder et al. (2022).

2.4 Conceitos de estatística e probabilidade

Essa seção aborda conceitos teóricos de estatística e probabilidade. Métodos estatísticos são uma importante ferramenta no desenvolvimento de novas tecnologias ou no aprimoramento de tecnologias existentes, porque apresentam recursos analíticos para lidar com a variabilidade dos dados observados (MONTGOMERY; RUNGER, 1994).

Devido ao comportamento aleatório de alguns parâmetros de entrada, como, tempo de utilização do estacionamento e distância percorrida, os quais não podemos garantir sua imutabilidade, uma vez que todos os VEs não irão chegar e sair simultaneamente, e percorreram distâncias diferentes. Portanto, para analisar a variação das variáveis de saída do algoritmo de carregamento de VEs é importante abordar alguns conceitos teóricos de estatística, como, valor médio, desvio padrão, histograma, função densidade de probabilidade e distribuição normal para tratar com a variabilidade desses dados de entrada.

2.4.1 Valor médio e desvio padrão

O valor médio é uma medida de localização do centro da distribuição de probabilidades da variável aleatória (LEVINE et al., 2008). As equações 2.1 e 2.2 representam o valor

médio de uma variável contínua e o valor médio de uma variável discreta, respectivamente.

$$\mu = E(X) = \int_{-\infty}^{\infty} xf(x) dx \quad (2.1)$$

$$\mu = E(X) = \sum_{i=1}^N x_i P(x_i) \quad (2.2)$$

N : Número máximo de interações.

X : Variável aleatória contínua ou discreta.

$f(x)$: Função densidade de probabilidade de x .

$P(x_i)$: Função densidade de probabilidade de x_i .

μ : Valor médio.

O desvio padrão mede a dispersão em torno do valor médio, o modo como os valores mais altos flutuam acima e o modo como os dados mais baixos se distribuem abaixo dele (LEVINE et al., 2008). As equações 2.3 e 2.4 representam a forma de calcular a variância na forma contínua e na forma discreta respectivamente. O desvio padrão é dado pela raiz quadrada da variância ($\sigma = \sqrt{\sigma^2}$).

$$\sigma^2 = V(X) = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx = \int_{-\infty}^{\infty} x^2 f(x) dx - \mu^2 \quad (2.3)$$

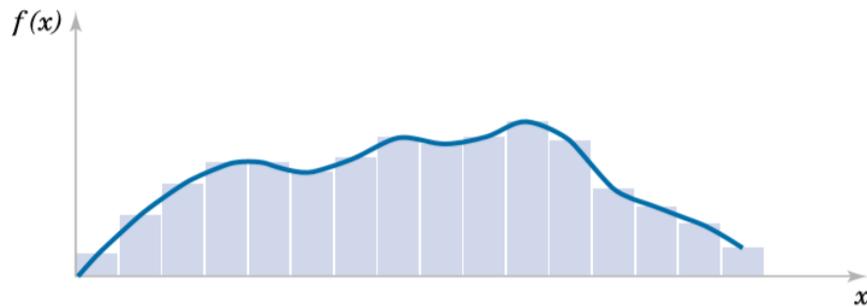
$$\sigma^2 = V(X) = \sum_{i=1}^N (x_i - \mu)^2 P(x_i) \quad (2.4)$$

σ^2 : Variância de X .

2.4.2 Histograma

Um histograma é uma aproximação de uma função densidade de probabilidade (Figura 6). Portanto, da mesma forma que a área abaixo de $f(x)$ representa a probabilidade de uma medida cair naquele intervalo, o histograma tem uma representação similar, onde para cada intervalo do histograma, a área da barra é igual à frequência relativa das medições no intervalo. Essa frequência relativa é a estimativa de uma medição cair naquele intervalo (MONTGOMERY; RUNGER, 1994).

Figura 6 – Exemplo de Histograma.



Fonte: Montgomery e Runger (1994).

2.4.3 Função densidade de probabilidade

Função densidade de probabilidade gera uma descrição para as probabilidades associadas com uma variável aleatória, contanto que siga algumas restrições, para uma distribuição contínua (equações 2.5 a 2.7) e para uma distribuição discreta (equações 2.8 a 2.10). Uma função densidade de probabilidade é zero toda vez que a variável utilizada, X , não pode ocorrer. A integral de $f(x)$ calcula a área abaixo da curva, a qual representa a probabilidade de uma variável ocorrer entre $[a, b]$ (Figura 7) (MONTGOMERY; RUNGER, 1994).

$$f(x) \geq 0 \quad (2.5)$$

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad (2.6)$$

$$P(a \leq X \leq b) = \int_a^b f(x) dx = \text{área abaixo de } f(x), \quad \text{para qualquer } a \text{ e } b \quad (2.7)$$

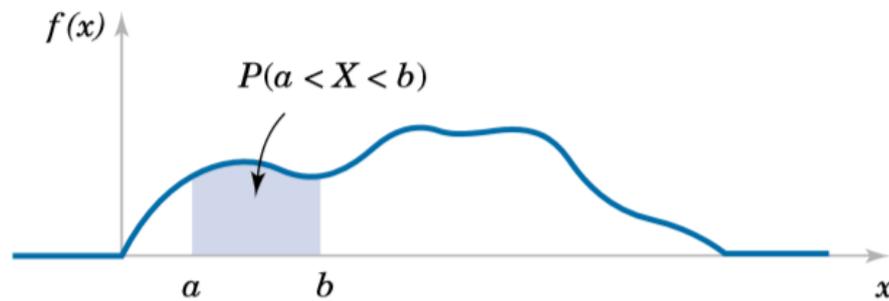
$$f(x_i) \geq 0 \quad (2.8)$$

$$\sum_{i=1}^n f(x_i) = 1 \quad (2.9)$$

$$P(X = x_i) = f(x_i) \quad (2.10)$$

$P(a \leq X \leq b)$: Probabilidade de um evento ocorrer entre a e b .

Figura 7 – Exemplo de uma função densidade de probabilidade.



Fonte: Montgomery e Runger (1994).

2.4.4 Distribuição normal

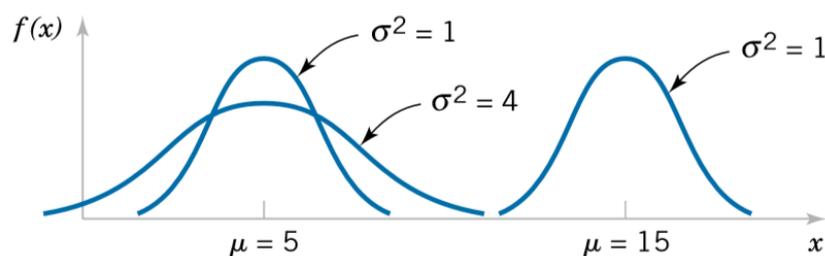
Quando um experimento aleatório é replicado, a variável aleatória igual à média ou total do resultado das repetições tende a ter uma distribuição normal à medida que os números de repetições aumenta (MONTGOMERY; RUNGER, 1994).

A distribuição normal é uma boa aproximação para computar probabilidades envolvendo a soma de muitas variáveis (contínuas ou discretas) aleatórias independentes (GUBNER, 2006).

Os valores médios e desvio padrão representam o centro e a largura respectivamente da função densidade de probabilidade normal (Figura 8). A função de distribuição normal é descrita pela Equação 2.11 (MONTGOMERY; RUNGER, 1994).

$$f(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp \frac{-(x-\mu)^2}{2\sigma^2} \quad -\infty < x < \infty \quad (2.11)$$

Figura 8 – Exemplo distribuição normal.

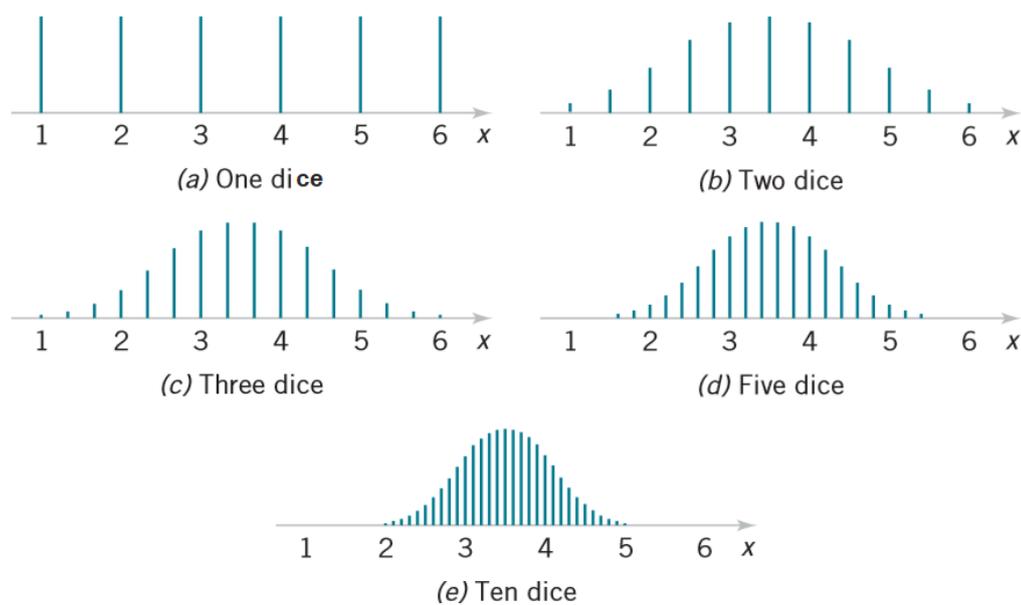


Fonte: Montgomery e Runger (1994).

2.4.5 Teorema do limite central

O teorema do limite central constata que a soma de "N" variáveis aleatórias independentes, com qualquer distribuição e variâncias semelhantes, aproxima-se cada vez mais de uma distribuição normal quando "N" aumenta, (GUBNER, 2006). Isso justifica o uso da distribuição normal para substituir os efeitos de variáveis não observadas em modelos (MONTGOMERY; RUNGER, 1994). Para exemplificar o teorema foi realizado um experimento com o lançamento de dados não viciados. A arremessar um dado obtemos uma probabilidade igual para todos os valores de $1/6$, ao arremessar dois dados e calcular a média podemos observar uma mudança na distribuição, e assim sucessivamente ao aumentar o número de dados percebemos que a distribuição se aproxima cada vez mais de uma distribuição normal, Figura 9.

Figura 9 – Teorema do limite central.



Montgomery e Runger (1994).

2.5 Modelo estocástico do perfil de viagem de um VE

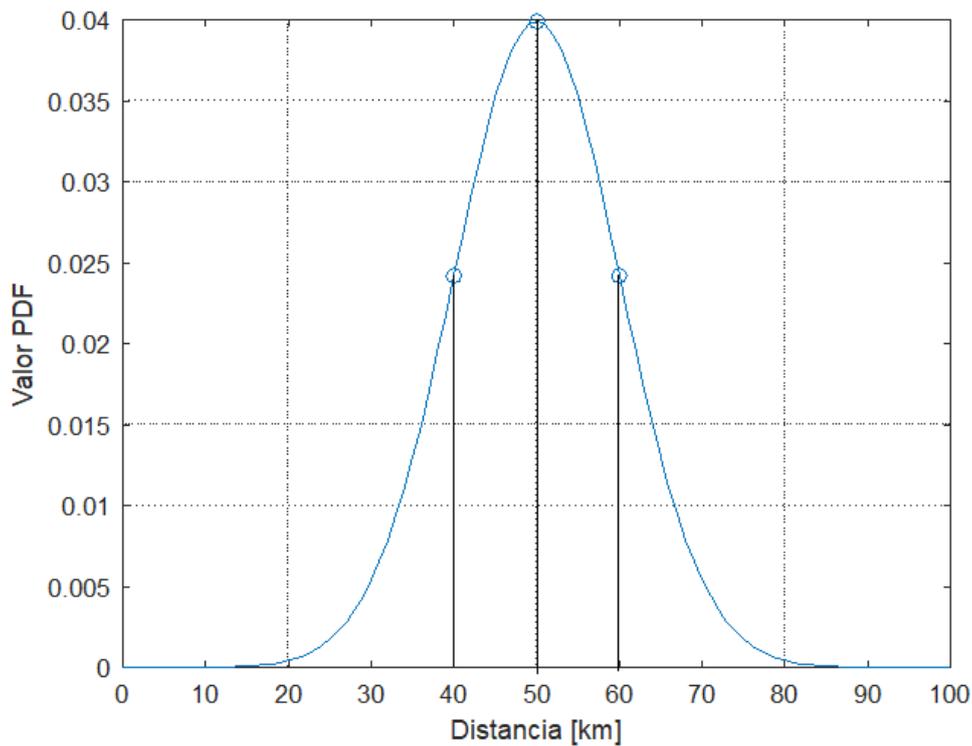
Os VEs podem apresentar um modelo estocástico para algumas de suas variáveis, tais como, distância percorrida pelo veículo, tempo de entrada e tempo de saída. A PDF escolhida para modelar estas variáveis foi a distribuição normal, pois de acordo com Guner e Ozdemir (2017) foi uma das distribuições que apresentou os melhores resultados para as funções objetivo trabalhadas por eles. Utilizou-se uma função do software MATLAB

"randn", a qual retorna um número retirado de uma distribuição normal, para definir os valores dessas variáveis.

2.5.1 Distância total percorrida pelo veículo (D)

O veículo percorre uma distância total de em média 50 km com um desvio padrão de 10 km, Figura 10, para uma cidade grande, por exemplo, Belo Horizonte, São Paulo e Rio de Janeiro. Essa distância é uma variável contínua e adota uma distribuição normal de probabilidade (REZAAE; KHORRAMDEL, 2013).

Figura 10 – Distância total (D).

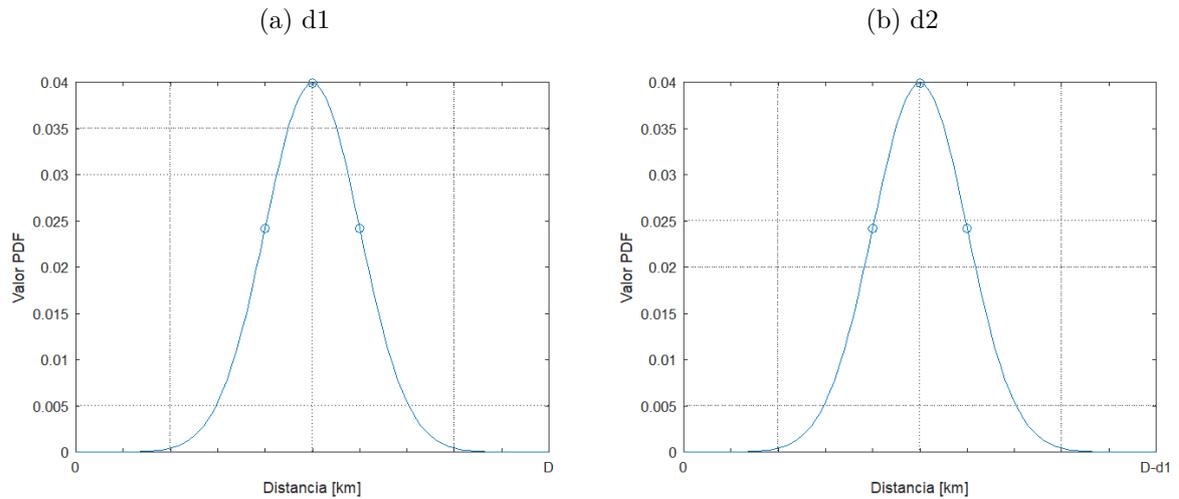


Fonte: Do Autor.

2.5.2 Partes da distância viajadas ($d_1 - d_3$)

O veículo realiza 3 viagens em sua rotina, a primeira e a segunda distância também adotam uma distribuição normal de probabilidade. A primeira distância (d_1) varia de 0% a 100% da viagem total (D), Figura 11a, a segunda distância (d_2) varia de 0% a 100% da viagem total menos a primeira viagem ($D - d_1$), Figura 11b, a terceira viagem (d_3) é o restante da viagem total ($D - d_1 - d_2$), (REZAAE; KHORRAMDEL, 2013).

Figura 11 – Distribuição de probabilidade para d1 e d2.

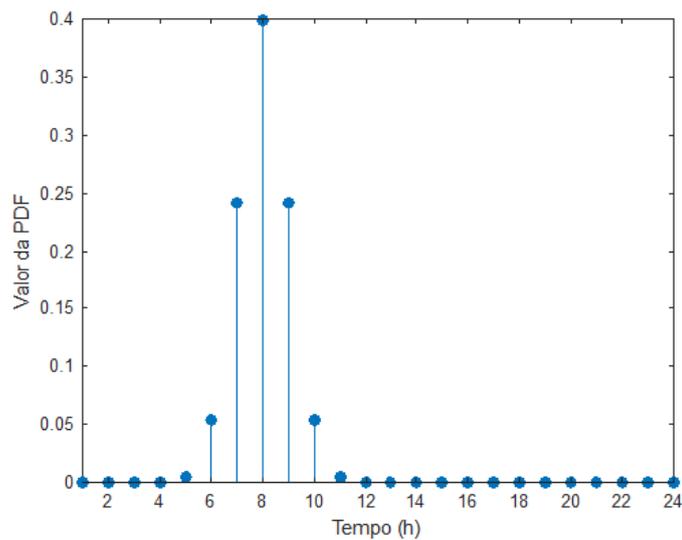


Fonte: Do Autor.

2.5.3 Tempo de entrada do veículo no estacionamento (t_{in})

O tempo de entrada pode ser modelado como uma variável discreta, e a média amostral pode também ser descrita por uma distribuição normal de probabilidade (GUNER; OZDEMIR, 2017), utilizando o teorema do limite central, com uma média de 8 horas com um desvio padrão de 1 hora. O horário de trabalho dos donos dos veículos que utilizam o estacionamento seja de 8 as 18 horas.

Figura 12 – Tempo de entrada (t_{in}).

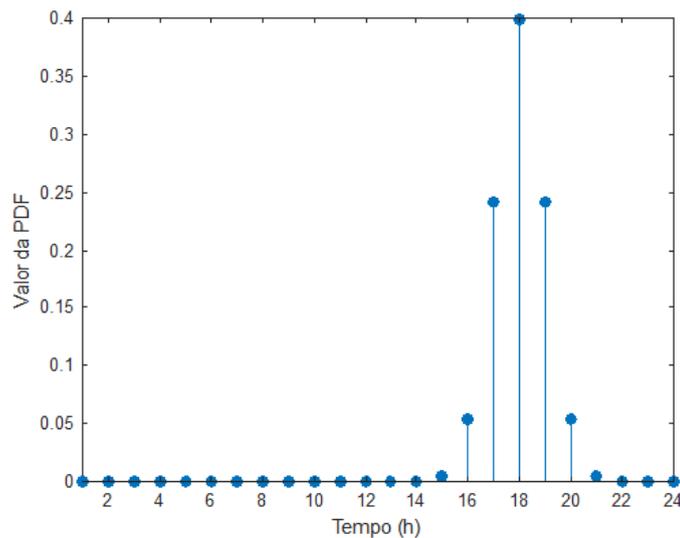


Fonte: Do Autor.

2.5.4 Tempo de saída do veículo do estacionamento (t_{out})

O tempo de saída também pode ser modelado como uma variável discreta, e também adere uma distribuição normal de probabilidade similarmente ao caso do tempo de entrada (GUNER; OZDEMIR, 2017). Porém, a média é 18 horas com um desvio padrão de 1 hora.

Figura 13 – Tempo de saída (t_{out}).



Fonte: Do Autor.

2.6 Cenário de carregamento de VEs

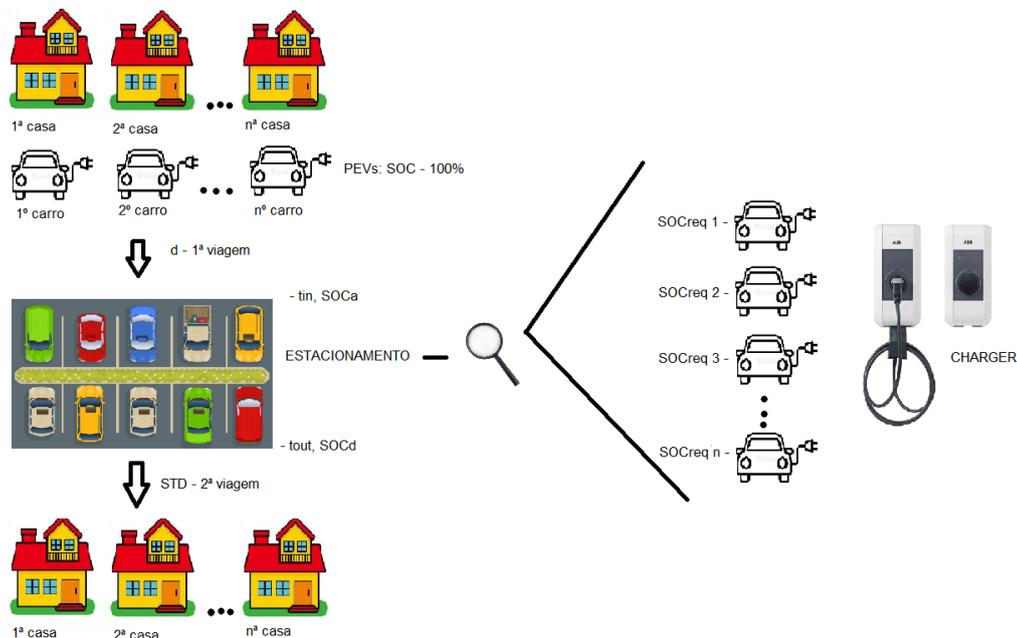
Essa seção apresentará uma descrição do modelo do problema, (Figura 14). O problema será aplicado em um grande consumidor (shopping, faculdade, etc.) com um estacionamento amplo, no qual uma grande quantidade de VEs, que realizam um deslocamento diário, podem realizar um carregamento V2G ou G2V, para minimizar o fator de carga associado à curva de carga do consumidor sob análise. Então, assume-se que:

- As residências dos donos de VE possuem carregadores, portanto todos os carros saem com um estado de carga (state of charge (SOC)) inicial completo de 100%.
- Realizam uma viagem da residência até o estacionamento, percorrendo uma distância inicial (d_1).
- No estacionamento o VE tem a possibilidade de carregamento ou descarregamento, dependendo do estado de carga requerido (SOCreq) pelo VE após a primeira viagem. As informações necessárias são passadas para um sistema coordenador de carrega-

mento que através do AG ou ACO escolhem a melhor estratégia de carregamento possível.

- A segunda viagem realizada do estacionamento à casa, pode conter uma parada em algum outro local, como, um supermercado. Assim, a distância da volta do VE para casa poderá ser maior que a distância da primeira viagem, percorrendo uma segunda distância (d_2) e/ou uma terceira distância (d_3), sendo a soma dessas duas distâncias a distância da viagem subsequente (subsequent trip distance (STD)).
- Neste modelo são aplicados os modos G2V e V2G.

Figura 14 – Cenário do Problema.



Fonte: Do Autor.

2.6.1 Características do veículo

Considera-se um VE de uso urbano, o qual possui uma bateria com uma capacidade nominal em média de 24,33 kWh e uma autonomia de 100 km (MATTHEY, 2017). Assim, assume-se que a bateria tem capacidade para cobrir toda a viagem diária do veículo ou parte no perímetro urbano.

2.6.2 Restrições dos veículos

Os VEs então percorrem uma distância inicial de casa até o estacionamento, se conectam ao equipamento de carregamento, realizando a transferência de potência nos

modos de operação V2G ou G2V, ao finalizar a transferência o veículo percorre uma distância até voltar para casa, figura 14. Para descrever esse comportamento foi utilizado o modelo matemático apresentado pelas equações 2.12 a 2.15 (MEHTA et al., 2018).

O SOC é definido como valor de energia elétrica disponível na bateria do VE. O SOC_A é calculado após a primeira viagem do VE, da residência até o estacionamento. SOC_D é o estado de carga final, calculado para as próximas duas viagens do veículo, após sair do estacionamento. Baseado nas informações do SOC_A e SOC_D , calcula-se o SOC_{req} . E assim, calcula-se a E_{req} a energia que a bateria precisa armazenar. Quando $SOC_D > 1$, o sistema entenderá que o VE irá recarregar totalmente a bateria atingindo seus 100%. Para $SOC_A < SOC_D < 1$ o sistema irá carregar a bateria para realizar a viagem subsequente. Para $SOC_D = SOC_A$ o sistema deixará o veículo inativo. Para $0.2 < SOC_D < SOC_A$ o sistema irá descarregar um pouco da bateria na rede de distribuição.

$$SOC_A = 1 - (d/d_R) \quad (2.12)$$

$$SOC_D = (STD/d_R) + .2 \quad (2.13)$$

$$SOC_{req} = \begin{cases} 1 - SOC_A, & SOC_D > 1 \\ (SOC_D - SOC_A), & SOC_A < SOC_D < 1 \\ 0, & SOC_D = SOC_A \\ -(SOC_A - SOC_D), & 0.2 < SOC_D < SOC_A \end{cases} \quad (2.14)$$

$$E_{req} = (SOC_{req} \cdot B_C) / \eta_C \quad (2.15)$$

B_C : Capacidade da bateria (kWh).

d : Distância da primeira viagem, da casa até o estacionamento (km).

d_R : Autonomia da bateria (km).

E_{req} : Energia requerida pelo veículo (%).

SOC_A : Estado de carga de chegada no estacionamento.

SOC_D : Estado de carga de saída do estacionamento.

ΔSOC_D : Variação do estado de carga de saída do estacionamento.

SOC_{req} : Estado de carga requerido pelo veículo.

STD : Distância das duas próximas viagens saindo do estacionamento (km).

η_C : Coeficiente de eficiência de carregamento e descarregamento de energia (%).

Após calcular a E_{req} , e assim gerar o vetor de estratégias de carregamento (s_k^t), é preciso respeitar algumas restrições para preservar a vida útil da bateria como: a

capacidade de armazenamento, potência máxima que a bateria pode absorver e o nível de carga, equações 2.16 à 2.18.

$$\sum_{t=t_{in,k}}^{t_{out,k}} S_k^t \cdot r_{PEV,k} = E_{req,k}, \quad \forall k \in Z \quad (2.16)$$

$$0 \leq r_{PEV,k} \leq P_{rated}, \quad \forall k \in Z \quad (2.17)$$

$$SOC_{min} \leq SOC_k^t \leq SOC_{max}, \quad \forall t \in H; k \in Z \quad (2.18)$$

k : índice de um VE ($k \in Z$).

P_{rated} : potência dos carregadores instalados em estacionamentos (kWh).

$r_{PEV,k}$: Taxa de carregamento ou descarregamento para o k -ésimo veículo (kWh).

S_k^t : Estratégia de carregamento do k -ésimo veículo no instante t .

SOC_k^t : Estado de carga para o k -ésimo veículo no instante t .

SOC_{max} : Limite superior para o estado de carga da bateria de VEs.

SOC_{min} : Limite inferior para o estado de carga da bateria de VEs.

$t_{in,k}$: Tempo de entrada do k -ésimo veículo (h).

$t_{out,k}$: Tempo de saída do k -ésimo veículo (h).

Z : Vetor indicando o número de VEs chegam em um estacionamento.

A estratégia de carregamento representa o comportamento de um determinado VE ao longo do tempo, sendo que ele pode absorver energia, ficar ocioso ou fornecer energia ao sistema elétrico. Ao calcular a diferença dos valores de SOC_A e SOC_D , o vetor de estratégia s_k^t pode ser composto pelos seguintes valores:

- $s_k^t = 1$ indica que o VE está na operação de carregamento no intervalo de tempo t . Isso ocorre quando $SOC_D > SOC_A$;
- $s_k^t = 0$ indica que o VE está inativo no intervalo de tempo t . Isso ocorre quando $SOC_D = SOC_A$;
- $s_k^t = -1$ indica que o VE está na operação de descarregamento no intervalo de tempo t . Isso ocorre quando $SOC_D < SOC_A$;

2.6.3 Função objetivo para o problema de carregamento

A função objetivo é o objeto de otimização. Assim, a função objetivo para o problema de VEs é a equação da relação entre o valor pico e médio da curva de carga do estacionamento (Peak-to-average ratio (PAR)). Portanto, o PAR será utilizado para verificar quais estratégias de carregamento mais achataram a curva de carga do estacionamento. Calculada conforme a Equação 2.19, na qual S_{total}^t representa a curva de carga somada à

demanda dos veículos no estacionamento. O objetivo desse método é obter o menor valor de PAR.

$$\min\{PAR\} = (\max_{t \in H} S_{total}^t) / ((\sum_{t=1}^T S_{total}^t) / T) \quad (2.19)$$

H : Vetor tempo.

PAR : Razão entre a demanda média e a demanda máxima de uma carga após adicionar N VEs.

S_{total}^t : Potência aparente total em um instante t após adicionar N VEs. (VA)

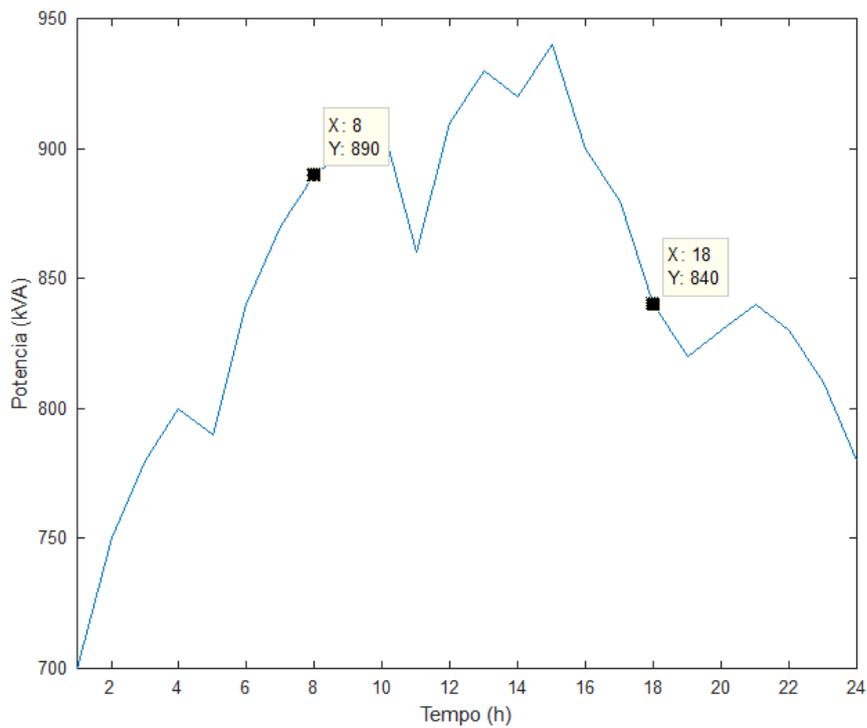
T : Tempo total. (h)

t : índice de tempo ($t \in H$).

2.6.4 Curva de carga do estacionamento

A curva de carga do estacionamento, figura 15, mostra uma carga típica de um estacionamento (MEHTA et al., 2018), a qual será utilizada para testar os dois algoritmos utilizados, ACO e AG.

Figura 15 – Curva de carga do estacionamento.



Fonte: Do Autor.

3 Descrição dos algoritmos e MC

Implementou-se dois algoritmos para otimizar o carregamento de VEs. O primeiro foi o algoritmo genético e o segundo o algoritmo de colônia de formigas. E utilizou-se do método de MC, para obter resultados numéricos.

Uma das vantagens de um algoritmo genético é a simplificação que eles permitem na formulação e solução de problemas de otimização (S.N.SIVANANDAM; S.N.DEEPA, 2008). A otimização por colônia de formigas já foi aplicada com sucesso para resolver problemas de Scheduling, inclusive mostrando-se mais eficiente do que um conjunto de algoritmos baseados em técnicas de programação dinâmica (DORIGO; STUTZLE, 2004).

3.1 Algoritmo genético

O Algoritmo genético é uma técnica da ciência da computação para resolver problemas de otimização e busca, que utiliza de conceitos de biologia evolutiva, como recombinação, seleção natural e mutação (S.N.SIVANANDAM; S.N.DEEPA, 2008).

3.1.1 indivíduo

Um indivíduo, chamado de cromossomo, é um portador do seu código genético. O código genético é uma representação do espaço de busca do problema a ser resolvido, em geral, na forma de sequências de bits.

3.1.2 Seleção

A seleção natural é a parte do algoritmo onde seleciona os indivíduos mais bem adaptados, sem deixar de lado a diversidade dos menos adaptados. Utilizando o método da "roleta" para isso, onde os indivíduos são ordenados conforme a função-objetivo e lhes são atribuídas probabilidades decrescentes de serem escolhidos, A escolha é feita então aleatoriamente de acordo com essas probabilidades.

3.1.3 Cruzamento

O cruzamento é a escolha de dois indivíduos para se reproduzirem. Assim, é um processo que imita o processo biológico homônimo na reprodução sexuada: os descendentes recebem em seu código genético parte do código genético do pai e parte do código da mãe. Então gerar descendentes ainda mais aptos.

3.1.4 Mutação

Por último vem as mutações, feitas com probabilidade a mais baixa possível, e visa permitir maior variabilidade genética na população, impedindo que a busca fique estagnada em um mínimo local. A mutação ocorre a uma taxa μ de probabilidade, a qual adotou-se 2%.

3.1.5 Elitismo

Entre a população de pais são selecionados os que tem o melhor valor para a função objetivo para se tornarem a população da próxima interação.

3.2 Algoritmo colônia de formigas

O algoritmo colônia de Formigas (Ant Colony Optimization (ACO)), foi criado para solução de problemas computacionais que envolvem procura de caminhos em grafos (DORIGO; STUTZLE, 2004). Este algoritmo foi inspirado na observação do comportamento das formigas ao saírem de sua colônia para encontrar comida, assim, a formiga percorre um caminho deixando rastros de feromônios para as próximas formigas seguirem até a comida.

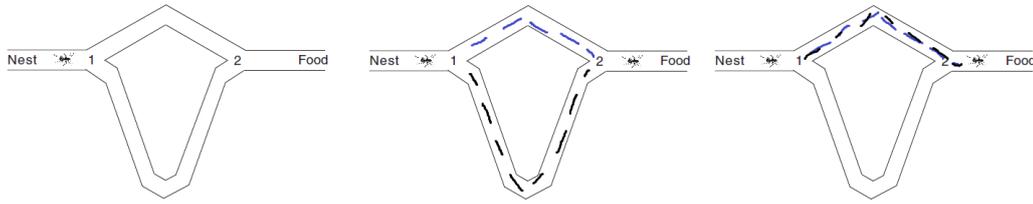
3.2.1 Indivíduo

Um indivíduo, chamado de formiga, representa uma possível solução do problema. Assim, utilizando o conceito da colonia, cada formiga irá deixar um rastro de feromônios por onde passar, se outras formigas encontram um desses rastros, elas tendem a não seguir mais caminhos aleatórios.

3.2.2 Caminho

Cada formiga precisa construir um caminho. A Figura 16 mostra esse trajeto de uma formiga percorrendo um caminho e deixando um rastro, e uma próxima formiga escolhendo o trajeto mais fácil.

Figura 16 – Caminho da formiga



Fonte: Adaptado de Dorigo e Stutzle (2004)

Para escolher o próximo caminho a formiga considera uma probabilidade, Equação 3.1. Os parâmetros α e β são selecionados para controlar a influência de τ e η respectivamente. Para esse trabalho foi selecionado $\alpha = 1$ e $\beta = 5$. O valor $\alpha > 1$ leva à rápida estagnação do problema, no qual todas as formigas seguem o mesmo caminho e constroem o mesmo caminho. Se α é muito próximo a zero, as formigas escolheriam o caminho mais próximo a elas, podendo levar a resultados muito dispersos. Para $\beta = 0$ somente a matriz de feromônios seria utilizada, o que pode causar soluções de baixa qualidade. Então, para aumentar a influência de η , utilizou-se cinco (DORIGO; STUTZLE, 2004).

$$P_{ij}^f = \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum [\tau_{ij}]^\alpha [\eta_{ij}]^\beta} \quad (3.1)$$

P_{ij}^f : Probabilidade para uma formiga escolher uma posição do caminho.

f : índice de uma formiga.

i : índice de linhas da matriz.

j : índice de colunas da matriz.

α : Peso exponencial do feromônio (Phromone Exponential Weight).

β : Peso exponencial heurístico (Heuristic Exponential Weight).

τ : Matriz de feromônios.

η : Matriz de Atração.

3.2.3 Feromônios

O rastro de feromônios deixados pela formiga são representados por uma matriz. Essa matriz é atualizada a cada nova formiga que percorre um caminho. A matriz é atualizada utilizando as Equações 3.2 e 3.3.

A matriz de feromônios é acumulativa, e assim se faz necessário, que os feromônios tenham uma taxa de evaporação de ρ , considerada em 5% para o problema, para evitar a ênfase em somente um caminho. A evaporação de feromônios permite que o algoritmo

mantenha uma aleatoriedade maior, uma vez que ele evita acumulação da trilha de feromônios e permite "esquecer" decisões ruins anteriormente realizadas (Equação 3.4).

$$\tau_{ij} \leftarrow \tau_{ij} + \sum_f \Delta\tau_{ij}^f \quad (3.2)$$

$$\Delta\tau_{ij}^f = \frac{1}{C^f + 1} \quad (3.3)$$

$$\tau_{ij} \leftarrow (1 - \rho)\tau_{ij} \quad (3.4)$$

C^f : Custo do caminho de uma formiga.

ρ : Taxa de evaporação de feromônios.

3.2.4 Matriz de Atração

A matriz η representa a atração de uma formiga por um caminho. Assim, a matriz ajuda na tomada de decisão da formiga, para melhorar a qualidade da resposta do algoritmo.

3.3 Simulação de MC

O método de MC se fundamenta em um processo de repetição de simulações em um número elevado de vezes para obter um resultado numérico (HROMKOVIČ, 2013). Assim, obteremos o algoritmo que otimizou melhor o problema de VEs, ou seja, qual deles reduziu mais a demanda máxima da curva de carga.

São utilizadas as Equações 3.5 a 3.8 para calcular as médias e o desvio padrão do PAR e da demanda máxima da curva de carga. Similarmente ao caso do lançamento dos dados, Seção 2.4.5, calcula-se a média e o desvio padrão após cada iteração da simulação. Assim, realizarmos a comparação entre o ACO e o AG.

$$\mu(PAR) = \frac{1}{N} \sum_{i=1}^N PAR_i \quad (3.5)$$

$$\sigma(PAR) = \frac{1}{N} \sum_{i=1}^N \sigma(PAR_i) \quad (3.6)$$

$$\mu(kV Amax) = \frac{1}{N} \sum_{i=1}^N kV Amax_i \quad (3.7)$$

$$\sigma(kV Amax) = \frac{1}{N} \sum_{i=1}^N \sigma(kV Amax_i) \quad (3.8)$$

N : número de iterações de MC.

i : Iteração i -ésima de MC.

PAR_i : Resultado do PAR, no AG ou ACO, na i -ésima iteração de MC.

$\sigma(PAR_i)$: Desvio padrão do resultado do PAR, no AG ou ACO, na i -ésima iteração de MC.

$kVAm_{ax_i}$: Demanda máxima final da curva de carga, no AG ou ACO, na i -ésima iteração de MC.

$\sigma(kVAm_{ax_i})$: Desvio padrão do resultado da demanda máxima final da curva de carga, no AG ou ACO, na i -ésima iteração de MC.

4 Metodologia

Como o AG e o ACO já foram aplicados com sucesso neste tipo de problema de carregamento ótimo de VEs, utilizados nos trabalhos de Mehta et al. (2018) e Mavrouniotis, Ellinas e Polycarpou (2019) respectivamente. Neste capítulo será mostrado como foi aplicado o problema de VEs aos algoritmos e como foram utilizados na simulação de MC. Utilizaram-se os conceitos mostrados no capítulo anterior como base para programar os dois algoritmos no ambiente computacional do MATLAB. O trabalho segue as etapas:

Etapa 1: Definir os parâmetros determinísticos: autonomia da bateria (dR), taxa de carregamento (rPEV), capacidade da bateria (Bc), quantidade de VEs (N).

Etapa 2: Iniciar a simulação de MC.

Etapa 3: Definir os parâmetros estocásticos: distância percorrida do veículo e tempo de entrada e saída do estacionamento.

Etapa 4: Simular que os automóveis percorrem a primeira distância até o estacionamento. No estacionamento o sistema recebe os parâmetros: autonomia da bateria (dR), taxa de carregamento (rPEV), capacidade da bateria (Bc), quantidade de VEs (N), distância percorrida do veículo e tempo de entrada e saída do estacionamento.

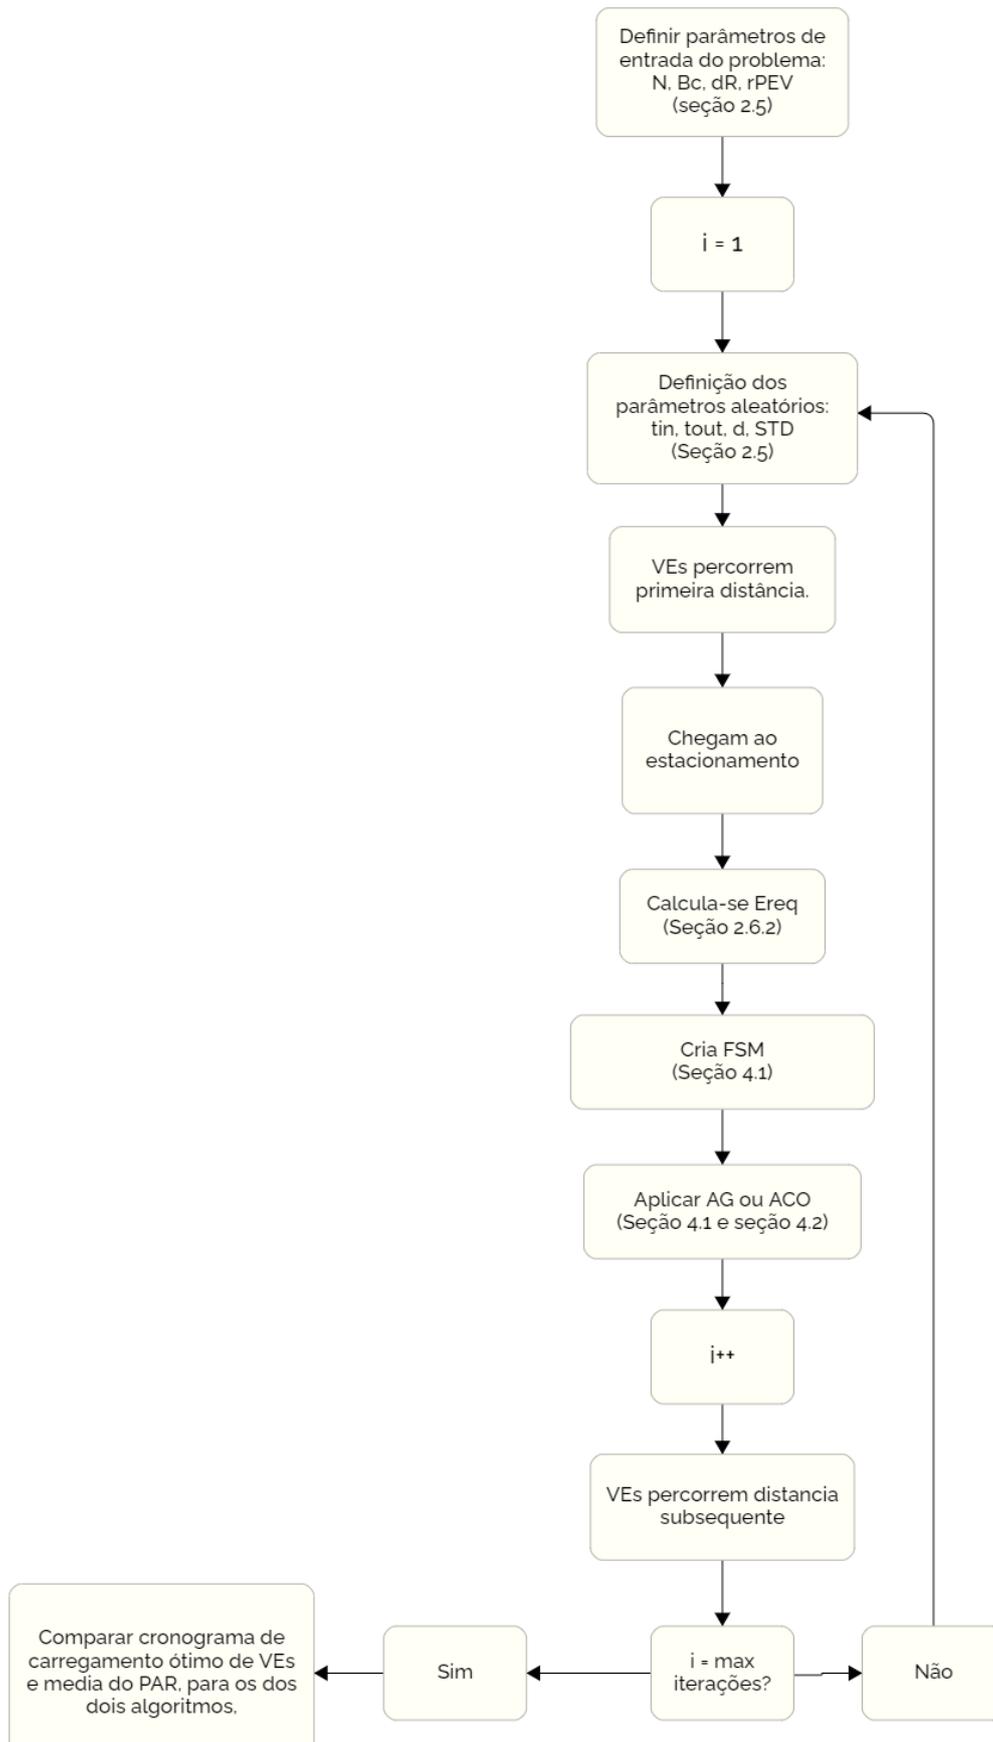
Etapa 5: O sistema de calcula a E_{req} para cada VE.

Etapa 6: Utiliza o AG e o ACO, para otimizar o cronograma de carregamento.

Etapa 7: Os veículos seguem o cronograma e retornam as suas residências.

Etapa 8: Repetir a simulação até encontrarmos dados suficientes para análise.

Figura 17 – Fluxograma do Problema de VEs.



Fonte: Do Autor.

4.1 Algoritmo genético aplicado ao problema de carregamento de veículos

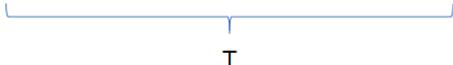
Essa seção é uma descrição de como o AG foi utilizado para o problema de VEs. A subseção "cronograma de carregamento" mostra como é elaborado um indivíduo e o que ele significa no problema de VEs. Na seção "seleção" descreve o procedimento para escolher os indivíduos mais aptos conforme o PAR de cada um. A seção "cruzamento" explica como funciona o cruzamento entre indivíduos no problema de VEs. A seção "elitismo" expõe como é selecionada os indivíduos para a próxima iteração do algoritmo.

4.1.1 Cronograma de carregamento

Para o caso de carregamento ótimo de VEs o cromossomo é representado por uma matriz ($N \times T$), figura 18, onde N é o número de veículos que chegam ao estacionamento em um período e T é o tempo total. Então o cromossomo é um conjunto de estratégias de carregamento para os veículos. Esse cronograma de carregamento é avaliado pelo PAR, Seção 2.6.3, quanto menor o valor do PAR, mais o cronograma reduziu a demanda máxima da curva de carga.

Figura 18 – Cromossomo.

| | | | | | |
|----|----|---|---|----|-------------|
| 1 | 0 | 0 | 1 | 0 | → veículo 1 |
| 0 | 0 | 0 | 1 | 0 | → veículo 2 |
| -1 | -1 | 0 | 0 | -1 | → veículo 3 |
| 1 | 1 | 1 | 0 | 0 | → veículo 4 |



T

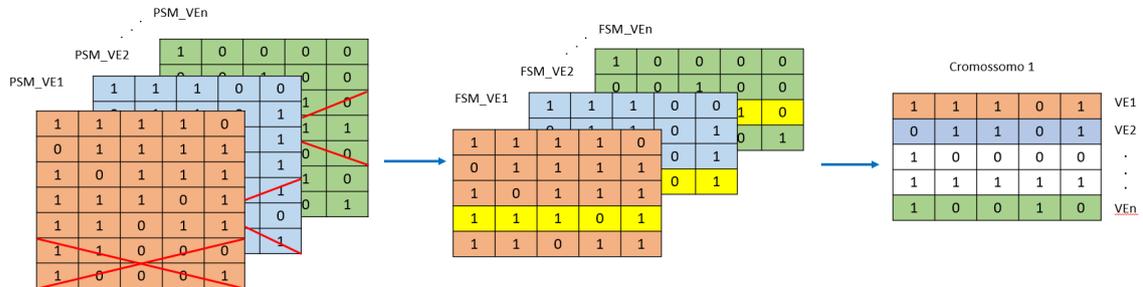
Fonte: Do Autor.

$$\text{Carregamento} = \begin{cases} -1, & \text{se veículo em operação de descarregamento} \\ 0, & \text{se veículo inativo} \\ 1, & \text{se veículo em operação de carregamento.} \end{cases}$$

Cada linha da matriz é preenchida com uma estratégia de carregamento para o veículo correspondente. Para selecionar as estratégias de carregamento da figura 18, cria-se uma matriz com várias estratégias de carregamento para um veículo, matriz de soluções possíveis (PSM). Então, ao eliminar as linhas que não atendem às restrições (equações 2.16 a 2.18), cria-se a matriz de soluções factíveis (FSM). Após criada a matriz FSM para

cada veículo é selecionada, de forma aleatória, uma linha da matriz FSM de cada veículo, e essas estratégias selecionadas são assimiladas pelo cronograma, figura 19.

Figura 19 – Criação de um cromossomo.

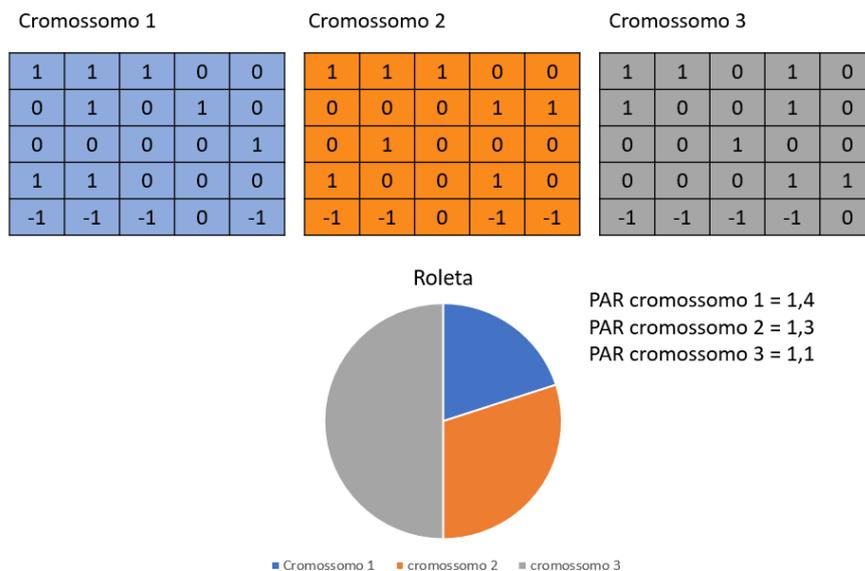


Fonte: Do Autor.

4.1.2 Seleção

O algoritmo inicia-se criando uma população, a qual é um conjunto de cronogramas, essa população passará pela seleção. A seleção ocorre por meio da roleta, onde os indivíduos são ordenados segundo a função-objetivo, PAR (Seção 2.6.3), conforme destacado na figura 20.

Figura 20 – Roleta para a seleção dos pais.

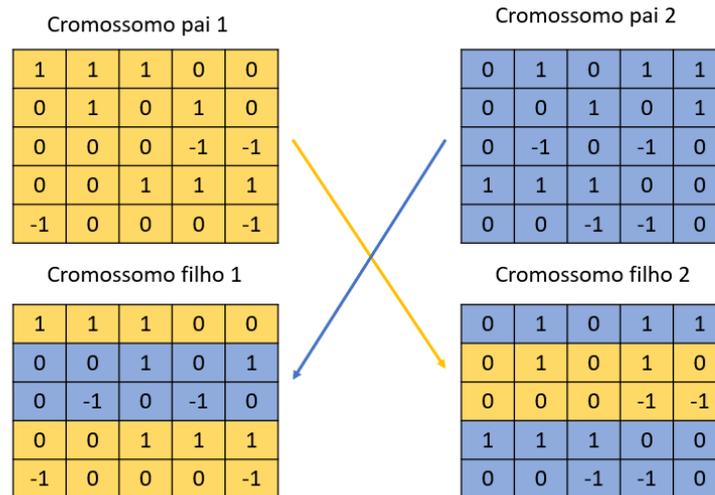


Fonte: Do Autor.

4.1.3 Cruzamento

O cruzamento trabalha selecionando dois pais e duas linhas de forma aleatória, e todo o conteúdo entre essas linhas é trocado entre os pais, dando origem a dois novos cromossomos chamados de filhos, figura 21.

Figura 21 – Cruzamento.

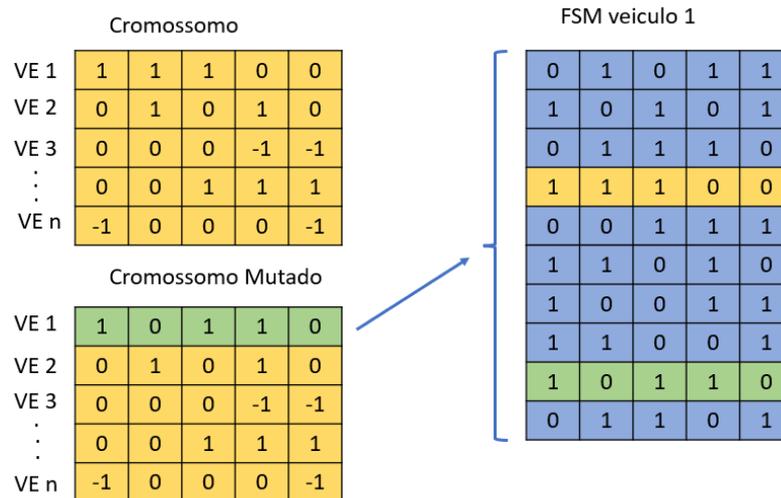


Fonte: Do Autor.

4.1.4 Mutação

A mutação ocorre ao selecionar uma linha qualquer de um cronograma filho. Essa linha então é trocada por uma estratégia de carregamento do mesmo veículo armazenada na FSM, como pode se ver na figura 22, em que a linha amarela é trocada com a verde retirada da FSM.

Figura 22 – Mutação.



Fonte: Do Autor.

4.1.5 Elitismo

Por último são selecionados os cronogramas que mais reduziram a demanda de carga para se tornarem a população da próxima iteração.

4.1.6 Rotina AG

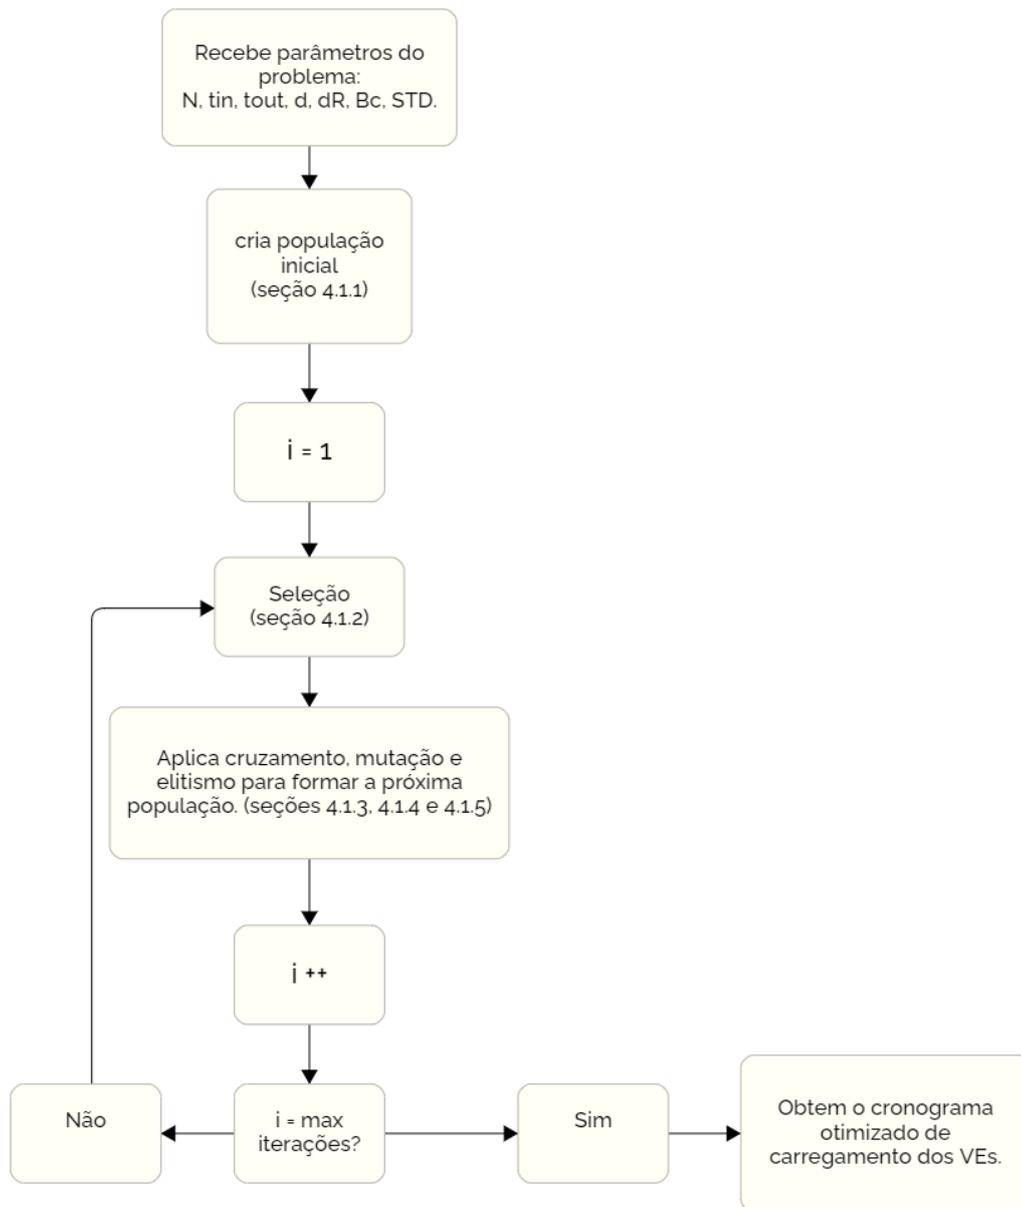
A figura 23 ilustra o fluxograma do algoritmo genético e os passos utilizados pelo mesmo para encontrar um cronograma otimizado de carregamento para os VEs. Ele então segue algumas etapas:

Etapa 1: O algoritmo se inicia recebendo parâmetros do modelo (Seção 2.6), então, cria-se a população inicial de acordo com esses parâmetros.

Etapa 2: Inicia-se o processo de otimização dessa população, através dos métodos evolutivos: seleção, reprodução, mutação e elitismo. Assim, a cada nova geração da população o algoritmo tende a diminuir o valor do PAR.

Etapa 3: Ao atingir um número limite de iterações, o algoritmo finaliza e obtém o cronograma otimizado de carregamento de VEs.

Figura 23 – Fluxograma do Algoritmo Genético.



Fonte: Do Autor.

4.2 Algoritmo colônia de formigas aplicado ao problema de carregamento de veículos

Essa seção é uma descrição de como o ACO foi utilizado para o problema de VEs. A subseção "cronograma de carregamento" mostra que a formiga é similar ao cromossomo. Na seção "caminho" descreve o procedimento para o indivíduo seguir um caminho. A seção "Matriz de feromônios" explica como funciona a matriz de feromônios para o problema de VEs. A seção "Matriz de atração" expõe como é criada a matriz de atração para o problema

de VE.

4.2.1 Cronograma de carregamento

Um indivíduo, chamado de formiga, é representado similarmente ao cromossomo do algoritmo genético (Seção 4.1.1), o qual é representado por uma matriz (NXT), Figura 18. Sendo assim também um cronograma de carregamento para os automóveis.

4.2.2 Caminho

Então o algoritmo cria um caminho simbólico para a formiga no problema de carregamento de VEs. As estratégias de carregamento de cada cronograma representarão o caminho a ser percorrido. Assim, o que se altera em cada cronograma serão as posições das estratégias de carregamento.

A Figura 24 mostra em destaque de azul as posições alteradas, utiliza-se do método da roleta para selecionar a posição que será alterada no cronograma. O método da roleta para esse caso seleciona espaços em que é possível fazer uma mudança na estratégia de carregamento, e escolhe essas posições de forma aleatória entre elas. A Equação 3.1 atribui pesos diferentes a cada opção para serem escolhidas, os quais são considerados na probabilidade da escolha de posições que se alteraram na roleta.

Figura 24 – Caminho da formiga para o problema de VEs

| Formiga | | | | | Formiga Atualizada | | | | |
|---------|---|---|----|----|--------------------|----|---|----|---|
| 1 | 1 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 1 |
| 0 | 1 | 0 | 1 | 0 | 0 | 0 | 1 | 0 | 1 |
| 0 | 0 | 0 | -1 | -1 | -1 | -1 | 0 | 0 | 0 |
| 0 | 0 | 1 | 1 | 1 | 1 | 1 | 0 | 0 | 1 |
| -1 | 0 | 0 | 0 | -1 | 0 | -1 | 0 | -1 | 0 |

Fonte: Do Autor

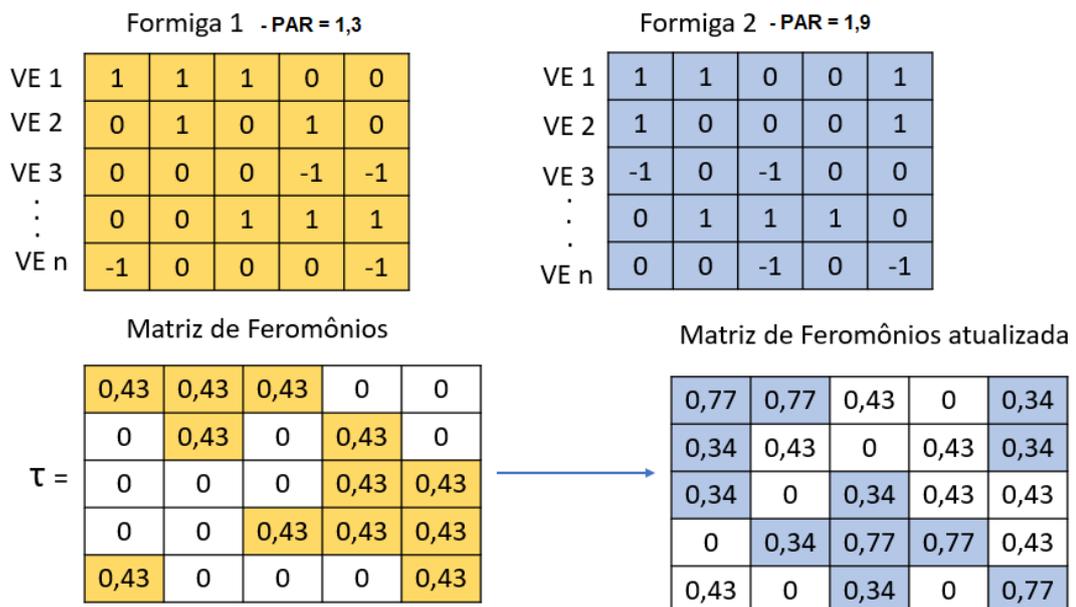
$$\text{Carregamento} = \begin{cases} -1, & \text{se veículo em operação de descarregamento} \\ 0, & \text{se veículo inativo} \\ 1, & \text{se veículo em operação de carregamento.} \end{cases}$$

4.2.3 Matriz de feromônios

Para o problema de veículos elétricos, o rastro de feromônios deixados pela formiga são representados por uma matriz de $(N \times T)$. Essa matriz é atualizada a cada novo cronograma que percorre um "caminho". Um cronograma é analisada de forma que onde apresentar uma estratégia de carregamento diferente de zero, a posição correspondente na matriz de feromônios é atualizada pelas equações 3.2 e 3.3.

A Figura 25 mostra um exemplo dessa atualização, em que duas formigas percorrem um "caminho". No exemplo, a formiga 1 possui um valor de PAR igual a 1,3 e a formiga 2 um valor de par igual a 1,9. Ou seja, quanto menor o valor do PAR, maior será o valor na matriz de feromônios nas posições utilizadas no caminho da formiga. Pode-se observar em destaque na matriz de feromônios que para a primeira formiga a matriz de feromônios recebe valores maiores onde a estratégia de carregamento difere de zero, e quando a segunda formiga atualiza a matriz os locais em destaque recebem um valor menor.

Figura 25 – Matriz de feromônios.



Fonte: Do Autor.

4.2.4 Matriz de atração

A matriz de atração tem tamanho $(N \times T)$ similarmente a formiga e a matriz de feromônios.

Para iniciar essa matriz, seguiram-se algumas etapas:

Etapa 1: Calcula-se a média da curva de carga, para distinguir os valores abaixo e acima da média dessa curva.

Etapa 2: aplicam-se as equações 4.1 a 4.3, para cada intervalo de tempo.

Etapa 3: Conforme o resultado apresentado pelas equações 4.1 a 4.3, defini-se o horário que o veículo irá descarregar ou carregar sua bateria, afastando-o do pico se ele precisar carregar sua bateria e aproximando-o do pico se ele precisar descarregar a bateria.

A Figura 26 representa essas etapas, onde podemos ver a matriz montada de acordo a curva de carga abaixo dela.

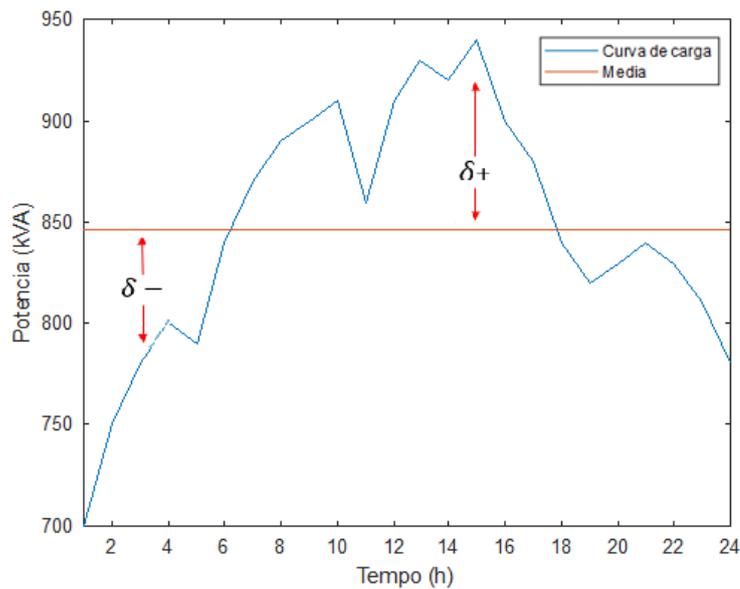
$$\eta_{ij} = \delta_{ij} + 1 \tag{4.1}$$

$$\delta_+ = (maxS_{total}^t - S_{total}^t) / maxS_{total}^t \tag{4.2}$$

$$\delta_- = (S_{total}^t - minS_{total}^t) / maxS_{total}^t \tag{4.3}$$

Figura 26 – Matriz de Atração do ACO e curva de carga do estacionamento.

| T (h) - | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | |
|---------|---|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|----|----|----|----|----|----|----|----|----|----|----|----|--|
| VE 1 | 1 | 1,2 | 1,3 | 1,4 | 1,0 | 1,1 | 1,4 | 1,5 | 1,5 | 1,6 | 1,3 | 1,2 | 1 | | | | | | | | | | | | |
| VE 2 | 1 | 1,3 | 1,4 | 1,1 | 1,4 | 1,3 | 1,1 | 1,0 | 1,0 | 1,1 | 1,4 | 1,4 | 1 | | | | | | | | | | | | |
| ⋮ | 1 | 1,2 | 1,3 | 1,4 | 1,0 | 1,1 | 1,4 | 1,5 | 1,5 | 1,6 | 1,3 | 1,2 | 1 | | | | | | | | | | | | |
| VE n | 1 | 1,3 | 1,4 | 1,1 | 1,4 | 1,3 | 1,1 | 1,0 | 1,0 | 1,1 | 1,4 | 1,4 | 1 | | | | | | | | | | | | |



Fonte: Do Autor.

4.2.5 Rotina ACO

A Figura 27, ilustra o fluxograma do algoritmo colônia de formigas, os passos utilizados pelo mesmo para encontrar um cronograma otimizado de carregamento para os VEs. Ele então segue algumas etapas:

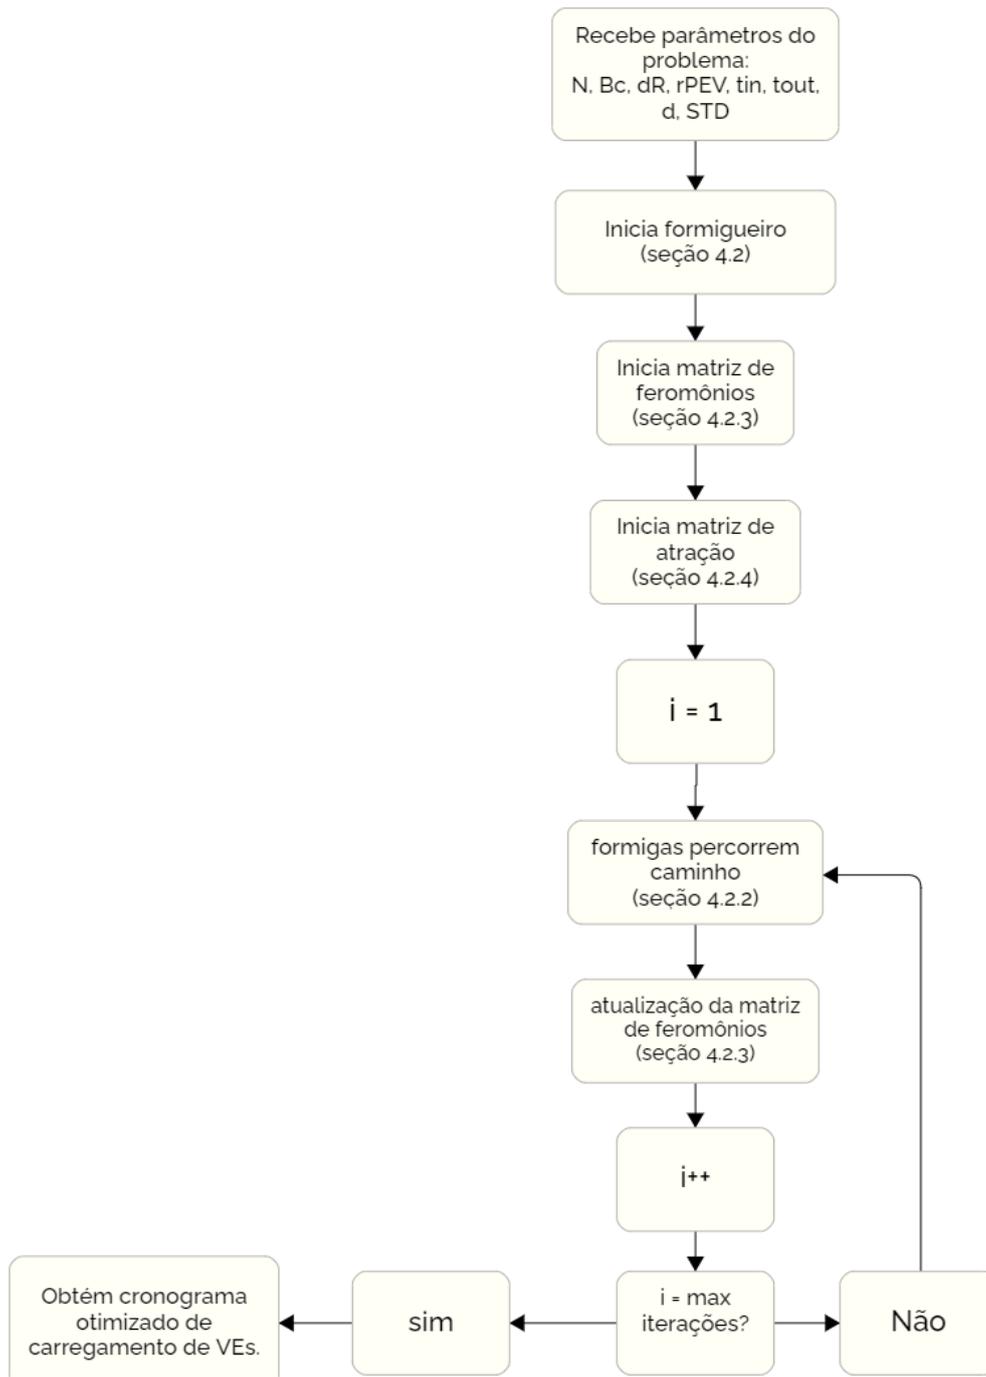
Etapa 1: O algoritmo se inicia recebendo parâmetros do modelo (Seção 2.6), então, cria-se a população inicial de acordo com esses parâmetros.

Etapa 2: Inicia-se a matriz de feromônios e cria-se a matriz de atração.

Etapa 3: Inicia-se o processo de otimização dessa população, através da procura de um "melhor" caminho pelas formigas. A formiga percorre um caminho simbólico em que ela deixa feromônios para a próxima formiga seguir o mesmo caminho, em algum momento o conjunto de formigas encontra o melhor "caminho". O algoritmo segue a mesma ideia, a cada iteração a matriz de feromônios é atualizada para encontrar o melhor cronograma de carregamento dos VEs.

Etapa 4: Ao atingir um número limite de iterações, o algoritmo finaliza, e obtém o cronograma otimizado de carregamento de VEs.

Figura 27 – Fluxograma do Algoritmo colônia de Formigas.



Fonte: Do Autor.

4.3 Simulação de MC para o problema de VEs

Neste trabalho a simulação de MC segue 4 etapas (Figura 28):

Etapa 1: Analisar todos os dados de entrada do problema e definir os parâmetros que são determinísticos e estocásticos. Os determinísticos serão: autonomia da bateria

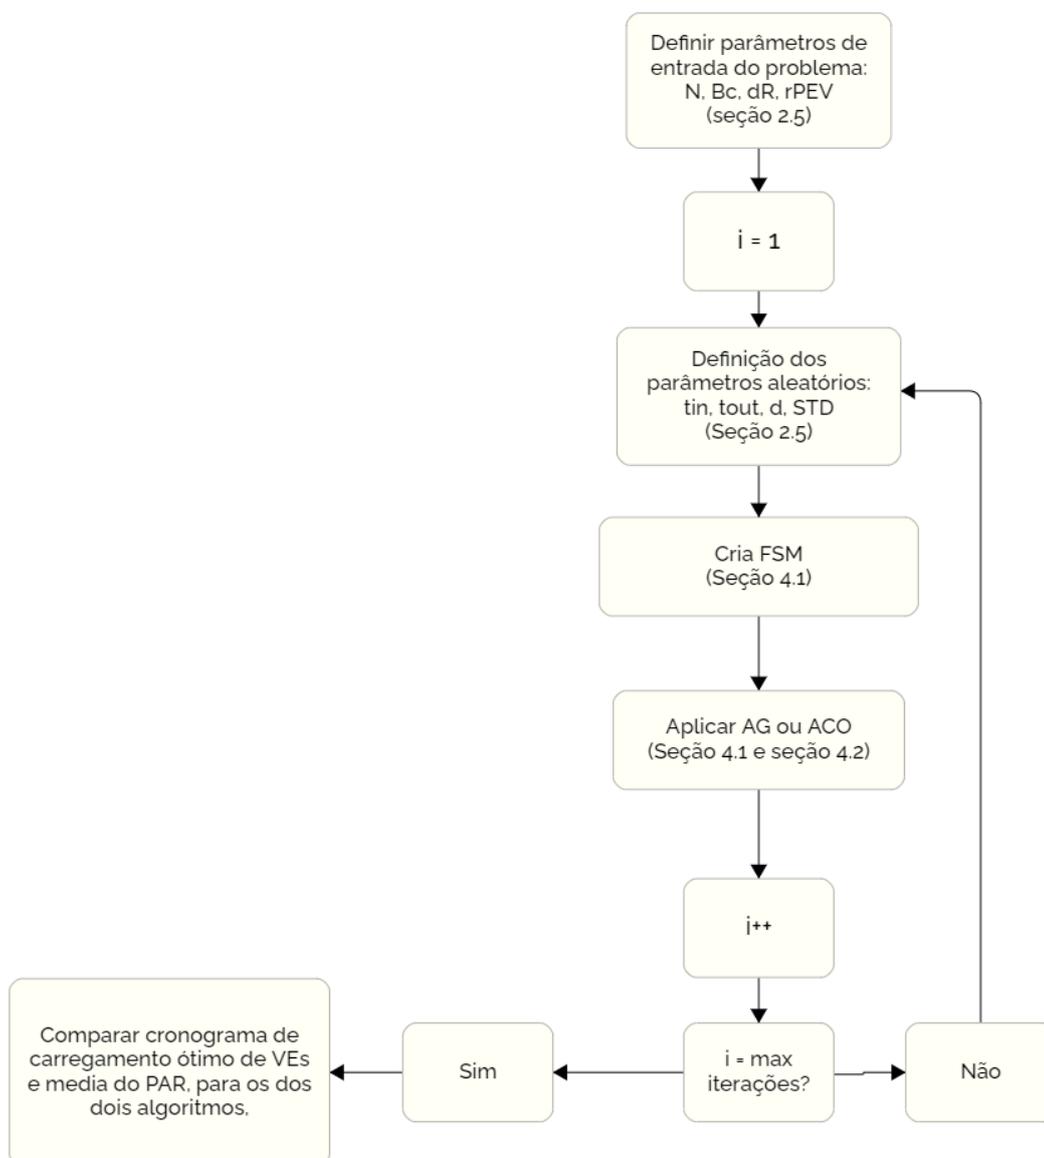
(dR), taxa de carregamento (rPEV), capacidade da bateria (B_c) e quantidade de VEs (N). Os parâmetros estocásticos são: distância percorrida do veículo e tempo de entrada e saída do estacionamento.

Etapa 2: Definir as variáveis que serão trabalhadas de forma aleatória (Seção 2.5), tempo de entrada, tempo de saída e distância percorrida. Atribuir uma distribuição de probabilidade, por exemplo, a distribuição normal (Seção 2.4.4), para simular o comportamento das mesmas. Assim, cria-se um cenário estocástico que simula a rotina diária de um VE, aplicando os conceitos apresentados na Seção 2.6.2.

Etapa 3: Iniciar os algoritmos de carregamento de VEs, AG e ACO, os quais trabalharão para otimizar o cronograma de carregamento de VEs.

Etapa 4: Repetir essa simulação várias vezes, para diferentes valores de tempo de entrada, de saída e de distância percorrida, até que o valor dos resultados na saída do algoritmo apresente uma resposta significativa para ser analisada utilizando o teorema do limite central. O resultado a ser analisado será a média e desvio padrão do PAR e da demanda máxima da curva de carga do estacionamento, Equações 3.5 a 3.8. Assim, definir qual algoritmo realizou melhor a otimização do problema em reduzir o custo de demanda do estacionamento.

Figura 28 – Fluxograma da simulação de Monte Carlo.



Fonte: Do Autor.

5 Resultados

Esta seção irá descrever os resultados do carregamento ótimo de VEs. Os algoritmos de otimização utilizados foram validados com base em um problema clássico da literatura: o problema que tenta determinar a menor rota para percorrer uma série de cidades, problema do caixeiro-viajante, verificando a capacidade dos algoritmos em otimizar o mesmo (ver apêndice A). Primeiramente será apresentada a validação do algoritmo de carregamento (utilizando AG e ACO), para o caso determinístico. Em seguida serão apresentados os resultados para o caso pirobalístico, utilizando a simulação de MC. Para validar os algoritmos, observou-se o resultado da função objetivo do problema, PAR, e a curva de carga do sistema. Assim, pretende-se verificar qual algoritmo (AG ou ACO) apresentou melhor desempenho para o problema tratado.

5.1 Validação do AG e do ACO

A Tabela 3 apresenta os parâmetros utilizadas para a validação do caso determinístico. Assim, as distâncias percorridas pelos veículos foram selecionadas segundo a tabela. Os 100 VEs foram divididos em dois grupos, os 50 primeiros receberam um valor para as distâncias, que assim, poderiam descarregar a bateria na rede do estacionamento, e o segundo grupo recebeu valores para as distâncias que eles precisariam carregar as baterias ao chegar no estacionamento.

Tabela 3 – Dados de entrada para validação determinística.

| Parâmetros | valores |
|---|----------|
| Autonomia da bateria (dR) | 100 (km) |
| Taxa de carregamento (rPEV) | 2 (kWh) |
| Capacidade da bateria (Bc) | 24 (kWh) |
| Quantidade de VEs (N) | 100 |
| Tempo de entrada (T_{in}) | 8 (h) |
| Tempo de saída (T_{out}) | 17 (h) |
| Distância da 1ª viagem para os 50 primeiros VEs (d_1) | 20 (km) |
| Distância da 2ª viagem para os 50 primeiros VE (d_2) | 5 (km) |
| Distância da 3ª viagem para os 50 primeiros VE (d_3) | 5 (km) |

| | |
|--|---------|
| Distância da 1ª viagem para os 50 últimos VE (d_1) | 50 (km) |
| Distância da 2ª viagem para os 50 últimos VE (d_2) | 25 (km) |
| Distância da 3ª viagem para os 50 últimos VE (d_3) | 25 (km) |

Fonte: Do autor.

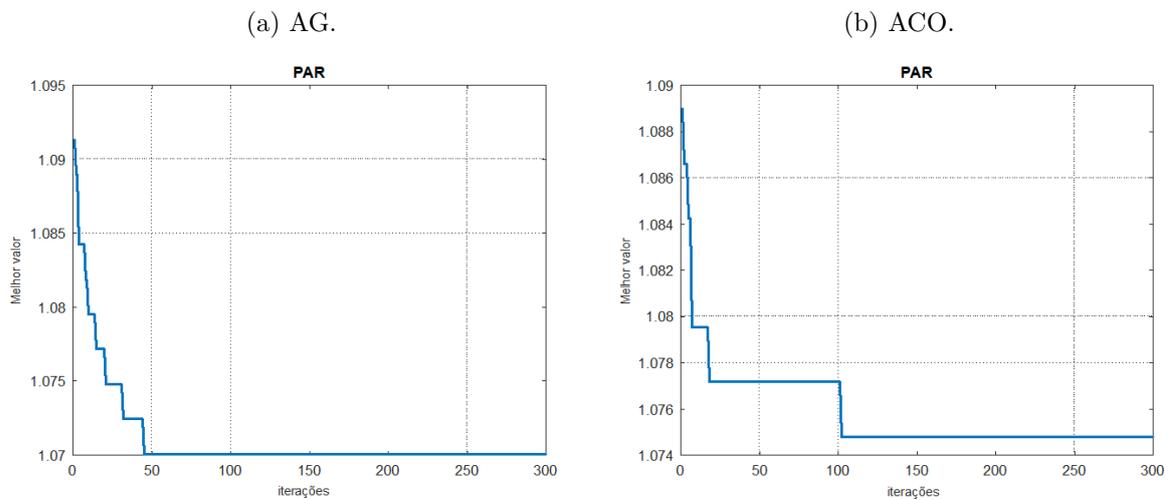
A Tabela 4, mostra a redução percentual entre as iterações do algoritmo. Percebe-se que os resultados são próximos após 300 iterações, e o PAR do AG apresentou um valor menor comparado ao ACO. Os gráficos da Figura 29 representam o valor do PAR por iterações, observa-se que o AG atingiu o melhor valor em menos iterações comparado ao ACO. A redução percentual do PAR, representa em termos da potência aparente que deixa de ser transportada pela rede e pelo transformador que supre a demanda daquele consumidor.

Tabela 4 – Redução percentual por iteração para o AG e ACO no caso determinístico.

| Iterações | AG | | ACO | |
|-----------|--------|--------------------|--------|--------------------|
| | PAR | redução percentual | PAR | redução percentual |
| 1 | 1,0913 | - | 1,0890 | - |
| 10 | 1,0847 | 0,6047 % | 1,0810 | 0,7346 % |
| 100 | 1,0700 | 1,9518 % | 1,0776 | 1,0468 % |
| 200 | 1,0700 | 0 % | 1,0750 | 1,2855 % |
| 300 | 1,0700 | 0 % | 1,0750 | 0 % |

Fonte: Do autor.

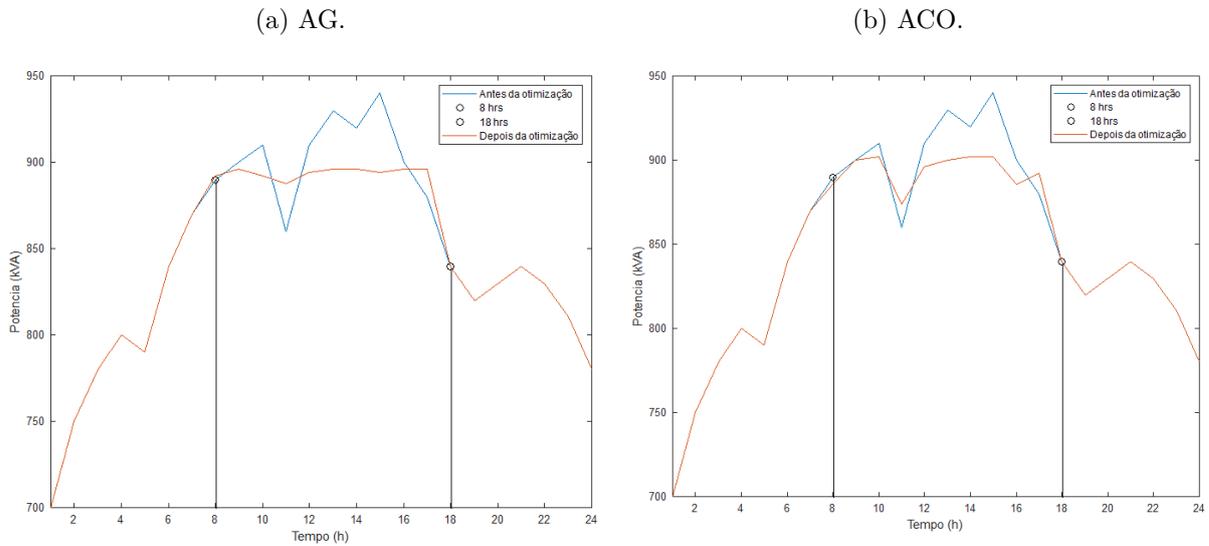
Figura 29 – Valores do PAR durante a otimização pelo AG e ACO.



Fonte: Do Autor.

A Figura 30 mostra os gráficos da curva de carga do estacionamento, a curva em azul é uma curva base antes da otimização, Seção 2.6.4, a curva em vermelho é a curva resultante da otimização pelos algoritmos. Como os algoritmos tem o objetivo de otimizar essa curva durante o horário que os veículos estão presentes, ela tende a atenuar os picos da curva de carga. Em vista disso, constata-se que os dois algoritmos apresentaram uma redução dos picos da curva de potência, aliviando a capacidade de transporte do transformador que alimenta o estacionamento. Porém, o AG realizou uma atenuação maior do que o ACO. A Tabela 5, mostra a redução percentual da curva de carga do estacionamento para o AG e o ACO. O valor máximo da curva antes da otimização para os dois algoritmos foi de 940kVA, após a otimização o ACO apresentou um valor máximo de 900kVA, e o AG apresentou um valor máximo de 890kVA.

Figura 30 – curva de carga do estacionamento para o AG e ACO.



Fonte: Do Autor.

Tabela 5 – Redução percentual da curva de carga do estacionamento para o AG e o ACO.

| AG | | ACO | |
|----------------|--------------------|----------------|--------------------|
| Potência (kVA) | redução percentual | Potência (kVA) | redução percentual |
| 940 | - | 940 | - |
| 890 | 5,31% | 900 | 4,25% |

Fonte: Do autor.

5.2 Simulações MC

A Tabela 6 apresenta os parâmetros fixos, enquanto a Tabela 7 apresenta os parâmetros modelados aleatoriamente.

Tabela 6 – Dados de entrada determinísticos.

| Parâmetros | valores |
|-----------------------------|----------|
| Autonomia da bateria (dR) | 100 (km) |
| Taxa de carregamento (rPEV) | 2 (kWh) |
| Capacidade da bateria (Bc) | 24 (kWh) |
| Quantidade de VEs (N) | 100 |

Fonte: Do autor.

Os parâmetros apresentadas na Tabela 7 seguem uma distribuição normal, e são apresentados a média e o desvio padrão dessas variáveis. O desvio padrão próximo a zero representa um resultado mais homogêneo, assim os valores não se dispersaram da média obtida. Dessa forma, observa-se que o valor que mais se diferenciou da média foi a distância da 1ª viagem do veículo.

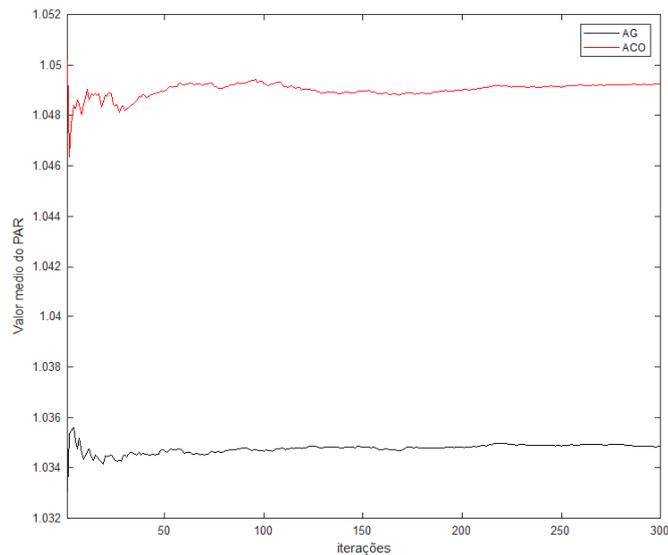
Tabela 7 – Dados de entrada estocásticos.

| Variáveis | μ | σ | PDF |
|--------------------------|---------|----------|---------------------|
| Tempo de entrada (h) | 8,0122 | 1,0349 | Distribuição normal |
| Tempo de saída (h) | 16,9983 | 0,9897 | Distribuição normal |
| Distância 1ª viagem (km) | 27,5041 | 7.2089 | Distribuição normal |
| Distância 2ª viagem (km) | 13,7641 | 4.6434 | Distribuição normal |
| Distância 3ª viagem (km) | 13,7750 | 4.2470 | Distribuição normal |

Fonte: Do autor.

A Figura 31 para efeito de comparação, representa os valores da média do PAR por iteração. O número máximo de iterações para a simulação de MC foi de 300. O vermelho representa a média do ACO e o preto representa a média do AG. Pode-se observar que os valores do PAR computados pelo ACO foram maiores que os valores computados pelo AG. Portanto, aumentando a média do ACO comparada com a média do AG. Podemos observar que o AG obteve uma média menor do que o ACO de 0,014.

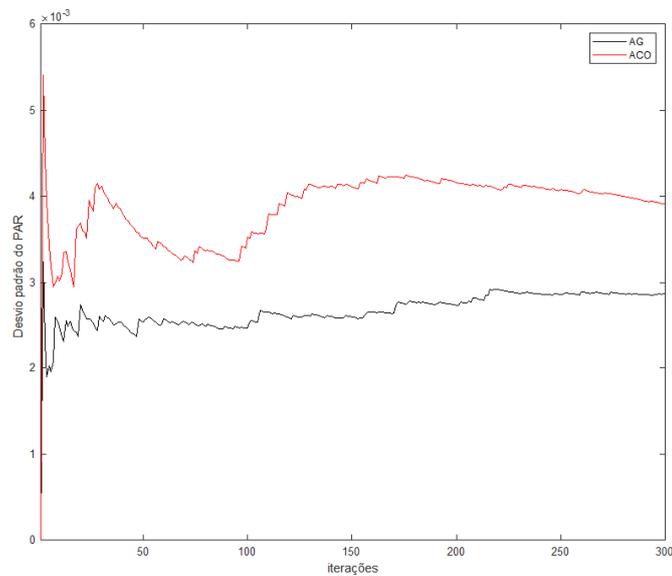
Figura 31 – Gráfico comparando o valor da média do PAR para o AG e o ACO na simulação de MC.



Fonte: Do Autor.

A Figura 32 apresenta os valores do desvio padrão dos algoritmos AG e ACO para simulação de MC realizada. Seguindo a mesma ideia da média, a curva em preto representa o desvio do AG e a em vermelho representa o desvio do ACO. Considerando a escala da média obtida, podemos observar que os dois desvios apresentam valores bem próximos de zero. O que indica que os valores apresentaram um resultado mais homogêneo.

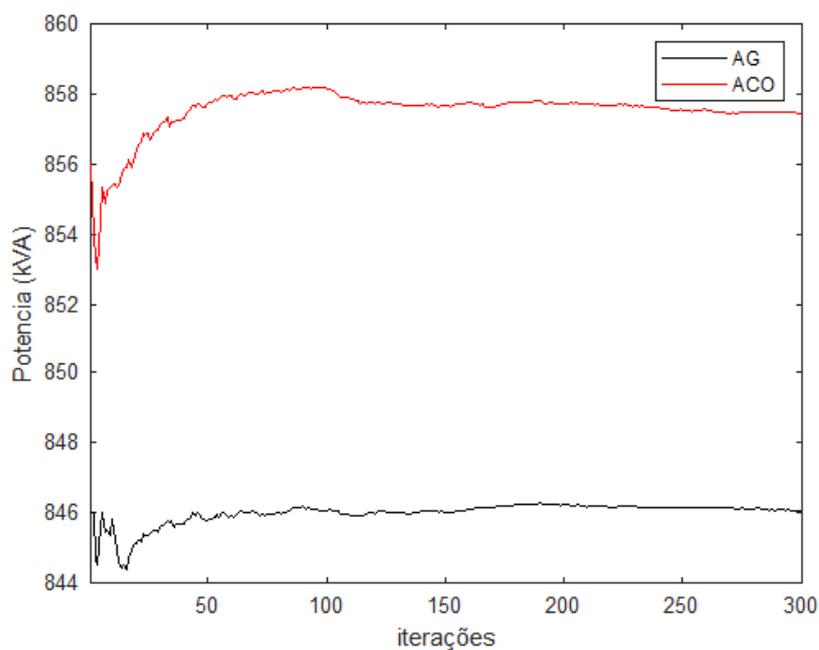
Figura 32 – Gráfico comparando o valor do desvio padrão do PAR para o AG e o ACO.



Fonte: Do Autor.

A Figura 33 representa o valor da média da curva de carga do estacionamento por iteração. A cor vermelha representa a média da curva de carga otimizada pelo ACO, e a preta a média da curva de carga otimizada pelo AG. O ACO apresentou uma redução menor da curva de carga, como observado pela média do PAR dos dois algoritmos. O ACO apresentou uma redução de 8,82% e o AG apresentou uma redução de 10%, Tabela 8.

Figura 33 – Gráfico comparando o valor da média da curva de carga para o AG e o ACO na simulação de MC.



Fonte: Do Autor.

Tabela 8 – Redução percentual da curva de carga do estacionamento para o AG e o ACO na simulação de MC.

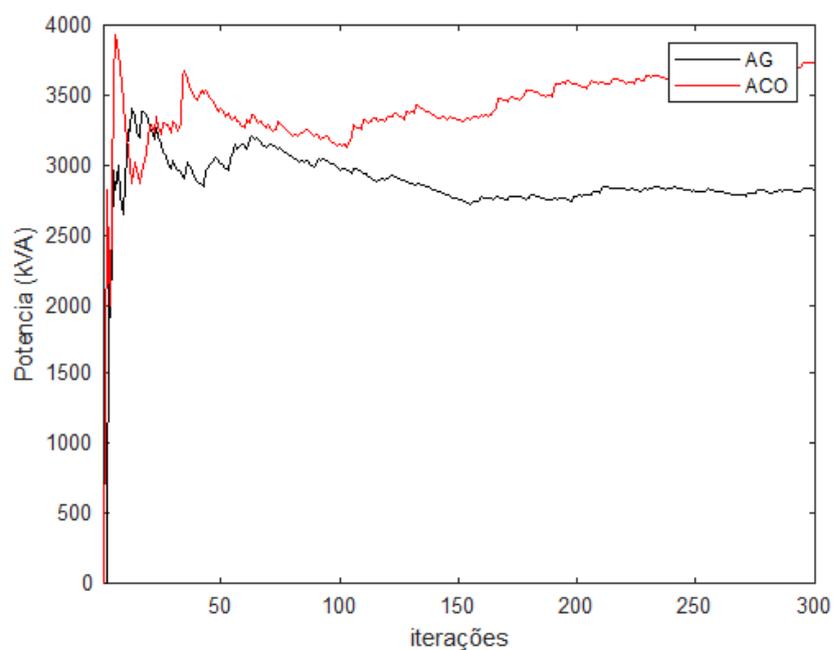
| AG | | ACO | |
|----------------|--------------------|----------------|--------------------|
| Potência (kVA) | redução percentual | Potência (kVA) | redução percentual |
| 940 | - | 940 | - |
| 846 | 10% | 857 | 8,82% |

Fonte: Do autor.

A Figura 34 representa o valor do desvio padrão da curva de carga do estacionamento por iteração. O vermelho representa o desvio da curva de carga otimizada pelo ACO, e o preto o desvio da curva de carga otimizada pelo AG. Pode-se observar que os valores

do desvio padrão para os dois algoritmos são bem pequenos, considerando a escala dos valores da média, se comparados com os valores da média, que implica em uma dispersão pequena dos dados.

Figura 34 – Gráfico comparando o valor do desvio padrão da curva de carga para o AG e o ACO.



Fonte: Do Autor.

6 Conclusões

O trabalho implementou o carregamento de VEs em um estacionamento de um shopping, para uma cidade similar a Belo horizonte, onde se utilizou de uma frota de 100 VEs. A simulação utilizou veículos iguais com capacidades de armazenamento iguais. Utilizou o método de MC, para refazer a simulação, varias vezes, e assim, obter um resultado numérico para esse trabalho.

O modelo determinístico executado considerou os parâmetros constantes, e assim foi utilizado para verificar se os algoritmos achataram a curva de carga do estacionamento e reduziram a demanda máxima da curva de carga. O modelo probabilístico implementado considerou a aleatoriedade de algumas variáveis de entrada (distância percorrida, tempo de entrada e tempo de saída) com uma distribuição de probabilidade normal, assim verificou-se o resultado das variáveis de saída.

Ao comparar os resultados da média obtida tanto para o PAR quanto para a demanda máxima da curva de carga, pode-se concluir que entre os algoritmos utilizados o que apresentou uma melhor resposta numérica, no cenário e condições simulados, para solucionar o problema de carregamento dos VEs foi o AG. O algoritmo ACO deve ser estudado de forma mais detalhada para possíveis melhorias em seu desempenho para o problema. Assim, pode-se estimar um valor médio e um desvio padrão para a redução de demanda máxima em curvas de carga para estacionamentos semelhantes ao modelo, o que pode influenciar no planejamento das instalações da rede de distribuição.

6.1 Trabalhos futuros

O Brasil ainda não possui uma frota considerável de VEs, então o problema de carregamento ótimo pode ser estudado para evitar os impactos que uma frota massiva pode causar. Assim, considerar tópicos que esse trabalho não utilizou, tais como: a possibilidade de usar a teoria de filas para modelar a chegada de veículos, um veículo não permanecer a quantidade de tempo prevista no estacionamento, utilização de outros tipos de bateria e VEs, utilização de outros tipos de algoritmos que se encaixam no problema de carregamento de VEs.

Referências

- AMINI, M. H.; MOGHADDAM, M. P. Probabilistic modelling of electric vehicles' parking lots charging demand. In: *2013 21st Iranian Conference on Electrical Engineering, ICEE 2013*. [S.l.]: IEEE, 2013. p. 1–4. ISBN 9781467356343. 3, 4, 5
- BARAN, R. et al. *Veículos elétricos : história e perspectivas no Brasil*. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2011. 207–224 p. Acesso em: 1 set. 2019. Disponível em: <<http://web.bndes.gov.br/bib/jspui/handle/1408/1489>>. 1, 8
- BRIEF, C. *Factcheck: How electric vehicles help to tackle climate change*. 2020. Disponível em: <<https://www.carbonbrief.org/factcheck-how-electric-vehicles-help-to-tackle-climate-change/>>. 1
- CASTRO, B. H. R. de; FERREIRA, T. T. *Veículos elétricos : aspectos básicos, perspectivas e oportunidades*. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2010. 267–310 p. Acesso em: 15 set. 2019. Disponível em: <<http://web.bndes.gov.br/bib/jspui/handle/1408/1764>>. 9, 11
- DORIGO, M.; STUTZLE, T. *Ant Colony Optimization*. [S.l.]: Massachusetts Institute of Technology, 2004. 321 p. ISBN 0262042193. 24, 25, 26, 57
- ESCUADERO-GARZAS, J. J.; GARCIA-ARMADA, A.; SECO-GRANADOS, G. Fair design of plug-in electric vehicles aggregator for V2G regulation. *IEEE Transactions on Vehicular Technology*, v. 61, n. 8, p. 3406–3419, 2012. ISSN 00189545. 11
- FELIPE, L. et al. *Veículos híbridos e elétricos : sugestões de políticas públicas para o segmento*. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2015. 295–344 p. 1
- Garcia Osorio, V. *Carregamento ótimo de veículos elétricos considerando as restrições das redes de distribuição de média tensão*. 166 p. Dissertação (Mestrado) — UNIVERSIDADE ESTADUAL PAULISTA, 2013. 10
- GUBNER, J. A. *PROBABILITY AND RANDOM PROCESSES FOR ELECTRICAL AND COMPUTER ENGINEERS*. [S.l.]: University of Wisconsin-Madison, 2006. 642 p. ISBN 9780511220234. 15, 16
- GUNER, S.; OZDEMIR, A. Stochastic energy storage capacity model of EV parking lots. *IET Journals*, v. 11, p. 1754–1761, 2017. ISSN 1751-8687. 16, 18, 19
- HERMANS, L. J. F. Moving around efficiently: Energy and transportation. In: . Netherlands: EDP Sciences, 2013. p. 18. 9
- HROMKOVIČ, J. *Algorithmics for Hard Problems: Introduction to Combinatorial Optimization, Randomization, Approximation, and Heuristics*. [S.l.]: Springer Berlin Heidelberg, 2013. 538 p. (Texts in Theoretical Computer Science. An EATCS Series, 2). ISBN 9783662052693. 27
- KUMAR, K. N. et al. V2G Capacity Estimation Using Dynamic EV Scheduling. *2014 IEEE TRANSACTIONS ON SMART GRID, TOSG*, v. 5, n. 2, p. 1051–1060, 2014. 2, 3, 4

- LEVINE, D. M. et al. *Estatística Teoria e Aplicações*. [S.l.: s.n.], 2008. 752 p. ISBN 9788521616344. 12, 13
- LI, H. L.; BAI, X. M.; TAN, W. Impacts of plug-in hybrid electric vehicles charging on distribution grid and smart charging. *2012 IEEE International Conference on Power System Technology, POWERCON 2012*, IEEE, p. 1–5, 2012. 3, 4
- MATTHEY, J. *Our Guide to Batteries*. 2017. 28 p. Acesso em: 15 set. 2019. Disponível em: <<http://www.jmbatterysystems.com/JMBS/media/JMBS/Documents/JMBS-28025-Battery-Guide-Reprint-July-2017.pdf>>. 7, 20
- MAVROVOUNIOTIS, M.; ELLINAS, G.; POLYCARPOU, M. Electric vehicle charging scheduling using ant colony system. In: *2019 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2019. p. 2581–2588. 2, 3, 5, 29
- MEHTA, R. et al. Smart charging strategies for optimal integration of plug-in electric vehicles within existing distribution system infrastructure. *IEEE*, v. 9, n. 1, p. 299–312, 2018. 1, 2, 3, 4, 10, 21, 23, 29
- MOJUMDER, M. R. H. et al. Electric vehicle-to-grid (v2g) technologies: Impact on the power grid and battery. *Sustainability*, v. 14, n. 21, 2022. ISSN 2071-1050. Disponível em: <<https://www.mdpi.com/2071-1050/14/21/13856>>. 12
- MONTGOMERY, D. C.; RUNGER, G. C. *Applied Statistics and Probability for Engineers*. [S.l.: s.n.], 1994. v. 19. 383 p. ISSN 14695898. ISBN 0471204544. 12, 13, 14, 15, 16
- OLIVEIRA, D. Q. *Otimização da recarga de veículos elétricos e híbridos recarregáveis em sistemas de distribuição*. 97 p. Dissertação (Mestrado) — UNIVERSIDADE FEDERAL DE ITAJUBÁ, 2012. 3, 5
- RAGHAVAN, S. S.; KHALIGH, A. Impact of plug-in hybrid electric vehicle charging on a distribution network in a Smart Grid environment. *2012 IEEE PES Innovative Smart Grid Technologies, ISGT 2012*, IEEE, p. 1–7, 2012. 3, 5
- REZAEI, E. F. S.; KHORRAMDEL, B. Probabilistic Analysis of Plug-In Electric Vehicles Impact on Electrical Grid Through Homes and Parking Lots. *IEEE Trans.*, v. 4, p. 1024–1033, 2013. 3, 4, 6, 17
- ROBLEDO, C. B. et al. Integrating a hydrogen fuel cell electric vehicle with vehicle-to-grid technology, photovoltaic power and a residential building. *Applied Energy*, Elsevier, v. 215, p. 615–629, 2018. ISSN 03062619. 10
- SHARIFF, N. B. M.; Al Essa, M.; CIPCIGAN, L. Probabilistic analysis of electric vehicles charging load impact on residential Distributions Networks. In: *2016 IEEE International Energy Conference, ENERGYCON 2016*. [S.l.]: IEEE, 2016. p. 1–6. ISBN 9781467384636. 3, 4, 5
- S.N.SIVANANDAM; S.N.DEEPA. *Introduction to Genetic Algorithms*. [S.l.]: Springer, 2008. 453 p. ISBN 978-3-540-73189-4. 24
- TEKDEMIR, I. G. et al. A probabilistic approach for evaluation of electric vehicles' effects on distribution systems. In: *2017 4th International Conference on Electrical and Electronics Engineering, ICEEE 2017*. [S.l.]: IEEE, 2017. p. 143–147. ISBN 9781509067886. 3, 4, 5

A Validação do AG e ACO pelo problema do Caixeiro Viajante

A.1 Caixeiro viajante

É um problema que tenta determinar a menor rota para percorrer uma série de cidades, visitando apenas uma vez cada uma delas, retornando à cidade de origem. Ele é um problema de otimização que trata a necessidade dos vendedores em realizar entregas em diversos locais percorrendo o menor caminho possível, reduzindo o tempo e os possíveis custos de cada viagem. E é geralmente representado por grafos para realizar a otimização do problema. Utilizou-se o ACO e o AG para otimização.

Para essa validação realizou-se testes com um problema de 30 cidades diferentes. Então é necessário todas as rotas entre as cidades como dados de entrada do problema. Assim, o algoritmo avalia várias rotas possíveis até encontrar a melhor rota para a entrega do material.

A.2 AG

O algoritmo genético utiliza conceitos da biologia evolutiva. Para o caso será seleção, cruzamento, mutação e elitismo.

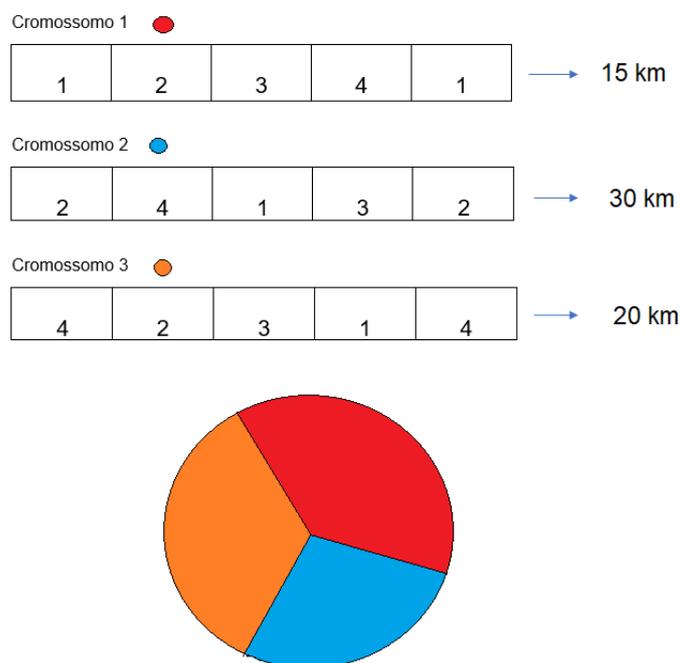
A.2.1 Cromossomo

O indivíduo criado para o problema é um vetor, o qual representa a rota de cidades que ele irá percorrer. As posições no vetor serão preenchidas com o número das cidades que irá percorrer. Por exemplo, existem 3 cidades, cidade 1,2 e 3, o cromossomo poderá ser representado dessa forma: $C = [1 \ 2 \ 3 \ 1]$, assim, ele percorre todas as cidades e volta a inicial como se pede o problema.

A.2.2 Seleção

A população, conjunto de cromossomos, após ser criada de forma que o percurso de cada cromossomo seja aleatório, é calculado a distância total percorrida no percurso. A seleção então é feita por roleta onde se atribui probabilidades a cada cromossomo, os que apresentam a menor rota recebe a probabilidade maior de serem escolhidos como pais da nova geração, Figura 35.

Figura 35 – Seleção.

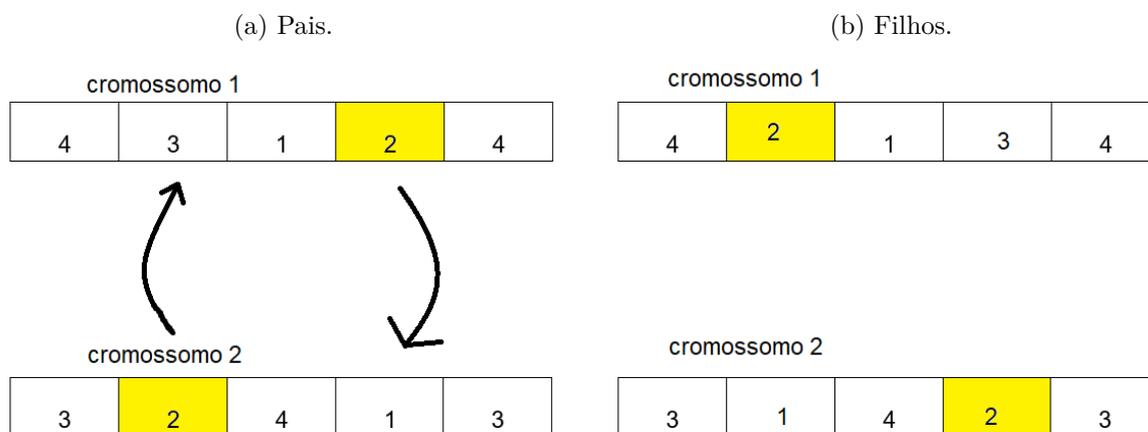


Fonte: Do Autor.

A.2.3 Cruzamento

O cruzamento é realizado então de forma que os pais selecionados trocam posições de uma cidade x conforme a posição de cada um dos pais, gerando os novos cromossomos chamados de filhos, Figura 36.

Figura 36 – Cruzamento.

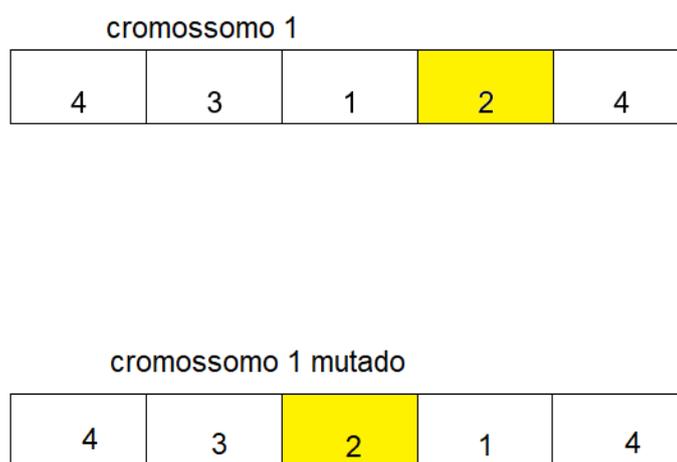


Fonte: Do Autor.

A.2.4 Mutação

A mutação ocorre a uma taxa de 2% de probabilidade de selecionar uma posição do vetor e substituir pela posição anterior do vetor.

Figura 37 – Mutação.



Fonte: Do Autor.

A.2.5 Elitismo

Por último ocorre o elitismo, os indivíduos que apresentaram o melhor percurso se tornarão a população da próxima interação.

A.3 ACO

O algoritmo colônia de Formigas, foi influenciado pelo comportamento das formigas ao saírem de sua colônia para encontrar comida. O algoritmo utiliza uma matriz de feromônios e de atração para decidir o caminho que a formiga irá seguir.

A.3.1 Formiga

A formiga é criada semelhantemente ao cromossomo, Seção A.2.1.

A.3.2 Feromônios

A matriz de feromônios para o problema do caixeiro viajante é representado por uma matriz de $(N \times N)$, onde N é o número de cidades do grafo em questão. Essa matriz é atualizada a cada nova interação do algoritmo, uma formiga é analisada, para as cidades

que ela escolheu percorrer a matriz de ferormônios é atualizada pela Equação A.1. Os feromônios possuem uma taxa de evaporação de 5%, Equação A.2. A evaporação de ferormônios permite que o algoritmo mantenha uma aleatoriedade maior.

$$\tau_{ij} \leftarrow \tau_{ij} + \frac{1}{C^f} \quad (\text{A.1})$$

$$\tau \leftarrow (1 - \rho) * \tau \quad (\text{A.2})$$

A.3.3 Matriz de atração

A matriz η representa a atração de uma formiga por um caminho. Essa matriz tem tamanho (NxN) similarmente a matriz de feromônios, Seção A.3.2. Logo η é montada utilizando uma matriz com o custo de todas as viagens possíveis é utilizado a Equação A.3.

$$\eta_{ij} = \frac{1}{weights} \quad (\text{A.3})$$

weights: matriz custo de todas as viagens do grafo.

A.3.4 Caminho

O caminho é decidido então pela probabilidade, Equação A.4, de cada opção. Então o algoritmo utiliza do método da roleta para selecionar a posição que será alterada na formiga conforme o caminho que ela decidiu seguir.

Para o problema do caixeiro viajante foi selecionado $\alpha = 1$ e $\beta = 3$ como recomendado por Dorigo e Stutzle (2004).

$$P_{ij}^f = \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum [\tau_{ij}]^\alpha [\eta_{ij}]^\beta} \quad (\text{A.4})$$

A.4 Resultados

Os resultados apresentados nessa seção foram obtidos via simulações utilizando o software MATLAB versão 2018a e os algoritmos AG e ACO. Os parâmetros utilizados para a simulação foram:

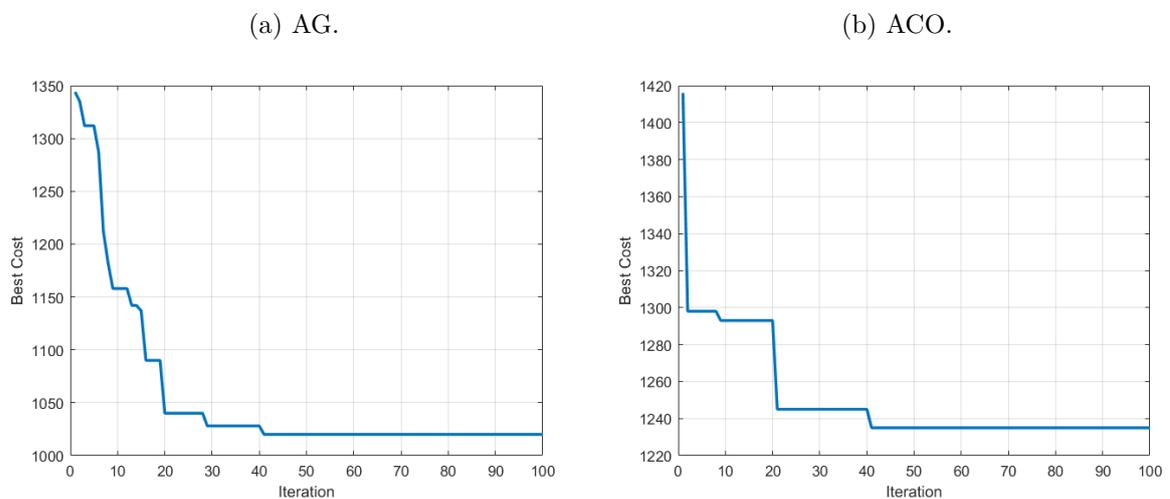
- O número de cidades (N): 30 cidades.
- Número da população para os algoritmos: 100.

- População inicial iguais para os dois algoritmos.

A Figura 38 representa a convergência dos dois algoritmos, a qual será utilizada como validação para ambos. Os algoritmos são considerados úteis ao observar que ambos apresentaram uma otimização da resposta do problema, a qual foi melhor do que a resposta inicial.

Entretanto, o AG, Figura 38a, apresentou uma melhor resposta que o ACO, Figura 38b, porque o AG obteve resposta mais próxima a 1000 km, enquanto o ACO apresentou uma resposta próxima a 1220 km.

Figura 38 – Convergência do algoritmo.



Fonte: Do Autor.