

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

Héricles Eduardo Oliveira Farias

**METODOLOGIA PARA GERENCIAMENTO DE SISTEMAS
DE ARMAZENAMENTO COM BATERIAS E OPERAÇÃO
FLEXÍVEL EM TEMPO REAL PARA SUPORTE A
INSTALAÇÕES COM GERAÇÃO DISTRIBUÍDA**

**Santa Maria, RS, Brasil
2021**

Héricles Eduardo Oliveira Farias

**METODOLOGIA PARA GERENCIAMENTO DE SISTEMAS DE
ARMAZENAMENTO COM BATERIAS E OPERAÇÃO FLEXÍVEL EM
TEMPO REAL PARA SUPORTE A INSTALAÇÕES COM GERAÇÃO
DISTRIBUÍDA**

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Processamento de Energia Elétrica, da Universidade Federal de Santa Maria (UFSM-RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Elétrica**.

Orientador: Prof. D.Sc. Luciane Neves Canha

**Santa Maria, RS, Brasil
2021**

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Farias, Hércles Eduardo Oliveira

METODOLOGIA PARA GERENCIAMENTO DE
SISTEMAS DE ARMAZENAMENTO COM BATERIAS E
OPERAÇÃO FLEXÍVEL EM TEMPO REAL PARA
SUPORTE A INSTALAÇÕES COM GERAÇÃO
DISTRIBUÍDA / Hércles Eduardo Oliveira Farias - 2021

84 p.; 30 cm

Orientador: Luciane Neves Canha

Dissertação (mestrado) – Universidade Federal de Santa
Maria, Centro de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, RS, 2021

1. Engenharia Elétrica 2. Gerenciamento 3. Sistema de
Armazenamento com Baterias 4. Estação de Recarga de Veículos
Elétricos 5. Otimização I. Neves Canha, Luciane II. Título.

© 2021

Todos os direitos autorais reservados a Hércles Eduardo Oliveira Farias. A reprodução de partes ou do todo deste trabalho só poderá ser feita com autorização por escrito do autor.

Endereço: Rua Barão do Triunfo, Nº 1420, Bairro Nossa Senhora de Fátima, Santa Maria, RS, Brasil, CEP: 97015-070;

Fone: (55) 991060504;

Endereço Eletrônico: hericleslannister@gmail.com

Héricles Eduardo Oliveira Farias

**METODOLOGIA PARA GERENCIAMENTO DE SISTEMAS DE
ARMAZENAMENTO COM BATERIAS E OPERAÇÃO FLEXÍVEL EM
TEMPO REAL PARA SUPORTE A INSTALAÇÕES COM GERAÇÃO
DISTRIBUÍDA**

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Processamento de Energia Elétrica, da Universidade Federal de Santa Maria (UFSM-RS), como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovado em 18 de Agosto de 2021:



Luciane Neves Canha, D.Sc. (UFSM)
(Presidente/ Orientador)



Camilo Alberto Sepulveda, Dr. (UFSM)



Mariana Resener, Dra. (UFRGS)

Santa Maria, RS, Brasil
2021

DEDICATÓRIA

A minha mãe Cleia, guerreira e inspiradora, que sempre me motivou a ir além. E a minha namorada Juliana, que há mais de 5 anos me incentiva a dar o melhor de mim.

AGRADECIMENTOS

A lista de pessoas que direta ou indiretamente me ajudaram nessa caminhada é enorme, a todos o meu mais sincero agradecimento.

A minha família, em especial minha mãe, que me ajudou a subir o primeiro degrau que foi o da graduação, e que, frente aos muitos obstáculos do caminho, sempre me incentivou a lutar pelos meus sonhos.

A minha namorada Juliana, que durante esses últimos 5 anos sempre serviu de inspiração para mim. Aos meus sogros Estefano e Eliane pela ajuda excepcional durante toda essa jornada, e obviamente aos meus gatos Cheewie e Podrick que sempre alegraram meus dias.

A minha orientadora Luciane pelo apoio e por ser uma grande referência de P&D que tomei como base.

Aos meus grandes amigos, que fiz aqui em Santa Maria, seja comendo no RU (aliás saudades) ou jogando nas horas de lazer. Em especial, por ordem alfabética (jogando *safe*) Eduardo, Emanuelli, Didi, Dranaju, João, Lucas, Marcelo, Ternes e Thiago.

Aos meus amigos de laboratório Leonardo e Camilo, que sempre me ajudaram e contribuíram para o meu crescimento profissional.

Agradeço ao Programa de P&D da ANEEL e à COPEL-Dis, que proporcionaram o desenvolvimento desta dissertação através do Projeto Estratégico PD 2866-0462/2016 - BATERIAS DE PEQUENO PORTE RESIDENCIAL INTEGRADAS AO CONCEITO DE HEM E GLD.

Um último agradecimento à UFSM por toda a estrutura e pela oportunidade dada de estudar em um dos maiores centros de educação do RS.

Por fim, a todos os guerreiros que durante essa quarentena se mantiveram fortes e crentes de um futuro melhor.

“Grrr grr grrrrr grrr gr grrrrr
Cheewie & Podd - My
beloved cats”

RESUMO

METODOLOGIA PARA GERENCIAMENTO DE SISTEMAS DE ARMAZENAMENTO COM BATERIAS E OPERAÇÃO FLEXÍVEL EM TEMPO REAL PARA SUPORTE A INSTALAÇÕES COM GERAÇÃO DISTRIBUÍDA

AUTOR: HÉRICLES EDUARDO OLIVEIRA FARIAS

ORIENTADOR: LUCIANE NEVES CANHA

Esta dissertação apresenta uma metodologia para gerenciamento de sistemas de armazenamento de energia com baterias, conectados a estações de recarga de veículos elétricos com suporte de geração distribuída. A dissertação foi desenvolvida a partir de três eixos principais: o primeiro eixo se refere ao processo de planejamento de recargas, onde são considerados clientes agendados. Nesta etapa é utilizada a técnica meta heurística Otimização por Enxame de Partículas Evolutivo (*Evolutionary Particle Swarm Optimization, EPSO*) em conjunto com o processo de Monte Carlo. O agendamento também considera os interesses tanto da estação quanto da rede. O segundo eixo é referente ao despacho otimizado do banco de baterias com base nas informações da etapa anterior. Nesta etapa a otimização leva em conta fatores como desgaste do elemento armazenador e minimização de custos. Para solução deste problema foi utilizado um modelo de otimização multi-critério. Por fim, o último eixo considera a operação de clientes agendados e não agendados em tempo real. Nesta etapa é computada a operação diária da estação de recarga, com base nas estratégias definidas e levando em conta a chegada dos usuários não agendados à estação. Na operação diária, são utilizados processos de fluxo de carga e de caixa, que são conduzidos por estratégias baseadas em regras. Esta dissertação também leva em conta diferentes fatores como: tipos de carregamento, conforto ao usuário, interesses da estação e da rede, entre outros. O estudo de caso apresentou uma boa operação da estação de recarga. Tanto o processo de agendamento quanto o de despacho otimizado apresentam benefícios à estação sem comprometer a operação da rede ou do próprio banco de baterias. Com uso do agendamento, a estação distribui melhor a carga do dia seguinte e coordena melhor o despacho dos recursos distribuídos. Com do despacho otimizado do banco de baterias, a estação consegue: reduzir custos operacionais de compra de energia da rede, desgastes da bateria, e maximizar o autoconsumo da geração distribuída.

Palavras-chave: gerenciamento, sistema de armazenamento com baterias, estação de recarga de veículos elétricos, otimização.

ABSTRACT

**METHODOLOGY FOR MANAGEMENT OF
BATTERY ENERGY STORAGE SYSTEMS AND
REAL TIME FLEXIBLE OPERATION TO
SUPPORT FACILITIES WITH DISTRIBUTED
GENERATION**

AUTHOR: HÉRICLES EDUARDO OLIVEIRA FARIAS
ADVISOR: LUCIANE NEVES CANHA

This dissertation presents a management methodology applied to battery energy storage systems connected to electric vehicle charging stations supported by distributed generation. The study is divided in three main parts: The first part consists of a planning process for vehicle recharge, taking into account only scheduled consumers. In this step the meta heuristic Evolutionary Particle Swarm Optimization (EPSO) along with the Monte Carlo process are used. The scheduling also considers both the recharge station and the grid interests. The second step refers to the optimized dispatch of the battery bank based on the information provided by the previous step. In this step, the optimization takes into account factors such as battery degradation and costs reduction. A multi-criteria optimization model was used to solve this problem. Finally, the last step considers the operation for both scheduled and non scheduled users in real time. In this step the daily operation of the recharge station is calculated, based on the defined strategies and considering the arrival of new users to the station. At daily operation, load and cash flow processes are used, based on rule based approaches. For validation, the case study takes into account different factors such as: charging types, user comfort, station and grid interests, among others. The results presented a good operation of the charging station. Both the scheduling and the dispatch optimization processes showed benefits to the station without compromising the grid or the battery bank operation. With the proposed scheduling, the recharge station has a better distribution of its own load in the following day, and improves the coordination of the distributed resources dispatch. With the optimization of the battery bank dispatch, the recharge station can: reduce the operational costs related to energy purchase from the grid; reduce the battery degradation; and maximize the self consumption of distributed generation.

Keywords: management, battery energy storage systems, electric vehicle charging station, optimization

LISTA DE FIGURAS

Figura 2.1 – Estrutura do NSGA-II.....	33
Figura 2.2 – Ordenação por não-dominância.	33
Figura 2.3 – Cálculo da distância de aglomeração.	34
Figura 2.4 – Fluxograma genérico do algoritmo NSGA-II.....	34
Figura 3.1 – Fluxograma da metodologia.	37
Figura 3.2 – Histogramas dos CAGs: (a) Histograma da média de solicitações de recarga. (b) Histograma do EC dos VEs durante a solicitação.	39
Figura 3.3 – Fluxograma das solicitações de recarga.	40
Figura 3.4 – Fluxograma da estimativa do usuário VE e SoC real de chegada. ...	41
Figura 3.5 – Dados usados para o CNAg: (a) Histograma da média de VEs para cada intervalo de tempo. (b) Histograma do SoC de cada EV na chegada.	43
Figura 3.6 – Fluxograma da etapa de agendamento das solicitações.....	44
Figura 3.7 – Processo de troca de posições.	45
Figura 3.8 – Exemplo de histograma da população de Custo do Cluster C3.	50
Figura 3.9 – Exemplo do Ponto de Pareto - Cluster 5.	51
Figura 3.10 – Fluxograma da conexão CNAg à ERVE.....	53
Figura 3.11 – Fluxograma da operação do SAEB.....	56
Figura 3.12 – Módulo SAEB.	57
Figura 4.1 – Tarifa: (a) Tarifa Branca (TB) e TB com variabilidade. (b) TB modificada e com variabilidade, e previsão FV.....	61
Figura 4.2 – FV real e prevista.	62
Figura 4.3 – Tempo vs população.	63
Figura 4.4 – Geração vs população.	63
Figura 4.5 – FO vs população.	64
Figura 4.6 – Demanda VE: (a) Só com f_1 . (b) Só com f_2 . (c) Pareto.	65
Figura 4.7 – Demanda VE: (a) Métrica de custos para os três casos. (b) Métrica PAPR para os três casos.	67
Figura 4.8 – Despacho otimizado do SAEB da ERVE.....	68
Figura 4.9 – Matriz de utilização dos carregadores dedicados.	70
Figura 4.10 – Despacho real do sistema.....	71
Figura 4.11 – Fluxo de caixa na ERVE.	74

LISTA DE TABELAS

Tabela 2.1	–	Comparativo dos estudos de cunho econômico	22
Tabela 2.2	–	Índices da tabela comparativa 2.1.....	22
Tabela 2.3	–	Comparativo dos estudos de cunho técnico	25
Tabela 2.4	–	Comparativo dos estudos de cunho técnico-econômico	27
Tabela 3.1	–	Clusters para recarga.	38
Tabela 3.2	–	Número máximo de reservas por tipo de carregamento considerando 10 carregadores.	42
Tabela 3.3	–	Custo de disponibilidade e Multiplicadores de Tarifa.....	58
Tabela 4.1	–	Solicitações de recarga.....	65
Tabela 4.2	–	Pontos de Pareto para cada Cluster.	66
Tabela 4.3	–	Métricas de cada caso	66
Tabela 4.4	–	Informações dos consumidores.....	70
Tabela 4.5	–	Principais impactos técnicos no sistema.	72
Tabela 4.6	–	Impactos do uso do SAEB no sistema.	73
Tabela 4.7	–	Resultados econômicos sumarizados.	75
Tabela 4.8	–	Indicadores econômicos do uso do SAEB.....	75

LISTA DE ABREVIATURAS E SIGLAS

VE	Veículo Elétrico
ERVE	Estação de Recarga de Veículos Elétricos
RDE	Recurso Distribuído de Energia
SAEB	Sistema de Armazenamento de Energia com Baterias
OSD	Operador do Sistema Distribuído
BR	Baseado em Regras
MH	Meta Heurística
SSFV	Sistema Solar Fotovoltaico
EPSO	Evolutionary Particle Swarm Optimization
PSO	Particle Swarm Optimization
CSD	Cenário Sustentável de Desenvolvimento
Li-Ion	Lithium Ion
SAE	Sistema de Armazenamento de Energia
SCP	Sistema Conversor de Potência
PID	Proporcional Integral Derivativo
IA	Inteligência Artificial
PL	Programação Linear
MC	Monte Carlo
AG	Algoritmo Genético
CC	Corrente Contínua
GDi	Gerador à Diesel
FCT	Fonte Conversora de Tensão
FV	Fotovoltaica
DP	Dinamic Programming
SoC	State of Charge
HC	Horário de Comercial
TS	Tempo de Simulação
CAG	Consumidor Agendado
CNAG	Consumidor Não Agendado
PLIM	Programação Linear Inteira Mista
CN	Carregamento Normal
CR	Carregamento Rápido
CUR	Carregamento Ultra Rápido
Hi	Hora Inicial
Hf	Hora Final

LISTA DE SÍMBOLOS

X_k^{novo}	Nova partícula
X_k	Partícula
vel_k^{novo}	Velocidade da nova partícula
vel_k	Velocidade da partícula
b_k	Melhor ponto encontrado pela partícula
b_G	Melhor ponto global
we_k	Peso
$\hat{E}sp$	Valor esperado
$G(x)$	Função de teste
$\hat{V}ar(G)$	Variância amostral
P_i	Demanda VE no passo de tempo i
$U_{i,m}$	Matriz binária com estado dos VEs
C_m	Custo de energia em cada intervalo de tempo
P_{max}	Potência máxima
$P_{méd}$	Potência média
L_i	Passos de tempo consecutivos da conexão considerada
X_{norm}	Valor normalizado
$X_{mín}$	Valor mínimo
$X_{máx}$	Valor máximo
E_{pos}^{novo}	Novo vetor de deslocamento
E_{pos}^{novo}	Vetor de deslocamento
D_i	Demanda esperada
GD_i	Potência do gerador distribuído esperada
x_i	Despacho do SAEB
$Bcap$	Capacidade total do SAEB
$Cost^B$	Custo do SAEB
s	Inclinação da aproximação linear da vida útil do SAEB em função do número de ciclos de vida
Tp_i	Preço da tarifa
VE_{Fat}	Valor da fatura total dos VEs
$ERVE_v$	Venda de energia por parte da ERVE para a rede
$ERVE_c$	Compra de energia por parte da ERVE da rede
$SAEB_{Deg}$	Degradação do SAEB
$Custo_{Disp}$	Custo de disponibilidade do uso dos carregadores

SUMÁRIO

1 INTRODUÇÃO	15
1.1 MOTIVAÇÃO E JUSTIFICATIVA	17
1.2 OBJETIVOS DO TRABALHO	18
1.2.1 Objetivo Geral	18
1.2.2 Objetivos Específicos	19
1.3 ORGANIZAÇÃO DOS CAPÍTULOS	19
2 REVISÃO DA LITERATURA	21
2.1 REVISÃO BIBLIOGRÁFICA	21
2.1.1 Abordagem Econômica	21
2.1.2 Abordagem Técnica	24
2.1.3 Abordagem Técnico-Econômica	27
2.2 REFERENCIAL TEÓRICO	29
2.2.1 Elemento Armazenador - Li-Ion	29
2.2.2 Evolutionary Particle Swarm Optimization (EPSO)	30
2.2.3 Monte Carlo	31
2.2.4 NSGA-II	32
2.3 RESUMO DO CAPÍTULO	35
3 METODOLOGIA	36
3.1 MODELO DE CARGA	37
3.1.1 Consumidor Agendado (CAg)	38
3.1.2 Consumidor Não-Agendado (CNAg)	42
3.2 ETAPA DE AGENDAMENTO DAS SOLICITAÇÕES DE RECARGA	43
3.2.1 Solução Inicial com PLIM	45
3.2.2 Busca com EPSO	47
3.2.3 Normalização da FO	49
3.2.4 Matriz de deslocamento binária	49
3.2.5 Processo do MC e busca do ponto de Pareto	50
3.3 ETAPA DE OTIMIZAÇÃO DO DESPACHO DO SAEB	51
3.4 CRIAÇÃO DA POPULAÇÃO CNAG	53
3.5 ETAPA DO BALANÇO ENERGÉTICO	54
3.5.1 Estratégia Baseada em Regras (BR) para o Balanço Energético ...	54
3.5.2 Módulo do SAEB - Baseado em Regras	54
3.6 ETAPA DO FLUXO DE CAIXA	58
3.7 DISCUSSÃO DO CAPÍTULO	59
4 ESTUDO DE CASO	60
4.1 VALIDAÇÃO DO EPSO	62

4.2 CARGAS AGENDADAS	64
4.3 IMPACTO DA OTIMIZAÇÃO DO SAEB	67
4.3.1 Análise Técnica	69
4.3.2 Análise Econômica	73
4.4 DISCUSSÃO DO CAPÍTULO	76
5 CONCLUSÃO	78
5.1 TRABALHOS FUTUROS	78
5.2 PRODUÇÃO CIENTÍFICA ASSOCIADA À DISSERTAÇÃO	79
REFERÊNCIAS	80

1 INTRODUÇÃO

Ao longo dos últimos anos o número de veículos elétricos (VEs) tem crescido significativamente ao redor do mundo. Projeções apontam crescimento esperado de 250 milhões de VEs até 2030 (IEA, 2019; IRENA, 2019b; IEA, 2020). Juntamente com este crescimento, o número de estações de recarga de veículos elétricos (ERVEs) em operação teve um aumento de 44% de 2018 a 2019 (IEA, 2020). Um ponto interessante é que grande parte das ERVEs são baseadas em investimentos privados (IEA, 2019).

Embora o crescimento tanto dos VEs quanto das ERVEs seja, em sua essência, benéfica ao meio ambiente, ainda sim, uma operação descoordenada deles pode acarretar em problemas ao desempenho do sistema elétrico de potência. Os principais agravantes geralmente estão relacionados aos altos picos de demanda no sistema de distribuição, problemas com níveis de tensão, sobrecarregamento de linhas e a má qualidade de energia (HEYDT, 1983; DEB et al., 2018; CHUNG et al., 2019). O conhecimento destes problemas justifica o gerenciamento inteligente das ERVEs, de modo que a estação consiga determinar os tempos de carregamento e montantes de energia associados, visando sempre minimizar os impactos na rede e/ou maximizar os benefícios econômicos da operação.

O uso de recursos distribuídos de energia (RDEs) representa uma ferramenta importante na operação de ERVEs, pois reduz a dependência de potência da estação em relação à rede. Dentre alguns RDEs pode-se citar o uso de geração renovável como a solar fotovoltaica e eólica, o uso de elementos armazenadores de energia, entre outros. Embora estes componentes forneçam benefícios à operação da estação, eles também aumentam a complexidade do sistema, tornando mais difícil o gerenciamento.

Com base nesse contexto, este trabalho busca coordenar a operação de uma ERVE com geração solar fotovoltaica em sinergia com o despacho otimizado de um Sistema de Armazenamento com Bateria (SAEB) estacionário. Este último, pode trazer vários benefícios à operação da estação, fornecendo serviços como deslocamento de energia no tempo, arbitragem, corte de pico de potência, integração de fontes renováveis, suporte de tensão e frequência, entre outros (BADAWY; SOZER, 2017; ABRONZINI et al., 2019; HAYAJNEH; LAINFIESTA; ZHANG, 2020; KOUKA; KRICHEN, 2019).

Tanto o problema de otimização da operação do SAEB quanto à da ERVE podem considerar diferentes objetivos, bem como pode haver a participação de múltiplos agentes. Sob o ponto de vista da ERVE, existe a necessidade de balancear o interesse da estação de recarga quanto à maximização das recargas dos VEs sem que isto comprometa os interesses do operador do sistema distribuído (OSD). Além disto, existe a necessidade de levar em conta os interesses dos usuários em termos de conforto, tempos de espera e velocidade da recarga.

Já sob a ótica da operação do SAEB, existe a necessidade de conciliar o despacho econômico com o desgaste associado pelo uso da bateria. Neste caso, os processos de

carga e descarga sob taxas de descarga muito profundas podem acarretar em uma redução significativa da vida útil do elemento armazenador (CHAUDHARI et al., 2018; ZHANG et al., 2014). Vale mencionar que, dependendo da tecnologia escolhida, também existem restrições operacionais relacionadas aos limites do estado de carga, bem como perdas e riscos operativos.

Como os investimentos em ERVEs vêm ganhando mais importância, algumas aplicações também se expandem e consideram longos percursos, em contraste ao uso curto dos VEs dentro das cidades (YANG et al., 2013). Como exemplo, a ERVE instalada na COPEL (Companhia Paranaense de Energia), na cidade de Curitiba/PR do Brasil, já estende uma eletrovia de grande distância que interliga diversas cidades (COPEL, 2019). No entanto, grandes percursos também agregam maior complexidade, bem como os VEs necessitam de uma disponibilidade confortável de reservas para carregamento. Outro ponto importante é que os tempos de recarga para os VEs devem ser curtos para considerar o conforto dos usuários. Assim sendo, o uso de métodos de agendamento se torna uma ferramenta essencial para a ERVE adequadamente gerenciar o uso dos carregadores para atender toda a sua demanda baseada em informações prévias.

Considerando o comportamento estocástico dos VEs, a análise preditiva pode ser útil para o planejamento das recargas (ZHANG et al., 2014; SHI et al., 2020). No entanto, a necessidade de dados históricos para adequação aos modelos de previsão limita estas ferramentas em lugares onde ainda não existem bases de dados consolidadas, como no Brasil. Uma alternativa para coletar informação pode ser o agendamento feito com base em reservas dadas pelos usuários interessados em futuras recargas. Neste estudo técnicas heurísticas como as em (MILAS; MOURTZIS; TATAKIS, 2020; ZHANG et al., 2014; BHARATIRAJA et al., 2017; LIU et al., 2020; ELECTRIC... , 2017; XU; PAN; TONG, 2016; SAVARI et al., 2019) são úteis para o planejamento operacional. Entretanto, a operação em tempo real se torna limitada na presença de informações insuficientes. Estas informações estão relacionadas à chegada de novos usuários sem agendamento. A diferença de percursos dos VEs até a chegada na ERVE também pode impactar nos tempos de carregamentos estimados.

Desta forma, estratégias baseadas em regras (BR) são apresentadas como uma solução para o problema de conexão de novos usuários em tempo real. Estratégias BR (MILAS; MOURTZIS; TATAKIS, 2020; ABRONZINI et al., 2019; XU; PAN; TONG, 2016; ZIMA-BOCKARJOVA et al., 2020) são baseadas em tomadas de decisões considerando regras e dependem das informações atuais do sistema. Assim sendo, a combinação de um planejamento agendado com a operação em tempo real de novas conexões pode fornecer um funcionamento mais robusto da ERVE, focando em interesses dos usuários, OSD e da própria ERVE. Além disto, o suporte do sistema de armazenamento se torna fundamental na hora de facilitar o despacho de energia, e garantir maiores receitas à ERVE. Para isto é importante contar com ferramentas de otimização do sistema de arma-

zenamento de modo a atender tanto as necessidades da ERVE como as restrições próprias da bateria e as restrições de despacho de energia.

Por estes motivos este trabalho apresenta uma metodologia que combina otimização meta heurística (MH) com estratégias BR para o gerenciamento da ERVE e do SAEB, considerando o suporte de um Sistema Solar Fotovoltaico (SSFV). Para o agendamento da demanda da ERVE é utilizada a técnica *evolutionary particle swarm optimization algorithm* (EPSO), que representa uma melhoria em relação ao método clássico do PSO (*Particle Swarm Optimization*) (MIRANDA; KEKO; JARAMILLO, 2007), apresentando rápida convergência e menor sensibilidade à variação de parâmetros estratégicos. Para o gerenciamento do despacho do SAEB foi utilizado uma variação do Algoritmo Genético, o *Non-dominated Sorting Genetic Algorithm* ou NSGA-II, com uso da biblioteca Pymoo na linguagem Python. Para os processos em tempo real foram utilizadas estratégias BR. O proposto estudo é definido como MH-BR pois combina as duas técnicas. Este trabalho é direcionado a longos percursos dos VEs e a ERVE é localizada em uma rodovia. Os carregadores operam com carregamento rápido (30 minutos à uma hora e 30 minutos), com três modos de carregamento. Os resultados parciais deste trabalho foram publicados em (FARIAS et al., 2021) pelo próprio autor. Aqui se apresentam algumas melhorias considerando modificações no gerenciamento do sistema de armazenamento e abordagens para agendamento mais robusto da recarga dos veículos elétricos utilizando simulação de Monte Carlo (MC).

1.1 MOTIVAÇÃO E JUSTIFICATIVA

O uso de armazenamento com baterias em diversos setores de energia, embora seja cada vez mais comum, nem sempre teve essa expressividade. De acordo com (AGENCY, 2020) cerca de 90% de toda a capacidade fabricada com baterias em 2013 supria o mercado de eletrônicos. No entanto, a partir de 2017 o crescimento do mercado de veículos elétricos aumentou a demanda por este tipo de tecnologia, e já em meados de 2019, o setor havia crescido mais de dois terços.

De acordo com a visão da IEA (AGENCY, 2020), sob uma ótica de Cenário Sustentável de Desenvolvimento (CSD), até 2040 cerca de 10 TWh de armazenamento de energia seriam necessários para suprir todos os setores. O setor de veículos elétricos representaria a maior parcela. Embora atualmente o número de VEs não seja significativo em relação aos veículos à combustão, ainda sim, é esperado que até 2050 este setor represente cerca de 5% da demanda global de energia. Isto o tornaria o mercado com a maior demanda de energia.

De modo a acompanhar este crescimento, a fabricação de baterias também deve aumentar. Desde 2010 o seu custo unitário já apresentou redução de 85%, e em 2019 o

custo médio de venda totalizou R\$ 828.36/kWh. Não obstante, além das reduções nos custos, as baterias para carros leves e comerciais também apresentaram melhorias em suas capacidades. Atualmente suportam mais 20% de energia que em relação à 2018, com a maioria dos VEs possuindo capacidades entre 50 e 70 kWh.

No que se refere ao armazenamento estacionário, similar ao utilizado nesta dissertação, o seu crescimento também vem crescendo anualmente, todavia sob uma taxa menor que a do setor de eletro mobilidade. Atualmente a capacidade global é cerca de 200 GWh, sendo que a categoria de armazenamento mecânico, com a tecnologia de usinas reversíveis, representa mais de 90% do total, enquanto que as baterias totalizam cerca de 3%. No entanto, excluindo a tecnologia de usinas reversíveis, em 2018 cerca de 90% da nova capacidade instalada foram com as variantes da tecnologia de íons de lítio (Li-Ion).

Ainda de acordo com o CSD da IEA, até 2040 é esperado que a capacidade com baterias totalize cerca de 550 GW, um crescimento considerável em comparação com os 6 GW de 2019. Outro fator importante é uso primário destas tecnologias, que em comparação a 2012, eram utilizadas majoritariamente em serviços de arbitragem de energia, e atualmente já estão presentes em uma vasta gama de aplicações, como regulação de frequência e tensão, resposta inercial, entre outros (AGENCY, 2020).

Com base neste contexto, a principal motivação desta dissertação reside na importância do armazenamento para o setor elétrico como um todo, levando em conta o papel primordial que estas tecnologias vão desempenhar na corrida pela transição sustentável da matriz elétrica.

Como justificativa, pode-se citar a necessidade por uma metodologia que alie tanto os interesses da ERVE quanto o dos usuários, sem que isto represente uma má operação do sistema elétrico. Sendo assim, esta dissertação visa otimizar o despacho econômico dos processos de carga/descarga do SAEB de modo a aumentar os ganhos da ERVE e ao mesmo otimizar a carga atendida com a utilização da metodologia MH-BR.

1.2 OBJETIVOS DO TRABALHO

1.2.1 Objetivo Geral

Esta dissertação tem como objetivo o desenvolvimento de uma metodologia para gerenciamento de sistema de armazenamento considerando suporte à operação da ERVE e desgaste da bateria. A metodologia representa uma estratégia baseada em regras combinada com uma meta-heurística para o agendamento do ERVE, e um modelo de otimização multi-critério para o gerenciamento da bateria.

1.2.2 Objetivos Específicos

Dentre os objetivos específicos pode-se citar:

- Desenvolvimento de uma técnica combinada de MH-BR para o gerenciamento da ERVE considerando demandas agendadas e em tempo real;
- Desenvolvimento de um *framework* para operação da ERVE levando em conta os interesses da própria ERVE, do conforto dos usuários e do impacto na rede;
- Aplicação de um modelo de otimização multi-critério para otimização da operação do sistema de armazenamento por baterias em suporte ao ERVE;
- Aplicação de uma MH para gerenciamento da recarga de veículos elétricos considerando usuários agendados;
- Aplicação de uma estratégia RB para controle da operação em tempo real do ERVA considerando tanto usuários agendados como não agendados;
- Otimizar o agendamento tanto dos veículos elétricos como do uso dos carregadores, considerando tres possíveis tipos de recarga;
- Desenvolvimento do modelo de otimização do SAEB estacionário da ERVE com base no desgaste associado à operação bem como no lucro operativo fornecido pela mesma;
- Análise técnica dos impactos do despacho de energia em termos de energia e potência;
- Análise econômica da fluxo de caixa das estratégias de despacho consideradas.

1.3 ORGANIZAÇÃO DOS CAPÍTULOS

Esta dissertação é dividida da seguinte forma:

O capítulo dois apresenta inicialmente uma revisão bibliográfica de alguns estudos recentes com temáticas semelhantes, abordando os principais tópicos relacionados com ênfase no âmbito econômico, técnico e técnico-econômico de cada estudo. Também são apresentados os referenciais teóricos associados às técnicas e métodos utilizados no decorrer deste trabalho.

O capítulo três aborda a metodologia desenvolvida, bem como os passos em cada etapa tanto do planejamento quanto da operação em tempo real das novas conexões.

O capítulo quatro apresenta os estudos de caso, onde são definidos os cenários de simulação. Finalmente, o capítulo cinco apresenta as conclusões deste estudo bem como as principais limitações e futuros trabalhos.

2 REVISÃO DA LITERATURA

2.1 REVISÃO BIBLIOGRÁFICA

O uso de elementos armazenadores tornou-se uma peça importante na operação do setor elétrico, seja na aplicação energética centralizada ou descentralizada. Em estações de recarga de veículos elétricos o mesmo também é importante. Existem diversos estudos buscando a integração de armazenadores no fornecimento de energia aos consumidores, principalmente com uso de tecnologias do tipo eletroquímica, como as baterias.

Geralmente, os tipos de abordagens destes estudos podem possuir caráter econômico, técnico ou técnico-econômico. Na abordagem econômica busca-se diminuir o custo do sistema, ou então aumentar o lucro, por meio dos serviços que o elemento armazenador consegue realizar, de modo a viabilizar o investimento na tecnologia.

Os estudos de caráter técnico já visam melhorar os índices técnicos do sistema, como por exemplo, redução de perdas, melhoria nos níveis de tensão, aumento de confiabilidade, etc. Este tipo de abordagem visa a viabilidade técnica.

Finalmente na abordagem técnico-econômica o uso do armazenador é analisado tanto sob o ponto de vista econômico quanto técnico. Tem-se por exemplo como objetivos aumento do lucro do sistema e minimização das perdas associadas. Estas abordagens tratam de problemas multi-critério de modo que a realização de uma tarefa, não afete negativamente a outra ou as outras. A seguir são apresentados alguns dos estudos em cada tipo de abordagem.

2.1.1 Abordagem Econômica

A tabela 2.1 apresenta um comparativo dos estudos de cunho econômico com base em algumas das especificidades desta dissertação. A tabela 2.2 apresenta a descrição dos índices comparativos da tabela 2.1.

Tabela 2.1 – Comparativo dos estudos de cunho econômico

Autor	A	B	C	D	E	F	G	H
JIANG, ZHEN, 2019	X	X	X	X			X	X
CHAUDHARI et al. 2018			X	X	X			X
MARTY, PIETROWICZ, 2018			X				X	X
ABRONZINI et al. 2019	X		X	X			X	
ZHANG et al. 2014			X				X	X
ABRONZINI et al. 2019			X				X	
SHIN, CHOI, KIM, 2020	X		X	X			X	
KO, PACK, LEUNG, 2020		X	X					X

Fonte: Autor.

Tabela 2.2 – Índices da tabela comparativa 2.1

LEGENDA			
A	Operação em Tempo Real	E	Usa Algoritmos BR
B	Operação Planejada	F	Considera degradação do SAEB
C	Tem SAEB	G	Considera ERVE
D	Tem SSFV	H	Variação nos preços da tarifa

Fonte: Autor.

Em (JIANG; ZHEN, 2019) os autores propõem um modelo de otimização de um estacionamento de VEs com uso de um otimizador *Grey Wolf (GWO)*. O estacionamento também é dotado de um sistema solar fotovoltaico (SSFV) e um sistema de armazenamento de energia (SAE). O estudo, primeiramente, realiza um gerenciamento inteligente de recargas. Posteriormente o estudo também conduz uma estratégia de agendamento em tempo real utilizando uma versão melhorada do GWO, definida como *binary Grey Wolf Optimizer*, em conjunto com previsões de curto prazo do sistema fotovoltaico. O despacho dos DERs, bem como a energia da rede de distribuição é otimizada com intuito de minimizar os custos de operação do estacionamento. O sistema de armazenamento de energia (SAE) representa uma peça chave na otimização, dado que ele consegue armazenar a energia da rede durante os períodos mais baixos da tarifa ou absorver o excesso do SSFV para uso posterior na carga dos VEs.

Os autores de (CHAUDHARI et al., 2018) propõem o uso de um algoritmo de otimização híbrida para o gerenciamento de sistemas de armazenamento de energia em estações de recarga de VEs. O estudo considera um modelo de degradação para o armazenador e incentivos governamentais que visam o aumento de penetração da fonte solar

fotovoltaica. O algoritmo então controla a carga/descarga do armazenador com base em seu modo de operação, seja ele determinístico ou baseado em regras. Tanto o despacho do ESS e a potência a ser importada da rede são baseadas no preço em tempo real do mercado elétrico. O estudo possui como objetivo analisar o montante de subsídio necessário para ser economicamente viável a utilização de um SSFV junto a um SAE em uma estação de recarga.

Em (Marty; Pietrowicz, 2018) é examinada a utilidade econômica do uso de baterias em estações de recarga que atendem VEs de uso pessoal, com o intuito de reduzir o pico de demanda na rede. O estudo considera um método de carga/descarga da bateria baseado em incentivos econômicos para o operador da estação de recarga, estes incentivos tomam como base as variações nos preços da energia.

Os autores de (ABRONZINI et al., 2019) desenvolvem uma estratégia de gerenciamento de energia para controle em tempo real de ERVES com múltiplas fontes, considerando RDEs, SAE estacionário e *vehicle to grid (V2G)*. O estudo propõem um controle de gerenciamento de energia dinâmico e com múltiplas camadas, onde o mesmo é baseado em uma abordagem com uso de uma técnica heurística que permite dividir o problema de otimização em sub problemas na forma de cascada. A estratégia busca minimizar o custo de operação do sistema levando em consideração a degradação do elemento armazenador e a natureza estocástica da fontes utilizadas.

Em (ZHANG et al., 2014) é proposto o agendamento das recargas dos VEs em uma estação atendida tanto pela rede quanto pelos recursos locais. O estudo considera as incertezas associadas à chegada dos VEs, energia renovável, preço da tarifa e à energia requerida por cada VE. Estas incertezas são então modeladas como processos Markov independentes. O estudo então busca minimizar o tempo médio de espera entre recargas considerando restrições de custo, também são levadas em consideração dois tipos de políticas estacionárias, uma com cunho radical e outra mais conservadora com intuito de estudar o impacto de cada uma no sistema. A política conservadora deste estudo leva em conta uma restrição de custo médio de carregamento, por outro lado, a política radical não a considera. O elemento armazenador deste estudo é utilizado como suporte ao fornecimento de energia.

Em (ABRONZINI et al., 2015) é proposto o dimensionamento otimizado e controle do fluxo de potência de um sistema conversor de potência (SCP) conectado à rede e com múltiplas fontes para uso em estações de recarga de VEs acoplado com SAEs. No estudo o SCP possui é baseado em uma análise de custo-benefício. O trabalho então estuda a redução do impacto do carregamento dos VEs na rede elétrica, bem como a redução dos custos associados ao utilizar recursos distribuídos como a fonte solar fotovoltaica e SAE.

No trabalho de (SHIN; CHOI; KIM, 2020) os autores propõem uma abordagem descentralizada para solucionar o problema de agendamento da carga dos múltiplos VEs. O estudo também considera dados em tempo real de geração solar FV, carga VE e dados

relacionados ao SAE, etc. No estudo é proposto uma nova técnica multi agente baseada em *Deep Reinforcement Learning* para lidar e aprender com os padrões da carga elétrica e para otimizar o consumo de energia e custos operacionais da ERVE. Deve-se salientar que a abordagem de (SHIN; CHOI; KIM, 2020) contava com uma base de dados numerosa para poder tratar os dados. Em casos em que a disponibilidade de dados é pouca esta metodologia não poderia ser aplicada corretamente. A proposta desta dissertação lida com o problema de escassez de dados ao combinar as técnicas MH com estratégias BR. Com o aumento dos dados e medições em aplicações reais no Brasil, a metodologia proposta nesta dissertação pode ser futuramente adaptada para considerar técnicas de *Machine Learning*.

Os autores de (KO; PACK; LEUNG, 2020), embora não abordem especificamente o tema de ERVE, propõem um modelo de carregamento otimizado de baterias onde uma estação de troca de baterias realiza este processo com base nos preços da tarifa de energia e na taxa de chegada de VEs. O estudo busca como objetivo maximizar o lucro da estação de troca. O estudo utiliza o processo de decisão de Markov juntamente com programação linear (PL) para solucionar o problema de agendamento das recargas. Fazendo um comparativo deste último trabalho com esta dissertação, o conceito de estação de reposição de baterias representa um serviço interessante para a ERVE, embora não seja contemplada nesta dissertação, ainda sim este tópico também é considerado em futuros trabalhos.

Analisando os trabalhos anteriores, se observa um grupo de estudos focados no SAEB para fins econômicos. Esta dissertação se difere (JIANG; ZHEN, 2019; Marty; Pietrowicz, 2018; ZHANG et al., 2014) ao considerar tanto a operação planejada quanto a em tempo real, bem como ao contemplar o uso de otimização multi objetivo tanto nos processo de agendamento de carga quanto na de despacho do SAEB. Analogamente à estes estudos, esta dissertação também considera o uso de fontes renováveis, porém, fatores como múltiplos tipos de carregamento, restrições contratuais definidos entre rede e ERVE também representam um diferencial desta dissertação.

Similarmente aos trabalhos de (CHAUDHARI et al., 2018; ABRONZINI et al., 2019), esta dissertação também considera a degradação do SAEB e o uso de algoritmos baseados em regras, no entanto, o modelo de degradação além de estar presente na função objetivo do processo de otimização também é levado em conta no fluxo de caixa da ERVE. Já o uso de algoritmos BR também é utilizado nas etapas de despacho de carga, gerenciamento das conexões de certos clientes e no fluxo de caixa.

2.1.2 Abordagem Técnica

A tabela 2.3 apresenta o comparativo dos estudos de cunho técnico, similarmente ao que foi apresentado na seção anterior.

Tabela 2.3 – Comparativo dos estudos de cunho técnico

Autor	A	B	C	D	E	F	G	H
BIYA, SINDHU, 2019			X	X			X	
KOUKA, KRICHEN, 2019			X	X			X	
VERMA, SINGH, 2020			X	X			X	
HAYAJNEH, LAINFIESTA,			X				X	
YAN et al. 2021			X	X			X	
SHING et al. 2020			X	X			X	
SHIN, CHOI, KIM, 2020	X		X	X			X	
KO, PACK, LEUNG, 2020		X	X					X

Fonte: Autor.

Os autores de (BIYA; SINDHU, 2019) estudam o uso de controlador PID, de corrente e de tensão para controle de uma estação de recarga. O controle procura obter valores desejados de potência no sistema ao manter a tensão do barramento CC da estação de recarga dentro de certos limites fixados. O elemento armazenador é primariamente utilizado para absorver o excesso vindo da fonte solar para uso noturno na carga dos VEs.

No trabalho de (KOUKA; KRICHEN, 2019) os autores buscam analisar a performance de uma estação de recarga conectada à rede e dotada de SSFV e SAEB. A variável de estudo do sistema é a tensão CC do barramento da estação. O banco de baterias é utilizado para auxiliar no abastecimento da carga da ERVE, juntamente com a rede, e para manter a tensão CC do barramento dentro de certos limites. O sistema é então avaliado sob diferentes circunstâncias de irradiação, e o estado de carga das baterias. A ERVE então busca maximizar o uso de energia fotovoltaica sempre que possível e usar a rede ou a bateria como um sistema de suporte sempre que a irradiância solar estiver indisponível ou existe um excesso de geração.

Em (HAYAJNEH; LAINFIESTA; ZHANG, 2020) os autores desenvolvem um conceito interessante de armazenamento estacionário em conjunto com móvel, com suporte de energia renovável, onde os objetivos principais são maximizar o uso dos recursos renováveis, incentivar o desenvolvimento de SAE em larga escala e promover o uso de transporte sem emissão de gases poluentes. O interessante deste estudo é que ambos os elementos armazenadores recebem energia da fonte renovável, a energia do BESS estacionário é utilizada em aplicações voltadas à rede, como por exemplo regulação de frequência. Já o BESS móvel é transportado por semi-caminhões elétricos e auxilia no fornecimento da demanda em corrente contínua das ERVEs da rede. Embora o conceito de armazenamento móvel não seja contemplado nesta dissertação, o autor considera este tópico como trabalho futuro. Essa abordagem, além de prover serviços importantes à rede também consegue auxiliar possíveis ERVEs distribuídas ao longo de um sistema de distribuição.

O estudo de (YAN et al., 2021) apresenta um esquema de dois estágios para solucionar tanto a alocação de potência quanto a coordenação de carregamento de uma frota de VEs do tipo *plugged-in*. Teoria de jogo é utilizado para levar em conta o interesse individual de cada componente do sistema. O primeiro estágio busca encontrar a alocação de potência para o SSFV, SAEB e rede, bem como a potência total requerida pelos VEs. Já o segundo estágio busca coordenar a estratégia de carregamento dos VEs com base na potência disponível calculada no estágio anterior. O objetivo do componente armazenador é modelado em termos do SoC da bateria, onde busca-se manter a mesma dentro de certos limites. A fonte solar fotovoltaica busca minimizar o *curtailment*, e quanto à rede, busca-se diminuir o consumo da energia vinda dela.

Em (SINGH et al., 2020) os autores propõem o estudo da viabilidade técnica de uma ERVE com suporte de SSFV, SAEB e gerador à diesel (GDi). O GDi atua, juntamente com a rede, sempre que a geração renovável ou a bateria estão indisponíveis, no entanto a potência drenada do GDi é utilizada de modo que sempre opere com 80-85% de carregamento para que se obtenha a máxima eficiência do combustível sob todas as condições de cargas do estudo. A ERVE então é modelada de modo que, em conjunto com o SAEB, regule a tensão e frequência do gerador sem depender de um mecanismo de regulação mecânica da velocidade.

No trabalho de (VERMA; SINGH, 2020) é proposto a operação multi modo de uma estação de recarga com SSFV, SAEB e gerador a diesel. A estação atende tanto os VEs quanto cargas residenciais, no estudo uma fonte conversora de tensão (FCT) é utilizada para operar a estação de recarga em modo ilhado, conectado à rede e no modo com o gerador à diesel conectado. A FCT realiza tarefas como gerenciamento de potência, carregamento dos VEs, extração de máximo potência dos painéis FV, regulação de tensão e frequência do gerador, compensação de harmônicos da corrente das cargas não lineares e compensação intencional de potência reativa. Na ausência de potência do SSFV e SAEB o controle opera utilizando o gerador à diesel, no entanto o mesmo opera gerando um percentual maior de potência do que a nominal, mas respeitando os limites de corrente dos condutores, possibilitando assim que o GDi seja subdimensionado. A tensão e frequência do GDi também são regulados sem o uso de um governador mecânico de velocidade.

Fazendo um comparativos de alguns dos trabalhos anteriormente apresentados com esta dissertação, analogamente à (YAN et al., 2021), esta dissertação também considera o impacto da carga dos VEs na rede elétrica, bem como a minimização dos encargos de compra de energia da rede. No entanto, a métrica PAPR (Peak to Average - Peak to Ratio) é utilizada para refletir o impacto esperado na rede e a compra de energia da rede é mensurada na função de minimização de custos da ERVE, ambas as variáveis são consideradas na etapa de agendamento de carga.

Similarmente aos trabalhos de (KOUKA; KRICHEN, 2019; BIYA; SINDHU, 2019), são considerados o uso do SAEB para suporte à ERVE. Todavia, nesta dissertação o ele-

mento armazenador não realiza o serviço de regulação de tensão, mas provê suporte à ERVE ao garantir que a carga vista pela rede esteja dentro dos limites definidos em contrato, e realiza serviços como maximização de auto consumo remoto de geração renovável e arbitragem.

Os trabalhos de (SINGH et al., 2020; VERMA; SINGH, 2020), similarmente à esta dissertação, também consideram o uso de recursos distribuídos, no entanto, neste trabalho o autor não considera a utilização de geradores à diesel para suporte à ERVE. A principal motivação disto é a busca por uma matriz energética focada em fontes renováveis, dado que a ideia final dos novos avanços é reduzir a dependência dos combustíveis fósseis e a poluição gerada por estes.

2.1.3 Abordagem Técnico-Econômica

A tabela 2.4 apresenta o comparativo dos estudos de cunho técnico-econômico.

Tabela 2.4 – Comparativo dos estudos de cunho técnico-econômico

Autor	A	B	C	D	E	F	G	H
LI et al., 2018	X		X		X		X	X
DING et al., 2014		X	X				X	X
BADAWY, SOZER, 2017		X	X	X		X	X	X
YANG et al., 2019		X	X				X	
HUSSAIN, BUI, KIM, 2020			X				X	
YAN, ZHANG, KEZUNOVIC, 2019	X		X	X			X	X
SHIN, CHOI, KIM, 2020	X		X	X			X	
KO, PACK, LEUNG, 2020		X	X					X

Fonte: Autor.

No trabalho de (LI et al., 2018), os autores desenvolvem uma estratégia hierárquica de gerenciamento de energia orientada a aplicações em tempo real para lidar com as incertezas da estação de recarga. A degradação do sistema é modelada como uma das funções objetivo juntamente com parâmetros econômicos e ambientais. Neste estudo o algoritmo de Monte Carlo é utilizado para lidar com as incertezas e visando um ótimo dimensionamento da estação é considerado a busca pelo ponto de Pareto. O estudo então utiliza o algoritmo genético para resolver o problema multi objetivo de minimização de custos, emissão de carbono e degradação do SAEB. Similarmente, nesta dissertação, os processos de MC e AG são utilizados. No entanto, a finalidade do MC é de auxiliar o EPSO no agendamento das recargas e a do AG é de conduzir o despacho otimizado do

SAEB.

Os autores de (DING et al., 2014) propõem a operação coordenada de ERVEs com tipo de carregamento rápido e SAEs. No estudo o despacho do armazenador é otimizado com base na média histórica dos dados de carregamento e também é implementada uma estratégia em tempo real para lidar com a compra de energia da rede. O estudo prioriza minimizar os montantes decorrentes dos períodos mais caros da tarifa, bem como para suavizar a carga de carregamento. Referente à esta dissertação, aqui também se leva em conta o uso de carregamento do tipo rápido e algoritmos BR para lidar com o despacho em tempo real. No entanto, os tipos de carregamento são divididos em três grupos e o algoritmo BR também é utilizado em outros processos cruciais da metodologia, como na conexão em tempo real dos usuários não agendados e no fluxo de caixa da ERVE. Vale mencionar que esta abordagem foi utilizada devido à escassez de dados históricos de VEs no Brasil.

Em (BADAWY; SOZER, 2017) é proposto uma técnica otimizada de fluxo de potência para uma ERVE com carregamento do tipo rápido e dotada de SSFV e SAEB. Os objetivos do estudo visam minimizar o custo operacional do sistema, aumentar a penetração dos recursos distribuídos na rede e dar suporte à demanda crescente por carregamento rápido. O estudo emprega o algoritmo Particle Swarm Optimization (PSO) e Dynamic Programming (DP) na resolução da função objetivo. Também são levadas em consideração os preços da rede e a degradação da bateria. A diferença deste estudo com a presente dissertação diz respeito ao uso do método EPSO, que representa uma versão aprimorada do PSO, apresentando melhores resultados em termos de tempo e qualidade de resposta (RANGEL et al., 2018; MIRANDA; FONSECA, 2002; FARIAS et al., 2021).

No trabalho de (YANG et al., 2019) os autores propõem uma estação de baterias compartilhada, onde a ela pode tanto atuar como estação carregadora ou de troca de baterias. O estudo aplica um método de controle chamado de bateria divisional para criar uma estratégia de despacho para controlar a carga/descarga, modo ocioso e processo da troca das baterias. O estudo busca maximizar a receita do sistema, atender satisfatoriamente a demanda dos consumidores sob condições seguras e sustentáveis de operação, e participar nos serviços de *peak shaving* e *valley filling*.

Em (HUSSAIN; BUI; KIM, 2020) os autores buscam determinar o dimensionamento ótimo de um SAE de uma ERVE de carregamento rápido visando minimizar os custos operacionais associados, melhorar a resiliência dos VEs e reduzir o pico de demanda no sistema. O estudo leva em conta o aspecto de resiliência em cenários de falta de energia. Referente à esta dissertação, aqui também são considerados o uso de carregamento do tipo rápido e o interesse da rede. No entanto, os tipos de carregamento são dividido em três grupos e a métrica de PAPR é utilizada para modelar o interesse da rede.

No trabalho de (YAN; ZHANG; KEZUNOVIC, 2019) é desenvolvido o controle e otimização inteligente em múltiplos estágios aplicado em uma ERVE. A estação de

recarga é equipada com SSFV e SAEB e integrada à um prédio comercial. O objetivo do estudo é minimizar os custos do consumidor considerando potenciais incertezas, e ao mesmo tempo balancear em tempo real a relação entre fornecimento e demanda ao ajustar o agendamento dos processos de carga/descarga dos VEs, SAEB, energia da rede e da carga deferível.

Fazendo um comparativo com os trabalhos anteriormente apresentados, analogamente à (YANG et al., 2019; HUSSAIN; BUI; KIM, 2020; YAN; ZHANG; KEZUNOVIC, 2019), esta dissertação também emprega o SAEB com despacho otimizado para auxiliar na minimização dos custos operacionais da ERVE. No entanto, a variável de desgaste também é levada em consideração. Outros pontos diferenciais desta dissertação diz respeito à operação agendada e em tempo real, restrições contratuais, uso de diferentes tipos de carregamento, bem como a dissertação também leva em conta os interesses dos usuários e da ERVE, bem como o impacto na rede.

2.2 REFERÊNCIAL TEÓRICO

Esta seção serve como referencial teórico sobre alguns dos métodos, componentes e ferramentas utilizadas ao longo deste trabalho.

2.2.1 Elemento Armazenador - Li-Ion

SAEs com baterias são sistemas que trabalham com reações químicas reversíveis. Basicamente durante os períodos de carga a energia elétrica de entrada é convertida em energia química, para armazenamento, e em períodos de demanda esta energia é então reconvertida em energia elétrica para uso final (BUENO; BRANDÃO, 2016).

Na bateria do tipo de Íons de Lítio o eletrodo positivo (cátodo) é usualmente feito de algum óxido metálico de lítio, e o negativo (ânodo), geralmente feito de alguma material de carbono. Estes eletrodos são separados por um material polimérico que possibilita o fluxo de elétrons e íons entre cada eletrodo, e estes são imersos em um eletrólito, que, por sua vez, pode ser feito de alguns sais de lítio dissolvidos em um líquido orgânico (LEWIS, 2016). Este tipo de tecnologia possui alta densidade de energia, o que a garante uma vasta gama de aplicações, as principais por setor são apresentadas a seguir:

- **Edificações residenciais e comerciais:** Deslocamento de energia no tempo, auto consumo de geração local;
- **Redes de distribuição:** Suporte à tensão, capacidade e frequência;
- **Transmissão:** Serviços ancilares;

- **Geração renovável:** Serviços de Smoothing (suavização da energia renovável exportada para a rede) e Shapping (modelagem do perfil de geração de fontes intermitentes para perfis desejados de geração) associados com suporte à tensão e frequência, de modo a garantir melhor integração de energia renovável.

De acordo com (AGENCY, 2020) atualmente dentre as principais químicas de Li-Ion pode-se citar a de lithium nickel cobalt aluminium oxide (NCA), lithium nickel manganese cobalt oxide (NMC) e lithium ion phosphate (LFP), com a de NMC sendo a mais comum.

2.2.2 Evolutionary Particle Swarm Optimization (EPSO)

O processo de agendamento da recarga dos VEs utiliza o método Evolutionary Particle Swarm Optimization (EPSO). Este método se baseia em uma técnica auto adaptável similarmente ao comportamento evolutivo. No EPSO é definido um conjunto de partículas que representam uma possível solução para o agendamento das recargas dos VEs. Uma população randômica é definida inicialmente para o conjunto de seleção. No espaço de busca, cada partícula apresenta um movimento e, para evitar soluções inválidas, um processo de filtragem é utilizado para selecionar candidatos válidos. O algoritmo EPSO é caracterizado por ser um aprimoramento do conhecido PSO, mostrando suas vantagens em vários trabalhos (SAVARI et al., 2019; MIRJALILI, 2019; POLI; KENNEDY; BLACKWELL, 2007). No EPSO, o movimento da partícula segue as regras baseada nos conceitos de inércia, memória e cooperação. Pode-se dizer que ele representa um algoritmo auto adaptável porque usa conceitos de mutação e seleção de parâmetros.

O movimento da partícula é apresentado na Equação (2.1). Onde X_k é uma partícula, X_k^{novo} é a nova partícula e vel_k^{novo} é a velocidade da partícula. A Equação (2.2) apresenta a equação da velocidade (MIRANDA; KEKO; JARAMILLO, 2007).

$$X_k^{novo} = X_k + vel_k^{novo} \quad (2.1)$$

$$vel_k^{novo} = we_{k0}^* \times vel_k + we_{k1}^* \times (b_k - X_k) + we_{k2}^* \times (b_G^* - X_k) \quad (2.2)$$

$$we_k^* = we_k + \sigma \mathcal{N}(0, 1) \quad (2.3)$$

onde, na Equação (2.2) os pesos we sofrem mutação com base em uma distribuição Gaussiana com média zero e variância unitária, como apresentado na Equação (2.3). A variável b representa o melhor ponto encontrado pela partícula e b_G é o melhor ponto global. A abordagem com EPSO também replica cada partícula r vezes e produz mutação em b_G para produzir um certo distúrbio (MIRANDA; KEKO; JARAMILLO, 2007). Este dis-

túrbio reduz a convergência mas garante mais variabilidade nas soluções. A seguir é apresentado o pseudo-código genérico utilizado para o algoritmo EPSO.

Algoritmo 1: Pseudo-código genérico do EPSO

Saída: $Melhor_G$ (melhor ponto encontrado pelo enxame)

```

1 Inicializa a população;
2 para  $i \leftarrow 0$  até  $tamanhoEnxame$  faça
3   | Inicializa  $X_i$  aleatoriamente;
4   | Inicializa  $v_i$  em 0;
5   | Inicializa  $Melhor_L$  (melhor ponto encontrado pela partícula);
6 fim
7 Inicializa  $Melhor_G$ ;
8 para  $i \leftarrow 0$  até  $N_{iterações}$  faça
9   | Replica  $X_i$  r vezes;
10  | Processo de mutação conforme Eq. (2.3);
11  | para  $i \leftarrow 0$  até  $tamanhoEnxame$  faça
12    | Calcula  $F_{obj}$  da partícula  $i$ ;
13    | Atualiza  $v_i$  conforme Eq. (2.2);
14    | Atualiza  $X_i$  conforme Eq. (2.1);
15    | Calcula  $F_{objtemp}$  da partícula  $i$ ;
16    | Avaliação;
17    | se  $F_{objtemp} < F_{obj}$  então
18      | |  $Melhor_L \leftarrow X_i$ ;
19      | | se  $X_i < Melhor_G$  então
20        | | |  $Melhor_G \leftarrow X_i$ 
21      | | fim
22    | fim
23  | fim
24 fim
  
```

2.2.3 Monte Carlo

A simulação de Monte Carlo (MC) é utilizada neste trabalho para criar uma população de indivíduos que representam possíveis soluções ao problema de agendamento a partir da melhor solução encontrada pelo algoritmo EPSO. Ele, trabalha como uma busca local em torno da melhor resposta com intuito de mapear outras possíveis alternativas.

Dado que, dependendo da solução, o universo de possíveis combinações pode vir a ser muito extenso, uma busca exaustiva de todas as variações acaba sendo impraticável, com base nisso o MC permite reduzir o tamanho da base dados ao determinar uma amostra significativa.

O processo da determinação do tamanho da população que seja significativa é descrito a seguir. Durante cada iteração é calculada a estimativa do valor esperado $\hat{E}sp(G)$

da função de teste $G(x)$ do sistema para uma dada configuração x_i sorteada com base no número de cenários K (Pereira et al., 1992). A equação do valor esperado é apresentada a seguir:

$$\hat{E}sp(G) = \frac{1}{K} \sum_{i=1}^K G(x_i), \quad (2.4)$$

a partir deste valor pode-se calcular a variância amostral $\hat{V}ar(G)$ por meio de (Pereira et al., 1992), conforme apresentado a seguir:

$$\hat{V}ar(G) = \frac{1}{K-1} \sum_{i=1}^K [G(x_i) - \hat{E}sp(G)]^2. \quad (2.5)$$

Como critério de parada, pode-se ainda utilizar de um fator chamado de β , definido como:

$$\beta = \frac{\delta(\hat{E}sp(G))}{\hat{E}sp(G)} = \sqrt{\frac{Var(\hat{E}sp(G))}{\hat{E}sp(G)^2}}, \quad (2.6)$$

onde um baixo valor de β fornece um maior intervalo de confiança e conseqüentemente uma melhor representação dos dados. A criação da população é continuada até que o critério de parada seja estabelecido.

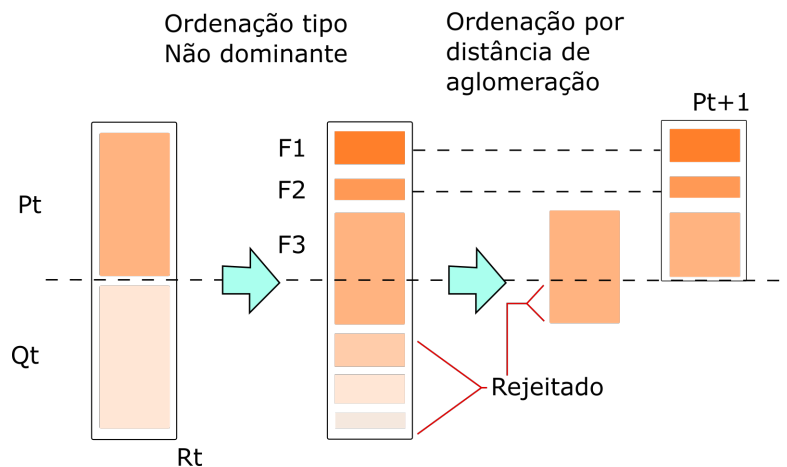
2.2.4 NSGA-II

Este método é utilizado no despacho otimizado do elemento armazenador. A critério de simplificação, ele foi utilizado por meio de uma *framework* da linguagem Python e a modelagem matemática do problema do despacho do SAEB é apresentado na seção da Metodologia.

O *Non-Dominated Sorting Genetic Algorithm* segue a ideia geral dos algoritmos genéticos. No entanto, este método também possui um processo de cruzamento modificado, bem como um processo de seleção de sobreviventes. Os passos do processo principal de cada iteração é apresentado a seguir, e são ilustrados na Figura 2.1 (DEB et al., 2002).

1. Criação das população de *Offspring* e da população R_t ;
2. Nivelamento e ordenação baseado nos índices definidos pelos *targets* (f_1 e f_2);
3. Seleção dos melhores membros para compor a nova população.


Figura 2.1 – Estrutura do NSGA-II.



Fonte: Autor.

Na Figura 2.1, primeiramente, uma população randômica P_t , de tamanho N , é gerada. A população é ordenada seguindo o critério de não-dominância. Cada solução passa então por um processo de nivelamento, onde são criados níveis de não-dominância (denominados F_1 , F_2 , F_3 ...). A população de *Offspring* Q_t de tamanho N , é criada a partir da utilização de técnicas como seleção com torneio binário, recombinação, e operadores mutacionais. A população R_t é formada a partir da combinação de P_t e Q_t , ou seja, possui tamanho $2N$, e também é ordenada seguindo o critério de não-dominância. A Figura 2.2 apresenta a ideia do processo de ordenação do tipo não-dominado.

Figura 2.2 – Ordenação por não-dominância.

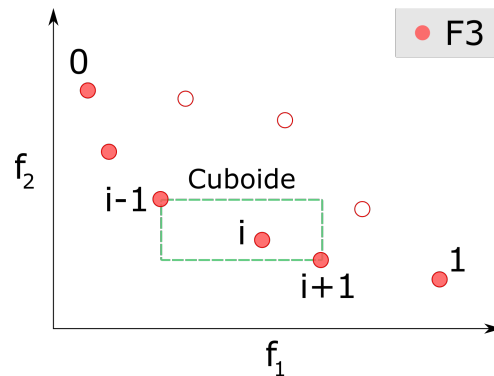


Fonte: Autor.

A Figura 2.2, cada ponto é avaliado conforme f_1 e f_2 , e comparado com os demais pontos para determinar os níveis de não-dominância. A ideia é que o nível F_1 , é melhor que F_2 , F_2 é melhor que F_3 , e assim por diante. No entanto, note que ao criar a nova população P_{t+1} , deve-se garantir que ela possua tamanho N . Isto significa que, nem todos os indivíduos de um certo nível podem ser selecionado para a nova população. Na Figura 2.1, de maneira ilustrativa, os conjuntos abaixo de F_3 , bem como parte do conjunto F_3 , são

rejeitados e não constituem a nova população P_{t+1} . Todavia, alguns indivíduos de F3 são de fato enviados para a próxima população. O processo que determina quais indivíduos da última camada podem ser selecionados é definido como ordenação por distância de aglomeração. Este processo é ilustrado na Figura 2.3.

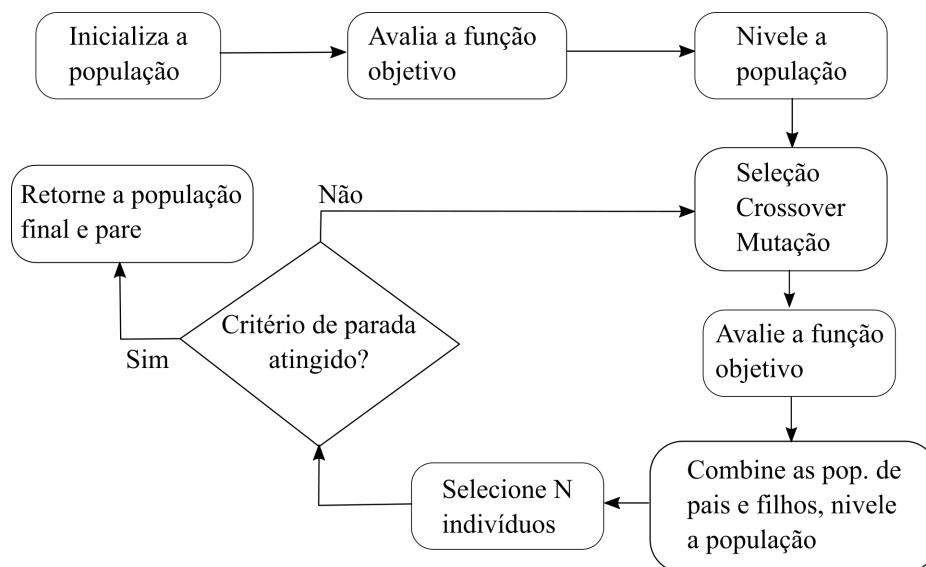
Figura 2.3 – Cálculo da distância de aglomeração.



Fonte: Autor.

Na Figura 2.3, os indivíduos com a maior distância de aglomeração são preferencialmente selecionados. A distância da solução i th do conjunto é o comprimento médio do lado do cuboide (representado pela caixa destacada na figura). O cuboide é formado pelos pontos vizinhos próximos, cujos pontos também foram os vértices do cuboide. A seguir é apresentado o fluxograma genérico do algoritmo NSGA-II.

Figura 2.4 – Fluxograma genérico do algoritmo NSGA-II.



Fonte: Autor.

2.3 RESUMO DO CAPÍTULO

Este capítulo apresentou tanto uma revisão de alguns dos principais estudos relacionados à temática desta dissertação, com foco no elemento armazenador, bem como uma revisão dos métodos utilizados.

A revisão da literatura foi dividida de acordo com a característica primária do estudo analisado, podendo este ter cunho técnico, econômico ou técnico-econômico. Os estudos técnicos focaram na utilização do elemento armazenador para obtenção de benefícios técnicos ao sistema, como por exemplo regulação de tensão e frequência, minimização de *curtailment* e consumo da rede, entre outros.

Já os estudos econômicos visaram otimizar o despacho econômico dos SAEB reduzindo assim custos operacionais do sistema e maximizando os lucros operativos. Por fim os estudos técnico-econômicos possuíam característica multi objetivo, buscando ganhos ao sistema sem comprometer a rede, como por exemplo, a otimização do carregamento de VEs em sinergia com o despacho de RDEs sem que isto sobrecarregue a rede de distribuição. Na parte do referencial teórico destacam-se o modelo BR do SAEB utilizado e o processo MH-BR com uso do algoritmo EPSO em conjunto com o de MC.

3 METODOLOGIA

O modelo proposto nesta dissertação é baseado em duas partes:

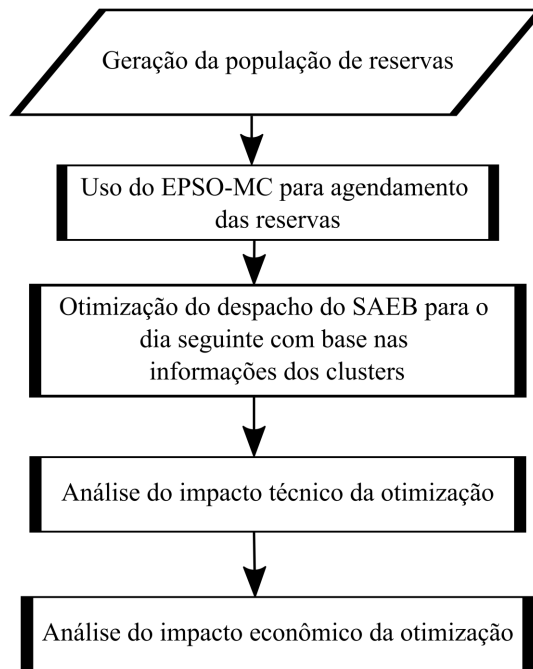
- **Operação agendada:** É realizado o planejamento do agendamento das reservas no dia anterior à operação. Este passo é baseado no algoritmo multi-critério EPSO-MC para cada cluster;
- **Operação em tempo real:** A carga agendada, juntamente com a carga não agendada, são utilizadas em conjunto com a previsão de geração solar fotovoltaica e da tarifa para otimizar o despacho do SAEB para cada cluster.

O modelo considera três tipos de carregamento. O primeiro é o carregamento normal (CN) que leva uma hora e 30 minutos para completar uma recarga. O segundo é o carregamento rápido (CR) que leva uma hora para realizar uma recarga, e o último é o carregamento ultra-rápido (CUR) que leva 30 minutos.

Nesta dissertação é considerado que quanto mais rápido for o tipo de carregamento escolhido maior será o custo associado que o usuário irá pagar, pois a potência entregue acaba sendo maior. Tomando como referência o CR, o tipo CUR é 10% mais caro e o tipo CN é 10% mais barato. Estes percentuais foram arbitrariamente escolhidos pelo autor.

O passo de simulação deste estudo é de 30 minutos e a janela de tempo é de 24 horas. As simulações são realizadas na linguagem de programação Python (ROSSUM; JR, 1995). Embora a abordagem deste estudo seja aplicada somente em uma ERVE ela também pode ser estendida para mais ao considerar comunicação entre as estações e um conjunto de regras para atender os objetivos dos múltiplos agentes. Além disto, caso os carregadores possuam um tempo de recarga menor, o passo de tempo das simulação também pode ser facilmente modificado. A Figura 3.1 apresenta o fluxograma geral da metodologia proposta.

Figura 3.1 – Fluxograma da metodologia.



Fonte: Autor.

Na Figura 3.1 inicialmente são geradas as solicitações de agendamento dos consumidores para cada cluster. Esta etapa ocorre no dia anterior à recarga e simula o processo do consumidor entrar em contato com a ERVE para requisitar um agendamento. Com a população de reservas finalizada é possível utilizar o algoritmo EPSO-MC de agendamento. Esta etapa busca otimizar a operação da ERVE com respeito ao atendimento da carga dos VEs. A carga total dos consumidores é separada em clusters, utilizando janelas de horários, e o algoritmo de otimização é aplicado a cada um.

Após finalizada a otimização dos clusters, a carga agendada é utilizada para otimizar o despacho do SAEB, juntamente com a previsão da geração solar fotovoltaica e dos preços da tarifa da rede. As duas últimas etapas representam o impacto do gerenciamento do SAEB, tanto na ERVE quanto na rede. As etapas de simulação de impacto técnico e econômico são realizadas utilizando algoritmos BR. Os algoritmos BR são também utilizados no gerenciamento das cargas que não requisitaram agendamento no dia anterior.

3.1 MODELO DE CARGA

A ERVE atende dois tipos de consumidores: O Consumidor Agendado (CAg) e o Consumidor Não-Agendado (CNAg). À critério de simplificação, a frota de VEs possui o mesmo modelo, baseado no VE Nissan Leaf com bateria de 40 kWh (WATTSON, 2021).

3.1.1 Consumidor Agendado (CAg)

O consumidor do tipo CAg deve solicitar sua recarga contatando a ERVE no dia anterior ao carregamento. O consumidor fornece informação para a estação sobre o tipo de carregamento desejado bem como a distância esperada de deslocamento antes de chegar na estação para realizar a recarga. O sistema associa esta estimativa com o modelo de estado de carga (*State of Charge - SoC*) do VE para calcular um valor mais preciso da energia requerida pelo usuário no instante da recarga.

Embora o usuário não possa requerer o instante específico de tempo para realizar a recarga ele ainda pode escolher solicitar que a recarga ocorra dentro de um período de tempo confortável a suas necessidades. Esta janela de tempo representa um cluster, ao todo existem sete *clusters* disponíveis para realizar recargas. A Tabela 3.1 apresenta as janelas de tempo associadas a cada cluster.

Tabela 3.1 – Clusters para recarga.

Cluster	C0	C1	C2	C3	C4	C5	C6
Horas	4	3	3	3	4	4	3
<i>Hi</i>	0:00	4:00	7:00	10:00	13:00	17:00	21:00
<i>Hf</i>	4:00	7:00	10:00	13:00	17:00	21:00	0:00

Fonte: Autor.

A Tabela 3.1 apresenta as sete opções de *clusters* para a recarga dos VEs. *Hi* representa a hora inicial do *clusters* e *Hf* a hora final. A escolha de um *cluster* por parte do consumidor pode ocorrer da seguinte maneira: Caso o usuário queira realizar a recarga durante o período noturno do dia seguinte, ele poderia escolher o *cluster* C6 (21:00 à 00:00). Após escolhido o cluster, o usuário deve então contatar a ERVE no dia anterior à recarga e durante a mesma janela de tempo do *cluster* escolhido. Desta maneira, para agendar o *cluster* C6, o usuário deve contatar a ERVE durante o período de 21:00 às 00:00 do dia anterior. Note que para os demais *clusters*, o processo é o mesmo.

Ao final do tempo do *cluster* a ERVE informa o consumidor sobre o horário agendado para a conexão. É importante notar que o usuário não será agendado fora do *cluster* escolhido.


A divisão em *clusters* é importante para garantir conforto ao usuário. Caso o espaço de tempo fosse muito grande isto acabaria gerando longos períodos de espera e incerteza de disponibilidade ao usuário. Deste modo, a clusterização proporciona:

- Uma maneira adequada aos usuários para solicitar uma recarga que esteja dentro de um período do dia de interesse;

- A possibilidade de otimização tanto do despacho dos RDEs quanto da carga agendada por parte da ERVE.

Devido à falta de dados práticos do perfil de carga dos VEs, neste estudo são utilizados e adaptados os dados de um projeto do Reino Unido com o modelo Nissan Leaf de 24 kWh para a criação da população de consumidores agendados (CROSS J. D. HARTSHORN, 2021). A Figura 3.2 apresenta o histograma dos dados utilizados.

Figura 3.2 – Histogramas dos CAGs: (a) Histograma da média de solicitações de recarga. (b) Histograma do EC dos VEs durante a solicitação.

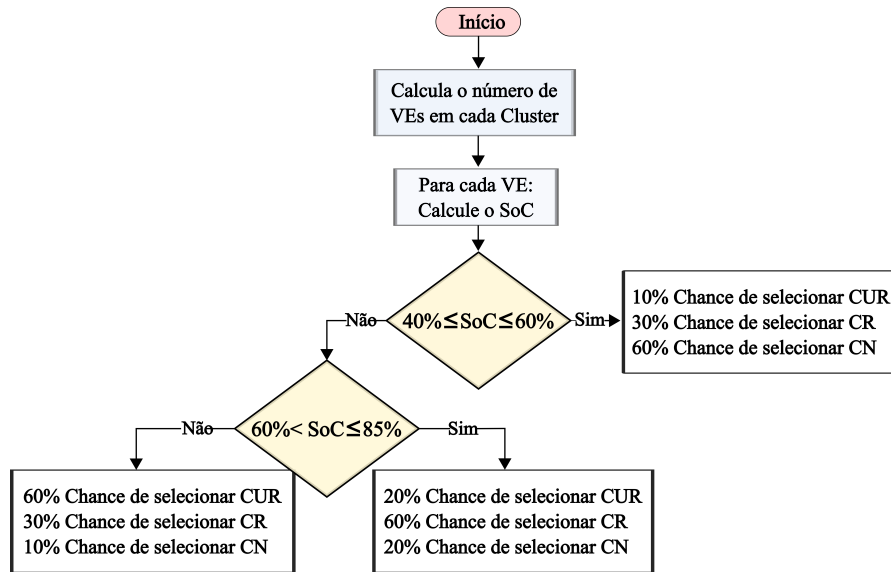


Fonte: Autor.

Os histogramas da Figura 3.2a e 3.2b são utilizados para gerar o total de solicitações de recarga a serem agendados em cada cluster pelo algoritmo EPSO-MC. A parte verde da Figura 3.2a representa o Horário Comercial (HC) onde a ERVE pode atender os dois tipos de cliente. Fora deste período somente o cliente CAG pode ser suprido. As linhas verticais denotam a área de cada cluster.

A etapa de coleta dos dados do CAG é dividida em duas partes: Primeiro, cada consumidor escolhe o tipo de carregamento. Segundo, cada usuário fornece a estimativa da capacidade remanescente de translocação (quilometragem relacionada com o estado de carga do veículo) durante a chegada à estação. A Figura 3.3 apresenta o processo da primeira etapa.

Figura 3.3 – Fluxograma das solicitações de recarga.



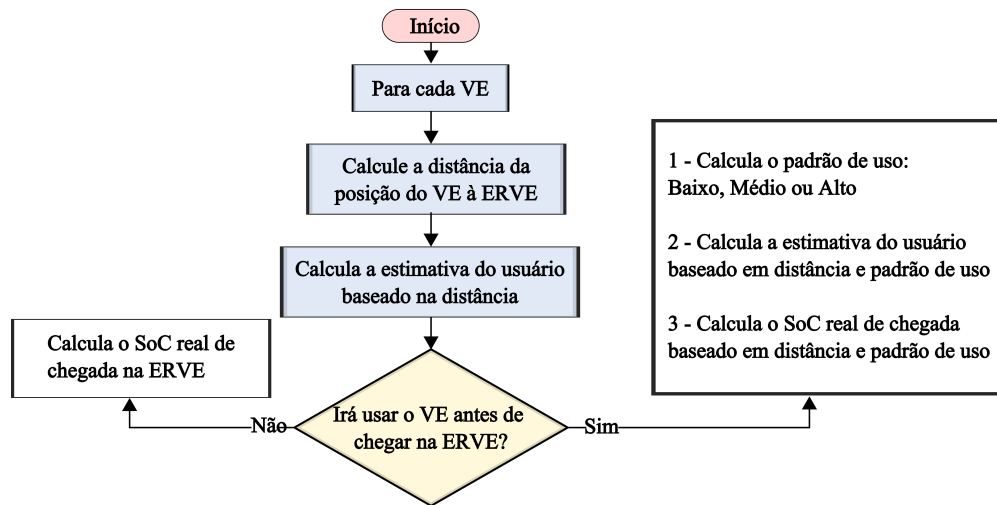
Fonte: Autor.

Na Figura 3.3 para cada VE avaliado durante o tempo de simulação (TS), existe uma probabilidade associada à escolha de um tipo específico de carregamento. Esta probabilidade é dependente do valor do SoC. O conjunto de regras adotadas nesta etapa foram criadas neste estudo para lidar com diferentes cenários. As ideias principais destas regras são:

- Dar um viés ao usuário para selecionar um modo de carregamento mais rápido, caso a quantidade de energia requerida seja baixa;
- Selecionar um modo de carregamento mais lento caso a demanda de energia seja alta.

O processo de estimativa do SoC, considerando a deslocação ao eletroposto é apresentado na Figura 3.4.

Figura 3.4 – Fluxograma da estimativa do usuário VE e SoC real de chegada.



Fonte: Autor.

Na Figura 3.4, o processo depende se o usuário irá utilizar ou não o VE antes de partir para a ERVE. A estimativa deste valor é então utilizada no algoritmo EPSO-MC para fornecer com maior precisão a carga a ser agendada e suprida. O valor real da carga a ser atendida é utilizado durante a etapa de despacho. Quanto menor for o erro entre a carga estimada e a carga real, melhor será o benefício da otimização tanto no lado da ERVE quanto na rede. Esta estimativa é baseada em dois fatores.

- Primeiro, a distância entre o VE e a ERVE;
- Segundo, o uso esperado do VE antes que ele chegue à ERVE.

Como exemplo, se um consumidor possui, no instante da solicitação 40% de SoC, então a energia requerida para recarga completa é 60% da capacidade utilizável. Caso o usuário pretenda usar o VE antes de se dirigir à estação, ele também deve estimar a média de quilômetros a serem percorridos. A estimativa deste valor - baseada na média de consumo por quilômetro do VE - proporciona um valor mais preciso para o SoC do VE durante a chegada à ERVE.

Estas estimativas ajudam a ERVE no abastecimento dos VEs e no despacho dos RDEs pertencentes a ela. É importante ressaltar que o usuário não sofre penalização na fatura da recarga caso o percentual de erro da estimativa esteja abaixo de 15%. Caso o erro seja maior que 15%, uma penalização de 5% é aplicada na fatura do usuário. Como o consumidor do tipo CAg é responsável por fornecer uma estimativa realista do uso esperado do EV antes da recarga acontecer, esta penalização é utilizada para minimizar a perda de performance da otimização do EPSO-MC dado que uma estimativa altamente errada da carga requerida poderia impactar negativamente, ou mesmo invalidar o agendamento otimizado de um cluster. Esta penalização é apenas aplicada ao consumidor

CAG, no entanto, caso o consumidor não queira fornecer a informação da estimativa, ele pode ainda realizar uma recarga na ERVE como consumidor CNAg. No entanto, este tipo de consumidor também está sujeito à disponibilidade de carregadores, ou seja, desde o momento de chegada na ERVE ele deve aguardar até que exista um carregador vago.

Devido ao número limitado de carregadores na ERVE, para cada cluster existe um número máximo de reservas que podem ser feitas para cada tipo de carregamento. Por exemplo, para uma recarga do tipo CUR em um cluster de quatro horas, o número máximo de reservas possíveis em um único carregador é oito, pois este tipo de recarga leva apenas 30 minutos. A Tabela 3.2 apresenta o número máximo possível de reservas para cada tipo de carregamento e para cada cluster.

Tabela 3.2 – Número máximo de reservas por tipo de carregamento considerando 10 carregadores.

Clusters/Ctipo	max CUR	max CR	max CN
C0,C4,C5	80	40	27
C1,C2,C3,C6	60	30	20


Fonte: Autor.

3.1.2 Consumidor Não-Agendado (CNAg)

O consumidor CNAg pode apenas recarregar seu veículo caso exista um carregador disponível. Este tipo de consumidor só pode chegar na ERVE durante o período do horário comercial, isto é, das 07h às 21h. Fora deste período a ERVE só atende os consumidores do tipo CAg. A razão disto é para fornecer uma margem de benefício aos consumidores que agendam a própria recarga. Deste modo, a ERVE tem um melhor controle de seu despacho de energia e é fornecido ao usuário um nível maior de conforto em termos de tempos de espera.

Neste estudo os consumidores CNAg são gerados randomicamente a partir do histograma da Figura 3.5. Como os CNAg representam a carga em tempo real que chega na ERVE, a estação possui completo conhecimento do SoC do VE durante sua chegada. Desta forma, não existe a necessidade da estimativa e o controle é feito utilizando a estratégia BR.

Figura 3.5 – Dados usados para o CNAg: (a) Histograma da média de VEs para cada intervalo de tempo. (b) Histograma do SoC de cada EV na chegada.



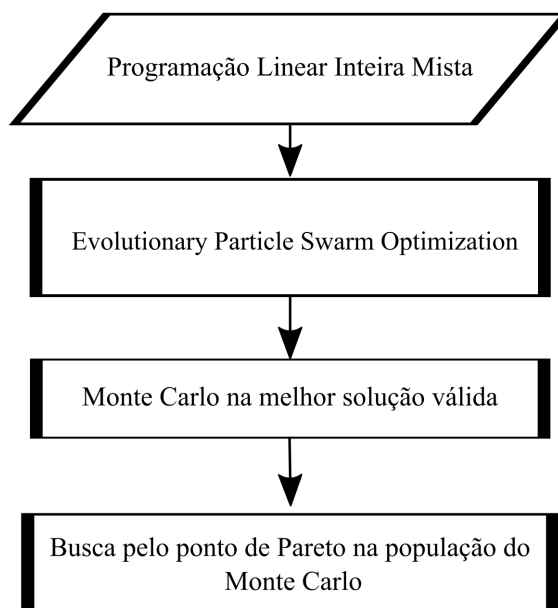
Fonte: Autor.

Ainda que o CNAg dependa de um carregador disponível durante a chegada, ele pode utilizar os carregadores que não tenham sido agendados pelos consumidores CAg. Esta abordagem maximiza a utilização dos carregadores da ERVE e aprimora a disponibilidade de recarga para os clientes CNAg.

3.2 ETAPA DE AGENDAMENTO DAS SOLICITAÇÕES DE RECARGA

Conforme mencionado anteriormente, a etapa de agendamento é realizada pela ERVE no dia anterior à operação. Esta etapa auxilia à estação para melhor atender os seus consumidores sob um custo de fornecimento minimizado. O fluxograma desta etapa é apresentada na Figura 3.6.

Figura 3.6 – Fluxograma da etapa de agendamento das solicitações.



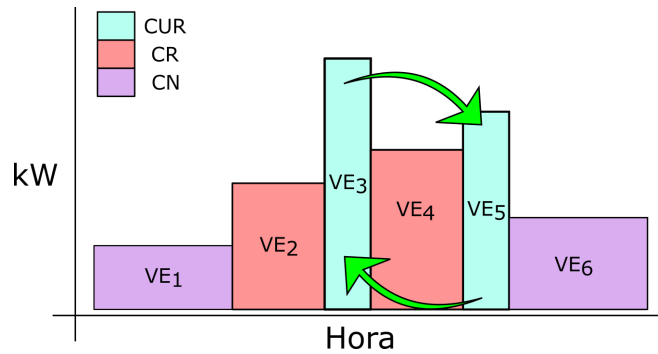
Fonte: Autor.

Na Figura 3.6 após as solicitações dos clusters serem computadas, o algoritmo de Programação Linear Inteira Mista (PLIM) é utilizado para buscar uma solução inicial válida. Esta solução inicial deve respeitar o número máximo de VEs sendo carregados simultaneamente. Esta solução inicial é posteriormente utilizada no algoritmo EPSO para acelerar o processo de busca de soluções, e para garantir ao menos uma solução válida na primeira geração.

Vale mencionar que o processo da Figura 3.6 é realizada em cada cluster ao final da janela de tempo do mesmo. No momento em que o agendamento é finalizado, a ERVE contata o consumidor informando sobre o horário e tipo de conexão, bem como o carregador a ser utilizado.

O processo de Monte Carlo (MC) é utilizado para mapear a solução do EPSO encontrada em busca de outras possíveis soluções não encontradas pelo algoritmo. Esta etapa é importante porque o EPSO determina os horários de recarga para cada carga. No entanto, pode-se ainda realizar uma mudança na disposição dos tipos de recargas, conforme apresentado na Figura 3.7.

Figura 3.7 – Processo de troca de posições.



Fonte: Autor.

Esta mudança é baseada na troca de lugar de cargas com o mesmo tipo de recarga. Por exemplo, considerando cargas do tipo CUR, o processo de MC computa todas as recargas CUR dentro de um mesmo *cluster* e então cria uma população randômica trocando as cargas de mesmo tipo de lugar. Na Figura 3.7, as recargas dos usuários VE_3 e VE_5 podem ser trocadas de posição, pois as duas possuem o mesmo tipo, neste caso a recarga CUR. Este processo muda a configuração de potência em cada passo de tempo, mas mantém a mesma configuração de tipos de recarga por instante de tempo obtida pelo EPSO. A abordagem MC então fornece uma busca mais efetiva por outras opções de agendamento.

Este processo é particularmente importante quando o número de solicitações de um certo cluster é igual ao máximo número de possíveis reservas, ou seja, todas as reservas foram preenchidas. Neste caso existe um número mais limitado de soluções ao problema, e possivelmente o EPSO não consiga achar outra solução melhor que a do PLIM.

Finalmente, com a população MC gerada é possível mapeá-la pelo ponto de Pareto que melhor atenda o sistema. O ponto de Pareto procura um equilíbrio entre os múltiplos objetivos do problema. O resultado deste processo final é utilizado na etapa de despacho otimizado do SAEB, e atua como a carga esperada a ser suprida pela ERVE. Os parâmetros utilizados em cada passo desta etapa são descritos a seguir.

3.2.1 Solução Inicial com PLIM

Na etapa da PLIM, cada indivíduo deve satisfazer a restrição do máximo número de VEs conectados simultaneamente em cada passo de simulação. Por exemplo, caso o total de carregadores seja dez, então o máximo de carros sendo simultaneamente carregados é dez. O modelo de PLIM utilizado para encontrar uma possível solução válida é descrito

a seguir:

$$\text{minimize } \sum_{c=0}^7 \sum_{i=0}^N CUR_i^c + CR_i^c + CN_i^c \quad (3.1a)$$

restrito a

$$\sum_{c=0}^7 \sum_{i=0}^N (CUR_i^c + 2 \times CR_i^c + 3 \times CN_i^c \leq Cts_c), \quad (3.1b)$$

$$\sum_{i=0}^N CN_i^c = TCN_c \quad CN=0, \dots, \max \left\{ n \in \mathbb{Z} : n \leq \frac{Cts_c}{3} \right\}, \quad (3.1c)$$

$$\sum_{i=0}^N CR_i^c = TCR_c \quad CR=0, \dots, \max \left\{ n \in \mathbb{Z} : n \leq \frac{Cts_c}{2} \right\}, \quad (3.1d)$$

$$\sum_{i=0}^N CUR_i^c = TCUR_c \quad CUR = 0, \dots, Cts_c \quad (3.1e)$$

onde, na Equação (3.1a), CUR_i^c , CR_i^c and CN_i^c representam o número de modos de carregamento reservados em um carregador específico i para um dado cluster c . A Função Objetivo (FO) da Equação (3.1a) é definida para encontrar uma solução viável que satisfaça as restrições da Equação (3.1b) à Equação (3.1e). A soma de todos os tipos de carregamento em cada carregador, e para um dado cluster c , deve ser igual à TCN_c , TCR_c e $TCUR_c$, que representam, respectivamente, o total de reservas do tipo CN , CR e CUR que foram feitas em um dado cluster c .

Na Equação (3.1b) as constantes multiplicando as variáveis CUR_i^c , CR_i^c e CN_i^c referem-se ao número de passos de simulação necessários por cada modo de carregamento, considerando o passo de simulação de 30 minutos neste estudo.

Desta maneira, o problema em PLIM busca encontrar uma configuração onde os modos de carregamento sejam atribuídos a alguns carregadores sem que ocorra a violação da restrição de carros simultaneamente conectados. A variável Cts_c representa o total passos de tempo de um dado cluster c , que pode ser oito (caso o cluster tenha quatro horas) ou seis (casos ele possua três horas), conforme apresentado na Tabela 3.1 da seção 3.1.1.

A solução do problema em PLIM fornece uma matriz que correlaciona modos de carregamento com carregadores, o passo final é randomicamente atribuir a estes carregadores os VEs apropriados. A solução final é então utilizada no algoritmo EPSO como um indivíduo da população inicial. É importante notar que para cada geração esta solução pode ou não ser melhorada por outro indivíduo. Ademais, esta abordagem também evita soluções não viáveis durante a procura pela solução ótima com o método EPSO.

3.2.2 Busca com EPSO

Nesta dissertação o problema de agendamento da ERVE é abordado utilizando a técnica de deslocamento de carga e é baseada em (BERTINETI et al., 2020). Também é considerado que o dia operacional é discretizado em M passos de tempo. O número total de VEs é N e podem ser conectados à ERVE apenas uma vez durante o dia. O VE deve ser carregado durante L_i passos consecutivos de tempo desde o instante inicial de conexão $n_{1,(i)}$. Considerando o EPSO, para avaliar o desempenho de cada partícula (candidato à solução) uma função de aptidão é aplicada e definida como:

$$F_{Obj} = w \times f_1 + (1 - w) \times f_2 + Penal, \quad (3.2)$$

onde a Equação (3.2) representa a função multi-critério do agendamento dos VEs. A variável w é definida como um peso associado a f_1 e a f_2 . Já f_1 representa o custo de fornecimento de energia à carga e é definida como:

$$f_1 = \sum_{i=0}^N \sum_{m=0}^{M-1} P_i \times U_{i,m} \times C_m, \quad (3.3)$$

onde $P \in \mathbb{R}^N$: é um vetor de dimensão $1 \times N$ que representa toda a potência demandada dos VEs (em kW) e é expressa como: $P = [P_1 \dots P_N]_{1 \times N}$; $C \in \mathbb{R}^M$: é um vetor de dimensão $M \times 1$ cujos valores representam o custo da energia em cada intervalo de tempo (em R\$/kWh) e é expressa como: $C = [C_0 \dots C_{M-1}]_{M \times 1}^T$; $U \in \mathbb{R}^{N \times M}$: é a matriz binária cujas entradas são os intervalos em que cada VE permanece conectado ou não à ERVE. As entradas $U_{n,m}$ podem assumir o valor de 1 para indicar que o VE n está carregando durante o tempo m , ou o valor 0 caso o VE não esteja conectado naquele instante.

Cada VE possui suas próprias características e permanece conectado a um carregador durante uma específica e contínua sequencia de intervalos, de acordo com o tipo de tipo de carregamento escolhido. O número de intervalos em que um carregador é utilizado é representado por L_i , enquanto que $m_{1,(n)}$ representa o instante de tempo inicial de operação do mesmo, conforme descrito a seguir:

$$U = \begin{bmatrix} 0 & \dots & 1 & \dots & 1 & 0 \\ & & m=m_{1,(1)} & \times L_1-2 & m=m_{1,(1)}+L_1 & \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & 1 & \dots & 1 & 0 \\ & & m=m_{1,(N)} & \times L_N-2 & m=m_{1,(N)}+L_N & \end{bmatrix}_{N \times M} .$$

A segunda parte da Equação (3.2) é f_2 , que representa a métrica da razão de pico à média (Peak to Average - Peak to Ratio (PAPR)) do sistema. Esta métrica procura garantir melhor controle e redução de carga no lado da rede. Um valor baixo da métrica de PAPR significa que o sistema possui uma curva de carga mais plana, o que, em

contrapartida, limita os picos de demanda e possíveis compras excessivas de potência da rede. Ademais, com um pico de potência menor é possível também melhorar o controle do despacho de energia. A métrica PAPR é definida como:

$$f_2 = \frac{P_{m\acute{a}x}}{P_{m\acute{e}d}}, \quad (3.4)$$

onde $P_{m\acute{a}x}$ é o pico de potência ao longo de M passos de simulação e $P_{m\acute{e}d}$ é o valor médio da potência ao longo de todos os passos de simulação. As variáveis $P_{m\acute{a}x}$ e $P_{m\acute{e}d}$ são apresentadas, respectivamente, nas Equações (3.5) e (3.6).

$$P_{m\acute{a}x} = \max_m \sum_{i=1}^N P_i \times U_{i,m}, \quad (3.5)$$

$$P_{m\acute{e}d} = \frac{1}{M} \sum_{m=0}^{M-1} \sum_{i=1}^N P_i \times U_{i,m}. \quad (3.6)$$

Conforme apresentado na Equação (3.2), f_1 e f_2 são linearmente combinadas através de uma soma ponderada. Quando o valor de w é unitário a modelagem somente considera o valor de f_1 , que é relacionado aos custos da ERVE. Quando $w = 0$, somente f_2 é levada em consideração, fornecendo mais importância às trocas de potência com a rede. Quaisquer valores de w entre 0 e 1 irá considerar ambas funções.

Finalmente, a variável *Penal* da Equação (3.2) representa a penalização aplicada na FO sempre que o indivíduo analisado excede o número máximo de VEs sendo carregados simultaneamente, isto é, sempre que existem mais VEs do que carregadores.

O objetivo principal é encontrar a matriz binária U que minimize a função de aptidão do EPSO para um dado peso w . O problema de otimização é descrito como:

$$\underset{U}{\text{minimize}} \quad F_{obj}(U) \quad (3.7a)$$

restrito a

$$P_i > 0 \forall i \in \{0, N\}, \quad (3.7b)$$

$$C_m > 0 \forall m \in \{0, 48\}, \quad (3.7c)$$

$$U_{i,m} \in \{0, 1\}, \quad (3.7d)$$

$$0 \leq \sum_{i=0}^N P_i \times U_{i,m} \leq P_{max} \forall m, \quad (3.7e)$$

$$0 \leq m_{1,(i)}^{min} \leq m_{1,(i)} \leq m_{1,(i)}^{max} \leq M - L_i \forall i \quad (3.7f)$$

onde a FO da Equação (3.2) deve ser minimizada em (3.7a). As restrições (3.7b) e (3.7c) significam que tanto a carga a ser agendada quanto o custo da energia considerada devem ser maiores do que zero. A restrição (3.7d) apresenta os valores possíveis da matriz binária U . A restrição (3.7e) significa que o pico de potência da configuração considerada

deve estar entre zero o máximo pico possível do sistema. Finalmente, a restrição (3.7f) apresenta que o tempo de conexão de cada VE deve respeitar a janela de tempo do cluster associado.

3.2.3 Normalização da FO

Na Equação (3.2) duas funções diferentes são combinadas linearmente. No entanto, f_1 possui uma magnitude maior que a de f_2 e também possui unidade em R\$, enquanto que f_2 é uma métrica a-dimensional. Para combinar ambas as funções, neste estudo, é feita uma normalização associada aos possíveis valores máximo e mínimos que elas podem assumir. O processo EPSO também é utilizado para mapear estes limites. Ao maximizar ou minimizar o sistema com respeito à apenas uma função (f_1 ou f_2) é possível mapear o espaço de busca para encontrar os limites em cada cluster. O próximo passo é então aplicar a normalização de cada métrica com uso da Equação (3.8). (JAIN; BHANDARE, 2013; NAIDU; MOKHLIS; BAKAR, 2014).

$$X_{Norm} = \frac{X - X_{mín}}{X_{máx} - X_{mín}}, \quad (3.8)$$

onde, X_{Norm} é o valor normalizado, $X_{máx}$ é o máximo encontrado, $X_{mín}$ é o mínimo encontrado e X é o valor real da métrica considerada.

3.2.4 Matriz de deslocamento binária

Neste estudo cada partícula é representada por um vetor contendo os expoentes de deslocamento cuja função principal é modificar a configuração inicial da matriz binária U . Por exemplo, considerando a posição inicial do vetor $v = [110000]$, onde as colunas representam os passos de tempo, o valor 1 significa que existe um VE conectado naquele passo de tempo e 0 que não há nenhum VE, ao converter o código binário posicional do vetor para decimal tem-se o valor 48, com base nisto é possível aplicar a Equação (3.9) (BERTINETI, 2019; FARIAS et al., 2021).

$$E_{pos}^{novo} = E_{pos} \times 2^{-desloc}. \quad (3.9)$$

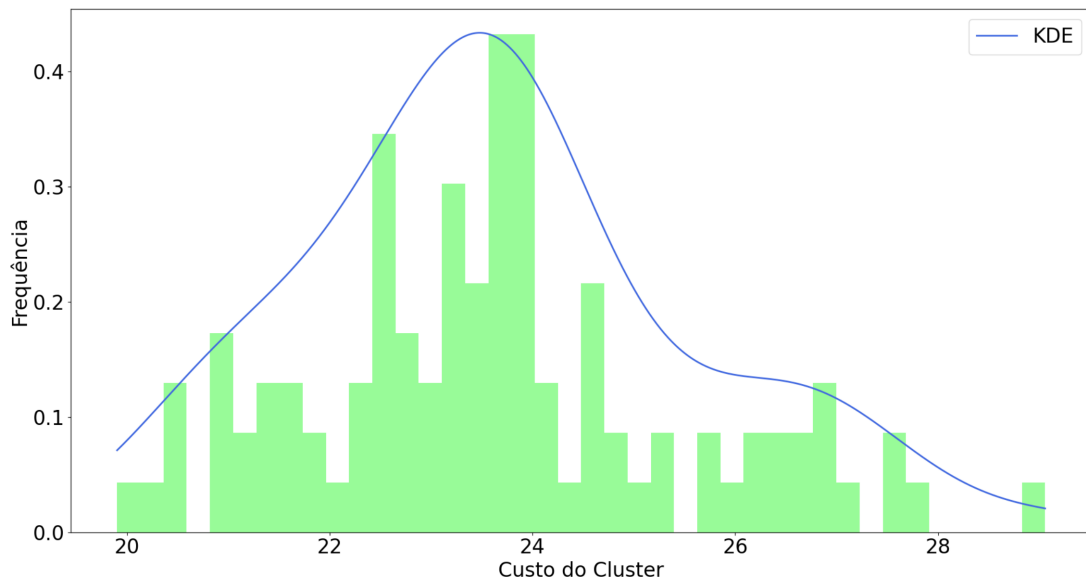
Considerando, por exemplo, um deslocamento de 1 ($desloc = 1$), o novo vetor v será $v = [011000]$, ou 24 em decimal. Esta lógica é então aplicada em cada VE da matriz U para mudar a configuração da carga.

3.2.5 Processo do MC e busca do ponto de Pareto

Com base na solução encontrada pela EPSO o sistema já possui uma boa e válida alternativa para o agendamento. No entanto, existem casos onde o processo de busca pode acabar não encontrando uma solução melhor que a fornecida pela PLIM. Estes casos acontecem quando o cluster em questão possui todas as possíveis reservas preenchidas e não existe uma boa margem de procura no espaço de busca. Neste caso pode haver poucas ou apenas uma solução que respeita a restrição de VEs carregados simultaneamente.

Para lidar com este problema o processo de MC é aplicado para criar uma população a partir da solução do EPSO trocando cargas de lugar sem modificar a configuração dos tipos de carregamento em cada cada carregador. Por exemplo, se no carregador número três, existe uma vaga de CR, e no carregador cinco existe outra vaga de CR, o processo MC troca estas cargas de posição, todavia, sem modificar a configuração de VEs em cada carregador. Para esta etapa, neste estudo, o primeiro critério de parada considerado é $\beta = 0.1$ e o segundo é o valor de 1000 iterações. À critério de exemplificação, a Figura 3.8 apresenta o histograma de uma população gerada pelo processo MC para o Cluster C3, considerando as trocas de posições e a função de custo.

Figura 3.8 – Exemplo de histograma da população de Custo do Cluster C3.



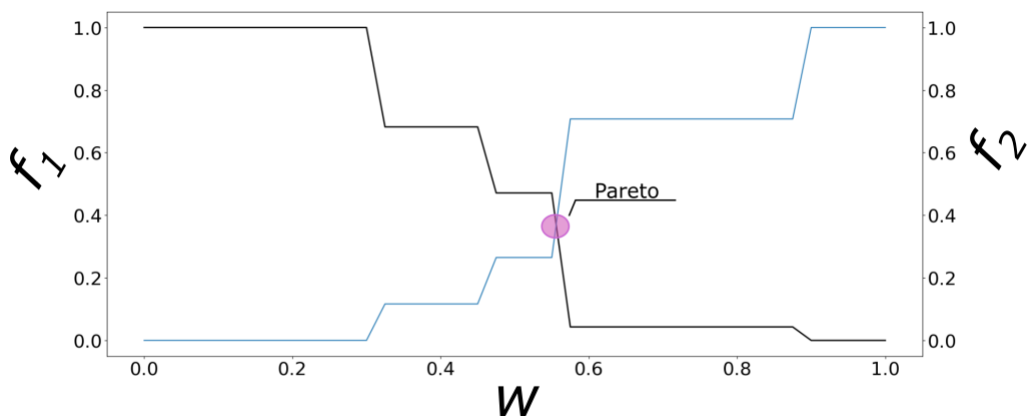
Fonte: Autor.

Na Figura 3.8, o tamanho da amostra que garante o valor de confiança com $\beta = 0.1$ foi de 100. Note que a população encontrada para a métrica de PAPR também passa pelo mesmo processo que gerou a população da métrica de custo. Deve-se salientar que o uso do MC foi necessário visto a dimensão da formulação do problema, dado que este modelo foi baseado no trabalho de (BERTINETI, 2019; FARIAS et al., 2021). Neste

caso, foi necessário fazer este tipo de ajuste para aprimorar e aproveitar a abordagem nesta metodologia proposta. Uma possível reformulação das equações poderia ajustar a solução para evitar o uso do MC. No entanto, os resultados obtidos com esta abordagem foram satisfatórios e o tempo de simulação não se viu comprometido.

Com base nas populações criadas pelo MC, é então possível mapeá-las em busca da melhor relação minimizada. A busca dentro da população também utiliza as equações de f_1 e f_2 descritas na seção 3.2.2 juntamente com o processo de normalização da FO. De modo a buscar a melhor relação entre PAPR e custo de fornecimento o passo final é então encontrar o ponto de Pareto da população através do ponto de intersecção das duas métricas. Neste estudo, analogamente à soma ponderada do processo EPSO, para o ponto de Pareto é utilizado um peso w associado à métrica f_1 e $(1 - w)$ à f_2 . A variável w é então modelada como um vetor variando de 0 à 1 com um passo de 0.05. À critério ilustrativo, a Figura 3.9 apresenta o ponto de Pareto para o cluster 5, onde o círculo verde denota o ponto escolhido do sistema.

Figura 3.9 – Exemplo do Ponto de Pareto - Cluster 5.



Fonte: Autor.

A solução final desta etapa é então utilizada como configuração de agendamento do cluster associado. Esta solução ajuda a determinar a carga esperada dos consumidores CAg a ser atendida pela ERVE no dia seguinte. Posteriormente, a carga calculada é aplicada no modelo de gerenciamento do SAEB como base para o despacho dos RDEs.

3.3 ETAPA DE OTIMIZAÇÃO DO DESPACHO DO SAEB

Nesta etapa é realizada o despacho otimizado da SAEB estacionário da ERVE, a ideia principal é utilizar o elemento armazenador para fornecer um benefício econômico à estação sem desgastar muito a vida útil da bateria, portanto, a otimização é do tipo multi-critério com foco em redução dos custos de fornecimento e minimização do desgaste

da bateria. A seguir é apresentada a função objetivo do problema de otimização do SAEB deste estudo.

$$Cost(x) = \sum_{i=0}^K (D_i - Gd_i + x_i)Tp_i, \quad (3.10)$$

onde na Equação (3.10), $Cost(x)$ representa a função objetivo associada à minimização do custo de fornecimento relacionada ao despacho dos RDEs. A variável D_i é a demanda esperada dos consumidores CAg no passo de tempo i , Gd_i é a potência disponível esperada do SSFV no passo de tempo i . Tp_i é custo da tarifa da rede no passo de tempo i . Aqui é considerado que a tarifa varia ao longo do dia e possui diferentes valores para a compra e venda de energia. Finalmente, a variável x_i representa a energia de carga/descarga do SAEB no passo de tempo i .

$$Deg(x) = \sum_{i=0}^K \left| \frac{s}{100} \right| \frac{x_i}{Bcap} Cost^B. \quad (3.11)$$

Na Equação (3.11), $Deg(x)$ representa a função objetivo associada ao desgaste total do SAEB estacionário da ERVE (ORTEGA-VAZQUEZ, 2014). Onde a variável s representa a inclinação da aproximação linear da vida útil do SAEB em função do número de ciclos de vida para o modelo de bateria em considerado. $Bcap$ é a capacidade total do SAEB e $Cost^B$ é o custo total do SAEB. A operação do elemento armazenador também é condicionada aos parâmetros descritos nas Equações (3.12) e (3.13).

$$SoC_{min} = 10\%, \quad (3.12)$$

$$SoC_{max} = 90\%. \quad (3.13)$$

A etapa de otimização do despacho também deve seguir as regras firmadas no contrato com a distribuidora, onde devem ser respeitados os limites de venda e compra de energia. Ao manter a carga da ERVE dentro de certos limites é possível aliviar a rede e evitar possíveis penalizações à estação de recarga.

O algoritmo escolhido para resolver a função objetiva foi o *Non-dominated Sorting Genetic Algorithm II (NSGA-II)* que representa uma variação do bem conhecido algoritmo genético (YUSOFF; NGADIMAN; ZAIN, 2011; LAMBORA; GUPTA; CHOPRA, 2019). No estudo foi considerado um tamanho de população de 100 indivíduos com *offspring* de 20. Os critérios de parada são por número máximo de gerações e por sequência de gerações com a mesma resposta. O *NSGA-II* foi aplicado com uso da biblioteca *Pymoo*, que é uma ferramenta de otimização desenvolvida em linguagem *Python* (Blank; Deb, 2020). Vale mencionar que esta ferramenta permite, como parâmetro de entrada, múltiplas funções. Deste modo, o processo de combinação de cada uma é realizado internamente.

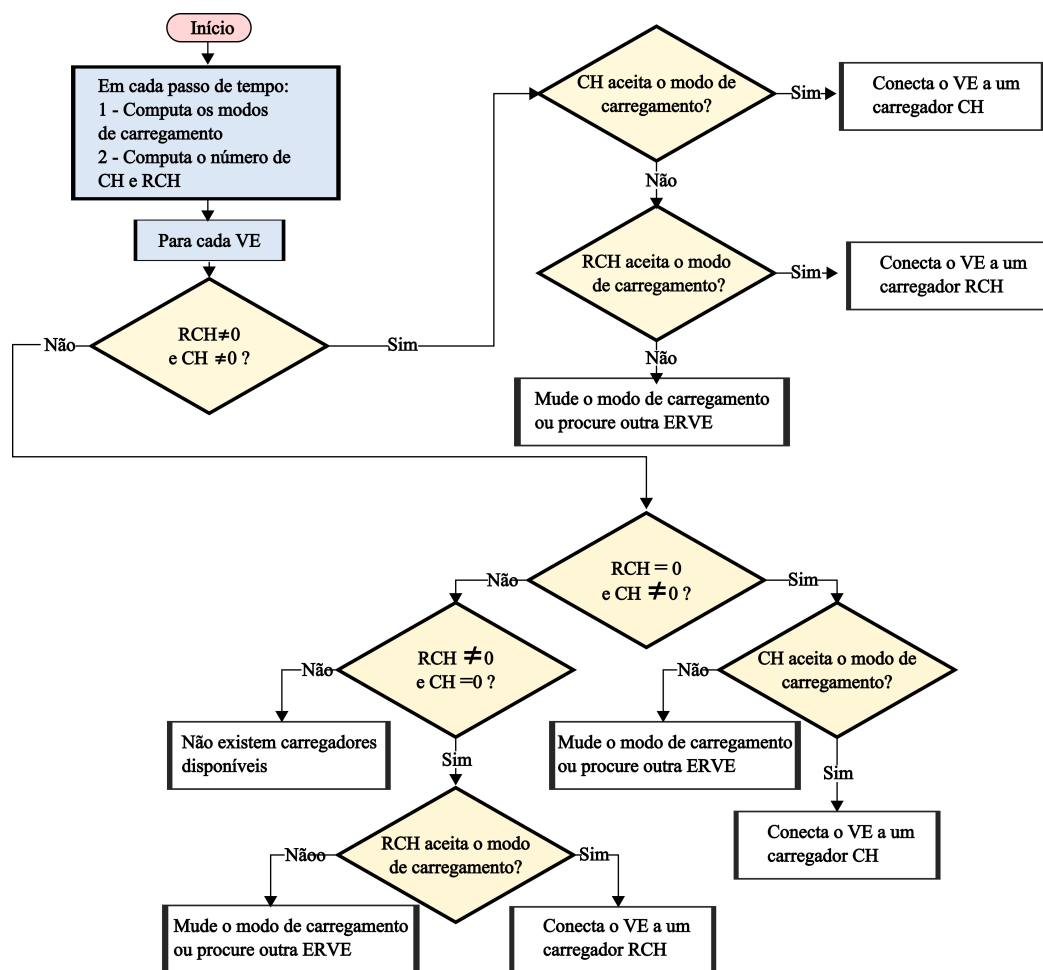
A solução do despacho do SAEB fornece um vetor com os valores de carga/descarga

que é utilizada como critério no processo de despacho em tempo real do sistema. Com base nestes valores, o algoritmo BR do despacho do SAEB registra os indicadores econômicos e técnicos do impacto do SAEB no sistema, e sem modificar a operação prevista para o elemento armazenador.

3.4 CRIAÇÃO DA POPULAÇÃO CNAG

O algoritmo utilizado na etapa de criação da população de consumidores não agendados é baseado em regras e também utiliza histogramas. Conforme mencionado anteriormente, a conexão dos VEs CNAg depende da disponibilidade dos carregadores dedicados a eles, bem como dos que não foram reservados pelos CAg. Os carregadores remanescentes são representados pelos espaços em branco na matriz calculada pela abordagem com EPSO. A Figura 3.10 apresenta o fluxograma do algoritmo que comanda a conexão CNAg à ERVE.

Figura 3.10 – Fluxograma da conexão CNAg à ERVE.



Na Figura 3.10, RCH representa os carregadores dedicados aos consumidores CNAg e CH os dedicados aos CAg. Existem quatro tipos de cenários que podem ocorrer:

1. **Existem carregadores RCH e CH disponíveis:** Neste caso, o VE CNAg é preferencialmente conectado a um carregador CH que está livre. Esta abordagem maximiza o uso dos carregadores CH e aumenta a disponibilidade dos carregadores RCH para outros possíveis consumidores CNAg. Caso o VE CNAg não consiga ser conectado, então o VE é conectado a um carregador RCH se possível;
2. **Só tem carregadores CH disponíveis:** Neste caso a única opção é conectar o VE CNAg a um carregador CH caso possível;
3. **Só carregadores RCH:** Neste caso o VE CNAg é conectado a um carregador RCH caso possível;
4. **Não existem carregadores disponíveis:** Neste caso o VE não é conectado à ERVE e deve procurar outra estação de recarga ou tentar em outra hora.

Vale mencionar que a população CNAg por ter característica randômica possui um número total de indivíduos menor que a população CAg. Esta abordagem é adotada de modo que a carga CNAg não acabe inviabilizando o despacho otimizado dos RDEs.

3.5 ETAPA DO BALANÇO ENERGÉTICO

3.5.1 Estratégia Baseada em Regras (BR) para o Balanço Energético

O Algoritmo 2 apresenta a operação simplificada da etapa do fluxo de carga BR. Em cada passo de tempo, o sistema verifica se existe carga VE a ser atendida, e sempre que possível usa a geração solar fotovoltaica para atendê-la caso a mesma esteja disponível.

Quando a geração FV está em excesso, esta parcela é enviada para o SAEB, caso ele esteja carregando. Quando o SAEB está cheio, ou em processo de descarga, o excesso do SSFV atende a carga própria da ERVE e/ou é vendido para rede. Toda a operação do fluxo de carga tem por objetivo priorizar o despacho econômico dos ativos, de modo a melhor servir a carga e fornecer reduções de custos à ERVE.

3.5.2 Módulo do SAEB - Baseado em Regras

Neste estudo tanto o elemento armazenador é modelado seguindo regras de carga/descarga na linguagem *Python*. Esta etapa auxilia o sistema a despachar o SAEB em tempo real

Algoritmo 2: Despacho baseado em regras

Entrada: Passos de tempo (NTS), Carga VE (VE), SSFV (GD), Tarifa (Tar), ERVE carga própria ($ERVE_{cp}$), SAEB despacho ($SAEB$), Balanço com a rede ($REDE_t$)

Saída: Dados de operação com o balanço energético do despacho

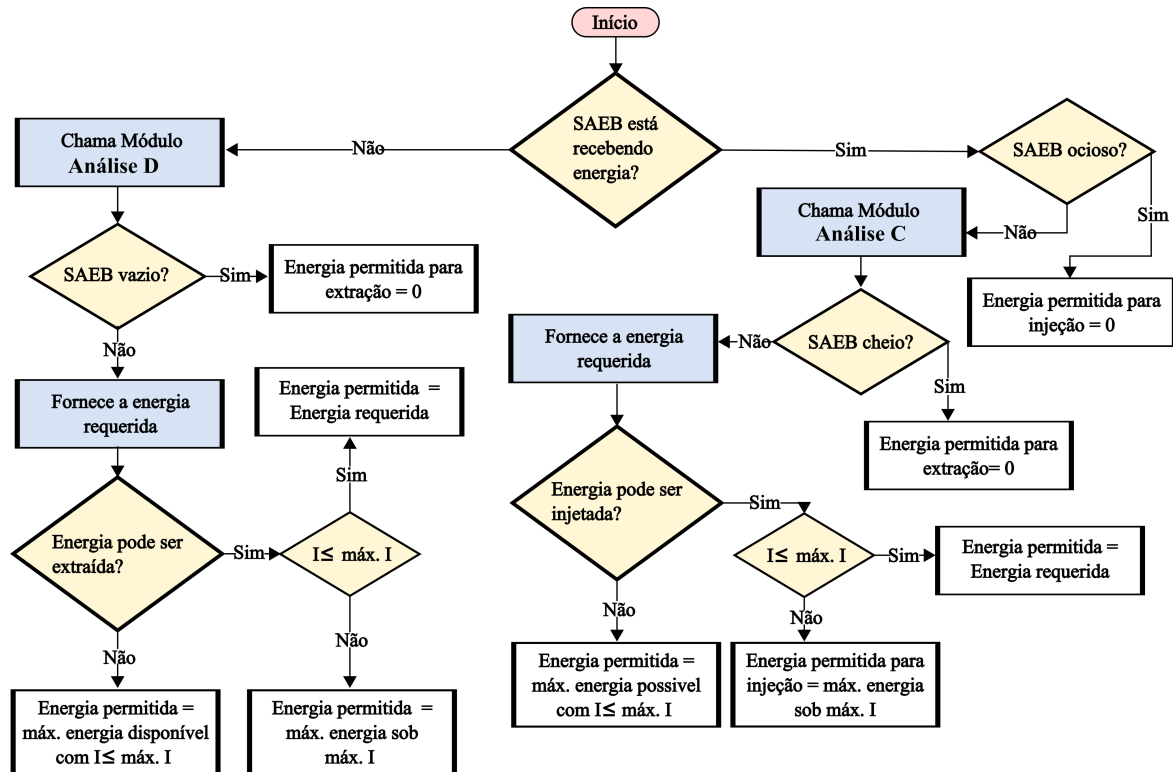
```

1 para  $i \leftarrow 0$  até  $NTS$  faça
2   | Atualização das variáveis deste TS;
3   | se  $SAEB \geq 0$  então
4     | se  $SAEB = 0$  então
5       |    $SAEB$  em modo ocioso, são calculadas as trocas com a rede para
6         |   atender a  $VE$ .  $REDE_t = VE - GD + ERVE_{cp}$ ;
7     | senão
8       | se  $GD \geq (VE + SAEB)$  então
9         |    $GD$  atenda a  $VE$  e supre toda a energia requerida pelo  $SAEB$ .
10        |   O excesso de energia atenda a  $ERVE_{cp}$  e caso ainda haja
11          |   excesso vai para rede;
12        | senão
13          | se  $GD > VE$  então
14            |    $GD$  atenda toda a  $VE$  e o excesso atende parte da energia
15              |   requerida pelo  $SAEB$  em conjunto com a energia da rede.
16            | senão
17              |    $GD$  atende o que conseguir do  $VE$  e a rede atenda toda a
18                |   energia do  $SAEB$ 
19            | fim
20          | fim
21        | fim
22      | fim
23    | fim
24  | fim
25  | fim
26  | fim
27  | fim
28  | fim
29  | fim
30  | fim
31  | fim
32  | fim
33  | fim
34  | fim
35  | fim
36  | fim
37  | fim
38  | fim
39  | fim
40  | fim
41  | fim
42  | fim
43  | fim
44  | fim
45  | fim
46  | fim
47  | fim
48  | fim
49  | fim
50  | fim
51  | fim
52  | fim
53  | fim
54  | fim
55  | fim
56  | fim
57  | fim
58  | fim
59  | fim
60  | fim
61  | fim
62  | fim
63  | fim
64  | fim
65  | fim
66  | fim
67  | fim
68  | fim
69  | fim
70  | fim
71  | fim
72  | fim
73  | fim
74  | fim
75  | fim
76  | fim
77  | fim
78  | fim
79  | fim
80  | fim
81  | fim
82  | fim
83  | fim
84  | fim
85  | fim
86  | fim
87  | fim
88  | fim
89  | fim
90  | fim
91  | fim
92  | fim
93  | fim
94  | fim
95  | fim
96  | fim
97  | fim
98  | fim
99  | fim
100 | fim

```


e com base nos valores de despacho definidos na etapa de otimização. O fluxograma da operação do elemento armazenador é apresentada na Figura 3.11.

Figura 3.11 – Fluxograma da operação do SAEB.

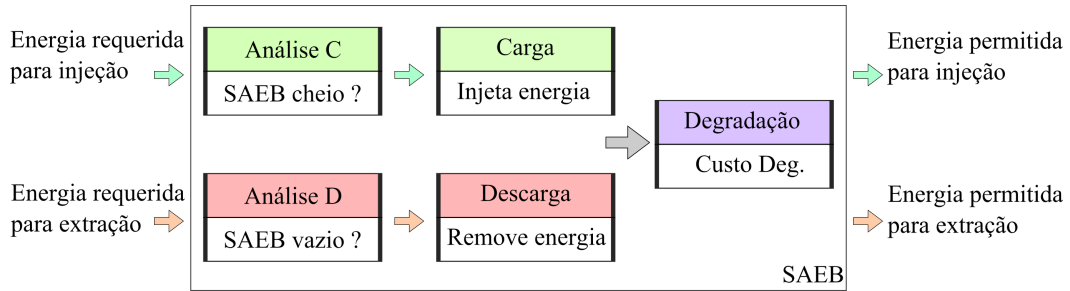


Fonte: Autor.

O fluxograma da Figura 3.11 representa a lógica por trás da operação do SAEB. O armazenador pode operar em três modos diferentes: Carregamento, descarga e ocioso. No modo de carregamento o SAEB recebe energia do sistema. Sob esta condição, o módulo *Análise C* é ativado e verifica se é possível absorver uma certa quantidade de energia ou não.

Quando o SAEB está sob modo de descarga, o módulo *Análise D* é ativado e verifica se é possível remover uma certa quantidade de energia do banco de baterias. Finalmente, em modo ocioso o SAEB permanece inativo e nenhuma operação de carga ou descarga é realizada. Note que em todos os modos, o despacho do SAEB leva em conta a máxima corrente de carga/descarga e o estado de carga do elemento armazenador. A Figura 3.12 apresenta a operação interna do SAEB.

Figura 3.12 – Módulo SAEB.



Fonte: Autor.

Na Figura 3.12 sempre que o sistema envia energia a ser absorvida pelo SAEB e o módulo *Análise C* assim o permite, o módulo *Carga* é ativado e realiza a operação de injeção enquanto atualiza as métricas do SAEB. Estas métricas são definidas como o estado de carga, preço médio e custos de degradação da operação. A métrica do preço médio reflete o preço das operações de injeção ou retirada de energia do SAEB e é definida como:

$$SAEB_{médpr} = \frac{C_{pr} + Bat_{deg}}{C_e} \quad (3.14)$$

onde, na Equação (3.14) a variável C_{pr} é a métrica que mensura o balanço de custos associados às variações de energia no SAEB. Estas variações são causadas pelas operações de carga e descarga, e é atualizada sempre que uma operação é realizada. Esta variável também leva em conta o custo de degradação Bat_{deg} associado à operação realizada, e é calculado de acordo com a Equação (3.11). A variável C_e é a métrica associada ao balanço de energia interna no SAEB computada em cada operação.

A métrica $SAEB_{médpr}$ é uma combinação de $(C_{pr} + Bat_{deg})$ e C_e . Por exemplo, caso o SAEB receba 1 kWh de energia, e o preço base desta energia é 1 R\$/kWh, então o custo da operação é de 1R\$ mais o custo de degradação do SAEB associado à operação realizada. Este valor é então adicionado ao preço cumulativo do SAEB e a energia cumulativa é atualizada pela energia que está sendo absorvida.

Em outras palavras, se a energia absorvida pelo SAEB é barata, então o $SAEB_{médpr}$ irá decrescer, e caso esta energia seja cara, ele irá aumentar. Esta operação também é computada durante os processos de descarga, onde $SAEB_{médpr}$ também varia de acordo com o montante de energia descarregada e com o preço da operação. Sob esta condição, o módulo *Descarga* é utilizado. Finalmente, por critérios de simplificação, apenas a degradação do SAEB da ERVE é considerado neste estudo.

3.6 ETAPA DO FLUXO DE CAIXA

O modelo econômico do fluxo de caixa representa um conjunto de regras e métricas utilizadas para avaliar as receitas e despesas da ERVE. O fluxo de caixa é definido como:

$$FC = \sum_{i=0}^{TS} ((VE_{Fat} - ERVE_v + Custo_{Disp}) - (SAEB_{Deg} + ERVE_c)) \quad (3.15)$$

onde, na Equação (3.15), VE_{Fat} é o valor total de todas as faturas dos VEs no passo de tempo i , esta variável leva em conta as receitas obtidas ao entregar energia aos consumidores. $ERVE_v$ é a remuneração obtida ao vender energia para a rede ao exportar o excesso do SSFV ou a energia do SAEB. $Custo_{Disp}$ representa o custo de disponibilidade dos carregadores e é cobrada de acordo com o tempo de utilização. Os preços utilizados diferem para cada tipo de consumidor e para cada tipo de carregamento, conforme apresentado na Tabela 3.3.

Tabela 3.3 – Custo de disponibilidade e Multiplicadores de Tarifa

	CR		CN		CUR	
	CD	Mult	CD	Mult	CD	Mult
CAg	R\$ 2,00	1,4	R\$ 4,00	1,25	R\$ 7,00	1,15
CNAg	R\$ 3,00	1,7	R\$ 5,00	1,45	R\$ 9,00	1,35

Fonte: Autor.

Na Tabela 3.3, note que, por exemplo, o $Custo_{Disp}$ sob CUR é mais barato que em relação ao sob CN. Isto acontece porque o VE permanece menos tempo conectado. Em contrapartida, o preço utilizado da tarifa pela ERVE é maior sob CUR em comparação ao CR.

O $SAEB_{deg}$ é o custo da energia despachada pelo SAEB já considerando o desgaste associado. O $ERVE_c$ representa o valor total pago à rede sempre que um montante de energia é comprada da mesma.

Um valor positivo para FC significa mais lucro para a ERVE, enquanto que um valor negativo representa déficit. É importante mencionar que esta etapa de fluxo de carga é apenas utilizada para fins de operação diária. Isto significa que o sistema apenas leva em conta as despesas e receitas geradas ao longo de um dia operacional, - Investimentos iniciais e custos de valor presente líquido para horizontes de tempos maiores não são levados em consideração. Finalmente, os custos relacionados ao desgaste do SAEB da ERVE são diluídos na conta dos consumidores e no fluxo de caixa da ERVE.

3.7 DISCUSSÃO DO CAPÍTULO

Este capítulo apresentou as principais técnicas e métodos utilizados nesta dissertação. Inicialmente foi apresentado o fluxograma do trabalho, onde destacam-se os processos de otimização da carga agendada com uso do algoritmo EPSO-MC com população inicial fornecida pela abordagem PLIM.

Vale mencionar que a adição do processo MC na busca de soluções proposta pelo método EPSO representa um aprimoramento em relação ao trabalho inicial desenvolvido em (FARIAS et al., 2021). Com a adição do processo MC a metodologia garante uma etapa a mais de refinamento da solução final. O despacho do SAEB se baseou num modelo de otimização multi-critério aplicando o método *NSGA-II*.

A carga foi então dividida em uma parcela composta por clientes agendados e outra por não agendados. Aos clientes CNAg foram definidas algumas restrições de conexão, regidas pelo algoritmo baseado em regras. Finalmente, as etapas do balanço energético, bem como o de fluxo de caixa, também foram modeladas com algoritmos BR.

4 ESTUDO DE CASO

Este estudo considera uma ERVE composta de:

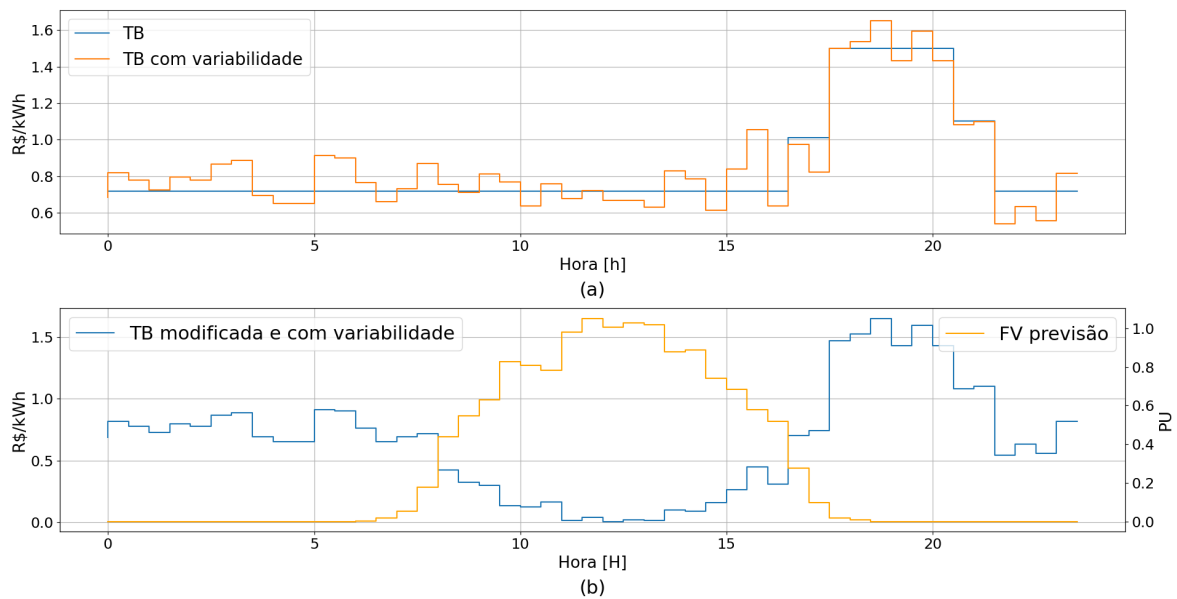
- 10 carregadores dedicados aos consumidores agendados;
- 5 carregadores dedicados aos consumidores não agendados;
- Um SSFV de 300 kWp e um SAEB de 300 kWh/90 kW;
- Tarifa variável baseada na tarifa branca (TB) (ANEEL, 2021);
- Contrato bilateral entre ERVE e concessionária com limites de compra/venda de energia e diferentes preços.

As simulações foram desenvolvidas em um computador de mesa com sistema operacional Windows, arquitetura 64-bits, processador Intel i5 de 2.90 GHz e com 16 GB de memória RAM. O *framework* foi desenvolvido em linguagem *Python*.

Este estudo de caso considera uma tarifa de característica variável, tendo como base a tarifa branca. O uso desta tarifa variável também é modificada nos processos de otimização para refletir a disponibilidade do recurso solar. A Figura 4.1 apresenta:

- A tarifa branca utilizada como referência;
- A tarifa branca com adição de variabilidade;
- A tarifa branca com variabilidade e modificada para refletir a disponibilidade do recurso fotovoltaico.

Figura 4.1 – Tarifa: (a) Tarifa Branca (TB) e TB com variabilidade. (b) TB modificada e com variabilidade, e previsão FV.



Fonte: Autor.


Na Figura 4.1, a partir dos valores base da tarifa branca, um ruído Gaussiano é aplicado à tarifa branca, de modo a produzir uma certa variabilidade nos preços. Esta operação é realizada com intuito de gerar um tarifa com características de precificação em tempo real (IRENA, 2019a). Note também que, na Figura 4.1b a tarifa com adição de variabilidade também é modificada para refletir a disponibilidade do recurso solar, sendo mais barata nos momentos em que existe geração fotovoltaica. No entanto, esta última modificação só é utilizada nos processos de otimização de modo a incentivar o sistema a suprir a carga com uso da fonte renovável.

Referente aos parâmetros EPSO, em todos os casos são consideradas 1000 gerações como critério de parada e 50 partículas por população. Quanto ao processo MC, o tamanho da população de estudo possui 1000 amostras, e $\beta = 0.1$.

Quanto ao processo de otimização do despacho do SAEB, a ferramenta de otimização multi-critério utilizada foi o método *NSGA-II*, disponível na biblioteca *Pymoo* da linguagem *Python* (Blank; Deb, 2020). Esta biblioteca pode ser usada para resolução de diferentes problemas de otimização sejam elas com uma única função objetiva ou várias. Um ponto interessante desta ferramenta, é que a mesma funciona de maneira *plug-and-play*, isto é, o usuário possui liberdade para escolher os componentes que farão parte do processo de otimização, como por exemplo, a técnica que resolverá o problema, podendo esta ser da família de algoritmos evolutivos ou não. Por fim, esta ferramenta também realiza a busca de Pareto para encontrar a melhor solução que satisfaça o problema multi-critério. No entanto, por ser uma característica interna e operativa da biblioteca, neste estudo estes pontos não foram mensurados.

Quanto ao recurso solar, a Figura 4.2 apresenta a curva FV real e a prevista utilizadas neste estudo em valores por unidade (PU). A curva PU da geração FV é baseada no SSFV instalado na Universidade Federal de Santa Maria (UFSM, 2021).

Figura 4.2 – FV real e prevista.



Fonte: Autor.

A previsão da geração FV é utilizada tanto na etapa de agendamento de carga quanto na de otimização do despacho multi-critério do SAEB, já os valores reais da geração solar são utilizados na etapa do fluxo de potência regido pelo algoritmo BR.

Finalmente, são definidas as regras do contrato entre a ERVE e a distribuidora. Aqui definem-se os montantes de troca de potência. Neste estudo foi considerado um limite de compra de 300 kW e um de venda (exporte) de 200 kW, quaisquer valores fora destes limites configura quebra de restrição e representa um custo a ser pago pela ERVE à distribuidora. Todas as simulações consideram um passo de tempo de 30 minutos. O modelo também pode ser adaptado para considerar menores tempos, o que torna esta abordagem válida em aplicações práticas.

4.1 VALIDAÇÃO DO EPSO

O método EPSO utilizado nesta dissertação, e desenvolvido em Python, apresenta o mesmo código que o utilizado no trabalho anterior, em (FARIAS et al., 2021). Dado que este último estudo é um resultado da pesquisa inicial desta dissertação, o autor apresenta aqui os resultados comparativos do EPSO com outros métodos heurísticos bastante conhecidos, como o AG e o PSO. Os parâmetros de simulação para o método AG são descritos a seguir:

- Técnica *Roulette Wheel* utilizada para seleção de indivíduos, com $\beta = 1.0$;
- Taxa de *Crossover* com $\epsilon = 0.5$;

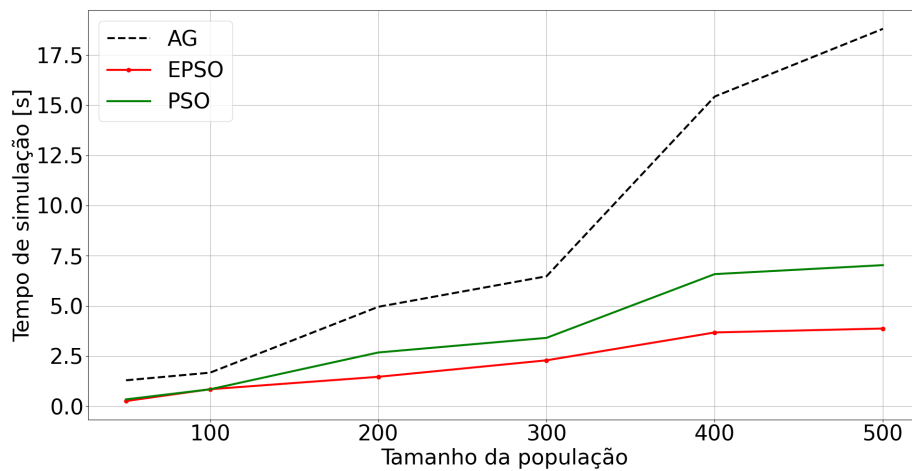
- Taxa de mutação com $\mu = 0.05$ e $\delta = 0.5$.

Já os parâmetros do método PSO utilizados foram:

- Constantes de aceleração $c1=1,5$ e $c2=2,0$;
- Inércia = $0,7$;
- Fator de decréscimo = $0,995$.

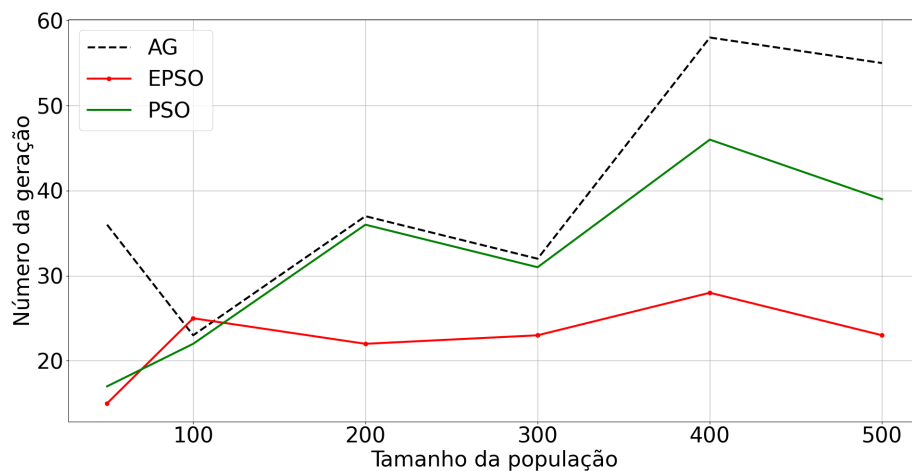
Por fim, os resultados de validação são apresentados nas Figuras 4.3, 4.4, e 4.5 para a população do Cluster 5.

Figura 4.3 – Tempo vs população.




Fonte: Autor - Exemplo de validação adaptado de (FARIAS et al., 2021).

Figura 4.4 – Geração vs população.



Fonte: Autor - Exemplo de validação adaptado de (FARIAS et al., 2021).

Figura 4.5 – FO vs população.



Fonte: Autor - Exemplo de validação adaptado de (FARIAS et al., 2021).

Conforme apresentado, o método EPSO apresenta, na maior parte dos casos, soluções com um menor tempo de simulação que os métodos AG e PSO. Na Figura 4.3 o EPSO requer apenas 3.87 segundos para obter uma solução final com 500 gerações, sendo cerca de 80% mais rápido que o método AG, e 45% mais que o PSO.

O EPSO também foi capaz de apresentar uma solução final com o menor número de gerações, requerendo de 15-28. Por fim, quanto ao número de indivíduos, o EPSO apresentou uma convergência melhor na maioria dos casos. Quanto ao valor da FO, o menor valor obtido foi com uso do método EPSO para todos os cenários de número de indivíduos analisados. Os resultados anteriores validam a abordagem utilizada para aplicar a metodologia desta dissertação.

4.2 CARGAS AGENDADAS

A Tabela 4.1 apresenta o número de solicitações de recarga de cada cluster. O número total de VEs agendados a serem atendidos no dia seguinte é 152. Na linha do EstLoadRow da tabela, é apresentado o total de energia em cada cluster que deve ser suprida. Em TotalCmods é apresentado o número de modos de carregamento de cada cluster.

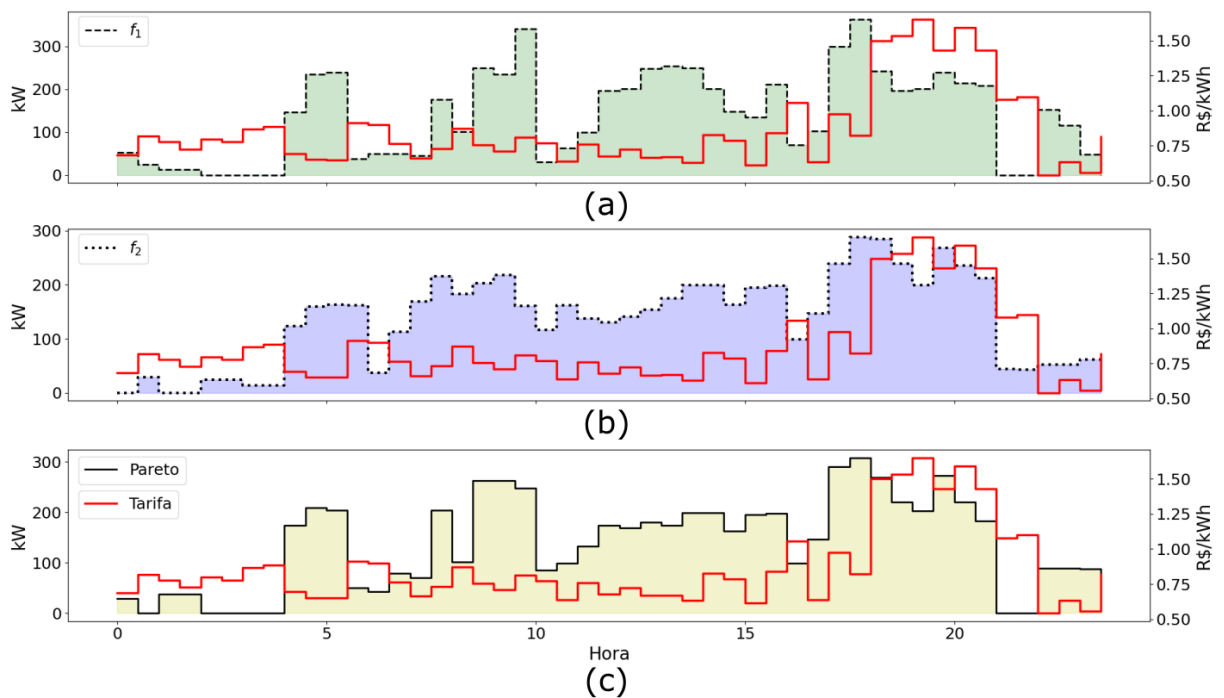
Tabela 4.1 – Solicitações de recarga

Ch/Clusters	C0	C1	C2	C3	C4	C5	C6
CUR	1	6	9	4	12	16	4
CR	2	10	9	10	13	26	5
CN	0	1	5	6	9	4	0
C_{tipos}	3	17	23	20	34	46	9
C_{est} (kWh)	52	379	574	420	687	983	157

Fonte: Autor.

De modo a visualizar o impacto do agendamento otimizado, a Figura 4.6 apresenta o comparativo da carga da ERVE sob três diferentes cenários. O primeiro é o agendamento baseado somente no PAPR, que representa a métrica associada à disposição da carga ao longo do tempo. O segundo cenário leva em conta apenas a métrica da redução do custo, ou seja, sem considerar o PAPR e por fim tem-se o agendamento com as duas métricas combinadas, onde busca-se o ponto de Pareto do sistema.

Figura 4.6 – Demanda VE: (a) Só com f_1 . (b) Só com f_2 . (c) Pareto.



Fonte: Autor.

Na Figura 4.6a, considerando somente f_1 , a carga tende a ser concentrada nos períodos mais baratos da tarifa. Este comportamento ocorre devido à FO do processo de otimização apenas considerar a função de custo f_1 , que por sua vez busca minimizar o

custo de fornecimento de energia à carga. No segundo caso, considerando somente f_2 , a carga possui uma característica mais distribuída, preenchendo os vales do caso anterior e reduzindo os picos de potência durante os períodos mais baratos da tarifa. Este caso considera apenas f_2 que é associada à métrica PAPR.

O último caso busca um consenso entre as duas funções, com w variando de 0 a 1. Neste caso, nota-se que, a distribuição da carga agendada apresenta alguns pontos de concentração, mas também distribui mais a carga em outros pontos. Os pontos de Pareto encontrados para cada cluster são apresentados na Tabela 4.2.

Tabela 4.2 – Pontos de Pareto para cada Cluster.

Cluster	0	1	2	3	4	5	6
w	0,7	0,5	0,15	0,35	0,25	0,9	0,15

Fonte: Autor.

Os pontos da Tabela 4.2 garantem o agendamento otimizado da carga levando em conta ambas as métricas da FO. De modo a quantificar os impactos esperados, a Tabela 4.3 apresenta os valores finais esperados de f_1 e f_2 para os três casos.


Tabela 4.3 – Métricas de cada caso

Caso	Custo (R\$)	PAPR
w=1	2920,24	2,67
w=0	3013,87	2,12
Pareto	2952,34	2,27

Fonte: Autor.

Na Tabela 4.3 os pontos extremos das funções são obtidos ao considerar os valores de 0 e 1 para o peso w . Vale notar que ao considerar ambas as funções, o sistema busca, além de prover energia aos consumidores de maneira econômica, também aliviar os possíveis picos de carga vistos pela rede elétrica. Finalmente, a Figura 4.7 apresenta o comparativos das métricas encontradas em cada cluster.

Figura 4.7 – Demanda VE: (a) Métrica de custos para os três casos. (b) Métrica PAPR para os três casos.



Fonte: Autor.

Na Figura 4.7a o cluster com os maiores custos associados é o C5, que também é o cluster com maior carga a ser atendida. No entanto, na Figura 4.7b, o cluster com maior variação na configuração de carga foi o C1. Nota-se que em todos os casos o ponto escolhido pelo sistema está entre os casos extremos que consideram apenas uma única métrica. Assim, o ponto de Pareto determinado mostrou um bom desempenho em cada cluster, com custos baixos e menor impacto na rede.

4.3 IMPACTO DA OTIMIZAÇÃO DO SAEB

De modo a avaliar o impacto da otimização do SAEB estacionário da ERVE, este estudo analisa os impactos técnicos e econômicos do modelo de gerenciamento na ERVE e no despacho da rede.

Inicialmente o SAEB é otimizado com base na carga agendada CAg considerando as duas métricas (custo e PAPR). Além disto é considerada a previsão de despacho solar e dos preços da energia. O despacho do SAEB é baseado na metodologia apresentada na Seção 3.3. A otimização também é sujeita as regras do contrato bilateral entre a ERVE a rede, o conjunto de regras é definido como:

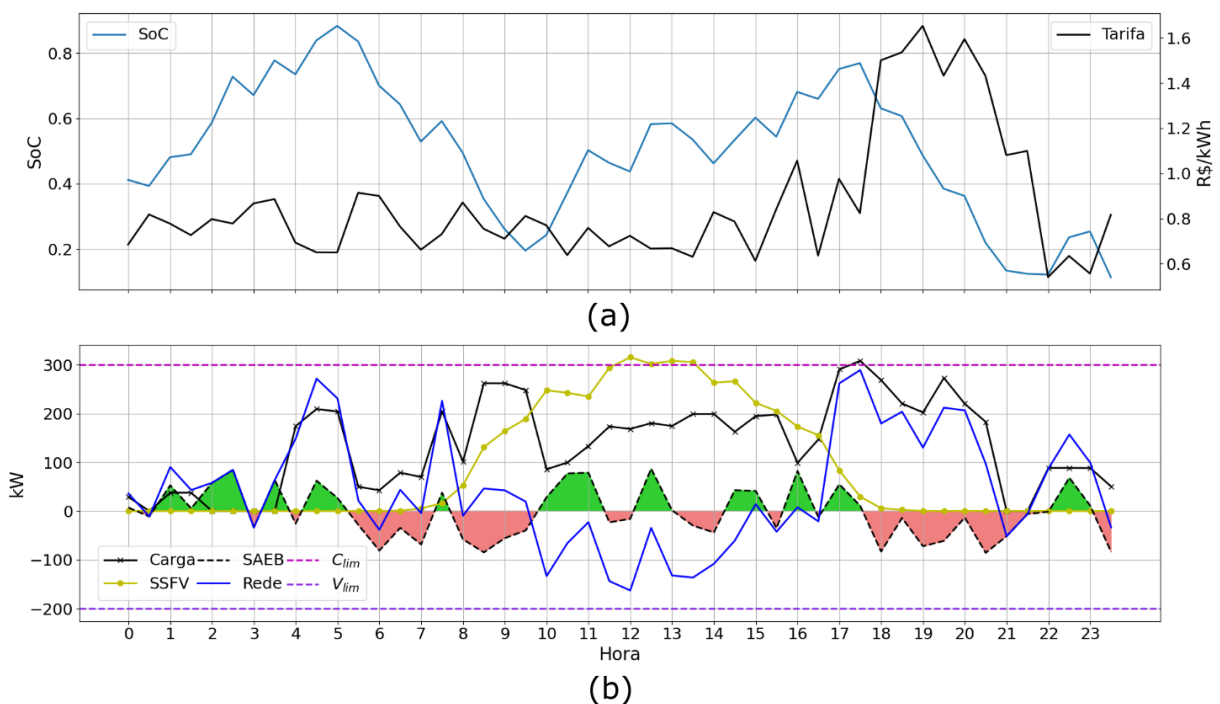
- Limite de potência requerida pela ERVE de 300 kW, sujeita à penalizações em caso

de ultrapassagem;

- Limite de potência exportada pela ERVE de 200 kW, sujeita à penalizações em caso de ultrapassagem;
- Multiplicador de ultrapassagem de valor igual a 2, aplicado no preço vigente da tarifa para a violação do limite superior e 0.5 para o limite inferior. A ERVE paga mais caro quando comprando acima do limite e recebe menos quando vendendo acima do limite inferior;
- Preço de compra de energia igual ao preço da tarifa praticada pela concessionária;
- Preço de venda de energia igual a 85% do preço da tarifa praticada pela concessionária.

Com base nas condições apresentadas, a Figura 4.8 apresenta o despacho otimizado do SAEB.

Figura 4.8 – Despacho otimizado do SAEB da ERVE.



Fonte: Autor.

A Figura 4.8a apresenta a relação do SoC do SAEB com a variação dos preços da tarifa utilizada. Neste estudo de caso também foi considerado que o SoC inicial, de maneira arbitrária, foi igual a 40%. Note que o período mais cara da tarifa também coincide com um longo processo de descarga do SAEB, com o elemento armazenador chegando próximo do seu limite inferior para o estado de carga.

Já a Figura 4.8b apresenta o balanço energético esperado dos DERS com a carga esperada e a rede. A solução do despacho do SAEB apresentou um valor de R\$ 1.256,34 associados à métrica de custo de fornecimento e R\$ 89,13 referentes à métrica de desgaste cumulativo do elemento armazenador. Note-se que as linhas magenta (C_{lim}) e lilás (V_{lim}) do gráfico inferior denotam, respectivamente, os limites de compra e exporte de energia definidos no contrato com a concessionária. Estas linhas também representam as restrições do problema de otimização, estes valores são definidos no contrato bilateral com a distribuidora e, portanto, devem ser respeitados pela ERVE. É possível notar que para evitar a violação destes limites o SAEB é despachado de modo que a carga vista pela concessionária esteja sempre dentro dos limites estipulados. Os valores negativos equivalem às descargas do SAEB, bem como às vendas de energia por parte da ERVE para a rede.

Conforme apresentado na Figura 4.8, a etapa de despacho sugere uma operação satisfatória sem que haja a violação das regras definidas no contrato. Deste modo, por exemplo, entre 10h e 15h - embora a geração fotovoltaica esteja acima do limite superior - o valor visto pela rede (*Rede*) é menor, pois parte desta energia é destinada ao atendimento da ERVE e do SAEB. Neste período, o exporte de energia para à rede fica abaixo do limite inferior (V_{lim}). Já no período das 15h às 20h, a carga total da ERVE ultrapassa o limite superior (C_{lim}), no entanto, o montante visto pela rede é menor, pois neste período o SAEB está sendo descarregado para respeitar o limite. A seguir são apresentados os impactos da otimização do SAEB levando em conta as métricas de desgaste e custo de despacho de energia.

4.3.1 Análise Técnica

Nesta etapa um algoritmo BR rege as condições de troca de potência entre os ativos da ERVE e a carga a ser atendida. Baseado no despacho otimizado do SAEB, na geração real do SSFV e na carga real CAg e CNAg o algoritmo da Seção 3.5 é utilizado para realizar a fluxo de potência simplificado do sistema.

É válido mencionar que nesta etapa são utilizados os valores reais de geração/carga. Embora o sistema seja otimizado com base nos valores esperados, o despacho baseado em regras é encarregado de atender toda a carga sem que haja interrupção no fornecimento. As informações sumarizadas da população CAg e CNAg para o dia operativo são apresentadas na Tabela 4.4.


Tabela 4.4 – Informações dos consumidores

	Pop_n	CUR	CR	CN	$Carga_{total}(kWh)$
CAG	152	52	75	25	3252
CNAG	43	21	16	6	428

Fonte: Autor.

Na Tabela 4.4 nota-se que, embora a carga da população (Pop_n) CNAG seja significativa, ela é bem menor que a carga da população CAG. Com base na carga total de ambas as populações, a Figura 4.9 apresenta a distribuição das recargas em cada carregador ao longo do dia operacional da ERVE.

Figura 4.9 – Matriz de utilização dos carregadores dedicados.



Fonte: Autor.

Na Figura 4.9 cada retângulo representa um tipo de recarga de um tipo específico de consumidor, note-se que a altura do retângulo também expressa o tipo de carregamento escolhido. O eixo vertical indica a área de cada cluster, enquanto que o eixo horizontal indica o tipo de carregador dedicado aos consumidores CNAG (Rch) e CAG (Ch), a legenda é descrita a seguir.

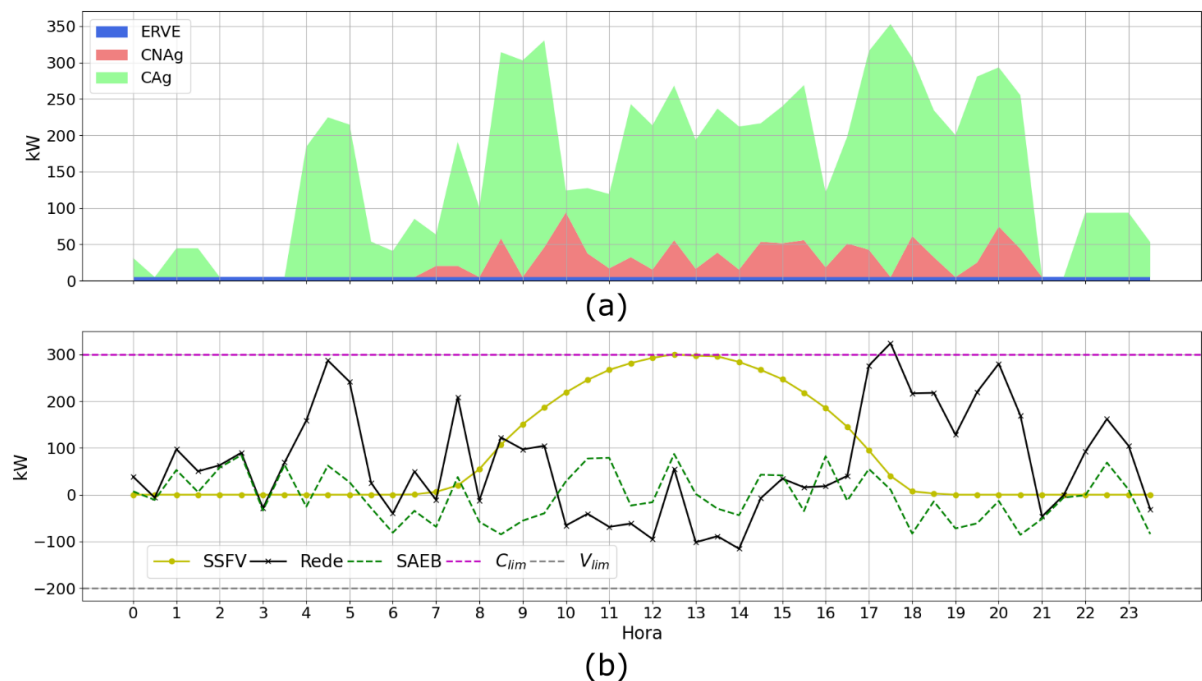
- **Disp** Espaço vago para conexão;
- **CAG-CUR** Espaço com recarga do tipo CUR para o consumidor CAG;

- **CAG-CR** Espaço com recarga do tipo CR para o consumidor CAg;
- **CAG-CN** Espaço com recarga do tipo CN para o consumidor CAg;
- **CNAg-CUR** Espaço com recarga do tipo CUR para o consumidor CNAg;
- **CNAg-CR** Espaço com recarga do tipo CR para o consumidor CNAg;
- **CNAg-CN** Espaço com recarga do tipo CN para o consumidor CNAg.

Um ponto interessante desta matriz é que as recargas do cliente CNAg realizam um movimento da esquerda para a direita durante o período comercial. Basicamente o CNAg utiliza um carregador do tipo Ch ao invés do Rch, ou seja, são utilizados primeiro os carregadores Ch que não foram agendados, maximizando assim o uso dos carregadores Ch e aumentando a disponibilidade dos carregadores RCh para outros usuários não agendados.

O movimento da direita para esquerda, por parte dos consumidores CAg, é possível também, mas o mesmo não acontece devido as recargas do tipo CAg serem poucas durante o período fora do horário comercial. Finalmente, a Figura 4.10 apresenta o despacho real do sistema.

Figura 4.10 – Despacho real do sistema.



Fonte: Autor.

A Figura 4.10a apresenta a carga total dos consumidores, bem como a carga própria da ERVE. Neste estudo, por critérios simplificativos, a carga de serviços da ERVE foi

considera como sendo 5 kW constante durante o dia operacional. A Figura 4.10b apresenta o despacho dos RDEs (SSFV e SAEB), bem como a carga total vista pela concessionária (rede). Note-se que o sistema opera durante a maior parte do tempo dentro dos limites definidos no contrato, entre o limite de compra (C_{lim}) e de venda (V_{lim}). No entanto, existe uma ultrapassagem do limite superior ao final do horário comercial. Esta pequena ultrapassagem se deve, majoritariamente, à carga dos usuários CNAg. Estes clientes, embora possam causar distúrbios na otimização do SAEB, são interessantes para a ERVE, dado que garantem maiores lucros devido ao maior atendimento de clientes. Alguns erros de estimação da carga CAg também podem gerar distúrbios, mas o impacto é significativamente menor.

Conforme mencionado anteriormente, as violações dos limites contratuais estão sujeitas à penalizações e são arcados pela ERVE. No entanto, neste estudo, é considerado que parte deste valor pode ser diluído na conta dos cliente CNAg caso a ultrapassagem seja causada pela carga excessiva dos mesmos. Também é considerado que este valor pode ser acrescido na conta dos clientes CAg caso a carga real de alguns indivíduos seja muito maior do que a carga estimada fornecida pelos próprios clientes. No caso da ultrapassagem ser causada por, em grande parte, erro na previsão do recurso solar, a ERVE arca integralmente com os custos associados. Com base no despacho real sistema, a Tabela 4.5 apresenta os principais impactos técnicos no sistema.

Tabela 4.5 – Principais impactos técnicos no sistema.

$PAPR_f$	$Carga_p$ (kW)	C_p (kW)
2,25	353	323,7
V_p (kW)	C_{evit} (kWh)	C_{nevit} (kWh)
115,5	73,4	11,85

Fonte: Autor.

Na Tabela 4.5, o PAPR total da carga da ERVE foi de 2,25, valor este ligeiramente abaixo do PAPR esperado da carga CAg. Assim, a carga CNAg em conjunto com a carga própria da ERVE, e somada com a variação na carga real CAg, representou uma carga mais distribuída ao longo do dia. Também é possível observar que o pico da carga total ($Carga_p$) foi de 353 kW, enquanto que o pico visto pela concessionária foi de 323,7 kW (C_p). O despacho dos RDEs reduziu a maior parte da potência acima do limite de compra, totalizando 73,4 kWh de ultrapassagem evitada (C_{evit}). No entanto, ainda assim, o sistema registrou uma pequena violação de 11,85 kWh de compra de energia acima do limite superior (C_{nevit}). Finalmente, o limite inferior foi respeitado integralmente, com potência máxima registrada de 115,5 kW (V_p). Deste modo, observa-se que o modelo

de despacho do SAEB auxiliou no atendimento técnico do sistema, reduzindo valores de ultrapassagem e melhorando a métrica PAPR. A Tabela 4.6 apresenta alguns dos principais impactos do despacho do SAEB na operação do sistema.

Tabela 4.6 – Impactos do uso do SAEB no sistema.

FV_{Carga} (kWh)	FV_{SAEB} (kWh)	$AutoC_{FV}$ (%)
1666,31	173,42	10,40
$Carga_{Ut}$ (kWh)	FV_{desp} (kWh)	$SAEB_{desp}$ (kWh)
961,55 para 569,98	292,8	98,77
40% - redução	75% - contribuição	25% - contribuição

Fonte: Autor.

Na Tabela 4.6, durante a operação diária do sistema, o SAEB conseguiu aumentar o percentual de energia renovável que abastece a carga. A variável $AutoC_{FV}$ indica o aumento percentual no auto consumo da energia localmente gerada pelo SSFV, o qual foi de 10,40%. Assim, do total de energia gerada pelo SSFV, 1666,31 kWh foram utilizados para atender a carga diretamente, enquanto que 173,42 kWh deste total foram armazenados no SAEB para uso posterior na carga. Note-se que o SAEB realizou nesta etapa o serviço ancilar conhecido como maximização do consumo local de energia renovável.

Outro ponto interessante da operação do SAEB se refere ao despacho durante os períodos em que a carga se encontra com potência total acima do limite de 300 kW do contrato com a concessionária. Esse evento ocorre duas vezes ao longo da operação diária do sistema, conforme apresentado anteriormente na Figura 4.10.

A energia total requerida pela carga durante estes eventos equivale a 961,55 kWh. No entanto, após o despacho coordenado dos RDEs, o montante total visto pela concessionária é de 569,98 kWh, representando uma redução de 40%. Esta redução é obtida por meio do despacho do SSFV de 292,8 kWh e com 98,77 kWh do SAEB, totalizando, respectivamente, contribuições de 75% e 25% de cada ativo energético. Nesta etapa ambos os RDEs realizam o serviço de corte de pico. Com base nos valores de despacho do sistema a seção seguinte busca avaliar o impacto econômico desta metodologia.

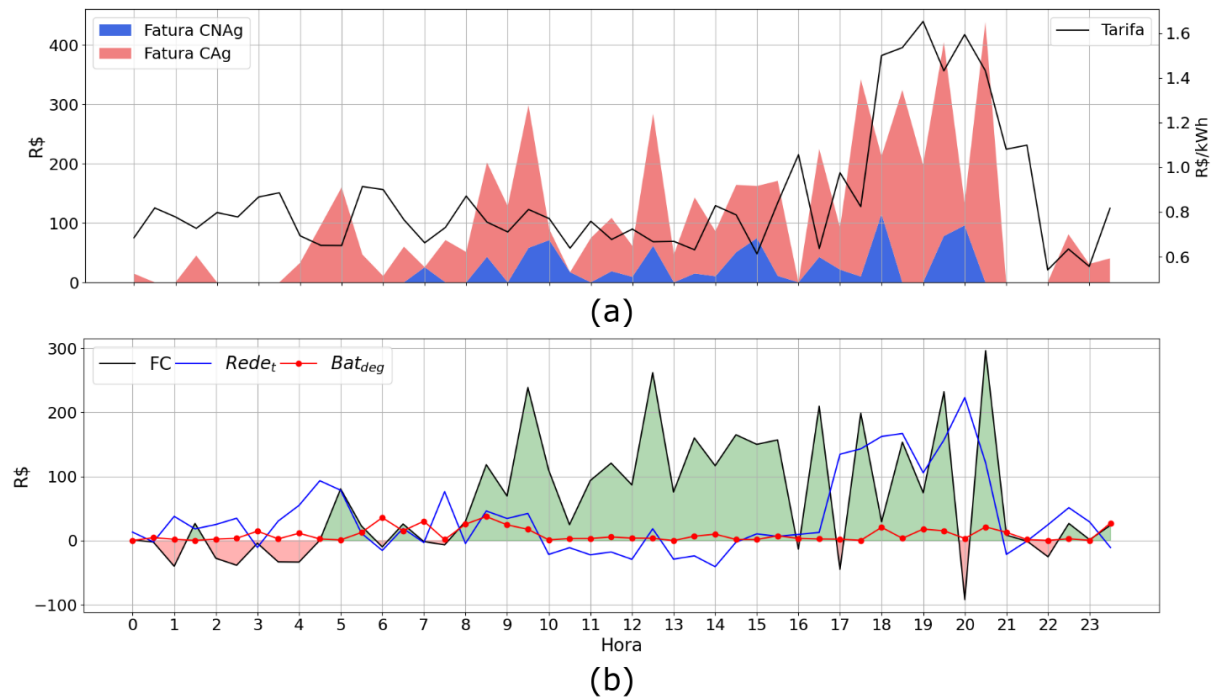
4.3.2 Análise Econômica

Nesta etapa um algoritmo BR rege as condições de troca de potência entre os ativos da ERVE e a carga a ser atendida. Utilizando o algoritmo da Seção 3.5, e tendo como variáveis de entrada o despacho otimizado do SAEB, os dados reais de geração do

SSFV e as cargas CAg e CNAg, é possível realizar o balanço energético do sistema.

É válido mencionar que nesta etapa são utilizados os valores reais de geração/carga, embora o sistema seja otimizado com base nos valores esperados, o despacho baseado em regras é encarregado de atender toda a carga sem que haja interrupção no fornecimento. A Figura 4.11 apresenta o fluxo de caixa da ERVE ao longo do dia operativo.

Figura 4.11 – Fluxo de caixa na ERVE.



Fonte: Autor.

A Figura 4.11a apresenta as receitas obtidas dos clientes CAg e CNAg. Nesta etapa o consumidor é cobrado somente no final do carregamento. Assim, caso o cliente esteja realizando CN, a ERVE só computará a receita obtida no último passo de tempo da conexão do usuário. Note-se que, embora o CNAg tenha uma carga significativa menor que a CAg, a receita das faturas obtidas ainda sim é bastante relevante. O anterior se deve aos multiplicadores da fatura final serem mais caros para o CNAg em comparação ao CAg. Também, é possível visualizar a relação das faturas com o preço da tarifa da rede. Note-se que as maiores receitas ocorrem durante os períodos mais caros da tarifa.

A Figura 4.11b apresenta o fluxo de caixa (FC) da ERVE, calculado conforme a metodologia da Seção 3.5. Note-se que sempre que FC é positivo, a área abaixo da curva tem coloração verde para indicar lucro, e quando FC é negativo a coloração é vermelha para indicar prejuízo. Conforme pode ser visualizado, a ERVE opera grande parte do tempo com FC positivo. Os momentos negativos são justificados pelas compras de energia da rede para abastecer a carga própria ou devido à possíveis penalizações por

quebra de alguma regra contratual. O anterior se destaca nos períodos fora do horário comercial, onde existe baixa demanda e geração fotovoltaica.

A variável $Rede_t$ apresenta o preço dos montantes de compra e venda de energia com a rede. Note-se que este estudo considera a compra feita com base no preço da tarifa daquele dado instante, enquanto que a venda leva em conta apenas 85% do valor total da venda com base no preço da tarifa. Por fim, a curva denotada como Bat_{deg} apresenta o custo associado ao desgaste do SAEB, seja por carga ou descarga. De modo à sumarizar as principais métricas econômicas relacionadas ao dia operativo da ERVE, a Tabela 4.7 apresenta os resultados econômicos encontrados.

Tabela 4.7 – Resultados econômicos sumarizados.

$VEFat_t(R\$)$	$Bat_{tdeg}(R\$)$	$Rede_t(R\$)$	$FC_t(R\$)$
5.179,00	431,67	1.728,36	3.018,97

Fonte: Autor.

Na Tabela 4.7 a variável $VEFat_t$ representa a receita total ao longo do dia recebida dos clientes CAg e CNAg. Bat_{tdeg} é o custo total diário associado ao despacho do SAEB. $Rede_t$ é o montante associado às compras e vendas de energia com a rede. O sistema apresentou um fluxo de caixa positivo e equivalente a R\$ 3.018,97 para o dia operativo em questão.

Conforme apresentado na seção anterior, a ERVE registrou uma carga de ultrapassagem de 11,85 kWh. Este custo deve então ser arcado pela estação de recarga. No entanto, também é levado em conta que o consumidor CNAg deve estar ciente dos encargos que podem ocorrer ao longo do seu carregamento. Com base nisto 50% do custo é então diluído na fatura dos consumidores CNAg, e o resto é computado como despesa para a ERVE. Ambas as partes, então, arcaram com R\$ 9,77. Este valor é referente ao preço da tarifa durante o respectivo momento, bem como o multiplicador de ultrapassagem de 2. De modo a quantificar o impacto econômico do despacho do SEAB, a Tabela 4.8 apresenta alguns indicadores do sistema referentes à operação do elemento armazenador.

Tabela 4.8 – Indicadores econômicos do uso do SAEB.

$Pbase_{ent}$ (R\$)	$Prede_{ent}$ (R\$)	Economia (R\$)
275,53	376,22	100,68
$Pbase_{saida}$ (R\$)	$Pmed_{venda}$ (R\$)	Lucro (R\$)
390,68	736,68	345,99

Fonte: Autor.

Na Tabela 4.8 a variável $Pbase_{ent}$ representa o valor da energia injetada no SAEB durante o processo de carga e juntamente com o custo de degradação associado. Este valor varia com a magnitude da energia de entrada e com a sua origem, seja ela proveniente do SSFV ou da rede. $Prede_{ent}$ é o valor da energia de entrada considerando somente o preço da tarifa da concessionária. Assim, este valor não leva em consideração que a energia poderia vir da fonte renovável. Como o montante de $Prede_{ent}$ ao longo do dia operativo é maior que o de $Pbase_{ent}$, o sistema obteve uma economia de R\$ 100.68 ao final do dia. Esta economia é referente ao aproveitamento da energia renovável durante os processos de carga do SAEB.

A variável $Pbase_{saida}$, por outro lado, representa o preço base associado à descarga de energia do SAEB ao longo do dia. $Pmed_{venda}$ é o preço médio da energia de saída vendida aos consumidores durante o processo de descarga do SAEB. Como $Pmed_{venda}$ é maior que $Pbase_{saida}$, o sistema registrou um lucro operativo total de R\$ 345.99 com o despacho do SAEB. Assim, se pode observar que o modelo de gerenciamento proposto pode aproveitar tanto as características de carga como as de descarga da bateria para fornecer benefícios econômicos à ERVE.

4.4 DISCUSSÃO DO CAPÍTULO

Este capítulo apresentou o estudo de caso para validação e análise da metodologia proposta. Foi apresentada a distribuição da carga agendada ao longo do dia com base nas métricas de PAPR e minimização do custo de fornecimento utilizando o algoritmo EPSO-MC. Também foram apresentados os impactos técnicos e econômicos do despacho do SAEB na operação diária da ERVE com base no modelo de otimização multi-critério desenvolvido.

Analisando os principais impactos técnicos apresentados, o despacho do SAEB conseguiu aumentar o auto consumo da fonte renovável em 10%. Além disto, obteve participação de 25% na redução da carga de ultrapassagem do sistema, que foi causada principalmente pela carga não agendada. Por fim, o sistema conseguiu uma redução de 40% na carga vista pela concessionária durante o período que a mesma se encontrava acima do limite superior de 300 kW, definido em contrato. Assim, foi possível reduzir significativamente os casos de ultrapassagem, que foram poucos ao longo do dia.

Sob a ótica econômica, o despacho do elemento armazenador representou uma economia de R\$ 100 na operação da ERVE ao evitar possíveis compras da rede durante os processos de carga ao utilizar a energia do SSFV. O sistema registrou um lucro com o SAEB de R\$ 345,00 com base na diferença do preço médio da venda de energia aos clientes e do preço base da energia de descarga do SAEB. Finalmente, vale mencionar que a ERVE obteve um fluxo de caixa positivo de R\$ 3.018,97 ao final do dia operacional com

o despacho coordenado e otimizado do RDEs. Desta forma, foram mostrados os benefícios econômicos e técnicos da metodologia proposta.

5 CONCLUSÃO

Este trabalho apresentou uma metodologia de coordenação do despacho do SAEB da ERVE otimizada, em conjunto com o agendamento inteligente de recargas com base em MH e algoritmos baseados em regras. Os métodos MH apresentaram uma boa solução para os processos de otimização tanto da carga agendada quanto do despacho do SAEB. Os algoritmos baseados em regras representaram alternativas interessantes para lidar com os processos em tempo real, como por exemplo, a coordenação da conexão dos clientes CNAg e o despacho do SSFV, fornecendo uma flexibilidade operativa à ERVE.

No que se refere aos benefícios observados, a utilização do agendamento otimizado apresentou reduções nos picos de potência vistas pela rede ao reduzir o PAPR, sem que isto compromettesse o fluxo de caixa operativo da ERVE. Sob o ponto de vista da otimização do SAEB, o despacho forneceu benefícios técnico-econômicos levando em conta a degradação interna do elemento armazenador. Considerando os benefícios pode-se citar a redução da carga total acima do limite superior contratual - que por sua vez alivia os encargos associados-, e o aumento do auto consumo de energia renovável produzida pelo SSFV, com o uso do serviço ancilar de maximização de auto consumo remoto.

Conforme apresentado, a metodologia MH-BR proporcionou uma boa operação da ERVE. A união das etapas de planejamento com a operação em tempo real forneceu à estação de recarga grande flexibilidade para atender os clientes CAg e CNAg.

5.1 TRABALHOS FUTUROS

Esta metodologia é baseada na operação diária da ERVE, para futuros estudos é considerado o aumento deste tempo de simulação, estendendo a metodologia para aplicações de tempos médios ou longos. Outro ponto importante é a quantificação das incertezas presentes no comportamento dos consumidores e na previsão da geração solar.

Referente ao agendamento de cargas, o uso de históricos de carregamento dos VEs poderia ser utilizado para aprimorar este processo. No entanto, estes cenários também requer uma base de dados bastante significativa. De fato, a principal motivação do uso dos algoritmos BR para a operação em tempo real foi considerada neste estudo devido à falta de dados práticos. Assim, com um melhor conhecimento do comportamento dos usuários de VEs, os processos de otimização se tornam mais precisos. Por fim, dentre outras melhorias na metodologia pode-se citar o uso distribuído do SAEB para aumento da eficiência na operação da rede do OSD, adição de mais ERVEs no sistema, contratos considerando agregadores privados e uso de inteligência artificial para substituição das etapas BR.

5.2 PRODUÇÃO CIENTÍFICA ASSOCIADA À DISSERTAÇÃO

Durante o período de estudo, foram realizadas as seguintes atividades de produção científica associadas em parte ao trabalho proposto:

Artigo publicado em revista internacional Qualis CAPES A1: Revista Energies Qualis CAPES A1 segundo referência mais atualizada (UFRGS, 2021), *Impact Factor* de 3.004 e *Citescore* de 4.7.

(Publicado) Oliveira Farias, H.; Sepulveda Rangel, C.; Weber Stringini, L.; Neves Canha, L.; Pegoraro Bertineti, D.; da Silva Brignol, W.; Iensen Nadal, Z. Combined Framework with Heuristic Programming and Rule-Based Strategies for Scheduling and Real Time Operation in Electric Vehicle Charging Stations. *Energies* 2021, 14(5), 1370; <https://doi.org/10.3390/en14051370>. <https://www.mdpi.com/1996-1073/14/5/1370>.

Artigo publicado em congresso internacional:

(Publicado) H. E. O. Farias and L. N. Canha, "Battery Energy Storage Systems: Impact Analysis on Different Loads with Distributed Generation," 2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America), 2019, pp. 1-5, doi: 10.1109/ISGT-LA.2019.8895361.

Registro de software:

(Registro de Software) CANHA, L. N. ; RANGEL, C. A. S. ; FARIAS, H. E. O. ; STRINGINI, L. W. PLANEP. 2020. Patente: Programa de Computador. Número do registro: BR512020002101-8, data de registro: 23/06/2020, título: "PLANEP", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.

Artigo publicado em congresso nacional:

(Publicado) Oliveira Farias, H.; Sepulveda Rangel, C.; Neves Canha, L.; Henrique Horquen Martins; Tiago Augusto Silva Santana; Iensen Nadal. Resiliency Analysis in Residential Consumer with Distributed Generation and Battery Energy Storage System. *CBA* 2020. Vol 2. No 1. <https://doi.org/10.48011/asba.v2i1.1514>.

Artigos aceitos para publicação em congressos internacionais:

(Aceito) Oliveira Farias, H.; Sepulveda Rangel, C.; Weber Stringini, L.; Neves Canha, L.; Pegoraro Bertineti, D.; da Silva Brignol, W.; Iensen Nadal, Z. Battery energy storage systems management in a day-ahead market scenario with transactive energy and private aggregators. *UPEC* 2021.

(Aceito) Weber Stringini, L.; Oliveira Farias, H.; Sepulveda Rangel, C.; Neves Canha, L.; Pegoraro Bertineti, D.; da Silva Brignol, W.; Iensen Nadal, Z. Smart energy management of multiple battery types for aggregators use considering negotiated contracts with the distribution system operator and battery degradation. *CIREN* 2021.

REFERÊNCIAS

- ABRONZINI, U. et al. Multi-source power converter system for EV charging station with integrated ESS. **2015 IEEE 1st International Forum on Research and Technologies for Society and Industry, RTSI 2015 - Proceedings**, n. 1, p. 427–432, 2015.
- _____. Cost minimization energy control including battery aging for multi-source EV charging station. **Electronics (Switzerland)**, v. 8, n. 1, p. 1–17, 2019. ISSN 20799292.
- AGENCY, I. E. **Innovation in Batteries and Electricity Storage**. Paris, 2020. International Energy Agency. Acesso em: 04 abr. 2021. Disponível em: <<https://www.iea.org/reports/innovation-in-batteries-and-electricity-storage>>.
- ANEEL. **Establishes the General Conditions of Electricity Supply from updated and consolidated form** . 2021. <<https://www.aneel.gov.br/documents/656877/>>.
- BADAWY, M. O.; SOZER, Y. Power Flow Management of a Grid Tied PV-Battery System for Electric Vehicles Charging. **IEEE Transactions on Industry Applications**, v. 53, n. 2, p. 1347–1357, 2017. ISSN 00939994.
- BERTINETI, D. P. **Aplicação de método de deslocamento de carga para sistemas de gerenciamento de energia**. Dissertação (Mestrado) — Universidade Federal de Santa Maria, Santa Maria,RS/Brasil, 2019. Programa de Pós Graduação em Engenharia Elétrica.
- BERTINETI, D. P. et al. Flexible Energy Management Strategy for Electric Vehicles Charging Stations. **UPEC 2020 - 2020 55th International Universities Power Engineering Conference, Proceedings**, 2020.
- BHARATIRAJA, C. et al. Real-time forecasting of EV charging station scheduling for smart energy systems. **Energies**, v. 10, n. 3, p. 1–16, 2017. ISSN 19961073.
- BIYA, T. S.; SINDHU, M. R. Design and Power Management of Solar Powered Electric Vehicle Charging Station with Energy Storage System. **Proceedings of the 3rd International Conference on Electronics and Communication and Aerospace Technology, ICECA 2019**, IEEE, p. 815–820, 2019.
- Blank, J.; Deb, K. Pymoo: Multi-objective optimization in python. **IEEE Access**, v. 8, p. 89497–89509, 2020.
- BUENO, A.; BRANDÃO, C. **Visão Geral de Tecnologia e Mercado para os Sistemas de Armazenamento de Energia Elétrica no Brasil**. [S.l.], 2016. 62 p.
- CHAUDHARI, K. et al. Hybrid Optimization for Economic Deployment of ESS in PV-Integrated EV Charging Stations. **IEEE Transactions on Industrial Informatics**, v. 14, n. 1, p. 106–116, 2018. ISSN 15513203.

CHUNG, H. M. et al. Electric Vehicle Charge Scheduling Mechanism to Maximize Cost Efficiency and User Convenience. **IEEE Transactions on Smart Grid**, v. 10, n. 3, p. 3020–3030, 2019. ISSN 19493053.

COPEL. **Copel inaugura maior eletrovia do país**. 2019. <<https://www.copel.com/hpcopel/root/nivel2.jsp?endereco={%}2Fhpcopel{%}2Froot{%}2Fpagcopel2.nsf{%}2Fdocs{%}2F66B766F31D7940A58325836200594384>>.

CROSS J. D. HARTSHORN, R. **My Electric Avenue: Integrating electric vehicles into the electrical networks**. 2021. <<http://myelectricavenue.info>>.

DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 2, p. 182–197, 2002.

DEB, S. et al. Impact of electric vehicle charging station load on distribution network. **Energies**, v. 11, n. 1, p. 1–25, 2018. ISSN 19961073.

DING, H. et al. Coordinated control strategy of energy storage system with electric vehicle charging station. **IEEE Transportation Electrification Conference and Expo, ITEC Asia-Pacific 2014 - Conference Proceedings**, IEEE, p. 1–5, 2014.

ELECTRIC vehicle scheduling and optimal charging problem: complexity, exact and heuristic approaches. **International Journal of Production Research**, v. 55, n. 2, p. 519–535, 2017. ISSN 1366588X.

FARIAS, H. E. O. et al. Combined framework with heuristic programming and rule-based strategies for scheduling and real time operation in electric vehicle charging stations. **Energies**, v. 14, n. 5, 2021. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/14/5/1370>>.

HAYAJNEH, H. S.; LAINFIESTA, M.; ZHANG, X. Three birds one stone: A solution to maximize renewable generation, incentivize battery deployment, and promote green transportation. **2020 IEEE Power and Energy Society Innovative Smart Grid Technologies Conference, ISGT 2020**, p. 4–8, 2020.

HEYDT, G. T. The impact of electric vehicle deployment on load management strategies. **IEEE Transactions on Power Apparatus and Systems**, PAS-102, n. 5, p. 1253–1259, 1983. ISSN 00189510.

HUSSAIN, A.; BUI, V. H.; KIM, H. M. Optimal Sizing of Battery Energy Storage System in a Fast EV Charging Station Considering Power Outages. **IEEE Transactions on Transportation Electrification**, IEEE, v. 6, n. 2, p. 453–463, 2020. ISSN 23327782.

IEA, I. E. A. **Global EV Outlook 2019**. Paris, 2019. International Energy Agency. Acesso em: 11 jan. 2021. Disponível em: <<https://www.iea.org/reports/global-ev-outlook-2019>>.

- _____. **Global EV Outlook 2020**. Paris, 2020. International Energy Agency. Acesso em: 3 de jan. 2021. Disponível em: <<https://www.iea.org/reports/global-ev-outlook-2020>>.
- IRENA. Time-of-Use Tariffs. **International Renewable Energy Agency**, p. 1–18, 2019.
- IRENA, I. R. E. A. **Innovation outlook: Smart charging for electric vehicles**. Abu Dhabi, 2019. International Renewable Energy Agency. Acesso em: 14 de fev. 2021. Disponível em: <<https://www.irena.org>>.
- JAIN, Y. K.; BHANDARE, S. K. Min Max Normalization Based Data Perturbation Method for Privacy Protection. **International Journal of Computer and Communication Technology**, v. 4, n. 4, p. 233–238, 2013. ISSN 0975-7449.
- JIANG, W.; ZHEN, Y. A Real-Time EV Charging Scheduling for Parking Lots with PV System and Energy Store System. **IEEE Access**, v. 7, p. 86184–86193, 2019. ISSN 21693536.
- KO, H.; PACK, S.; LEUNG, V. C. An Optimal Battery Charging Algorithm in Electric Vehicle-Assisted Battery Swapping Environments. **IEEE Transactions on Intelligent Transportation Systems**, p. 1–10, 2020. ISSN 15580016.
- KOUKA, K.; KRICHEN, L. Energy management strategy of a photovoltaic electric vehicle charging station. **19th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering, STA 2019**, IEEE, p. 124–129, 2019.
- LAMBORA, A.; GUPTA, K.; CHOPRA, K. Genetic algorithm- a literature review. In: **2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)**. [S.l.: s.n.], 2019. p. 380–384.
- LEWIS, H. Lithium-ion battery consultation report. n. August, p. 1–21, 2016.
- LI, T. et al. An optimal design and analysis of a hybrid power charging station for electric vehicles considering uncertainties. **Proceedings: IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society**, IEEE, p. 5147–5152, 2018.
- LIU, W. L. et al. Coordinated Charging Scheduling of Electric Vehicles: A Mixed-Variable Differential Evolution Approach. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 21, n. 12, p. 5094–5109, 2020. ISSN 15580016.
- Marty, J.; Pietrowicz, S. Economic incentives for reducing peak power utilization in electric vehicle charging stations. In: **2018 IEEE Power Energy Society Innovative Smart Grid Technologies Conference (ISGT)**. [S.l.: s.n.], 2018. p. 1–5.
- MILAS, N.; MOURTZIS, D.; TATAKIS, E. A Decision-Making Framework for the Smart Charging of Electric Vehicles Considering the Priorities of the Driver. **Energies**, v. 13, n. 22, p. 6120, 2020. ISSN 1996-1073.

- MIRANDA, V.; FONSECA, N. Epso - best-of-two-worlds meta-heuristic applied to power system problems. In: **Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No.02TH8600)**. [S.l.: s.n.], 2002. v. 2, p. 1080–1085 vol.2.
- MIRANDA, V.; KEKO, H.; JARAMILLO, A. Epso: Evolutionary particle swarms bt - advances in evolutionary computing for system design. In: JAIN, L. C.; PALADE, V.; SRINIVASAN, D. (Ed.). Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 139–167. ISBN 978-3-540-72377-6.
- MIRJALILI, S. Genetic algorithm. **Studies in Computational Intelligence**, v. 780, p. 43–55, 2019. ISSN 1860949X.
- NAIDU, K.; MOKHLIS, H.; BAKAR, A. H. Multiobjective optimization using weighted sum Artificial Bee Colony algorithm for Load Frequency Control. **International Journal of Electrical Power and Energy Systems**, v. 55, n. 2018, p. 657–667, 2014. ISSN 01420615.
- ORTEGA-VAZQUEZ, M. A. Optimal scheduling of electric vehicle charging and vehicle-to-grid services at household level including battery degradation and price uncertainty. **IET Generation, Transmission and Distribution**, v. 8, n. 6, p. 1007–1016, 2014. ISSN 17518687.
- Pereira, M. V. F. et al. Combining analytical models and monte-carlo techniques in probabilistic power system analysis. **IEEE Transactions on Power Systems**, v. 7, n. 1, p. 265–272, 1992.
- POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization: An overview. **Swarm Intelligence**, v. 1, n. 1, p. 33–57, 2007. ISSN 1935-3820.
- RANGEL, C. A. S. et al. Methodology for ESS-type selection and optimal energy management in distribution system with DG considering reverse flow limitations and cost penalties. **IET Generation, Transmission and Distribution**, v. 12, n. 5, p. 1164–1170, 2018. ISSN 17518687.
- ROSSUM, G. V.; JR, F. L. D. **Python reference manual**. [S.l.]: Centrum voor Wetkunde en Informatica Amsterdam, 1995.
- SAVARI, G. F. et al. Optimal charging scheduling of electric vehicles in micro grids using priority algorithms and particle swarm optimization. **Mobile Networks and Applications**, Mobile Networks and Applications, v. 24, n. 6, p. 1835–1847, 2019. ISSN 15728153.
- SHI, R. et al. Multidispatch for microgrid including renewable energy and electric vehicles with robust optimization algorithm. **Energies**, v. 13, n. 11, 2020. ISSN 19961073.
- SHIN, M.; CHOI, D. H.; KIM, J. Cooperative Management for PV/ESS-Enabled Electric Vehicle Charging Stations: A Multiagent Deep Reinforcement Learning Approach. **IEEE Transactions on Industrial Informatics**, v. 16, n. 5, p. 3493–3503, 2020. ISSN 19410050.

- SINGH, B. et al. Implementation of Solar PV-Battery and Diesel Generator Based Electric Vehicle Charging Station. **IEEE Transactions on Industry Applications**, IEEE, v. 56, n. 4, p. 4007–4016, 2020. ISSN 19399367.
- UFRGS. **Qualis Novo**. 2021. Acesso em: 28 de jul. 2021. Disponível em: <<https://www.ufrgs.br/ppggeo/ppggeo/wp-content/uploads/2019/12/QUALIS-NOVO-1.pdf>>.
- UFSM. **Photovoltaic power plant starts to work at UFSM** . 2021. <<https://www.ufsm.br/2018/10/10/usina-de-geracao-de-energia-solar-comeca-a-funcionar-na-ufsm/>>.
- VERMA, A.; SINGH, B. Multimode Operation of Solar PV Array, Grid, Battery and Diesel Generator Set Based EV Charging Station. **IEEE Transactions on Industry Applications**, v. 56, n. 5, p. 5330–5339, 2020. ISSN 19399367.
- WATTSON. **Nissan Leaf 40 kWh**. 2021. Acesso em: 25 de mar. 2021. Disponível em: <<https://www.wattson.pt/carros/nissan-leaf-40-kwh/>>.
- XU, Y.; PAN, F.; TONG, L. Dynamic Scheduling for Charging Electric Vehicles: A Priority Rule. **IEEE Transactions on Automatic Control**, v. 61, n. 12, p. 4094–4099, 2016. ISSN 00189286.
- YAN, D. et al. A Two-Stage Scheme for Both Power Allocation and EV Charging Coordination in A Grid Tied PV-Battery Charging Station. **IEEE Transactions on Industrial Informatics**, v. 3203, n. c, p. 1–10, 2021. ISSN 19410050.
- YAN, Q.; ZHANG, B.; KEZUNOVIC, M. Optimized operational cost reduction for an EV charging station integrated with battery energy storage and PV generation. **IEEE Transactions on Smart Grid**, IEEE, v. 10, n. 2, p. 2096–2106, 2019. ISSN 19493053.
- YANG, J. et al. Optimal Dispatching Strategy for Shared Battery Station of Electric Vehicle by Divisional Battery Control. **IEEE Access**, IEEE, v. 7, p. 38224–38235, 2019. ISSN 21693536.
- YANG, S. N. et al. Charge scheduling of electric vehicles in highways. **Mathematical and Computer Modelling**, Elsevier Ltd, v. 57, n. 11-12, p. 2873–2882, 2013. ISSN 08957177. Disponível em: <<http://dx.doi.org/10.1016/j.mcm.2011.11.054>>.
- YUSOFF, Y.; NGADIMAN, M. S.; ZAIN, A. M. Overview of nsga-ii for optimizing machining process parameters. **Procedia Engineering**, v. 15, p. 3978–3983, 2011. ISSN 1877-7058. CEIS 2011. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877705811022466>>.
- ZHANG, T. et al. Charging scheduling of electric vehicles with local renewable energy under uncertain electric vehicle arrival and grid power price. **IEEE Transactions on Vehicular Technology**, v. 63, n. 6, p. 2600–2612, 2014. ISSN 00189545.
- ZIMA-BOCKARJOVA, M. et al. Charging and discharging scheduling for electrical vehicles using a shapley-value approach. **Energies**, v. 13, n. 5, p. 1–21, 2020. ISSN 19961073.