

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Eduardo Mendes Loureiro

Método para Alocação e Operação de Baterias em Sistemas de Distribuição

Juiz de Fora

2025

Eduardo Mendes Loureiro

Método para Alocação e Operação de Baterias em Sistemas de Distribuição

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de Sistemas de Energia Elétrica, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Prof^ª. Débora Rosana Ribeiro Penido Araujo, D. Sc.

Coorientador: Prof. Leandro Ramos de Araujo, D. Sc.

Juiz de Fora

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a).

Mendes Loureiro, Eduardo.

Método para Alocação e Operação de Baterias em Sistemas de Distribuição / Eduardo Mendes Loureiro. – 2025.

157 p. : il.

Orientadora: Débora Rosana Ribeiro Penido Araujo

Coorientador: Leandro Ramos de Araujo

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2025.

1. Armazenamento de energia. 2. Sistemas de distribuição de energia. 3. Alocação e operação de baterias. 4. Otimização. I. Rosana Ribeiro Penido Araujo, Débora , orient. II. Ramos de Araujo, Leandro , coorient. III. Título.

Eduardo Mendes Loureiro

Método para Alocação e Operação de Baterias em Sistemas de Distribuição

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica.
Área de concentração: Sistemas de Energia Elétrica

Aprovada em 11 de setembro de 2025.

BANCA EXAMINADORA

Profa. Dra. Débora Rosana Ribeiro Penido Araujo - Orientadora
Universidade Federal de Juiz de Fora

Prof. Dr. Leandro Ramos de Araujo - Coorientador
Universidade Federal de Juiz de Fora

Prof. Dr. André Milhorce de Castro
Pontifícia Universidade Católica do Rio de Janeiro

Prof. Dr. Ivo Chaves da Silva Junior
Universidade Federal de Juiz de Fora

Juiz de Fora, 18/08/2025.



Documento assinado eletronicamente por **Debora Rosana Ribeiro Penido Araujo, Professor(a)**, em 11/09/2025, às 18:01, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leandro Ramos de Araujo, Professor(a)**, em 11/09/2025, às 18:05, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ivo Chaves da Silva Junior, Professor(a)**, em 11/09/2025, às 19:36, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **André Milhorce de Castro, Usuário Externo**, em 12/09/2025, às 09:03, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2558935** e o código CRC **D9623A31**.

AGRADECIMENTOS

Agradeço a Deus por sua graça e bondade, por todas as capacidades que me concedeu, e por ter me dado a condição e a oportunidade de viver mais essa etapa da minha vida.

Aos meus pais, Carlos Augusto e Dalva, por acreditar e investir tanto em mim, pelo incentivo e apoio incondicionais ao longo de todos os meus anos de vida, por todo o amor demonstrado a mim de tantas formas, e por serem minha referência e meu exemplo.

À minha noiva, Elisabeth, pelo presente de compartilhar a vida cotidiana e por estar ao meu lado nos momentos de alegria e de dificuldade. Obrigado por me motivar e incentivar tanto, especialmente na condução deste trabalho.

À minha irmã, Ana Luiza, e a todos os meus outros familiares, por tanto amor e carinho, pelas orações e pelas palavras de apoio. Também por todos os ensinamentos e lições aprendidas desde a infância, que com certeza contribuíram para que eu chegasse até aqui.

A todos os meus amigos, de perto e de longe, por dividir momentos tão especiais, pela força para enfrentar os desafios, e por saber que posso contar com vocês sempre. Sou grato a Deus pela vida e amizade de todos vocês.

Aos professores Leandro e Débora, e à parceira de projeto, Maria Elisa, pela orientação, pelos conselhos e por todo o apoio no desenvolvimento dessa pesquisa ao longo dos últimos anos e na elaboração deste trabalho.

Aos colegas de curso, aos outros professores e a todos que participaram dessa etapa, pelas colaborações, discussões e pelo conhecimento compartilhado.

À Universidade Federal de Juiz de Fora, à Faculdade de Engenharia e à CAPES pelo fomento e estrutura necessários para a elaboração deste trabalho e pelos conhecimentos adquiridos e habilidades desenvolvidas nesse processo.

Muito obrigado a todos que cruzaram meu caminho na jornada até aqui e que de alguma forma contribuíram para que eu me torne uma pessoa cada vez melhor. Deus abençoe cada um de vocês.

“dizendo:

*‘Amém! O louvor, a glória,
a sabedoria, as ações de graças,
a honra, o poder e a força
sejam ao nosso Deus,
para todo o sempre. Amém!’”*

Apocalipse 7:12

RESUMO

A modernização dos sistemas de distribuição de energia elétrica, impulsionada pela inserção crescente de Recursos Energéticos Distribuídos (REDs), como geração distribuída e dispositivos de armazenamento, exige novas estratégias de planejamento e operação. Nesse contexto, esta dissertação apresenta o desenvolvimento de um método para alocação e operação de baterias em sistemas de distribuição, visando otimizar aspectos técnicos e econômicos, especificamente a redução das perdas elétricas e do custo de aquisição de energia. A metodologia proposta compreende a implementação, em Matlab, de uma ferramenta flexível capaz de variar parâmetros de simulação e empregar diferentes técnicas de otimização para resolução do problema. Internamente ao método, são executados fluxos de potência acoplados no tempo, no formato de séries temporais quase-estáticas (QSTS), por meio de interface com o OpenDSS. O modelo considera restrições técnicas e operativas, como limites de estado de carga das baterias e prevenção de fluxos reversos na subestação ou aumento da demanda máxima, além de possibilitar a análise sob diferentes curvas de carga, tarifas e cenários com geração fotovoltaica. Para validação, foram realizados testes em sistemas IEEE de 13, 34 e 123 barras, sob múltiplas condições, comparando métodos de otimização e configurações de capacidade de armazenamento. Os resultados indicam que o uso de baterias é promissor para a minimização dos custos de aquisição de energia, especialmente em cenários com tarifas horárias e perfis de carga favoráveis, enquanto seu potencial isolado para redução de perdas na rede elétrica é limitado. A abordagem desenvolvida demonstra versatilidade para aplicação em estudos técnicos e econômicos, contribuindo para a integração eficiente de sistemas de armazenamento em redes de distribuição.

Palavras-chave: Sistemas de armazenamento de energia; Alocação e operação de baterias; Otimização; Sistemas de distribuição de energia elétrica.

ABSTRACT

The modernization of electric power distribution systems, driven by the increasing deployment of Distributed Energy Resources (DERs), such as distributed generation and storage devices, requires new planning and operation strategies. In that context, this dissertation presents the development of a method for allocating and operating batteries in distribution systems, with the aim of optimizing technical and economic aspects, particularly the reduction of electrical losses and energy purchase costs. The proposed methodology comprises the implementation, in Matlab, of a flexible tool capable of varying simulation parameters and employing different optimization techniques to solve the problem. Within the method, time-coupled power flows are executed in quasi-static time series (QSTS) format, via an interface with OpenDSS. The model takes into account technical and operational restrictions, such as battery state of charge limits and prevention of substation reverse power flows or increases in maximum demand, and also allows for analysis under different load curves, tariffs and scenarios with photovoltaic generation. For validation purposes, tests were carried out on IEEE 13, 34 and 123-bus systems, under multiple conditions, comparing optimization methods and storage capacity settings. The results indicate that the use of batteries is promising for minimizing energy acquisition costs, especially in scenarios with hourly tariffs and favorable load profiles, while their isolated potential for reducing grid losses is limited. The developed approach demonstrates versatility for application in technical and economic studies, contributing to the efficient integration of storage systems into distribution networks.

Keywords: Energy storage systems; Battery allocation and operation; Optimization; Electric power distribution systems.

LISTA DE FIGURAS

Figura 1 – Adições anuais de BESS em escala de rede (GW), entre 2016 e 2022.....	22
Figura 2 – Investimentos em BESS por região (à esquerda) e por segmento (à direita), entre 2015 e 2025.	22
Figura 3 – Diagrama conceitual de um sistema de armazenamento conectado à rede.....	34
Figura 4 – Tecnologias de armazenamento de energia.....	35
Figura 5 – Tempo de descarga e potência nominal de diversas tecnologias de DAEs.....	36
Figura 6 – Modelo de bateria adotado.	38
Figura 7 – Comparação de densidades de potência e energia.	41
Figura 8 – Exemplo da relação entre o SOC e a tensão interna de uma bateria.	42
Figura 9 – Ilustração da relação entre DoD e SOC.	44
Figura 10 – Exemplo do efeito da profundidade de descarga na vida útil de uma bateria.	45
Figura 11 – Ilustração da autodescarga.	47
Figura 12 – Modelo de bateria disponibilizado pelo OpenDSS.	58
Figura 13 – Ilustração da potência de carga vista externa e internamente.	62
Figura 14 – Fluxograma de funcionamento do processo iterativo de simulação do método proposto.	74
Figura 15 – Fluxograma da resolução dos casos.	76
Figura 16 – Fluxograma da resolução do problema de otimização por meio do AG.....	79
Figura 17 – Ilustração do cromossomo.....	80
Figura 18 – Curvas geradas manualmente para composição da população inicial.	81
Figura 19 – Curva de carga diária única.....	87
Figura 20 – Curva de carga semanal.	88
Figura 21 – Curvas de carga dos dias da semana.	89
Figura 22 – Curvas de carga do verão e do outono.	91
Figura 23 – Curvas de carga do inverno e da primavera.	92
Figura 24 – Curva de custo diária.....	94
Figura 25 – Curva de custo semanal.....	95
Figura 26 – Curva de geração fotovoltaica diária.....	96
Figura 27 – Curva de geração fotovoltaica semanal.....	97
Figura 28 – Sistema IEEE 13 barras.....	98
Figura 29 – Sistema IEEE 34 barras.....	99

Figura 30 – Sistema IEEE 123 barras.....	100
Figura 31 – Resultado dos casos S13.A.	103
Figura 32 – SOC das baterias no caso S13.A com capacidade de 1500 kWh.....	104
Figura 33 – Resultado dos casos S13.B com a capacidade de 500 kWh.....	106
Figura 34 – Resultado dos casos S13.B com a capacidade de 1000 kWh.....	107
Figura 35 – Resultado dos casos S13.B com a capacidade de 1500 kWh.....	108
Figura 36 – SOC das baterias no caso S13.B com curva semanal e capacidade de 1500 kWh.	109
Figura 37 – Resultado dos casos S13.C com a capacidade de 500 kWh, com a curva única.	111
Figura 38 – Economia nos casos S13.C com a capacidade de 500 kWh.	112
Figura 39 – Tempo computacional dos casos S13.C com a capacidade de 500 kWh.....	113
Figura 40 – Resultado dos casos S13.C com a capacidade de 1000 kWh, com a curva única.	114
Figura 41 – Economia nos casos S13.C com a capacidade de 1000 kWh.	115
Figura 42 – Tempo computacional dos casos S13.C com a capacidade de 1000 kWh.....	116
Figura 43 – Perdas totais nos casos S13.D.	117
Figura 44 – Perdas no sistema elétrico nos casos S13.D.....	118
Figura 45 – Resultado dos casos S34.A.	120
Figura 46 – SOC das baterias no caso S34.A com capacidade de 1500 kWh.....	121
Figura 47 – Resultado dos casos S34.B com a capacidade de 500 kWh.....	122
Figura 48 – Resultado dos casos S34.B com a capacidade de 1000 kWh.....	123
Figura 49 – Resultado dos casos S34.B com a capacidade de 1500 kWh.....	124
Figura 50 – SOC das baterias no caso S34.B com curva semanal e capacidade de 1500 kWh.	125
Figura 51 – Resultado dos casos S34.C com a capacidade de 500 kWh, com a curva única.	126
Figura 52 – Economia nos casos S34.C com a capacidade de 500 kWh.	127
Figura 53 – Tempo computacional dos casos S34.C com a capacidade de 500 kWh.....	128
Figura 54 – Resultado dos casos S34.C com a capacidade de 1000 kWh, com a curva única	129
Figura 55 – Economia nos casos S34.C com a capacidade de 1000 kWh.	130
Figura 56 – Tempo computacional dos casos S34.C com a capacidade de 1000 kWh.....	131
Figura 57 – Perdas totais nos casos S34.D.	132
Figura 58 – Perdas no sistema elétrico nos casos S34.D.....	133
Figura 59 – Resultado dos casos S123.A.	134

Figura 60 – SOC das baterias no caso S123.A com capacidade de 1500 kWh.....	135
Figura 61 – Resultado dos casos S123.B com a capacidade de 500 kWh.....	136
Figura 62 – Resultado dos casos S13.B com a capacidade de 1000 kWh.....	137
Figura 63 – Resultado dos casos S123.B com a capacidade de 1500 kWh.....	138
Figura 64 – SOC das baterias no caso S123.B com curva semanal e capacidade de 1500 kWh.	139
Figura 65 – Resultado dos casos S123.C com a capacidade de 500 kWh, com a curva única.	140
Figura 66 – Economia nos casos S13.C com a capacidade de 500 kWh.	141
Figura 67 – Tempo computacional dos casos S123.C com a capacidade de 500 kWh.....	142
Figura 68 – Resultado dos casos S123.C com a capacidade de 1000 kWh, com a curva única.	143
Figura 69 – Economia nos casos S123.C com a capacidade de 1000 kWh.	144
Figura 70 – Tempo computacional dos casos S123.C com a capacidade de 1000 kWh.....	145
Figura 71 – Perdas totais nos casos S123.D.	146
Figura 72 – Perdas no sistema elétrico nos casos S123.D.....	147
Figura 73 – Exemplo de SOC e das operações das baterias.....	161
Figura 74 – Trecho do código utilizado no exemplo de aplicação.	163
Figura 75 – Curva do estado de carga da bateria.....	164
Figura 76 – Diagrama com as potências para cada intervalo.	165

LISTA DE TABELAS

Tabela 1 – Comparação de parâmetros de baterias eletroquímicas.....	49
Tabela 2 – Parâmetros da geração fotovoltaica inserida no sistema.	77
Tabela 3 – Casos simulados.	85
Tabela 4 – Número de dias das curvas de carga sazonais.	93
Tabela 5 – Dados nominais da bateria fictícia.....	161
Tabela 6 – Alocação de baterias nos casos do grupo A.....	166
Tabela 7 – Contagem das barras em que houve alocação nos casos do grupo A.....	166
Tabela 8 – Alocação de baterias nos casos do grupo B.....	167
Tabela 9 – Contagem das barras em que houve alocação nos casos do grupo B.....	168
Tabela 10 – Alocação de baterias nos casos do grupo C.....	169
Tabela 11 – Contagem das barras em que houve alocação nos casos do grupo C.....	171
Tabela 12 – Alocação de baterias nos casos do grupo D.....	172
Tabela 13 – Contagem das barras em que houve alocação nos casos do grupo D.....	172

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
BESS	Sistemas de Armazenamento de Energia com Baterias (do inglês: <i>Battery Energy Storage Systems</i>)
CCEE	Câmara de Comercialização de Energia Elétrica
DAE	Dispositivo de Armazenamento de Energia
DOD	Profundidade de Descarga (do inglês: <i>Depth of Discharge</i>)
EPE	Empresa de Pesquisa Energética
FOB	Função Objetivo
FP	Fator de Potência
FV	Fotovoltaico
GD	Geração Distribuída
IEA	Agência Internacional de Energia (do inglês, <i>International Energy Agency</i>)
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IRENA	Agência Internacional para as Energias Renováveis (do inglês, <i>International Renewable Energy Agency</i>)
Li-Ion	Lítio-íon
NaS	Sódio-Enxofre
NiCd	Níquel-Cádmio
NiMH	Níquel-Hidreto Metálico
ONS	Operador Nacional do Sistema Elétrico
OpenDSS	<i>Open Distribution System Simulator</i>
PbO ₂	Chumbo-Ácido
PLD	Preço de Liquidação das Diferenças

PSB	Bateria de Polissulfeto-Bromo (do inglês, <i>Polysulfide Bromide Battery</i>)
PSO	Otimização por Enxame de Partículas (do inglês, <i>Particle Swarm Optimization</i>)
p.u.	Por unidade
QSTS	Séries Temporais Quase-Estáticas (do inglês, <i>Quasi-Static Time Series</i>)
REDs	Recursos Energéticos Distribuídos
SDEE	Sistema de Distribuição de Energia Elétrica
SOC	Estado de Carga (do inglês: <i>State of Charge</i>)
SOH	Estado de Saúde (do inglês: <i>State of Health</i>)
UFJF	Universidade Federal de Juiz de Fora
VRB	Bateria de Redox de Vanádio (do inglês, <i>Vanadium Redox Battery</i>)

SUMÁRIO

RESUMO.....	7
ABSTRACT	8
LISTA DE FIGURAS.....	9
LISTA DE TABELAS.....	12
LISTA DE ABREVIATURAS E SIGLAS	13
SUMÁRIO.....	15
1. INTRODUÇÃO	19
1.1. CONSIDERAÇÕES INICIAIS	19
1.2. MOTIVAÇÃO.....	21
1.3. REVISÃO BIBLIOGRÁFICA	23
1.4. OBJETIVOS.....	31
1.5. PUBLICAÇÕES DECORRENTES	32
1.6. ESTRUTURA DO TRABALHO	32
2. FUNDAMENTAÇÃO TEÓRICA.....	33
2.1. DISPOSITIVOS DE ARMAZENAMENTO DE ENERGIA (DAEs).....	33
2.2. BATERIAS.....	37
2.2.1. Parâmetros das Baterias	37
2.2.1.1. Capacidade Nominal e Energia Armazenada	38
2.2.1.2. Potência Nominal e Tempo de Descarga.....	39
2.2.1.3. Densidade de Energia e Densidade de Potência	40
2.2.1.4. Estado de Carga (SOC)	41
2.2.1.5. Estado de Saúde (SOH)	42
2.2.1.6. Profundidade de descarga (DoD)	43
2.2.1.7. Eficiência de Carga e Descarga	45
2.2.1.8. Autodescarga	46

2.2.1.9.	Custos	47
2.2.2.	Tipos de Baterias	48
2.3.	FLUXO DE POTÊNCIA COM SÉRIES TEMPORAIS.....	50
2.4.	MÉTODOS DE OTIMIZAÇÃO	52
2.4.1.	Algoritmo Genético	53
2.4.2.	<i>Outros Métodos de Otimização</i>	55
3.	METODOLOGIA.....	57
3.1.	MODELAGEM	58
3.1.1.	Modelagem de Baterias	58
3.1.2.	Modelagem de Outros Elementos	64
3.2.	PROBLEMA DE OTIMIZAÇÃO.....	64
3.3.	MÉTODO PROPOSTO.....	73
3.3.1.	Definição de Parâmetros de Criação dos Casos.....	74
3.3.2.	Simulação dos Casos.....	76
3.3.2.1.	Definição de Parâmetros Fixos.....	77
3.3.2.2.	Execução do Caso Base.....	78
3.3.2.3.	Resolução do Problema de Otimização	79
4.	SIMULAÇÕES E RESULTADOS	85
4.1.	INTRODUÇÃO.....	85
4.1.1.	Curvas adotadas	86
4.1.1.1.	Curvas de carga	86
4.1.1.2.	Curvas de custo de energia	94
4.1.1.3.	Curvas de geração fotovoltaica.....	95
4.1.2.	Casos S13 – Sistema IEEE 13 Barras	97
4.1.3.	Casos S34 – Sistema IEEE 34 Barras	98
4.1.4.	Casos S123 – Sistema IEEE 123 Barras	99
4.1.5.	Casos A – Comparação por Capacidade de Armazenamento.....	100

4.1.6.	Casos B – Comparação por Curva de carga	101
4.1.7.	Casos C – Comparação por Método de Otimização.....	101
4.1.8.	Casos D – Minimização de Perdas	102
4.2.	RESULTADOS OBTIDOS.....	102
4.2.1.	Sistema IEEE 13 Barras	102
4.2.1.1.	Casos S13.A	102
4.2.1.2.	Casos S13.B.....	105
4.2.1.3.	Casos S13.C.....	110
4.2.1.4.	Casos S13.D	117
4.2.2.	Sistema IEEE 34 Barras	119
4.2.2.1.	Casos S34.A	119
4.2.2.2.	Casos S34.B.....	121
4.2.2.3.	Casos S34.C.....	125
4.2.2.4.	Casos S34.D	132
4.2.3.	Sistema IEEE 123 Barras	134
4.2.3.1.	Casos S123.A	134
4.2.3.2.	Casos S123.B.....	135
4.2.3.3.	Casos S123.C.....	139
4.2.3.4.	Casos S123.D	146
5.	CONSIDERAÇÕES FINAIS.....	149
5.1.	CONCLUSÕES.....	149
5.2.	TRABALHOS FUTUROS	151
	REFERÊNCIAS.....	152
	ANEXO A – DETALHES DE MODELAGEM DAS BATERIAS.....	159
	ANEXO B – EXEMPLO DE APLICAÇÃO DO MODELO DE BATERIA	161
	ANEXO C – BARRAS DE ALOCAÇÃO DAS BATERIAS	166

1. INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

Os sistemas elétricos de potência são fundamentais na sociedade moderna, fornecendo energia elétrica para uma ampla gama de usuários, desde grandes indústrias até pequenos consumidores residenciais. Esses sistemas desempenham os papéis de produtores e distribuidores de eletricidade, sendo projetados para atender às necessidades de geração, transmissão e distribuição, garantindo a entrega de eletricidade com altos padrões de confiabilidade, disponibilidade, qualidade e segurança, mantendo também a eficiência econômica (Oliveira et al., 2021, p. 11).

Na etapa da geração, diferentes formas de energia, como a mecânica e a térmica, são convertidas em eletricidade em grandes usinas, como as hidrelétricas e as térmicas. Nesta fase, deve-se assegurar que a produção de energia seja adequada para atender à demanda dos consumidores e às perdas associadas à geração e ao transporte da eletricidade (Kagan; Oliveira; Robba, 2000, p. 15). No Sistema Interligado Nacional brasileiro, assim como na maioria dos casos, os grandes centros de geração estão localizados a distâncias consideráveis dos centros de consumo, sendo necessárias linhas de transmissão com capacidade para transportar grandes blocos de energia a longas distâncias (Robba, 2020, p. 21).

Após a transmissão da energia elétrica, é preciso distribuí-la aos consumidores. Os sistemas de distribuição de energia elétrica (SDEE) representam a etapa final do sistema elétrico, na qual a energia é levada até os consumidores finais, em níveis de tensão mais baixos em comparação com os da transmissão (Barros; Borelli; Gedra, 2014, p. 28). Nas últimas décadas, diversos fatores têm contribuído para a modernização destes sistemas, como avanços tecnológicos, questões ambientais, mudanças nas políticas energéticas, entre outros.

Com a transição energética, atualmente o setor elétrico passa por uma nova fase de reestruturação, impulsionada pela difusão dos Recursos Energéticos Distribuídos (REDs). Dois dos principais REDs são a Geração Distribuída (GD) e os Dispositivos de Armazenamento de Energia (DAEs). A inserção desses elementos tem sido acelerada devido à redução nos custos de equipamentos, a políticas de incentivo e à maior disseminação de tecnologias de

telecomunicação e controle, permitindo que os consumidores se tornem mais ativos na geração e gestão de sua própria energia (EPE, 2024, p. 12, 2019, p. 2).

Os REDs oferecem vantagens técnicas e sistêmicas significativas. Sua proximidade com o consumo pode reduzir perdas elétricas e postergar ou substituir investimentos em infraestrutura de transmissão e distribuição. Eles também contribuem para a diversificação da matriz energética com baixo impacto ambiental e promovem a criação de empregos. (EPE, 2019, p. 2; Silva et al., 2016, p. 12).

Os sistemas de armazenamento, especificamente, podem ser utilizados em uma gama de aplicações e seu uso pode acarretar em diversas vantagens para a rede elétrica, como: o deslocamento temporal da geração (*time shifting*), que permite armazenar energia em períodos de baixa demanda e utilizá-la em horários de pico; a suavização da geração intermitente de fontes renováveis, como solar e eólica, atenuando flutuações rápidas de potência; o suporte à regulação de tensão e ao controle de potência reativa; além de funções adicionais como o alívio de fluxos reversos, redução de picos de demanda (*peak shaving*), substituição de reserva girante, e suporte a *black start* em situações de falha na rede (Wong et al., 2019, p. 491).

Nos sistemas elétricos tradicionais, cuja geração de energia é proveniente de fontes hidráulicas e térmicas, existe facilidade no despacho por parte do operador do sistema elétrico, além de que os consumidores, em geral, não participam na injeção de energia no sistema. Nesses casos, o uso de tecnologias de armazenamento de energia não é justificado, especialmente por questões econômicas.

Entretanto, com a diminuição dos custos e com os avanços das tecnologias de fontes renováveis, especialmente fotovoltaicas e eólicas, essa realidade tem mudado drasticamente. Em diversos países no mundo as energias renováveis já possuem alta penetração na rede e grande contribuição na matriz elétrica. Apesar de possuírem diversas vantagens, especialmente do ponto de vista ambiental, as fontes renováveis também apresentam desvantagens como a intermitência e a imprevisibilidade ligadas a fenômenos climáticos. Além disso, a variação da demanda de eletricidade é naturalmente diferente, ao longo do dia, da geração proveniente dessas fontes. Nesse contexto, os dispositivos de armazenamento de energia tornam-se uma alternativa interessante para a modernização dos sistemas elétricos e sua adequação a esta nova realidade (Silva et al., 2016, p. 19).

Dentre os tipos de DAEs existentes, os sistemas de armazenamento de energia com baterias (BESS, do inglês *Battery Energy Storage Systems*) têm se destacado, tendo em vista

que, nos últimos anos, seu custo vem diminuindo e seu desempenho, aumentando. Dois aspectos importantes quando se trata do uso de BESS em SDEEs são sua localização no sistema e o gerenciamento dos seus processos de carga e de descarga ao longo de um horizonte de tempo. O primeiro aspecto diz respeito à alocação das baterias, que é feita levando em consideração as particularidades das barras do sistema elétrico, suas necessidades ou problemas e as possíveis vantagens do uso dos BESS em cada uma. O segundo aspecto abrange a operação desses dispositivos, realizada com a finalidade de otimizar aspectos operativos no SDEE. A otimização destes dois aspectos faz parte do método proposto neste trabalho, com objetivo de melhorar aspectos econômicos e técnicos dos SDEEs.


1.2. MOTIVAÇÃO

A crescente inserção dos Recursos Energéticos Distribuídos tem redesenhado o setor elétrico global e nacional. No Brasil, a Geração Distribuída (GD) destaca-se como o RED mais consolidado, ultrapassando os 40 GW de potência instalada em junho de 2025 (ANEEL, 2025). A GD fotovoltaica de pequeno porte lidera esse movimento, impulsionada principalmente por políticas de incentivo e quedas nos custos dos equipamentos.

Nesse contexto de descentralização e diversificação da matriz, os sistemas de armazenamento de energia, em especial as baterias, ganham relevância estratégica. Sua capacidade de mitigar a intermitência das fontes renováveis e aumentar a flexibilidade operacional da rede os posiciona como elementos chave da infraestrutura elétrica do futuro. Essa tendência já se reflete no volume de novos projetos. Na Figura 1, observa-se que as adições anuais de sistemas de armazenamento em baterias (BESS) em escala de rede passaram de menos de 1 GW em 2016 para mais de 11 GW em 2022 (IEA, 2023).


Paralelamente, a Figura 2 mostra que os investimentos globais nesse tipo de tecnologia saltaram de aproximadamente 1 bilhão de dólares em 2015 para uma projeção de 66 bilhões em 2025, aproximando-se do patamar dos investimentos em geração térmica a gás. Essa evolução tem sido favorecida por políticas de suporte e pela expressiva queda – de cerca de dois terços – nos custos de baterias na última década (IEA, 2025, p. 42).

Figura 1 – Adições anuais de BESS em escala de rede (GW), entre 2016 e 2022.



Fonte: IEA (2023).

Figura 2 – Investimentos em BESS por região (à esquerda) e por segmento (à direita), entre 2015 e 2025.¹



Fonte: IEA (2025, p. 42).

¹ Notas: *OECD Pacific* = Japão, Coreia do Sul, Austrália e Nova Zelândia; *2025e* = valores estimados para 2025; *Natural gas* = investimento total estimado em 2025 em geração a gás, com ou sem captura, uso e armazenamento de carbono (CCUS).

Em seu relatório intitulado *Renewables 2023*, a Agência Internacional de Energia destaca que essa dinâmica de investimentos vem sendo observada principalmente em regiões onde gargalos nas redes e o avanço das fontes renováveis variáveis exigem soluções de armazenamento para garantir a segurança energética. A expectativa é que, entre 2023 e 2028, mais de 400 GW de capacidade de armazenamento sejam instalados no mundo (IEA, 2024, p. 79).

A Agência Internacional para as Energias Renováveis (IRENA) destaca que, embora os recursos hidrelétricos com reservatórios sigam desempenhando papel relevante no equilíbrio entre oferta e demanda, as baterias devem se tornar a espinha dorsal do sistema elétrico após 2040, à medida que se tornem competitivas em larga escala. Até lá, espera-se a implementação de projetos voltados à resolução de problemas locais e com abordagens experimentais (IRENA, 2022, p. 74).

Diante desse cenário, torna-se evidente a importância de aprofundar os estudos sobre o papel das baterias no setor elétrico. A inclusão dos BESS nos planejamentos de expansão e operação de sistemas de distribuição traz diversos desafios, como a análise de seus impactos técnicos na rede e a avaliação dos benefícios econômicos provenientes de sua utilização. Com essa perspectiva, o tema revela-se atual e oferece amplas oportunidades de pesquisa.

1.3. REVISÃO BIBLIOGRÁFICA

O planejamento e a operação de sistemas de baterias em redes de distribuição têm sido objeto de significativa produção acadêmica nos últimos anos. Essa variedade de estudos reflete o potencial do armazenamento de energia, que pode ser explorado com diferentes finalidades, dependendo das necessidades do sistema e dos objetivos da análise. A revisão bibliográfica contida nesta seção reúne os principais trabalhos identificados durante o desenvolvimento desta pesquisa, destacando suas contribuições metodológicas e conceituais, e evidenciando a amplitude de possibilidades de aplicação dos sistemas de armazenamento na modernização das redes elétricas.

A base de dados de armazenamento de energia do Departamento de Energia dos Estados Unidos (DOE, 2023) fornece informações sobre projetos de armazenamento em todo o mundo. Dentre os projetos operacionais listados, a potência instalada mundialmente de sistemas de

baterias de diversas tecnologias é de 5,83 GW, enquanto a capacidade de armazenamento instalada é de 11,94 GWh. Um destaque destes dados vai para a alta participação dos Estados Unidos, que conta com 4,80 GW e 9,41 GWh, respectivamente; além disso, os projetos com maior potência (FPL Manatee Energy Storage Center, com 409 MW) e maior capacidade (McCoy Battery Storage, com 920 MWh) também estão no país. Outros países que se destacam são Austrália, Japão, Alemanha, Itália, China e Coreia do Sul.

A Direção-Geral de Energia da União Europeia publicou, em 2020, a base de dados das tecnologias e instalações europeias de armazenamento de energia (DG ENER, 2020). Nela, três países se destacaram pelo uso de sistemas com baterias: 1) o Reino Unido, com a maior potência instalada, 569,8 MW; 2) a Alemanha, com a segunda maior potência instalada, 406,2 MW; e 3) a Itália, com a maior capacidade instalada, 305,7 MWh. É interessante ressaltar que os dois primeiros são compostos majoritariamente por sistemas de Lítio-Íon (Li-Ion) e suas potências são maiores do que suas capacidades instaladas, com uma razão em torno de 8 a 10 MW/MWh. Enquanto isso, a Itália conta principalmente com baterias baseadas em Sódio (NaS, entre outras) e sua razão entre potência e capacidade fica em torno de 0,185 MW/MWh, o que as concede um maior tempo de descarga na potência nominal.

A Associação Europeia de Armazenamento de Energia (EASE, 2020), em seu sumário de aplicações de armazenamento de energia, elencou 36 serviços que estas tecnologias podem oferecer, organizando-os em cinco categorias: suporte à geração e ao armazenamento em grande escala, serviços ancilares, suporte à infraestrutura de transmissão, suporte à infraestrutura de distribuição, e gerenciamento de energia por parte do consumidor. Além disso, cada uma das 36 aplicações foi categorizada em termos de maturidade (serviço existente, emergente ou futuro) e brevemente descrita.

Nadeem et al. (2019) fazem uma análise das tecnologias de armazenamento de energia, com foco em suas características construtivas, princípios operacionais e potenciais campos de aplicação nos sistemas de potência. É dada especial atenção aos diversos tipos de baterias, ressaltando as vantagens, desvantagens, desafios e possíveis aplicações. Segundo os autores, as baterias de chumbo ácido – tecnologia consolidada, robusta e de bom custo-benefício – são utilizadas como reserva de energia em casos de fornecimento emergencial, em aplicações de serviços de rede, na suavização da geração renovável e até em veículos híbridos. Outras tecnologias de baterias trazem diversas melhorias, mas altos custos e outros desafios operacionais podem ser fatores limitantes em sua aplicação.

Em Olabi et al. (2021), são discutidas características de diversas tecnologias de armazenamento de energia, apontando, em cada caso, as principais aplicações e os desafios tecnológicos e econômicos associados. No caso das baterias, foram destacadas como promissoras as aplicações de qualidade de energia, *peak shaving* e suprimento energético integrado com fontes renováveis.

Em sua revisão de projetos e documentos acerca dos usos de BESS, Wüllner et al. (2021) trazem um panorama das aplicações atuais mais importantes, divididas em categorias e apresentadas em forma de tabela. Nela, são vistos os respectivos provedores dos serviços, os níveis de rede, o potencial técnico-econômico e alguns artigos científicos relevantes para uma compreensão abrangente dos empregos de BESS e seus potenciais de receita. Os autores ressaltam seis destas aplicações que, em sua visão, possuem alta relevância e potencial: suporte de renováveis, serviços ancilares (com destaque para o controle de frequência), *peak shaving*, deslocamento temporal da energia gerada e consumida, e o adiamento de investimentos tanto na rede de distribuição quanto de transmissão.

O trabalho de Prakash et al. (2022) investiga de forma mais aprofundada e abrangente o uso de BESS para fornecimento de serviços ancilares em redes de distribuição. Após analisar o cenário geral sobre o assunto, os autores chegaram à divisão entre serviços de curto prazo (de resposta rápida, como suporte de tensão, regulação de frequência e *black start*) e de longo prazo (que focam em armazenar e utilizar grandes quantidades de energia, como *peak shaving*, arbitragem energética e nivelamento de carga). O trabalho traz um panorama acerca dos desafios da aplicação de BESS em SDEEs, abordando fatores econômicos, tecnológicos, ambientais, regulatórios e de planejamento, além de abordar direções de pesquisa futura para suprir as lacunas identificadas.

Com foco nos sistemas de distribuição, Das et al. (2018) realizam uma extensa revisão bibliográfica acerca das aplicações dos diversos tipos de dispositivos de armazenamento. Dentre os diversos métodos citados para otimizar as estratégias de alocação, dimensionamento e operação de DAEs, os autores dão destaque para as meta-heurísticas, especialmente em abordagens híbridas que combinam mais de um método com diferentes vantagens e desvantagens.

Rahman et al. (2020) realizaram uma revisão focada nas avaliações técnico-econômicas e ambientais de sistemas de armazenamento de energia, incluindo tecnologias mecânicas, eletroquímicas, químicas e térmicas. Sua análise, que abrangeu publicações abordando

avaliações técnico-econômicas e do ciclo de vida, fornece uma atualização sobre os avanços recentes e estabelece um banco de dados contendo principalmente indicadores de tomada de decisão. Os autores destacam a vida útil, a eficiência e a duração dos ciclos como parâmetros de mais impacto nos custos e nos impactos ambientais desses sistemas.

Suyambu e Vishwakarma (2024) discutem o uso de BESS para melhorar o desempenho operacional da rede, revisando aplicações voltadas a eficiência, estabilidade e confiabilidade. Quanto à profundidade de descarga, os autores argumentam que ela é um fator crítico na degradação das baterias, influenciando diretamente sua vida útil e desempenho operacional, sendo essencial considerá-la em estratégias de controle dos BESS.

Sobre o problema de dimensionamento e localização de DAEs, Zidar et al. (2016) apresentam uma revisão voltada a redes de distribuição, classificando as metodologias de solução em quatro categorias principais: analíticas, programação matemática, busca exaustiva e métodos heurísticos. O trabalho destaca alguns desafios para pesquisas na área, como capturar o valor de serviços específicos e compreender melhor custos e benefícios de várias tecnologias de armazenamento e sua comparação com tecnologias concorrentes ou complementares, como a resposta à demanda.

O trabalho de Garcia-Garcia et al. (2017) avalia economicamente o uso de BESS em SDEEs como alternativa para substituir ou adiar investimentos convencionais em infraestrutura. A metodologia proposta compara os custos de investimento em BESS com os custos de expansão da rede, considerando perfis de carga e o crescimento da demanda ao longo do horizonte de planejamento. As variáveis otimizadas incluem a localização e a capacidade do sistema de armazenamento, bem como sua operação ao longo do tempo. Os testes, realizados com dados reais de alimentadores representativos de uma distribuidora norte-americana, indicam que, em diversos cenários, o uso de BESS é viável para esta finalidade.

No seu estudo de caso em uma rede de distribuição na Arábia Saudita, Almehizia et al. (2020) avaliam a viabilidade do uso de baterias para adiamento de investimentos. Para isso, a alocação e o dimensionamento das baterias são obtidos utilizando um modelo de otimização matemática que também inclui a possibilidade de investimentos em infraestrutura de expansão do sistema. Já a operação das baterias é realizada com uma abordagem de *peak shaving*. Os resultados obtidos mostram que uma redução significativa dos custos de baterias é necessária para que essa aplicação se torne viável.

Também com foco em adiar investimentos na expansão de redes de distribuição, Pedersen et al. (2021) propõem um novo modelo de fluxo de potência ótimo multi-período que inclui duas opções de flexibilidade: corte de geração (*curtailment*) e dispositivos de armazenamento. Os melhores resultados foram obtidos quando as duas opções foram utilizadas, mas os autores não analisaram as perdas de receita causadas pelos cortes de geração.

O trabalho de Singh e Rawat (2021) foca no uso de geradores eólicos e fotovoltaicos distribuídos e BESS para minimização de perdas em redes de distribuição. Enquanto a GD tem grande efeito na redução das perdas, as baterias são utilizadas principalmente na integração das fontes renováveis, armazenando energia excedente e fornecendo-a quando necessário. Os autores propõem o uso do PSO e de um algoritmo de programação não linear, para resolver, respectivamente os problemas de alocação e dimensionamento dos dispositivos.

O artigo de Selim et al. (2024) propõe uma abordagem para a alocação ótima de GD fotovoltaica e BESS em SDEEs, considerando incertezas e variações de carga. O método desenvolvido, denominado *Improved Runge–Kutta optimizer*, combina três estratégias para melhorar a exploração e evitar mínimos locais. A otimização é realizada em duas etapas: primeiro, determina-se a capacidade e a localização ideais dos sistemas fotovoltaicos; depois, gerencia-se a energia armazenada considerando a demanda variável e incertezas de geração. A função objetivo visa minimizar as perdas de energia na rede elétrica e os testes foram realizados em dois sistemas IEEE (33 e 69 barras), alcançando bons resultados em comparação com outros métodos.

Saha e Ganguly (2022) utilizam uma metodologia baseada em algoritmo genético (AG) para otimizar o dimensionamento e a operação de BESS em sistemas de distribuição com o objetivo de minimizar o custo de perdas de energia, incluindo também gastos com investimento e operação das baterias por meio de um custo diário baseado nos seus ciclos de uso. A alocação das baterias é realizada nas barras com os maiores riscos de desvio de tensão, por meio de um processo que atualiza esse parâmetro iterativamente.

Camargo (2016) desenvolveu um modelo matemático de Programação Cônica de Segunda Ordem Inteira Mista para resolver o problema de alocação e operação ótimas de BESS em sistemas de distribuição, com o objetivo de minimizar o custo de compra de energia pela subestação. Também há um custo associado aos ciclos de carga e descarga, e a profundidade de descarga é incluída como restrição operacional, ambos visando a preservação da vida útil das baterias.

Como destaca a IEA (2025, p. 43), projetos de armazenamento em baterias vêm buscando múltiplas fontes de receita para garantir sua viabilidade econômica – como arbitragem de energia, regulação de frequência, *peak shaving* e integração de renováveis –, mas a ausência de uma regulação adequada ainda limita o pleno aproveitamento dessas funções. Apesar disso, o armazenamento em larga escala continua sendo considerado essencial para garantir a flexibilidade da rede elétrica e viabilizar uma maior penetração de energias renováveis.

Um modelo estocástico em duas etapas é proposto por Khajeh et al. (2023) para alocação e dimensionamento de BESS em redes de distribuição. Na primeira etapa, o método busca o dimensionamento mínimo necessário para melhorar a confiabilidade da operação, atuando em congestionamentos ou interrupções de fornecimento na rede local. Já a segunda etapa encontra o tamanho ótimo dos BESS por meio do lucro obtido com serviços voltados para o sistema de transmissão, especificamente por meio da reserva de contenção de frequência. São realizados dois estudos de caso para validação do método, um deles com dados reais de mercado e operação de um sistema de distribuição rural na Finlândia.

Babacan et al. (2016) propõem um modelo de otimização multiobjetivo baseado em algoritmo genético para alocação e dimensionamento de BESS em redes de distribuição com alta penetração de geração solar fotovoltaica. Os objetivos principais são minimizar variações de tensão e perdas de energia, considerando também os custos de capital e a vida útil dos sistemas. O despacho diário das baterias é determinado por uma rotina de programação linear que visa minimizar o pico de demanda não coincidente, utilizando previsões de carga e geração solar como entrada. Os testes são realizados no sistema teste IEEE 8500-Node.

Alves (2020) analisa o impacto da inclusão de BESS em redes de distribuição com elevada penetração de GD fotovoltaica, avaliando parâmetros como nível de perdas, violações de tensão e carregamento de condutores e transformadores. O estudo utiliza simulações no OpenDSS em conjunto com o Matlab e considera estratégias operacionais vantajosas para os consumidores, baseadas nas tarifas branca e binômia. Os resultados indicam que a aplicação de BESS, mesmo com operação descentralizada, pode agregar benefícios indiretos para a rede.

Com o intuito de reduzir efeitos negativos provenientes de fontes renováveis, Boonluk et al. (2020) alocam baterias para minimização dos custos associados a desvios de tensão, perdas de energia e picos de demanda. O estudo compara o desempenho do AG e da otimização por enxame de partículas (PSO) para resolver o problema de localização e dimensionamento ótimos de baterias na rede de distribuição IEEE 33 barras. O PSO chegou aos melhores

resultados, mas com ambos os métodos foi possível observar melhorias nos três objetivos de otimização. Em um artigo subsequente, Boonluk et al. (2021) utilizam o PSO para realizar um estudo de caso com BESS em um alimentador de uma subestação na Tailândia, com dados reais de carga e geração fotovoltaica. Os mesmos objetivos de otimização foram utilizados, e foi possível melhorar o desempenho de cada um deles por meio da metodologia proposta.

Razali et al. (2024) comparam um método denominado de *Grasshopper Optimization Algorithm* (GOA) com a programação evolutiva (EP) para alocação e dimensionamento de baterias em SDEEs. Os testes, realizados no sistema IEEE 69 barras, apontam para a eficiência do GOA, que foi capaz de reduzir perdas e custos totais, encontrando valores menores do que o EP em todos os casos.

O GOA também é utilizado por Kasturi et al. (2020) para otimizar a alocação e o dimensionamento de BESS em redes de distribuição, com os objetivos de minimizar perdas, melhorar o perfil de tensão e adiar investimentos em infraestrutura da rede. O gerenciamento da energia das baterias é feito por meio de uma estratégia baseada em *peak shaving*, e essa operação também contribui para a diminuição dos custos de compra de energia.

Utilizando um modelo com acúmulo de receitas pelo uso de baterias conectadas a redes de comunidades com energia renovável, Pocola et al. (2025) desenvolvem uma metodologia baseada em programação linear para dimensionamento e controle ótimos de BESS. Os autores avaliam economicamente o modelo de aluguel de baterias para operadores e comunidades, analisando diferentes modos de tarifação. O estudo utiliza dados reais de geração, demanda, tarifas e dados de baterias em um estudo de caso nos Países Baixos, que obteve resultados positivos de economia a partir do modelo proposto.

Utilizando a co-simulação com o OpenDSS, Barukčić et al. (2023) têm os objetivos de minimizar as perdas elétricas e a importação de energia pela subestação. Para isso, na fase de planejamento, são otimizados a alocação, o dimensionamento e o fator de potência (FP) de unidades de BESS e GD (solar, eólica e biogás), além do despacho de BESS e biogás. Os problemas de otimização são formulados com horizonte anual e resolução horária, com intuito de incorporar todas as variações anuais de GD e demanda. Porém, como, na fase de operação, os dados de carga e geração ainda diferem dos utilizados na fase de planejamento, os autores propõem o uso de uma rede neural artificial para estimar os perfis de potência e FP em tempo real. Os testes, realizados no sistema IEEE 37 barras, mostraram a eficácia do método de duas

etapas proposto, que foi capaz de reduzir as perdas e a importação de energia mesmo em casos com incertezas de até 80% entre o planejamento e a operação.

O trabalho de Mazza et al. (2020) também adota metodologias diferentes para as fases de planejamento e operação de BESS. O objetivo é melhorar condições gerais do SDEE, considerando aspectos econômicos (custos de investimento, operação e manutenção) e técnicos (limites de tensão e fluxo reverso). Para isso, as baterias são alocadas na rede de baixa tensão utilizando um algoritmo genético modificado, e o agendamento da operação é determinado por meio de um algoritmo guloso (*greedy*) em um tempo relativamente curto. Porém, os autores consideram incertezas na geração e na carga, sendo necessária a criação de diversos cenários. A solução final é obtida através de uma abordagem de tomada de decisão multicritério, que aplica conceitos da teoria da decisão a um conjunto de alternativas de planejamento selecionadas.

Pham et al. (2025) propõem uma versão modificada do algoritmo de otimização do coioote (MCOA) para minimização de custos totais, incluindo: investimento, operação e manutenção de BESS, turbinas eólicas e painéis fotovoltaicos; custo de importação de energia para suprimento de cargas e perdas na rede; e custo de emissões geradas por usinas convencionais. Uma contribuição importante do estudo é a restrição do nível de distorção harmônica proveniente das cargas não-lineares e dos conversores de potência acoplados às fontes distribuídas. Os autores utilizam a interface entre Matlab e OpenDSS para realizar as simulações de fluxo de potência no sistema teste IEEE 123 barras e em um sistema real de 55 barras no Vietnã, e os resultados mostram que o uso de BESS em conjunto com GD contribui para uma redução significativa dos custos totais, além de resultar em menores valores de perdas elétricas.

Nesta seção, foram apresentados estudos com diferentes objetivos, que trazem contribuições relevantes para o uso de baterias em sistemas de distribuição de energia elétrica. Apesar de não abranger toda a produção científica da área, esse levantamento ofereceu uma base conceitual importante para o desenvolvimento deste trabalho. A partir dessa revisão, constata-se que a questão de alocação e gerenciamento de baterias ainda não está totalmente definida, estimulando novas pesquisas nesta área.

1.4. OBJETIVOS

Este trabalho tem como objetivo principal desenvolver um método para alocação e operação de baterias em sistemas de distribuição com a finalidade de melhorar dois aspectos operativos: o custo com aquisição de energia e as perdas elétricas.

Para isso, a pesquisa visa construir um modelo de otimização capaz de incorporar restrições técnicas, considerar diferentes curvas de carga e cenários tarifários, e executar fluxos de potência com acoplamento temporal, modelando corretamente as variações do sistema de distribuição e a dinâmica do estado de carga das baterias. O modelo também deverá incorporar restrições operativas, por exemplo, não permitindo que o gerenciamento das baterias ocasione um fluxo reverso ou o aumento da demanda máxima da subestação.

Além disso, busca-se criar uma ferramenta de simulação capaz de variar diversos parâmetros, como: o sistema elétrico simulado, as características técnicas das baterias, o método de otimização empregado, objetivos e restrições, entre outros. Por meio dessa flexibilidade, planeja-se a criação de diversos cenários de teste, para avaliar como mudanças em determinados parâmetros afetam os resultados da otimização, além de validar a metodologia proposta.

Este trabalho é a continuação de estudos iniciados em Loureiro (2022) e expande tópicos como: a aplicação de baterias com finalidade econômica e na presença de tarifas variáveis de energia ao longo do dia, a presença de GD em conjunto com as baterias, a avaliação de outros métodos de otimização na solução do problema, entre outros.

Em outros trabalhos, realizou-se a análise do investimento em baterias considerando índices econômicos. Entretanto, no presente trabalho, as simulações têm o objetivo de avaliar apenas os benefícios do uso das baterias, não levando em conta os custos envolvidos na aquisição desses equipamentos. A ideia é que a decisão de alocar baterias já está definida, e o objetivo é alocar e gerenciar de forma otimizada, o que será realizado com o método proposto.

A ferramenta proposta será implementada utilizando o Matlab como ferramenta principal, contemplando a elaboração e a execução dos diversos casos de teste, com destaque para a etapa de otimização. Internamente a esse processo, será feita a interface com o OpenDSS para executar os fluxos de potência e obter os resultados de simulação, os quais são utilizados dentro dos processos de otimização.

1.5. PUBLICAÇÕES DECORRENTES

O presente trabalho resultou nas seguintes publicações:

- “Método para Dimensionamento e Gerenciamento da Operação de Baterias em Sistemas Industriais para Minimização de Custos de Energia”, artigo apresentado no X Simpósio Brasileiro de Sistemas Elétricos (SBSE), em Manaus – AM, em outubro de 2023;
- “Avaliação do Impacto da Capacidade e da Eficiência de Baterias na Redução das Perdas e no Custo de Operação de Sistemas de Distribuição”, artigo apresentado no XXV Congresso Brasileiro de Automática (CBA), no Rio de Janeiro – RJ, em outubro de 2024.

1.6. ESTRUTURA DO TRABALHO

A estrutura deste trabalho está organizada em cinco capítulos, além dos anexos. O Capítulo 1 apresenta uma introdução geral sobre o tema abordado neste trabalho, a motivação para o estudo do tema, uma breve revisão bibliográfica da área, os objetivos do trabalho e, por fim, as publicações decorrentes dele. No Capítulo 2, será feita a fundamentação teórica necessária para a compreensão do método proposto, tratando sobre armazenamento de energia, baterias, fluxo de potência com séries temporais e métodos de otimização. No Capítulo 3, será apresentada a metodologia do trabalho, contemplando a modelagem dos elementos do sistema, a formulação do problema de otimização e a estratégia proposta para a resolução dos casos. O Capítulo 4 reúne as simulações realizadas e a análise dos resultados obtidos, com aplicação da metodologia em diferentes sistemas teste e sob variadas condições. O Capítulo 5 apresenta as considerações finais, destacando as conclusões gerais e possíveis direções para trabalhos futuros. Por fim, três anexos complementam o trabalho, com detalhes da modelagem das baterias e dos resultados.

2. FUNDAMENTAÇÃO TEÓRICA


Este capítulo tem como objetivo apresentar os conceitos fundamentais para a compreensão do método desenvolvido neste trabalho. Inicialmente, será oferecida uma visão geral sobre os dispositivos de armazenamento de energia e, em seguida, será feita uma ênfase sobre as baterias, incluindo suas principais características e os diferentes tipos existentes. Posteriormente, será abordada a metodologia do fluxo de potência com séries temporais aplicada neste trabalho. Por fim, será resumido o tema dos métodos de otimização, com os conceitos principais relacionados aos métodos utilizados.

2.1. DISPOSITIVOS DE ARMAZENAMENTO DE ENERGIA (DAEs)

O processo de armazenamento de energia elétrica é composto pela conversão da energia elétrica para outra forma de energia, podendo ser convertida de volta quando necessário (Santos, 2018, p. 21). Os Dispositivos de Armazenamento de Energia (DAEs), portanto, são equipamentos capazes de realizar estes processos de conversão, armazenando energia para consumo em um momento posterior.

Gantz (2012, p. 10) destaca que as tecnologias de armazenamento de energia elétrica consistem em dois estágios fundamentais: o de conversão de energia elétrica e o de armazenamento de energia. O estágio de conversão desempenha o papel de transformar a energia elétrica em uma forma adequada para ser transferida ao sistema de armazenamento e recuperada dele. Essa conversão pode ocorrer por meio de máquinas elétricas rotativas, que convertem diretamente a energia elétrica em energia cinética rotacional, ou através de conversores eletrônicos de potência, que realizam a conversão entre corrente alternada (CA) e corrente contínua (CC), por exemplo a partir de uma conexão à rede elétrica. Já o estágio de armazenamento é responsável pelos mecanismos que possibilitam o fornecimento e a absorção de energia em seu estado armazenado. A relação entre a rede elétrica, o processo de conversão e o armazenamento é ilustrada no esquema visto na Figura 3.

Figura 3 – Diagrama conceitual de um sistema de armazenamento conectado à rede.




Fonte: Adaptado de Gantz (2012, p. 10).

Diversas tecnologias de armazenamento de energia estão disponíveis para atender às diferentes demandas do setor elétrico, cada uma com características específicas. Essa diversidade permite que soluções sejam adaptadas a diferentes aplicações e requisitos técnicos, ampliando as possibilidades de utilização em sistemas elétricos.

Conforme ilustrado na Figura 4, as tecnologias de armazenamento de energia podem ser classificadas de acordo com a forma de energia armazenada, por exemplo: mecânica (hidrelétrica reversível – *pumped hydro*, ar comprimido, volante de inércia – *flywheel*), térmica (sistemas de termoacumulação), elétrica e eletromagnética (capacitores e bobinas supercondutoras), eletroquímica (baterias), entre outras.

Figura 4 – Tecnologias de armazenamento de energia.



Fonte: Camargo (2016, p. 27).

Camargo (2016, p. 27) destaca que os sistemas que funcionam por meio do armazenamento de energia mecânica utilizam-se de máquinas rotativas (motores e geradores) para realizar os processos de conversão. Nas hidrelétricas reversíveis, bombas são utilizadas para aumentar a elevação da água, armazenando-a com maior energia potencial e, utilizando-a para acionar turbinas quando necessário. Nos sistemas em que a energia é armazenada em forma de ar comprimido, este ar – em alta temperatura e pressão – é posteriormente utilizado em turbinas a gás para conversão em energia elétrica. Já os volantes de inércia são dispositivos mecânicos cujo armazenamento é feito na forma de energia cinética rotacional.


Os dispositivos de armazenamento de energia térmica são compostos por sistemas isolados de termoacumulação (capazes de armazenar calor), que podem trabalhar com água, vapor fundido, entre outros. Após estabilizado, o calor armazenado pode ser utilizado posteriormente em máquinas térmicas para conversão em energia elétrica (Alves, 2020, p. 38).

Os sistemas de armazenamento de energia elétrica e eletromagnética são representados respectivamente pelos capacitores – que armazenam energia por meio do campo elétrico produzido entre placas carregadas – e pelas bobinas supercondutoras, cujo armazenamento ocorre por meio de campo magnético. Estas últimas são compostas por materiais supercondutores de baixíssima resistência, e precisam operar em temperaturas criogênicas, próximas a -270°C (Aneke; Wang, 2016, p. 26).

As baterias são os principais dispositivos de armazenamento de energia eletroquímica, que são o objeto central deste trabalho e serão tratadas com mais detalhes na seção a seguir. Conforme apontado por Vian et al. (2021), entre os diversos tipos de DAEs as baterias destacaram-se significativamente na última década, apresentando avanços notáveis em termos de eficiência, densidade de potência e energia, além da diminuição dos custos.

A seleção da tecnologia de armazenamento de energia mais adequada depende de uma avaliação criteriosa das necessidades técnicas da aplicação e das características específicas de cada tecnologia. Na Figura 5, é visto um diagrama com as diversas tecnologias de armazenamento de energia em função de sua potência nominal e tempo de descarga.

Figura 5 – Tempo de descarga e potência nominal de diversas tecnologias de DAEs.



Fonte: Pokhriyal et al. (2023)

Na figura, as tecnologias são coloridas de acordo com o tipo de energia armazenada: Mecânica (amarelo), térmica (laranja), eletromagnética (cinza), elétrica (verde azulado), eletroquímica (verde) e química (roxo). Também é feita a divisão entre as aplicações de suprimento de potência (*power supply*, no canto inferior esquerdo), suporte à rede (*grid support*, ao centro) e armazenamento de energia em larga escala (*bulk energy storage*, no canto superior direito).

Além da potência e do tempo de descarga, outros fatores como densidade energética, eficiência e vida útil devem ser considerados para garantir a compatibilidade com os requisitos do sistema. Essa análise é essencial para maximizar o desempenho e a viabilidade da solução adotada. Estes e outros fatores serão vistos na seção a seguir, aplicados de forma mais direta às baterias.

2.2. BATERIAS

As baterias são dispositivos eletroquímicos que armazenam e fornecem energia elétrica por meio da reação química de oxirredução. Essa reação ocorre a partir da transferência de elétrons entre os reagentes (eletrodos ânodo e cátodo), por meio de um eletrólito. A corrente flui por meio de um circuito externo, caracterizando o processo de descarga da bateria.

Godinho et al. (2022, p. 58) classificam as baterias entre primárias e secundárias, diferenciando-as pela capacidade ou não de realizar a reação química reversa entre os dois eletrodos, recarregando as baterias. Nas baterias secundárias (recarregáveis), utiliza-se tensão e corrente de uma fonte externa para ionizar o eletrólito e restabelecer os eletrodos ao seu estado inicial (Eyer; Corey, 2010, p. 11). Essa reação constitui o processo de carga da bateria.

Esses processos são realizados em ciclos de carga e descarga. O número de ciclos realizados é frequentemente utilizado para mensurar a vida útil das baterias, com condições de operação especificadas.

Com o objetivo de esclarecer os aspectos fundamentais relacionados ao funcionamento e à modelagem das baterias, a seguir são apresentadas as definições dos principais parâmetros que caracterizam seu comportamento operacional.


2.2.1. Parâmetros das Baterias

A modelagem adequada de uma bateria e do seu funcionamento envolve a identificação de grandezas que são definidas a partir das propriedades elétricas, físico-químicas e operacionais do dispositivo. O conhecimento desses parâmetros é essencial para que as baterias

sejam dimensionadas, modeladas, simuladas e operadas corretamente, uma vez que eles influenciam diretamente o desempenho operacional e a adequação à aplicação em questão.

Em trabalho anterior (Loureiro, 2022), foram apresentados os principais parâmetros da modelagem de baterias para aplicação em sistemas de distribuição. Tais conceitos baseiam-se no modelo de bateria ilustrado na Figura 6, e serão revisitados com mais detalhes nas subseções a seguir.

Figura 6 – Modelo de bateria adotado.



Fonte: Dugan (2010) apud Oliveira (2018, p. 36).

2.2.1.1. Capacidade Nominal e Energia Armazenada

A capacidade nominal (E_{nom}) é uma grandeza que indica o valor máximo de energia que a bateria pode armazenar e eventualmente fornecer ao sistema na forma de eletricidade, sendo comumente expressa em Ah (ampère-hora) ou Wh (watt-hora).

Quando vista em Ah (ampère-hora), esta grandeza representa a corrente que o dispositivo pode receber ou fornecer em um intervalo de tempo estabelecido, para um dado nível de tensão e em regimes de operação específicos. Quando expressa em Wh, ou mais comumente seus múltiplos kWh e MWh, indica de forma mais direta a energia armazenada, representando também a potência que esse dispositivo pode fornecer ou receber durante determinado período.

Por exemplo, uma bateria de 100 Ah, operando na tensão nominal, pode entregar uma corrente de 1 A por 100 horas. Semelhantemente, uma bateria de 100 kWh pode fornecer uma potência de 1 kW por 100 horas, e assim entregar ao sistema o total de 100 kWh de energia elétrica ao longo deste tempo.

A energia armazenada (E_{arm}), por sua vez, corresponde à quantidade de energia efetivamente armazenada na bateria na forma de energia química em dado momento. Assim, após o fim de um ciclo de descarga completo, não há energia armazenada na bateria. Em seguida, caso seja fornecida energia para a bateria com uma potência de 1 kW por um período de uma hora, a energia armazenada será de 1 kWh.

É importante notar que os exemplos anteriores são bastante simplificados, para fins didáticos, e que foram desconsideradas as perdas de energia na bateria, assim como outras questões relacionadas a potência nominal, estado de saúde, etc., as quais serão abordadas nas próximas seções.

2.2.1.2. Potência Nominal e Tempo de Descarga

A potência nominal (P_{nom}) é o valor estabelecido pelo fabricante para a taxa à qual a energia pode ser continuamente armazenada ou extraída da bateria (Gantz, 2012, p. 12).

Nota-se que a potência nominal de uma bateria está diretamente relacionada à sua capacidade nominal e ao tempo requerido para completar um processo de carga ou descarga. Quanto maior a potência nominal, mais rapidamente a bateria é capaz de entregar ao sistema a energia armazenada nela.

Define-se, portanto, o tempo de descarga (t_{desc}) como o tempo necessário para que uma bateria complete um processo de descarga (ou carga) total, na sua potência nominal (Eyer; Corey, 2010, p. 13). Esse tempo pode ser calculado através da razão entre E_{nom} e P_{nom} . Sendo assim, a relação entre essas grandezas pode ser expressa pela Equação (1).

$$E_{nom} = P_{nom} \times t_{desc} \quad (1)$$

Assim, baterias com a mesma capacidade nominal podem possuir diferentes configurações de potência nominal e tempo de descarga, conforme explicado em Octaviano (2021, p. 32). Além disso, em geral, a potência e o tempo de descarga variam significativamente entre os diversos tipos e composições químicas das baterias, conforme visto anteriormente na Figura 5.

2.2.1.3. *Densidade de Energia e Densidade de Potência*

A densidade de energia (ou energia específica) e a densidade de potência (ou potência específica) dos DAEs são grandezas intimamente ligadas às dimensões desses equipamentos. Em um dispositivo de armazenamento com determinado volume ou massa, a densidade de energia associa o quanto de energia pode ser armazenada nesse dispositivo, enquanto a densidade de potência é a taxa à qual a energia pode ser fornecida a ele ou a partir dele.

Esses parâmetros podem ser estabelecidos da perspectiva da massa ou do volume do dispositivo, sendo possível, portanto, utilizar Wh/kg ou Wh/L como unidades para a densidade de energia, e W/kg ou W/L para a densidade de potência.


A densidade de energia e a densidade de potência são especialmente relevantes em aplicações com limitações de espaço ou peso, como em ambientes urbanos ou instalações compactas. Nesses casos, a capacidade das baterias de armazenar e fornecer energia de forma eficiente em volumes reduzidos representa uma vantagem significativa. Essa característica influencia diretamente a escolha tecnológica quando a disponibilidade física é um fator restritivo, favorecendo o uso de baterias em relação a outras alternativas de armazenamento.

A densidade de energia de uma bateria varia bastante a depender do seu tipo. A Figura 7 mostra uma comparação entre os diversos tipos de armazenamento, incluindo diversos tipos de baterias, em termos de suas densidades de potência e energia.

Na figura, observa-se que alguns tipos de baterias, como as de Redox de Vanádio (VRB) e de Polissulfeto-Bromo (PSB) possuem densidades baixas, enquanto outras como as de Íons de Lítio (Li-ion) apresentam valores significativamente mais altos.

Nota-se também que, a depender da composição das baterias, suas possíveis densidades podem compor intervalos maiores ou menores, indicando a variabilidade da tecnologia. Por exemplo, as baterias de Sódio-Enxofre (NaS) podem apresentar densidades de potência na faixa de aproximadamente 100 a 140 W/L, enquanto as de Níquel-Cádmio (NiCd) podem estar entre 80 e 600 W/L. A maior variabilidade pode ser sinal de maior flexibilidade ou, por outro lado, de uma falta de padronização. Por outro lado, faixas mais estreitas podem indicar maior previsibilidade.

Figura 7 – Comparação de densidades de potência e energia.



Fonte: Adaptado de Luo et al. (2015, p. 527).

Essa comparação mostra como a escolha correta do tipo de bateria afeta drasticamente as densidades de energia e potência do dispositivo. E, como esses parâmetros são cruciais para o projeto, essa escolha também é determinante para avaliar se a bateria projetada é adequada para a respectiva aplicação.


2.2.1.4. Estado de Carga (SOC)

O estado de carga (SOC, do inglês *state of charge*) é um parâmetro crucial para a operação de baterias. O SOC é uma medida da quantidade de energia armazenada na bateria em um determinado momento, expressa como uma porcentagem da capacidade nominal total da bateria (Picciano, 2007, p. 15). Numericamente, o SOC no instante t é obtido a partir da Equação (2).

$$SOC_t = \frac{E_{arm,t}}{E_{nom}} \times 100 \% \quad (2)$$

Variações na quantidade de energia armazenada na bateria resultam necessariamente em variações de SOC. Logo, o SOC da bateria aumenta durante o processo de carga e diminui durante o processo de descarga. Como a energia armazenada na bateria é sempre positiva e inferior à sua capacidade nominal, conclui-se que o SOC estará entre 0 e 100 % em qualquer instante de tempo.

No entanto, Oliveira (2018, p. 36–38) demonstra que o funcionamento e a vida útil das baterias são prejudicados pela operação com valores de SOC próximos a esses limites. Isto ocorre devido à variação das tensões internas da bateria nestas situações, conforme exemplificado no gráfico visto na Figura 8. Portanto, recomenda-se que as baterias não operem perto desses limites, sendo comum a utilização de restrições nesse sentido.



Fonte: Oliveira (2018, p. 37).

2.2.1.5. Estado de Saúde (SOH)

Frequentemente, a vida útil das baterias é medida em termos do número de ciclos de carga e descarga que ela pode realizar antes de sofrer uma perda significativa de desempenho (IRENA, 2015, p. 6). Com o envelhecimento da bateria, ou seja, após vários ciclos de carga e descarga, sua degradação pode ser observada através da redução de sua capacidade e potência.

Esse fenômeno é evidente em baterias de dispositivos eletrônicos de uso cotidiano, que, com o tempo, apresentam uma redução perceptível em sua capacidade de armazenamento. Em

alguns casos, os dispositivos chegam a fornecer informações sobre a saúde da bateria, permitindo que os usuários monitorem seu desempenho e tomem medidas preventivas quando necessário.

O estado de saúde (*SOH*, do inglês *state of health*) é um parâmetro que quantifica a condição da bateria e seu desempenho em relação a uma bateria nova, que ainda não sofreu degradações (Picciano, 2007, p. 15).

O SOH é determinado pela razão entre a capacidade da bateria em certo instante de tempo e a capacidade nominal no início de sua vida útil. A expressão matemática do SOH é vista na Equação (3).

$$SOH = \frac{E_t}{E_{nom,0}} \quad (3)$$

Este parâmetro também é utilizado para mensurar a vida útil das baterias. Alguns autores consideram, por exemplo, que o fim da vida útil ocorre quando seu estado de saúde chega a 80% (Barbosa, 2020), enquanto outros aceitam valores na faixa de 60 a 80% (IRENA, 2015).


2.2.1.6. Profundidade de descarga (DoD)

A vida útil das baterias pode ser drasticamente estendida ou reduzida a depender, principalmente, das suas condições de operação. Inúmeros estudos apontam para a profundidade de descarga (DoD, do inglês *depth of discharge*) da operação das baterias como uma importante causa da diminuição de sua vida útil, como por exemplo Gantz (2012, p. 15) e Santos (2018, p. 28). Outros destacam que tipos diferentes de bateria, devido às características químicas, são afetados de maneira diferente pela profundidade de descarga (IRENA, 2015, p. 6).

Define-se a profundidade de descarga como a parcela da capacidade total de uma bateria que é utilizada durante os ciclos de carga e descarga (Oliveira, 2018, p. 40). Esse valor é expresso como uma porcentagem da capacidade total de energia da bateria, e está diretamente relacionado aos limites mínimo e máximo do estado de carga.

A profundidade de descarga média pode ser determinada a partir dos valores típicos de SOC que a bateria atinge durante seus ciclos de operação. Por exemplo, se uma bateria trabalha em média entre 30% e 70% de sua capacidade, a DoD média será de 40%. A relação entre a DoD e os limites do SOC é ilustrada na Figura 9.

Figura 9 – Ilustração da relação entre DoD e SOC.



Fonte: Elaborado pelo autor (2022).

Generalizando, obtém-se a expressão vista na Equação (4), na qual SOC_{max} e SOC_{min} representam as médias dos valores máximos e mínimos do SOC durante os ciclos de carga e descarga analisados.

$$DOD = SOC_{max} - SOC_{min} \quad (4)$$

Apesar de os diversos tipos de bateria serem diferentemente afetadas pela DoD, é consenso entre os autores que, em geral, a vida útil é mais reduzida quando opera-se em maiores profundidades de descarga (Datta; Kalam; Shi, 2019, p. 12). Na Figura 10, é visto um gráfico de um sistema de baterias comercial (Hoppecke, 2014) que exemplifica essa relação.

Figura 10 – Exemplo do efeito da profundidade de descarga na vida útil de uma bateria.



Fonte: Oliveira (2018, p. 35), adaptado.

As baterias desempenham funções variadas nos sistemas elétricos, que dependem dos perfis de carga e descarga, bem como dos requisitos energéticos específicos de cada aplicação. Por exemplo, na aplicação de regulação de frequência, a bateria precisa operar em vários ciclos rápidos de carga e descarga, com demandas significativas de potência em curtos períodos, o que pode resultar na operação com altos valores de DoD.

Em contrapartida, quando as baterias são empregadas para o deslocamento de fornecimento de energia, armazenando o excesso de energia renovável para uso posterior, são necessários de ciclos de carga e descarga mais longos, com maior necessidade de capacidade energética de armazenamento.

Dessa forma, ao projetar baterias para determinada aplicação é necessário considerar os requisitos de desempenho e avaliar cuidadosamente os impactos das condições operacionais, especialmente da DoD, na vida útil das baterias.

2.2.1.7. Eficiência de Carga e Descarga

A eficiência ou rendimento total de um dispositivo de armazenamento de energia (η), expressa em valores absolutos ou percentuais, corresponde, no processo de carga, à proporção da energia recebida da rede que é efetivamente armazenada no dispositivo; já no processo de descarga, a eficiência é a razão entre a energia efetivamente entregue pelos terminais do

dispositivo em relação à redução total de energia armazenada. Sua expressão matemática genérica é vista na Equação (5).

$$\eta = \frac{E_{\text{útil}}}{E_{\text{total}}} \quad (5)$$

Em que:

- $E_{\text{útil}}$ é a energia efetivamente armazenada (na carga), ou a energia efetivamente fornecida pelos terminais do dispositivo (na descarga);
- E_{total} é a energia fornecida aos terminais do dispositivo (na carga), ou a redução total de energia armazenada (na descarga).

A Figura 6, vista anteriormente, ilustra esse fenômeno por meio do circuito equivalente da bateria, no qual se observa uma impedância série (Z_2) que absorve parte da energia entregue à bateria (ou por ela). A energia consumida por essa impedância corresponde ao que se chama de perdas por eficiência. Essas perdas são inerentes a qualquer tecnologia de armazenamento de energia, visto que nunca é possível transferir ou converter energia de forma ideal e livre de dissipações.

As perdas por eficiência são proporcionais à energia armazenada e descarregada, se intensificando à medida que o dispositivo opera mais. De modo geral, as perdas são um aspecto crítico para qualquer sistema de armazenamento de energia, podendo, em muitos casos, comprometer sua viabilidade para determinadas aplicações.

Embora os processos de carga e descarga possuam eficiências conceitualmente distintas, é comum adotar, para fins práticos, um mesmo valor para ambos. Alternativamente, alguns estudos utilizam a chamada “eficiência de ida e volta” (do inglês, *round-trip efficiency*), que indica a perda de energia em um ciclo de carga e descarga (Vian et al., 2021, p. 24). Esse valor é equivalente ao produto das eficiências de carga e de descarga, consolidando-as em um único indicador, inferior às eficiências individuais.

2.2.1.8. Autodescarga

A autodescarga das baterias, expressa em kW/dia (ou também como percentual por unidade de tempo), é o processo de descarga desses dispositivos de forma contínua, mesmo que

eles não estejam sendo utilizados. Esse processo é devido principalmente às características eletroquímicas das baterias, sendo inevitáveis e irreversíveis (Vian et al., 2021, p. 24). Além disso, a literatura constata que, com o aumento do número de ciclos de carga e descarga, as características de autodescarga tendem a piorar.

O processo de autodescarga é ilustrado na Figura 11. Nela, a energia é representada pela água, a bateria, por um tanque, e a autodescarga é como furos nesse tanque, de modo que o nível de água diminui continuamente mesmo quando não está sendo realizada nenhuma carga ou descarga.

Figura 11 – Ilustração da autodescarga.



Fonte: Picciano (2007, p. 18).

Esse efeito também pode ser constatado ao observar a impedância em paralelo (Z_I) no circuito equivalente da bateria visto na Figura 6, a qual funciona como um caminho para descarga da energia armazenada, mesmo quando a bateria não está conectada à rede. A energia descarregada por esse fenômeno é correspondente ao que é chamado de perdas por autodescarga.

2.2.1.9. Custos

A adoção de dispositivos de armazenamento de energia envolve diversos custos, que podem ser classificados, de forma geral, em duas categorias principais: custos de aquisição e custos de operação e manutenção. Em decisões de investimento, o custo de aquisição representa a saída inicial de caixa, correspondendo ao valor necessário para a implementação do sistema. No caso específico de sistemas baseados em baterias, esse custo inicial costuma ser o fator mais relevante, dado que esses dispositivos, em sua maioria, exigem pouca intervenção operacional e manutenção relativamente simples.

Por outro lado, é importante destacar que o carregamento da bateria envolve um custo associado, uma vez que a energia armazenada precisa ser previamente adquirida da rede ou de outra fonte geradora. Nesse contexto, o custo de operação é determinado pelo preço da energia no momento da carga, o qual, por ser normalmente mais barato do que no momento de uso da energia, influencia diretamente os benefícios econômicos obtidos ao longo do tempo. Esse aspecto torna os sistemas de armazenamento especialmente atrativos em cenários com tarifação variável, nos quais é possível otimizar o uso das baterias para chegar ao menor custo global.

Ainda assim, os benefícios econômicos do armazenamento dependem da consideração adequada das perdas associadas à eficiência e à autodescarga, pois, mesmo em cenários com diferença significativa de preços entre os horários de compra e uso da energia, parte dessa energia é inevitavelmente dissipada ao longo do processo.

2.2.2. Tipos de Baterias

Diversos elementos químicos podem reagir entre si através das reações de oxirredução. Portanto, há uma ampla gama de composições possíveis para baterias eletroquímicas. Dentre as principais tecnologias utilizadas, destacam-se as seguintes: Chumbo-Ácido (PbO_2), Níquel-Hidreto Metálico (NiMH), Lítio-íon (Li-Ion) e Sódio-Enxofre (NaS). Na Tabela 1 são vistas comparações de parâmetros técnicos relevantes para esses diferentes tipos de baterias.

Tabela 1 – Comparação de parâmetros de baterias eletroquímicas.

<i>Parâmetro</i>	PbO₂	NiMH	Li-Ion	NaS
<i>Energia Específica [Wh/kg]</i>	30 – 50	60 – 120	100 – 300	150 – 240
<i>Potência Específica [W/kg]</i>	75 – 300	300 – 900	150 – 315	150 – 230
<i>Eficiência de Round-trip (%)</i>	80 – 85	65 – 70	90 – 95	80 – 85
<i>Temperatura de Operação (°C)</i>	-20 – 60	-40 – 60	-30 – 60	300 – 500
<i>Tempo de vida (anos)</i>	5 – 20	5 – 15	5 – 20	10 – 20
<i>Ciclos durante a vida</i>	500 – 2000	500 – 3000	500 – 10000	1000 – 5000
<i>Taxa de autodescarga [% /dia]</i>	0,09 – 0,3	0,3 – 4	0,09 – 0,33	0,1 – 15
<i>Escala [MW]</i>	0 – 50	0,01 – 3	0 – 3	0,01 – 80
<i>Custo Capital de Energia [US\$/kWh]</i>	100 – 400	900 – 3500	200 – 1200	300 – 500

Fonte: Adaptado de (Hu et al., 2017, p. 22; Vian et al., 2021, p. 48; IRENA, 2017, p. 124–125; Chen et al., 2009, p. 307–308).

Neste trabalho, considera-se a utilização de baterias de Lítio-íon, devido ao seu desempenho técnico consolidado e ampla adoção no setor elétrico. Essa tecnologia destaca-se pela elevada densidade de energia, baixa taxa de autodescarga e boa eficiência em ciclos de carga e descarga. Essas características tornam as baterias de Lítio-íon especialmente atrativas tanto para aplicações móveis quanto estacionárias.

Conforme observado por Nkembi et al. (2024, p. 4), trata-se de uma das tecnologias recarregáveis mais utilizadas, combinando alta performance eletroquímica com menor impacto ambiental quando comparada a outras opções. Apesar dessas vantagens, as baterias de Lítio-íon também apresentam limitações importantes, sendo suscetíveis ao superaquecimento e à degradação com o tempo, especialmente quando mal gerenciadas, e seu custo de aquisição ainda permanece superior ao de outras tecnologias.

Outras informações sobre os tipos de baterias e suas características podem ser encontrados em Oliveira (2018, p. 41–44), Hu et al. (2017, p. 21–26), IRENA (2017) e Aneke e Wang (2016).

2.3. FLUXO DE POTÊNCIA COM SÉRIES TEMPORAIS

A análise convencional de sistemas de distribuição por meio de ferramentas comerciais de fluxo de potência tem sido historicamente limitada a simulações instantâneas, geralmente avaliando momentos críticos como carga máxima ou mínima. Essa abordagem, embora útil para estudos pontuais, é insuficiente para capturar os efeitos dinâmicos da operação diária, como as variações de carga e geração e seus efeitos nos sistemas de controle. Para realizar esse tipo de análise, é necessária a realização de simulações em séries temporais, que consistem na resolução sequencial do fluxo de potência ao longo do tempo, em que o estado final de um intervalo serve como condição inicial para o seguinte (Broderick et al., 2013, p. 10).

Nesse contexto, adota-se a metodologia conhecida como séries temporais quase-estáticas (QSTS, do inglês *Quasi-Static Time Series*), amplamente utilizada para representar a operação dinâmica de sistemas elétricos em múltiplos intervalos discretos. Segundo a definição proposta pelo IEEE (2013, apud Broderick et al., 2021, p. 24), a simulação quase-estática refere-se a uma sequência de soluções de fluxo de potência em regime permanente, conduzidas com passos de tempo entre um segundo e uma hora. Trata-se, portanto, de uma abordagem que mantém a simplicidade das simulações estacionárias, mas com sensibilidade temporal, incorporando informações entre um intervalo e outro.

Oliveira (2018, p. 45) destaca que a atuação de baterias depende não apenas das condições atuais de carga e geração, mas de uma sequência de operações. Isso ocorre pois o SOC das baterias no final de um intervalo também serve como condição inicial para o SOC do intervalo seguinte, caracterizando um acoplamento temporal, que justifica o uso dessa metodologia.

As curvas de carga são ferramentas essenciais nas análises temporais de sistemas elétricos. Elas representam, para cada intervalo, o valor da potência demandada pelas cargas conectadas ao sistema, permitindo simular o comportamento típico dos consumidores ao longo de dias ou semanas. A incorporação dessas variações possibilita identificar os períodos de picos e vales de demanda, que são críticos para decisões operacionais e gestão de energia, incluindo a operação de sistemas de armazenamento.

De semelhante modo, as curvas de geração fotovoltaica e de custos descrevem a variação temporal das respectivas grandezas. Todas essas curvas podem ser obtidas a partir de dados históricos reais ou construídas com base em perfis típicos de consumo.

As curvas de geração fotovoltaica representam, ao longo dos intervalos analisados, a potência ativa entregue pelos sistemas de geração. Essas curvas são fortemente dependentes da irradiância solar, que varia ao longo do dia e de acordo com fatores geográficos e climáticos. Em simulações com séries temporais, o uso de perfis de geração realistas, ou que considerem boas previsões, é essencial para capturar o comportamento dessas fontes e analisar os impactos decorrentes de seu uso.

Já as curvas de custo de energia seguem a estrutura tarifária e são utilizadas para determinar o preço de aquisição de energia em cada intervalo. No contexto brasileiro, consumidores cativos estão sujeitos a tarifas reguladas, que podem incorporar sinalização temporal por meio de modalidades tarifárias diversas. Já no ambiente de contratação livre, os preços variam conforme condições de mercado e os consumidores podem negociar diretamente com os fornecedores, permitindo maior flexibilidade na gestão de consumo. A elaboração de curvas de custo a partir de dados históricos pode utilizar, por exemplo, o Preço de Liquidação das Diferenças (PLD) horário, calculado e disponibilizado pela Câmara de Comercialização de Energia Elétrica (CCEE).

Utilizando as curvas de custo e obtendo a potência demandada do sistema em cada intervalo a partir das execuções sequenciais do fluxo de potência, calcula-se o custo de operação ao longo do horizonte de análise a partir da energia adquirida da rede em cada intervalo, ponderada pelo respectivo valor da tarifa naquele instante. Esse custo reflete a soma das aquisições de energia necessárias para suprir as cargas diretamente, as perdas elétricas, e também para alimentar os dispositivos de armazenamento. Uma vez que o uso das baterias visa justamente deslocar parte do consumo para períodos de menor custo, o perfil de carregamento e descarregamento influenciará diretamente o custo total.

Nesse trabalho, o OpenDSS será a ferramenta utilizada para executar os fluxos de potência com QSTS. Isso será feito ao utilizá-lo no modo de simulações diárias, conforme será mencionado na Seção 3.1 e explicado em mais detalhes no Anexo A.

2.4. MÉTODOS DE OTIMIZAÇÃO

Um problema de otimização é composto por três elementos fundamentais: um conjunto de variáveis de decisão, uma função objetivo e um conjunto de restrições. As variáveis de decisão representam os parâmetros que podem ser ajustados ou escolhidos dentro de um determinado domínio, com o intuito de alcançar o melhor desempenho possível segundo um critério definido. Esse critério é formalizado por meio da função objetivo (FOB), uma expressão matemática que quantifica a qualidade ou o custo associado a cada combinação de variáveis. O objetivo do processo de otimização é encontrar os valores dessas variáveis que maximizem ou minimizem essa função, conforme a finalidade do problema (Aandréasson; Evgrafov; Patriksson, 2005, p. 14).

Em geral, as variáveis do problema estão relacionadas aos recursos ou condições de operação, que são comumente limitados. Por isso, os problemas de otimização são frequentemente sujeitos a restrições técnicas, físicas ou lógicas que delimitam o conjunto de soluções admissíveis. Essas restrições podem ser expressas por equações ou inequações envolvendo uma ou mais variáveis, e são essenciais para garantir que as soluções obtidas sejam viáveis dentro do contexto real do problema.

Logo, as técnicas de otimização têm como objetivo determinar os valores ideais das variáveis de um problema, buscando minimizar ou maximizar a função objetivo, enquanto respeitam um conjunto de restrições impostas. Dependendo da abordagem, os métodos de otimização podem ser classificados como determinísticos (que sempre obtêm o mesmo resultado com as mesmas entradas) ou estocásticos (que podem chegar a resultados diferentes em cada execução).

Em geral, os métodos determinísticos fazem uso de propriedades matemáticas da formulação do problema (frequentemente recorrendo ao uso de derivadas e gradientes). Quando aplicáveis e corretamente modelados, podem oferecer garantias de otimalidade (por exemplo, em problemas convexos). No entanto, essa modelagem exige uma formulação matemática precisa e uma descrição rigorosa das variáveis, restrições e da função objetivo. Em problemas de grande porte, a execução destes métodos pode tornar-se impraticável devido a requisitos computacionais ou de memória. Além disso, esses métodos podem ter grande dependência de uma solução inicial ou de reduções do espaço de busca, que em muitos casos são fatores determinantes na garantia da otimalidade das soluções encontradas.

Já os métodos estocásticos exploram o espaço de soluções de forma aleatória ou estatística, buscando resultados aproximados, mas eficientes. Esses métodos são especialmente úteis quando abordagens determinísticas são inviáveis, devido à não convexidade da função objetivo e/ou das restrições (criando múltiplos mínimos locais), à presença de variáveis de decisão discretas (inteiras ou binárias), e ao elevado custo computacional associado a grandes dimensões do problema. Esses métodos não garantem encontrar a solução ótima global, mas buscam soluções suficientemente satisfatórias em um tempo razoável, utilizando estratégias que exploram o espaço de busca de forma eficiente. Portanto, são amplamente utilizados em problemas práticos onde restrições computacionais e de tempo são relevantes.

Dentro do conjunto de métodos estocásticos, as meta-heurísticas representam uma classe sofisticada de abordagens de alto nível e adaptáveis a diversos problemas que combinam técnicas gerais de busca com estratégias inspiradas em analogias com fenômenos físicos, químicos, biológicos, sociais, entre outros (Goldbarg; Goldbarg; Luna, 2016, p. 72). Essas estratégias têm se mostrado eficazes em diversos tipos de problemas, permitindo uma busca mais abrangente e robusta pelo espaço de soluções, mesmo quando as funções objetivo são altamente não-lineares ou multimodais. Dentre as principais meta-heurísticas, destaca-se o algoritmo genético, que será abordado com mais detalhes a seguir.

2.4.1. Algoritmo Genético

O Algoritmo Genético (AG) é um método de otimização meta-heurístico inspirado na evolução biológica, com ênfase nos três princípios de Darwin: variação genética, hereditariedade e seleção natural. Segundo a teoria de Darwin, espécies que sobrevivem são aquelas cujos indivíduos se adaptam melhor ao ambiente e, conseqüentemente, têm maiores chances de reproduzir suas características a uma nova geração (Goldbarg; Goldbarg; Luna, 2016, p. 102).

O modo que o AG incorpora esses conceitos pode ser resumido da seguinte maneira: Gera-se uma população inicial de possíveis soluções; busca-se, em um processo iterativo, chegar a uma boa solução por meio da evolução da população, de acordo com uma função de aptidão (ou adaptação), que avalia cada indivíduo; para a evolução da população a cada geração, aplicam-se comumente três operadores genéticos: elitismo, reprodução e mutação; esse

processo continua até que algum critério de convergência predefinido seja atingido (Faceli et al., 2022, p. 284).

Para representar cada possível solução, o respectivo indivíduo é codificado por um cromossomo que contém um conjunto de genes, que nada mais são do que variáveis do problema de otimização. Um cromossomo é composto pela sequência desses valores, que podem ser números binários, inteiros, reais ou até mesmo caracteres.

Dentre os operadores genéticos aplicados, o elitismo diz respeito à efetuação de cópias simples dos melhores indivíduos de uma geração para a próxima, sem que haja mudança em seus genes. A reprodução, por sua vez, é caracterizada por duas etapas estocásticas: a seleção de um par de indivíduos para se reproduzirem e o cruzamento do material genético dos dois cromossomos. Por fim, a mutação refere-se a alterações aleatórias da composição de algumas soluções, possibilitando a criação de soluções que ainda não foram observadas (Faceli et al., 2022, p. 278–284).

Vicente e Rizzi (2010, p. 3–6) destacam que o processo de seleção de indivíduos para compor a próxima geração deve privilegiar os indivíduos mais bem adaptados. Destes, a maior parte passará pelo processo de cruzamento, gerando um indivíduo cujo cromossomo possui genes aleatoriamente extraídos dos dois progenitores. A outra parcela dos indivíduos selecionados passa pelo processo de mutação, que pode ocorrer, por exemplo, somando em seus genes valores aleatórios de uma distribuição gaussiana para proporcionar maior diversidade à população. O desvio da distribuição também pode ser reduzido ao longo das gerações, permitindo uma busca mais ampla nas fases iniciais e mais refinada nas etapas finais da otimização.

Por ser um método estocástico e não garantir a otimalidade das soluções, diversos critérios de convergência podem ser adotados para os algoritmos genéticos. Os mais comuns são a estagnação do melhor indivíduo por um número de gerações e os limites de tempo de execução ou número máximo de gerações.

Neste trabalho, o AG será executado no *software* Matlab para a resolução do problema de alocação e operação ótimas de baterias. Para isso, será utilizada a função *ga*, que faz parte do *Global Optimization Toolbox*. Além disso, para realizar a integração com o OpenDSS, será utilizada a interface COM (do inglês: *Component Object Model*).

2.4.2. Outros Métodos de Otimização

Além do Algoritmo Genético, serão utilizados outros quatro métodos de otimização: a Otimização por Enxame de Partículas (PSO – função *particleswarm*), o método de Nelder–Mead (*fminsearch*), o método de busca direta (*patternsearch*), e uma abordagem em cascata que combina o AG e o *patternsearch*. Todos os métodos são baseados em meta-heurísticas ou busca sem derivadas e estão disponíveis no Matlab.

O PSO é um algoritmo baseado em população, assim como o AG. Cada partícula representa uma possível solução e movimenta-se iterativamente com base na sua melhor posição já visitada e na melhor posição global descoberta pelo grupo. Essa dinâmica possibilita a exploração de diversas regiões do espaço de busca simultaneamente, favorecendo a descoberta de ótimos globais. A principal diferença em relação ao algoritmo genético está no mecanismo de atualização da população: enquanto o AG depende de operadores de reprodução e mutação, o PSO se apoia em atualizações contínuas de posição e velocidade das partículas.

Os métodos *fminsearch* e *patternsearch* pertencem à família das buscas diretas, que operam sobre soluções individuais e não requerem o uso de derivadas. O *fminsearch* implementa o algoritmo de Nelder–Mead, que utiliza um conjunto de vértices e o modifica iterativamente através de operações geométricas. É adequado para problemas suaves e de baixa dimensão, mas sensível a mínimos locais e à escolha da solução inicial.

Já o *patternsearch* é mais robusto e sistemático, utilizando uma malha de pontos ao redor da solução atual, construída com base em direções fixas em cada dimensão e escaladas por um fator de passo. Ele avalia esses pontos em busca de melhorias na FOB e, caso encontre, refina a malha. O *patternsearch* é mais tolerante a funções não suaves ou com ruído, mas também se beneficia significativamente de uma boa solução inicial, o que o torna especialmente adequado para uso em métodos em cascata.

Na abordagem híbrida adotada neste trabalho, a solução obtida pelo AG é utilizada como ponto inicial para o *patternsearch*. Isso permite aproveitar a capacidade de exploração global do AG para localizar regiões promissoras e, em seguida, empregar o *patternsearch* para um refinamento local mais eficiente, reduzindo o risco de convergência prematura e aumentando a qualidade final da solução.

Essas e outras informações sobre os algoritmos e suas configurações podem ser encontradas na documentação oficial do Matlab, mais especificamente do *Global Optimization Toolbox* e do *Optimization Toolbox* (MathWorks, 2025).

3. METODOLOGIA

Este capítulo apresenta a metodologia proposta neste trabalho, contemplando a modelagem dos elementos considerados, a formulação matemática do problema de otimização e os procedimentos computacionais propostos para a resolução deste problema. O foco está na resolução do problema de gerenciamento da operação de baterias em sistemas de distribuição de energia elétrica, considerando diferentes configurações e cenários.

A modelagem adotada busca representar de forma consistente os principais componentes do sistema de distribuição, com ênfase nas baterias e suas interações com as cargas e a geração distribuída. Inicialmente neste capítulo são definidos os parâmetros técnicos e operacionais das baterias que impactam em sua modelagem e nas simulações da rede.

A partir destas definições, a modelagem resulta em um conjunto de equações que representam o comportamento do sistema simulado. Estas equações são as restrições que, juntamente com a função objetivo, compõem a formulação do problema de otimização. Para a solução deste problema, são utilizados algoritmos meta-heurísticos capazes de lidar com a complexidade e a não linearidade do problema.

A operação das baterias pode ser realizada de modo a armazenar ou fornecer energia a depender das variações de carga e geração no sistema de distribuição, e de acordo com as características das baterias. Parâmetros como a capacidade e o rendimento, por exemplo, são determinantes para um bom aproveitamento energético e uma melhor operação.

As operações de carga e descarga podem ser otimizadas com o objetivo de melhorar diversos aspectos da operação dos sistemas de distribuição. Isto pode ser realizado por meio do gerenciamento do estado de carga das baterias ao longo dos intervalos de tempo analisados. A escolha dos valores de SOC da bateria em cada intervalo será determinada principalmente pelas características do sistema elétrico, com destaque para as variações da curva de carga e de geração.

A alocação das baterias no sistema também faz parte do problema de otimização. As barras de conexão são otimizadas juntamente com os perfis de operação, de modo que o algoritmo determine, de forma coordenada, os pontos ótimos de alocação e a estratégia de carga e descarga.

A dependência temporal entre as decisões de operação é incluída na modelagem, considerando o acoplamento entre o estado de carga das baterias em intervalos de tempo sequenciais. Para representar adequadamente esses fatores, são realizados cálculos de fluxo de potência com séries temporais por meio do *software* OpenDSS.


A seção seguinte apresenta em detalhes a modelagem de baterias adotada neste trabalho, com a definição das variáveis, restrições e parâmetros considerados nas simulações.

3.1. MODELAGEM

3.1.1. Modelagem de Baterias

Toda a modelagem apresentada nesta seção é baseada no modelo de bateria implementado pelo OpenDSS (denominado *Storage*), conforme EPRI (2024a), o qual é visto na Figura 12.

Figura 12 – Modelo de bateria disponibilizado pelo OpenDSS.



Fonte: Adaptado de EPRI (2024a).

Conforme visto na figura, os componentes do modelo são (EPRI, 2024a):

- Bateria ideal, que representa o armazenamento de energia, sem perdas;
- Perdas por eficiência de carga e descarga;
- Perdas por autodescarga;

- Estado de operação, que pode ser de carga, descarga ou ociosidade (nesse estado a rede supre a autodescarga da bateria e ela não sofre modificações na sua energia armazenada); e
- Inversor incorporado, que inclui a modelagem das perdas no inversor e as possibilidades de despachar potência reativa e limitar a taxa de carga e descarga.

Para realizar simulações com esse objeto no OpenDSS, é necessário apenas que sejam informados alguns dados nominais da bateria. Caso eles não sejam fornecidos, os valores padrão do programa são utilizados. Os dados fornecidos ao OpenDSS neste trabalho para a criação de objetos *storage* são:

- Capacidade nominal (kWh);
- Potência nominal (kW);
- Eficiências de carga e de descarga (%);
- Autodescarga (percentual da potência nominal);
- SOC mínimo (%);
- SOC inicial (%) ou energia inicial (kWh);
- Número de fases;
- Barra de alocação;
- Tensão nominal (kV); e
- Dados sobre o estado de operação ou modo de despacho.

O elemento *storage* é modelado com três estados de operação básicos: carga, descarga e ociosidade. Na carga, a potência fornecida pela rede é utilizada para carregar a bateria, mas o sistema também precisa compensar as perdas associadas ao processo de carregamento e à autodescarga da bateria, de forma que a energia efetivamente armazenada é menor do que a energia fornecida pela rede. Na descarga, ocorre o inverso: a energia removida da bateria é maior do que a energia fornecida ao sistema, pois nesse caso as perdas são compensadas pela bateria. Já na ociosidade, a bateria não realiza carga nem descarga, e a energia fornecida pela

rede é apenas suficiente para alimentar as perdas do sistema, sem realizar trocas de energia significativas entre a bateria e a rede ou carga conectada.

O modelo pode ser utilizado em diversas escalas temporais de simulação, e seu despacho pode ser programado a partir de alguns modos fornecidos pelo modelo. Mais informações sobre essas possibilidades são vistas no Anexo A.

As simulações deste trabalho são realizadas no modo diário, com intervalos horários, e o modo de despacho utilizado é o *follow*. Nele, a operação das baterias é realizada a partir de uma curva de despacho predefinida, contida no vetor *daily*. Isso permite um gerenciamento preciso da operação das baterias em cada intervalo.

Cada elemento do vetor descreve a potência retirada da bateria em cada intervalo, devidamente normalizada em relação à sua potência nominal. O comportamento operacional da bateria é então regido por essa curva, com a devida consideração das perdas inerentes ao processo. Valores positivos do vetor indicam um estado de descarga, valores negativos caracterizam um estado de carga, e valores iguais a zero representam períodos de inatividade ou ociosidade da bateria.

Adicionalmente, as potências normalizadas que compõem o vetor podem ser calculadas em função dos valores de estado de carga (SOC) no início e no fim de cada intervalo. Esse procedimento torna-se especialmente relevante em problemas de otimização nos quais o SOC é tratado como variável de decisão, como no presente trabalho. Para tal, é necessário aplicar algumas manipulações matemáticas.

Inicialmente, para ambas as operações de carga e descarga, define-se a potência injetada ou retirada da bateria, vista internamente – isto é, do ponto de vista da bateria ideal do modelo da Figura 12 –, a partir da variação da energia ao longo do determinado intervalo. Como a variação de energia é obtida a partir da variação do estado de carga, então a potência vista internamente é definida conforme a Equação (6).

$$P_{bat.}^{int.} = \frac{(SOC_f - SOC_i) \cdot E_{nom}}{\Delta t} \quad (6)$$

Em que:

- $P_{bat.}^{int.}$ é a potência injetada ou retirada da bateria, vista internamente, em kW;

- SOC_f é o estado de carga ao final do intervalo, cujo valor deve pertencer ao intervalo $[0,1]$;
- SOC_i é o estado de carga ao início do intervalo, cujo valor deve pertencer ao intervalo $[0,1]$;
- E_{nom} é a capacidade nominal da bateria, em kWh;
- Δt é a duração do intervalo, em horas.

É importante observar que nos processos de carga, em que o SOC final é maior que o inicial, a potência será injetada na bateria, portanto seu valor será positivo. Na descarga, porém, o SOC final é menor do que o inicial, de modo que a potência será retirada da bateria e seu valor será negativo.

Para encontrar o valor da potência de carga (injetada) ou descarga (retirada) vista externamente – ou seja, do ponto de vista do sistema elétrico –, é necessário incluir as perdas por eficiência e por autodescarga. Essas relações são vistas respectivamente nas Equações (7) e (8).

$$P_{bat.(carga)}^{ext.} = \frac{P_{Bat}^{int.}}{\eta} + P_{perdas}^{autod.} \quad (7)$$

$$P_{bat.(descarga)}^{ext.} = P_{Bat}^{int.} \cdot \eta + P_{perdas}^{autod.} \quad (8)$$


Em que:

- $P_{bat.}^{ext.}$ é a potência injetada ou retirada da rede elétrica, vista externamente, em kW, a qual é diferente nos processos de carga e descarga;
- η é a eficiência de carga e descarga da bateria, cujo valor deve pertencer ao intervalo $[0,1]$;
- $P_{perdas}^{autod.}$ é a potência relativa às perdas por autodescarga, em kW.

As potências vistas externa e internamente são diferentes devido às perdas, que são modeladas como impedâncias em série (eficiência) e em paralelo (autodescarga). A relação entre essas potências é ilustrada na Figura 13, na qual as setas indicam a operação de carga da

bateria. Na operação de descarga, as setas azuis estariam com seu sentido invertido, indicando que a potência flui da bateria para o sistema.

Figura 13 – Ilustração da potência de carga vista externa e internamente.



Fonte: Adaptado de EPRI (2024a).

Voltando às Equações (7) e (8), nota-se que no processo de carga a potência injetada na bateria é menor do que a potência fornecida pela rede, enquanto no processo de descarga a potência fornecida à rede é menor do que a potência retirada da bateria. Adicionalmente, como nos momentos de ociosidade da bateria a potência útil é nula (uma vez que não há variação de carga), nota-se que a potência suprida pelo sistema é exatamente igual à potência das perdas por autodescarga. Estes conceitos estão coerentes com as definições vistas anteriormente, uma vez que as perdas são alimentadas pela bateria nos processos de descarga e pela rede nos processos de carga e nos momentos de inatividade da bateria.

O próximo passo é a determinação da potência normalizada, que requer a inversão do sinal da potência observada externamente pelo sistema, pois o modelo adota o sinal positivo para o processo de descarga e negativo para a carga. Por fim, o valor resultante é dividido pela potência nominal da bateria, conforme descrito na Equação (9).

$$P_n = \frac{-P_{bat.}^{ext.}}{P_{nom}} \quad (9)$$

Em que:

- P_{nom} é a potência nominal da bateria, em kW;
- P_n é a potência normalizada.

Essas manipulações matemáticas são compiladas e formalizadas de modo mais direto nas Equações (10) e (11), correspondentes às operações de carga e descarga, respectivamente.

$$P_{n(carga)} = - \left(\frac{(SOC_f - SOC_i) \cdot E_{nom}}{\Delta t \cdot \eta} + P_{perdas}^{autod.} \right) \cdot \frac{1}{P_{nom}} \quad (10)$$

$$P_{n(descarga)} = - \left(\frac{(SOC_f - SOC_i) \cdot E_{nom} \cdot \eta}{\Delta t} + P_{perdas}^{autod.} \right) \cdot \frac{1}{P_{nom}} \quad (11)$$

Por meio destas equações, é possível compor o vetor de potências normalizadas que será fornecido ao elemento *Storage* para operação no modo *follow* de despacho. Essa composição depende apenas da definição de um vetor de estados de carga correspondentes aos intervalos de interesse, uma vez que parâmetros como eficiência, taxa de autodescarga, potência e capacidade nominais são constantes ao longo dos intervalos.

Ao contrário das perdas por autodescarga, que são constantes e fornecidas em kW, as perdas por eficiência são dadas em porcentagem, e seu valor em kW em cada intervalo varia de acordo com a potência útil transferida para a bateria ou para o sistema. Ou seja, quanto mais potência é utilizada para carregar ou descarregar a bateria em um intervalo, maiores são as perdas. As relações utilizadas para calcular as perdas por eficiência nas operações de carga e descarga são vistas nas Equações (12) e (13).

$$P_{perdas(carga)}^{efic.} = |P_{Bat}^{int.}| \cdot \frac{(1 - \eta)}{\eta} \quad (12)$$

$$P_{perdas(descarga)}^{efic.} = |P_{Bat}^{int.}| \cdot (1 - \eta) \quad (13)$$

Nota-se, por fim, que quando a bateria está em estado de ociosidade as perdas por eficiência são nulas, uma vez que a potência útil é igual a zero.

No Anexo B, é visto um exemplo de aplicação do modelo de baterias utilizado. Nele, as equações vistas aqui são demonstradas, e os cálculos realizados são comparados com os resultados obtidos a partir do uso do modelo, validando o equacionamento.

3.1.2. Modelagem de Outros Elementos

Além das baterias, outros elementos do sistema elétrico foram modelados conforme os modelos disponíveis no OpenDSS. Isso inclui, principalmente, componentes como linhas (elemento *Line*), cargas (*Load*), transformadores (*Transformer*) e capacitores (*Capacitor*). A configuração desses elementos segue os padrões típicos do OpenDSS e não é abordada em detalhes neste trabalho, uma vez que tais modelagens já estão amplamente documentadas na literatura. Para uma descrição completa de suas características e parametrizações, recomenda-se consultar a documentação oficial do OpenDSS (Dugan; Montenegro; Ballanti, 2021).

3.2. PROBLEMA DE OTIMIZAÇÃO

O problema de otimização resolvido neste trabalho consiste em alocar e operar baterias com objetivo de melhorar aspectos operativos do sistema de distribuição.

Conforme descrito na modelagem apresentada na seção anterior, o OpenDSS é utilizado como ferramenta de simulação para resolver os fluxos de potência sequenciais necessários na avaliação temporal do sistema. O acoplamento entre o algoritmo de otimização e o simulador permite que os impactos de cada solução candidata sejam calculados e que iterativamente o objetivo de otimização seja alcançado.

Para cada bateria considerada, é necessária uma variável de decisão associada à sua alocação no sistema e várias outras relacionadas à sua operação. O número de variáveis operacionais depende diretamente da discretização do horizonte de planejamento, ou seja, da quantidade de intervalos de tempo avaliados. Desse modo, em cada intervalo são tomadas decisões sobre o estado de carga e, conseqüentemente, sobre o fluxo de potência da bateria.

Os problemas que podem ser resolvidos pelo método proposto neste trabalho são modelados matematicamente pelas Equações (14) a (33), diferenciando um do outro pela função objetivo a ser utilizada e as restrições associadas a cada caso, conforme será explicado após o equacionamento.

$$\min \quad f = \begin{cases} \Delta t \cdot \sum_t (P_t^{Subestação} \cdot C_t^{energia}) + 10^5 \cdot Pen \\ ou \\ \Delta t \cdot \sum_t \left(P_{perdas,t}^{sist.} + \sum_B P_{perdas,t}^{bat,B} \right) + 10^5 \cdot Pen \end{cases} \quad (14)$$

$$\begin{aligned} s. a. \quad \Omega_t &= \{1, 2, \dots, T\}, & t \in \Omega_t \\ \Omega_B &= \{1, 2, \dots, nBat\}, & B \in \Omega_B \\ \Omega_k &= \{1, 2, \dots, nBarras\}, & k \in \Omega_k \\ \Omega_L &= \{1, 2, \dots, nLinhas\}, & L \in \Omega_L \end{aligned} \quad (15)$$

$$Local_B \in \Omega_k, \quad \forall B \quad (16)$$

$$SOC_{B,t} = \frac{E_{B,t}}{E_{nom,B}}, \quad \forall B \text{ e } \forall t \quad (17)$$

$$\begin{cases} SOC_{B,min} \leq SOC_{B,t} \leq SOC_{B,max} \\ ou \\ E_{B,min} \leq E_{B,t} \leq E_{B,max} \end{cases}, \quad \forall B \text{ e } \forall t \quad (18)$$

$$P_{B,t}^{int.} = \frac{E_{B,t} - E_{B,t-1}}{\Delta t}, \quad \forall B \text{ e } \forall t \quad (19)$$

$$E_{B,t} = \begin{cases} E_{B,t-1} + (P_{B,t}^{ext.} - P_{perdas,B}^{autod.}) \cdot \Delta t \cdot \eta_c, & P_{B,t}^{int.} > 0 \\ E_{B,t-1} + (P_{B,t}^{ext.} - P_{perdas,B}^{autod.}) \cdot \frac{\Delta t}{\eta_d}, & P_{B,t}^{int.} < 0, \\ E_{B,t-1}, & P_{B,t}^{ext.} = P_{perdas,B}^{autod.} \text{ e } P_{B,t}^{int.} = 0 \end{cases}, \quad \forall B \text{ e } \forall t \quad (20)$$

$$\begin{cases} SOC_{B,0} = SOC_{B,T} \\ ou \\ E_{B,0} = E_{B,T} \end{cases}, \quad \forall B \quad (21)$$

$$P_t^{Subestação} = \sum_k (P_{k,t}^{carga} - P_{k,t}^{geração}) + \sum_B (P_{B,t}^{ext.}) + P_{perdas,t}^{sist.}, \quad \forall t \quad (22)$$

$$P_{perdas,t}^{sist.} = \sum_L R_L \cdot (I_{L,t})^2, \quad \forall t \quad (23)$$

$$P_{perdas,t}^{bat,B} = \begin{cases} P_{perdas,B}^{autod} + |P_{B,t}^{int.}| \cdot \frac{(1 - \eta_c)}{\eta_c}, & P_{B,t}^{int.} > 0 \\ P_{perdas,B}^{autod} + |P_{B,t}^{int.}| \cdot (1 - \eta_d), & P_{B,t}^{int.} < 0 \\ P_{perdas,B}^{autod}, & P_{B,t}^{int.} = 0 \end{cases}, \quad \forall B \text{ e } \forall t \quad (24)$$

$$P_{k,t}^{carga} = P_k^{carga \text{ máx.}} \cdot FC_t, \quad \forall k \text{ e } \forall t \quad (25)$$

$$P_{k,t}^{geração} = P_k^{geração \text{ máx.}} \cdot FG_t, \quad \forall k \text{ e } \forall t \quad (26)$$

$$Pen = Pen_{alocação} \vee Pen_{Potência \text{ Bat.}} \vee Pen_{fluxo \text{ reverso}} \vee Pen_{demanda \text{ máx.}} \quad (27)$$

$$Pen_{alocação} = \begin{cases} 0, & Local_{b1} \neq Local_{b2}, \quad \forall (b1, b2) \in \Omega_B, \quad b1 \neq b2 \\ 1, & \exists (b1, b2) \in \Omega_B, \quad b1 \neq b2, \quad Local_{b1} = Local_{b2} \end{cases} \quad (28)$$

$$Pen_{Potência \text{ Bat.}} = \begin{cases} 0, & P_{B,t}^{int.} \leq P_B^{máx.}, \quad \forall B \text{ e } \forall t \\ 1, & \exists (B, t), \quad P_{B,t}^{int.} > P_B^{máx.} \end{cases} \quad (29)$$

$$Pen_{fluxo \text{ reverso}} = \begin{cases} 0, & P_t^{Subestação} \geq 0, \quad \forall t \\ 1, & \exists P_t^{Subestação} < 0 \end{cases} \quad (30)$$

$$Pen_{demanda \text{ máx.}} = \begin{cases} 0, & P_t^{Subestação} \leq P_{Máx. \text{ Caso Base}}^{Subestação}, \quad \forall t \\ 1, & \exists (P_t^{Subestação} > P_{Máx. \text{ Caso Base}}^{Subestação}) \end{cases} \quad (31)$$

$$\sum_{\text{barra } k} P_{k,t}^{entrada} - \sum_{\text{barra } k} P_{k,t}^{saída} = 0, \quad \forall k \text{ e } \forall t \quad (32)$$

$$\sum_{\text{barra } k} Q_{k,t}^{entrada} - \sum_{\text{barra } k} Q_{k,t}^{saída} = 0, \quad \forall k \text{ e } \forall t \quad (33)$$

Em que:

- f é a função objetivo, a qual se deseja minimizar;

- Δt é o tempo de duração de um intervalo analisado, em horas;
- t é o índice que identifica o intervalo de tempo analisado, $t \in \Omega_t$;
- Ω_t é o conjunto de números inteiros que contém os intervalos de tempo analisados;
- $P_t^{Subestação}$ é a potência fornecida ao sistema pela subestação no intervalo t , em kW;
- $C_t^{energia}$ é o custo da energia elétrica no intervalo t , em R\$/kWh;
- Pen é uma variável binária que controla quando penalizações são aplicadas à função objetivo;
- $P_{perdas,t}^{sist}$ é a potência das perdas elétricas no sistema de distribuição no intervalo t , em kW;
- B é o índice que identifica a bateria analisada, $B \in \Omega_B$;
- Ω_B é o conjunto de números inteiros que contém os números das baterias analisadas;
- $P_{perdas,t}^{bat,B}$ é a potência das perdas elétricas na bateria B no intervalo t , em kW;
- T é o número de intervalos analisados;
- $nBat$ é o número de baterias alocadas;
- Ω_k é o conjunto de números inteiros que contém os números das barras analisadas;
- k é o índice que identifica a barra analisada, $k \in \Omega_k$;
- $nBarras$ é o número de barras do sistema de distribuição analisado;
- Ω_L é o conjunto de números inteiros que contém os números das linhas analisadas;
- L é o índice que identifica a linha analisada, $L \in \Omega_L$;
- $nLinhas$ é o número de linhas do sistema de distribuição analisado;
- $Local_B$ é a barra de alocação da bateria B ;
- $SOC_{B,t}$ é o estado de carga da bateria B no intervalo t ;
- $E_{B,t}$ é a energia armazenada na bateria B no intervalo t , em kWh;
- $E_{nom,B}$ é a capacidade nominal de armazenamento da bateria B , em kWh;

- min e max são índices referentes aos valores mínimos e máximos das respectivas variáveis;
- $P_{B,t}^{int.}$ é a potência injetada ou retirada da bateria B pelo sistema, vista internamente, no intervalo t , em kW;
- $P_{B,t}^{ext.}$ é a potência injetada ou retirada do sistema pela bateria B , vista externamente, no intervalo t , em kW;
- $P_{perdas,B}^{autod.}$ é a potência das perdas por autodescarga na bateria B , em kW;
- η_{carga} e $\eta_{descarga}$ são, respectivamente, as eficiências de carga e descarga das baterias, cujo valor deve pertencer ao intervalo $[0,1]$;
- $P_{k,t}^{carga.}$ é a potência consumida pelas cargas localizadas na barra k , no intervalo t , em kW;
- $P_{k,t}^{geração.}$ é a potência injetada pelos geradores distribuídos localizados na barra k , no intervalo t , em kW;
- R_L é a resistência série da linha L , em $m\Omega$;
- $I_{L,t}$ é a corrente na linha L no intervalo t , em kA;
- FC_t é o fator de carga no intervalo t ;
- FG_t é o fator de geração no intervalo t ;
- $Pen_{alocação}$ é uma variável binária que indica que penalizações devem ser aplicadas devido a restrições na alocação de baterias;
- $Pen_{Potência Bat.}$ é uma variável binária que indica que penalizações devem ser aplicadas devido à restrição de potência de baterias;
- $Pen_{fluxo reverso}$ é uma variável binária que indica que penalizações devem ser aplicadas devido à presença de fluxo reverso;
- $Pen_{demanda máx.}$ é uma variável binária que indica que penalizações devem ser aplicadas devido à restrição de demanda máxima do sistema;
- $P_{k,t}^{entrada}$ são as potências ativas injetadas pelo sistema ou geradas na barra k no intervalo t , em kW;

- $P_{k,t}^{saída}$ são as potências ativas retiradas pelo sistema ou consumidas na barra k no intervalo t , em kW;
- $Q_{k,t}^{entrada}$ são as potências reativas injetadas pelo sistema ou geradas na barra k no intervalo t , em kW;
- $Q_{k,t}^{saída}$ são as potências reativas retiradas pelo sistema ou consumidas na barra k no intervalo t , em kW.

Cada uma das funções objetivo (FOB), vistas na Equação (14), busca minimizar um de dois possíveis critérios de otimização, escolhido conforme o cenário de análise. O primeiro critério visa minimizar o custo total de energia a longo dos T intervalos de Δt horas, o qual é calculado a partir da soma dos produtos entre a potência fornecida pela subestação e o custo da energia em cada intervalo de tempo. Este critério tem finalidade econômica e é o critério principal deste trabalho, utilizado na maioria dos casos de estudo.

O segundo critério da FOB tem finalidade técnica, com foco na minimização das perdas do sistema, considerando tanto as perdas na rede elétrica quanto as perdas associadas às baterias. Em ambos os critérios, há a adição de um termo de penalização, que impõe um custo elevado para violações de restrições operacionais, desestimulando soluções que não atendam aos critérios técnicos definidos. O operador "ou" indica que o modelo pode alternar entre as diferentes funções objetivo conforme o foco da otimização.

As Equações (15) a (33) são as restrições do problema, isto é, as igualdades e desigualdades às quais as variáveis estão sujeitas. Elas definem o comportamento operacional do sistema elétrico – especialmente das baterias alocadas –, e impõem limites para garantir que o modelo respeite as características físicas e operacionais.

A Equação (15) define os conjuntos de variáveis inteiras contendo a contagem do número de intervalos analisados (de 1 a T), de baterias alocadas (de 1 a $nBat$) e de barras (de 1 a $nBarras$) e linhas (de 1 a $nLinhas$) do sistema elétrico analisado, respectivamente. Cada um desses conjuntos é utilizado iterativamente na composição das demais restrições do problema.

No caso dos intervalos (t), a variável não significa o tempo decorrido, mas o índice do intervalo. Para obter a duração correspondente, esse número é multiplicado pelo tempo Δt . Para as baterias (B), a variável é um indicador numérico usado para referenciar cada bateria alocada.

Quanto às barras (k) e linhas (L), as variáveis não são o nome de cada barra e linha, mas sim índices numéricos que as identificam na ordem em que são registradas pelo OpenDSS para cada sistema elétrico simulado. É importante ressaltar que as baterias utilizadas neste trabalho são monofásicas e, portanto, não são alocadas em todos os nós de uma barra. Assim, quando o termo “barra” é utilizado, implica-se que se trata de nós, que descrevem a barra e a respectiva fase.

A Equação (16) modela os limites para a alocação de cada uma das baterias, restringindo-a ao conjunto de barras do sistema. Portanto, para cada bateria B , o valor de $Local_B$ deve ser um número inteiro entre 1 e $nBarras$.

A Equação (17) define o estado de carga da bateria B no final do intervalo t como a razão entre a energia armazenada e a capacidade nominal de armazenamento. Esse valor também pode ser expresso como um percentual da capacidade nominal.

A Equação (18) impõe limites de operação para cada bateria, que podem ser modelados de forma equivalente como limites de estado de carga ou limites de energia armazenada. Nela, é determinado que, em todos os intervalos de tempo, o SOC das baterias (ou a energia armazenada) deve estar entre limites mínimo e máximo preestabelecidos. Dessa maneira, é possível limitar a profundidade de descarga das baterias, contribuindo para o prolongamento de sua vida útil. Neste trabalho, serão adotados os limites de 20% e 80%.

A Equação (19) define a potência injetada ou retirada da bateria B pelo sistema no intervalo t , calculada como a razão entre a variação de energia ao longo deste intervalo e a duração Δt . Essa definição não inclui perdas porque esta potência é enxergada do ponto de vista interno da bateria.

A energia armazenada na bateria B no intervalo t é atualizada conforme a Equação (20). Esse valor é calculado a partir do valor armazenado no final do intervalo anterior, acrescido da potência injetada ou retirada do sistema pela bateria B , considerando as perdas associadas. Quando a bateria está carregando ($P_{B,t}^{int.} > 0$), a energia armazenada aumenta, considerando a eficiência de carregamento η_c . Quando a bateria está descarregando ($P_{B,t}^{int.} < 0$), a energia armazenada diminui, levando em conta a eficiência de descarga η_d . Caso a bateria não esteja operando ($P_{B,t}^{int.} = 0$), seu estado de energia permanece inalterado em relação ao intervalo anterior e a potência fornecida pelo sistema é igual à potência das perdas por autodescarga.

Na Equação (21) é estabelecida a condição de ciclo completo para o estado de carga de cada uma das baterias ao longo do horizonte de otimização. Ela impõe que o estado de carga inicial deve ser igual ao estado de carga final, ou, de forma equivalente, que a energia armazenada no início do primeiro intervalo seja igual à energia armazenada ao final do último intervalo. Assim, evita-se que a bateria termine o período com uma carga artificialmente alta ou baixa e garante-se um balanço energético coerente ao longo do horizonte de análise.

A Equação (22) define a potência fornecida pela subestação em cada intervalo de tempo t . Ela estabelece que essa potência é igual à soma das potências consumidas pelas cargas do sistema, subtraída da potência gerada localmente, acrescida da potência fornecida às baterias e das perdas no sistema de distribuição. A potência $P_{B,t}^{ext.}$ é fornecida à bateria B na operação de carga e seu valor é positivo, mas na operação de descarga seu valor é negativo, pois a potência é retirada da bateria. Dessa forma, a equação assegura o balanço de potência no sistema, garantindo que toda a demanda não suprida localmente – de cargas, baterias e perdas elétricas – sejam supridas pela subestação em cada instante de tempo considerado. Essa equação também é útil para o cálculo do critério econômico de uma das FOBs analisadas, pois o custo total de energia depende dos valores de potência fornecida pela subestação em cada intervalo.

Na Equação (23), são calculadas as perdas elétricas no sistema de distribuição em cada intervalo de tempo t . Esse cálculo é composto pela soma das perdas em cada linha L do sistema.

A Equação (24) modela as perdas associadas às baterias em cada intervalo t . A primeira parcela da soma representa as perdas por autodescarga, que ocorrem independentemente do uso da bateria. A segunda parcela diz respeito às perdas por eficiência, que dependem não só dos valores das eficiências de carga e descarga, mas também da potência de entrada ou saída da bateria.

As Equações (25) e (26) modelam, respectivamente, as potências de carga e de geração em cada barra k no intervalo t . Ambas as equações são baseadas nas potências máximas de carga e de geração em cada barra, ajustadas em cada intervalo por fatores multiplicativos. No caso da carga, FC_t é o que foi chamado neste trabalho de fator de carga e a composição desse valor em cada intervalo forma a curva de carga ou curva de demanda do sistema. Semelhantemente, no caso da geração, FG_t é o fator de geração e seus valores compõem a curva de geração do sistema.

As Equações (27) a (31) modelam as penalizações aplicadas à função objetivo do problema de otimização, com o intuito de assegurar o cumprimento das restrições operacionais

do sistema. A Equação (27) define a variável binária Pen , que é composta pelas penalizações que podem ser consideradas no método proposto, associadas à alocação das baterias, à potência das baterias, ao fluxo reverso na subestação e à demanda máxima da subestação. Por meio do uso do operador lógico *ou* ($\vee$) a penalização Pen é ativada caso qualquer uma das condições associadas a essas variáveis ou equações seja violada, desestimulando o descumprimento das restrições operacionais e promovendo a busca de soluções que atendam a todos os requisitos do sistema.

A Equação (28) aborda a penalização de alocação, que é ativada quando duas baterias são alocadas na mesma barra do sistema. Nesse caso, a variável binária $Pen_{alocação}$ assume o valor 1, indicando a violação da restrição de alocação exclusiva de baterias em determinado nó.

A Equação (29) descreve a penalização associada à potência das baterias, que ocorre quando a potência injetada ou retirada de uma bateria B excede a potência máxima em algum intervalo de tempo. A variável $Pen_{potência\ Bat.}$ assume o valor 1 e a penalização é aplicada somente se a potência da bateria ultrapassar o limite estabelecido, o que visa garantir que o funcionamento da bateria respeite as suas capacidades técnicas.

A Equação (30) refere-se à penalização do fluxo reverso da subestação. Esta penalização é acionada caso a potência fornecida pela subestação seja negativa em algum intervalo de tempo, o que indicaria a ocorrência de um fluxo de energia reverso, um comportamento indesejado do ponto de vista operacional. Nesse caso $Pen_{fluxo\ reverso}$ assume o valor 1 e a penalização é aplicada, desestimulando soluções que resultem em tal cenário.

A última penalização proposta, definida na Equação (31), é associada à demanda máxima da subestação. A variável $Pen_{demanda\ máx.}$ assume o valor 1 e a penalização é ativada quando a potência fornecida pela subestação ultrapassa o valor máximo estabelecido no caso base para cada sistema elétrico simulado. Esta restrição visa evitar que a subestação seja sobrecarregada a partir do uso das baterias, garantindo que a demanda não ultrapasse os limites operacionais dos equipamentos da subestação ao longo do horizonte de otimização.

Por fim, as Equações (32) e (33) descrevem, respectivamente, o balanço de potência ativa e reativa nas barras do sistema de distribuição durante o horizonte de otimização. Essas restrições impõem que as somas das potências ativas e reativas que entram em cada barra sejam iguais às somas das potências que saem, modelando o princípio de conservação de energia. Ao

manter o equilíbrio energético nas barras, essas equações asseguram que as restrições de fluxo de potência sejam atendidas, refletindo o comportamento real dos sistemas elétricos.

Devido ao grande número de variáveis de decisão e de restrições, este problema apresenta elevada complexidade computacional, além de ser de natureza não linear. Além disso, o espaço de busca é amplo e contém vários pontos ótimos locais, o que inviabiliza o uso de métodos exatos convencionais, especialmente de métodos baseados em derivadas, cuja efetividade dependeria majoritariamente da qualidade da solução inicial fornecida. Por essa razão, optou-se pela aplicação de meta-heurísticas como estratégias de solução. A metodologia adotada será abordada em mais detalhes na seção seguinte.


3.3. MÉTODO PROPOSTO

Um dos objetivos deste trabalho é construir uma ferramenta de simulação capaz de realizar estudos de conexão e gerenciamento de baterias para avaliar determinados benefícios do uso de baterias em sistemas de distribuição. Para isso, foi implementado um método que permite variar diferentes parâmetros de simulação, como a topologia do sistema elétrico, os perfis de carga e geração, a curva de custos, as características técnicas das baterias, o método de otimização empregado, objetivos e restrições, entre outros.

Essa flexibilidade permite a construção de diversos cenários de teste, nos quais é possível investigar o comportamento do sistema sob diferentes condições operacionais. Com isso, o método possibilita uma análise comparativa dos resultados obtidos, considerando diferentes funções objetivo com finalidades técnicas e econômicas diferenciadas.

A ferramenta desenvolvida permite organizar e executar automaticamente diversos casos em sequência, por meio de um processo iterativo em que os parâmetros são variáveis de entrada. Na Figura 14, é visto um fluxograma deste processo iterativo, no qual para cada combinação de parâmetros um caso é formulado e resolvido e seus resultados são armazenados.

Figura 14 – Fluxograma de funcionamento do processo iterativo de simulação do método proposto.



Fonte: Elaborado pelo autor (2025).

3.3.1. Definição de Parâmetros de Criação dos Casos

Entre os parâmetros básicos de simulação que podem ser ajustados iterativamente entre os casos, destaca-se, em primeiro lugar, o sistema elétrico de distribuição utilizado. Como a simulação desenvolvida neste trabalho possui integração direta com o OpenDSS, há flexibilidade para realizar os testes em uma ampla variedade de sistemas elétricos. Isso inclui tanto os sistemas de teste clássicos amplamente utilizados na literatura quanto sistemas reais ou personalizados, modelados pelo próprio usuário. Para que a ferramenta funcione corretamente, é necessário apenas fornecer o conjunto de barras candidatas à alocação das baterias, além dos arquivos compatíveis com o OpenDSS que definem os elementos da rede. Neste trabalho, foram realizadas simulações em três sistemas teste: o IEEE 13 barras, o IEEE 34 barras e o IEEE 123 barras. Mais explicações sobre cada sistema serão feitas na seção 4.1.

As curvas de carga, que representam o comportamento da demanda ao longo do tempo, são outro parâmetro variável da simulação. O método permite a utilização de curvas com qualquer número de intervalos, podendo avaliar desde períodos com poucas horas até semanas, com discretizações horárias. Com isso, também é possível observar como a escolha das curvas de carga pode afetar o uso das baterias e os resultados obtidos, e comparar os conjuntos de curvas em termos de custo-benefício computacional.

Semelhantemente ao caso da carga, também são configuradas curvas temporais para o custo da energia e para a geração fotovoltaica, ambas com o mesmo número de intervalos da curva de carga. A curva de custos permite simular diferentes cenários tarifários, com variações mais ou menos intensas ao longo do tempo, possibilitando avaliar seu impacto na operação das baterias. Já o gerador fotovoltaico, além da curva de geração, pode ter sua potência e localização ajustadas.

Entre as características das baterias, diversos parâmetros podem ser configurados. Dentre eles, destacam-se a capacidade energética nominal, a potência máxima de carga e descarga, as perdas associadas ao processo de conversão de energia, a taxa de autodescarga e os limites operacionais definidos pelos valores mínimos e máximos de SOC. Ressalta-se que estes são os parâmetros configuráveis, pois o método também otimiza, para cada bateria, sua localização no sistema e seu perfil de operação ao longo do horizonte de simulação.

Em relação ao processo de otimização, o método permite a adoção de diferentes algoritmos. O algoritmo genético é o método padrão e mais utilizado neste trabalho. No entanto, a estrutura da implementação admite a substituição por outros métodos, como algoritmo de enxame de partículas (PSO), método de busca direta, entre outros, que também foram implementados e simulados nos casos propostos. Assim, é possível realizar estudos comparativos em termos de eficiência e qualidade das soluções encontradas.

Quanto às funções objetivo, o método suporta diferentes critérios de otimização. Neste trabalho, foram consideradas duas funções principais: a minimização dos custos operacionais do sistema com energia e a minimização das perdas elétricas. A primeira busca reduzir o valor financeiro da compra de energia, favorecendo a operação das baterias em horários economicamente vantajosos, enquanto a segunda visa diminuir as perdas elétricas associadas ao fluxo de potência na rede, incluindo também os valores de perdas nas baterias.

A partir da definição de todos os parâmetros mencionados, forma-se um caso de simulação, que corresponde à resolução de um único problema de otimização, com um objetivo


determinado e com configurações específicas de curvas de carga, sistema elétrico, método de otimização e capacidade das baterias. Os valores assumidos por esses parâmetros serão abordados no Capítulo 4, com detalhes dos casos formulados e simulados neste trabalho.

A ferramenta proposta permite, então, simular diversos desses casos ao iterar sobre diferentes combinações de parâmetros, conforme visto na figura anterior. Nela, a simulação de cada caso é representada por um único bloco, chamado “simular caso e armazenar resultados”, mas esse bloco é, na realidade, composto por diversos processos, os quais serão subdivididos e explicados em detalhes na seção a seguir.

3.3.2. Simulação dos Casos

A simulação de cada caso é um processo composto de diversos passos. Para fins de estruturação do método, a Figura 15 divide esse processo em 3 passos principais: a definição de parâmetros fixos, a execução do caso base e, por fim, a resolução do problema de otimização. Cada processo será explicado nas subseções a seguir.

Figura 15 – Fluxograma da resolução dos casos.



Fonte: Elaborado pelo autor (2025).

3.3.2.1. Definição de Parâmetros Fixos

A primeira etapa inclui a definição dos dados que não são parâmetros de entrada para o processo iterativo e que, portanto, irão assumir apenas valores predefinidos ao longo das simulações. Como visto na Figura 14, os parâmetros que variam ao longo dos casos simulados neste trabalho são o sistema elétrico, a curva de carga, o método de otimização e a capacidade das baterias. Assim, os outros parâmetros são definidos previamente nessa etapa.

Os principais parâmetros fixos que são definidos nessa etapa estão relacionados aos custos de energia, à geração fotovoltaica, às baterias e ao conjunto de barras candidatas à inserção de baterias.

Destes parâmetros, os custos de energia e a geração fotovoltaica são representados por meio de curvas que serão vistas em detalhes nas seções 4.1.1.2 (Curvas de custo de energia) e 4.1.1.3 (Curvas de geração fotovoltaica), no capítulo seguinte. Quanto aos outros parâmetros da geração, a potência e a barra de alocação para cada sistema são vistas na Tabela 2.

Tabela 2 – Parâmetros da geração fotovoltaica inserida no sistema.

Parâmetro	IEEE 13	IEEE 34	IEEE 123
<i>Potência total do circuito (kW)</i>	3567,02	2047,03	3615,24
<i>Potência do gerador FV (kW)</i>	356,702	204,703	361,524
<i>Barra de alocação do gerador FV</i>	671	834	60

Fonte: Elaborado pelo autor (2025)

Na tabela, observa-se que a potência do gerador fotovoltaico não é a mesma entre os diferentes sistemas elétricos, uma vez que a potência total do circuito (isto é, o somatório das potências das cargas) é diferente entre os sistemas. Para lidar com isso, tratou-se a potência do gerador fotovoltaico como um valor proporcional à potência total do circuito, mais especificamente 10% desse valor. Nota-se também que a alocação do gerador foi feita em uma única localização e de forma fixa por sistema, não sendo otimizada, e a seleção da barra foi feita de forma arbitrária após testes em algumas barras. A decisão de utilizar apenas um gerador foi tomada com o intuito diminuir o número de fatores de influência nas simulações, facilitando a observação das baterias.

Com relação às baterias, além da sua capacidade (que será variada a depender dos casos) e das barras de alocação (que serão otimizadas), suas outras características são fixas em todas as simulações. Em todos os casos simulados serão alocadas três baterias monofásicas de lítio-íon. Assim, em conformidade com a Tabela 1, foram definidos os seguintes valores para os parâmetros dos BESS simulados: SOC mínimo de 20% e SOC máximo de 80% (DOD máxima de 60%), eficiência de *round-trip* de 95% (rendimento de carga e de descarga equivalentes de aproximadamente 97% cada) e autodescarga de 0,33% por dia. Quanto à potência das baterias, foi estabelecida uma relação de potência/energia igual a 1. Assim, embora essa relação seja um parâmetro fixo, ela implica que a potência também varie juntamente com a energia a depender do caso simulado.

Por fim, os conjuntos de barras candidatas selecionadas nos casos propostos neste trabalho são compostos por todas as barras trifásicas de cada sistema, com exceção apenas da barra da subestação. Como as baterias são monofásicas, a alocação pode ser feita em cada uma das três fases de cada barra, o que faz com que o conjunto (número de nós candidatos) tenha 3 vezes o número de barras trifásicas candidatas. Com isso, o conjunto de locais candidatos à alocação no IEEE 13 possui 24 nós; no IEEE 34, 75 nós; e no IEEE 123, 198 nós. Assim, cada um desses locais (nós, definidos por barra e fase) poderá receber no máximo uma bateria monofásica.


3.3.2.2. Execução do Caso Base

Em seguida, é executado o caso base, isto é, a simulação do sistema sem a presença das baterias, que fornece informações de referência a respeito do sistema elétrico com a respectiva curva de carga aplicada. Essas informações são, nomeadamente, o custo de aquisição de energia ou as perdas elétricas, a depender da função objetivo definida para o referido caso. O resultado do caso base é armazenado e, a partir dele, é possível realizar comparações posteriores e avaliar numericamente os impactos do uso das baterias.

3.3.2.3. Resolução do Problema de Otimização

Por fim, com base nos parâmetros fixos e variáveis definidos para o caso, é realizada a etapa de resolução do problema de otimização, que busca encontrar a melhor alocação e operação das baterias conforme a função objetivo selecionada. O processo de otimização é estruturado em etapas bem definidas, vistas no fluxograma da Figura 16 com base na lógica adotada para o Algoritmo Genético, que constitui o método principal utilizado neste trabalho. Nos demais algoritmos, a estrutura geral pode variar, especialmente quanto às estratégias de aprimoramento de soluções e critérios de convergência.

Figura 16 – Fluxograma da resolução do problema de otimização por meio do AG.



Fonte: Elaborado pelo autor (2025).


- Definir parâmetros de otimização

Inicialmente é feita a definição dos parâmetros da otimização, dos quais se destacam as variáveis de otimização (no caso do AG, a estrutura dos cromossomos) e as opções do algoritmo.

Os cromossomos definidos neste trabalho trazem informações a respeito da localização das baterias alocadas e da sua operação ao longo dos intervalos, sendo compostos de $T+1$ genes

para cada bateria inserida, sendo o primeiro deles relativo à barra de alocação e os outros T , aos valores do SOC da bateria durante os T intervalos de tempo analisados. O cromossomo é ilustrado na Figura 17 para o caso de alocação de n baterias. Na figura, observa-se que as primeiras n variáveis envolvem a alocação das baterias e as últimas $n \cdot T$ variáveis compõem a sua operação.

Figura 17 – Ilustração do cromossomo.



Fonte: Elaborado pelo autor (2025).

Em seguida, são configuradas as opções do algoritmo genético. O tamanho da população foi estabelecido em 400 indivíduos com base em testes preliminares, que indicaram esse valor como suficiente para manter diversidade populacional e favorecer a convergência com um número reduzido de gerações. Também foi habilitado o uso de processamento paralelo, aproveitando múltiplos núcleos de CPU para acelerar a execução das simulações, e o uso de uma função híbrida, que aciona a rotina *fmincon* após a convergência do AG, com o objetivo de refinar a solução obtida pelo algoritmo.

Outras opções relevantes, como os critérios de convergência e os parâmetros dos operadores genéticos (elitismo, reprodução e mutação), também são definidos nesta etapa, mas serão detalhados posteriormente ao descrever as etapas do algoritmo.


- Criar população inicial

A execução do algoritmo genético tem início com a criação da população que será avaliada e modificada até sua convergência. Conforme mencionado anteriormente, essa população foi definida com 400 indivíduos, e cada um deles contempla a alocação e a operação de n baterias ao longo de T intervalos.

Por padrão, essa população é gerada de modo completamente aleatório, mas esse processo pode tornar a otimização computacionalmente custosa e até mesmo comprometê-la em muitos casos. Assim, é possível utilizar do conhecimento adquirido acerca do comportamento esperado da operação de baterias, criando uma população inicial diversa e com bons indivíduos para aumentar a eficiência computacional do método.

Para isso, foi desenvolvida uma rotina de criação da população inicial, que sorteia aleatoriamente as barras de alocação, e que segue três abordagens complementares para a criação do SOC: Uma porcentagem dos indivíduos é gerada com valores de SOC totalmente aleatórios, enquanto outra parcela utiliza curvas manualmente definidas, que refletem uma variedade de estratégias operacionais desejadas – carregando nas primeiras horas do dia, em que há menores preços e menor carregamento na rede, e descarregando durante os períodos de pico de carga ou de preços elevados. Nesse conjunto também são incluídas curvas em que o SOC não varia, com a intenção de fornecer ao algoritmo um ponto inicial para os casos em que a operação das baterias não seja tão vantajosa. As curvas geradas manualmente são vistas na Figura 18.

Figura 18 – Curvas geradas manualmente para composição da população inicial.



Fonte: Elaborado pelo autor (2025).

Nos indivíduos da terceira e última parcela da população, são criadas variações de até 20% de SOC sobre as mesmas curvas geradas manualmente. Essas variações são aplicadas aleatoriamente em cada intervalo, resultando em outro conjunto de perfis diversos que mantêm o comportamento desejado e respeitam os limites técnicos das baterias.

Por meio dessa abordagem, buscou-se criar populações iniciais bem distribuídas em termos de alocação e operação das baterias, além de relativamente próximas ao seu comportamento esperado, de modo a direcionar o algoritmo para uma região de boas soluções e melhorar seu desempenho.

- Avaliar indivíduos

De posse da população inicial, passa-se à etapa do algoritmo genético referente à otimização, que ocorre por meio da avaliação da aptidão dos indivíduos que formam a população a cada geração, bem como da evolução dessa população ao longo das gerações.

O processo de avaliação dos indivíduos é fundamental e ocorre por meio de uma função que, a partir de um cromossomo, retorna o valor da aptidão do respectivo indivíduo. Esse procedimento é repetido para todos os indivíduos a cada geração, sendo executado milhares de vezes até a convergência do algoritmo.

Neste trabalho, os cromossomos são formados pelos dados de alocação e SOC das baterias ao longo do dia e, a partir desses dados, a função de aptidão retorna o valor da respectiva função objetivo, que pode ser de custo de operação ou de perdas elétricas.

Para isso, a função de aptidão decodifica os genes do indivíduo e utiliza esses dados para alocar as baterias no sistema. Conforme mencionado previamente, será utilizado o OpenDSS no modo *follow* para simulações diárias, no qual a bateria segue a curva de despacho fornecida, sendo nesse caso proveniente dos dados de SOC contidos no cromossomo.

Para a observação do comportamento do sistema elétrico com a presença das baterias ao longo do período analisado, faz-se necessária a consideração de uma análise temporal, visto que a atuação dos BESS em cada intervalo depende da sua condição final no intervalo anterior.

Essa dependência temporal é considerada neste trabalho mediante a execução de fluxos de potência com séries temporais. Conforme ressaltam Dugan, Montenegro e Ballanti (2021, p.

59), ao realizar simulações diárias no OpenDSS, a solução no intervalo atual é usada como ponto de partida para a solução no intervalo seguinte.

Desse modo, após a execução dos fluxos de potência, os valores de perdas ou custos obtidos durante todos os intervalos são somados e retornados pela função. Além disso, em cada intervalo verifica-se os limites operativos e são aplicadas penalizações caso eles não sejam obedecidos. Nesses casos, os indivíduos recebem uma aptidão ruim e tendem a ser rejeitados pelo algoritmo.

- Convergência

Após a obtenção da aptidão de todos os indivíduos em cada geração, é verificada a convergência do algoritmo. Neste trabalho, o principal critério de convergência adotado é o de estagnação, que ocorre quando a aptidão média da população varia menos do que uma tolerância de 2×10^{-6} ao longo de 10 gerações. Esses valores foram modificados em relação aos valores padrão com base em testes que demonstraram uma boa relação entre precisão e tempo de execução.

Também foram estabelecidos dois critérios de parada adicionais: o tempo máximo de execução, que variou entre 40 e 60 minutos de acordo com o caso simulado, e o número máximo de gerações, fixado em 500. Contudo, esses critérios foram atingidos apenas em uma pequena parcela dos casos simulados, em situações nas quais os métodos de otimização utilizados se mostraram ineficientes para a solução dos respectivos casos.

- Aplicar operadores genéticos

Ao fim de cada geração, caso não seja atingido nenhum dos critérios de convergência, são aplicados os operadores genéticos: elitismo, reprodução e mutação.

Neste trabalho, após a realização de testes em diversas configurações possíveis, decidiu-se por utilizar as definições padrão do *toolbox* do Matlab para esses operadores, comentados brevemente nos parágrafos seguintes (MathWorks, 2025).

O número dos melhores indivíduos mantidos para a próxima geração (elitismo) é de 5% da população. Além destes, os outros 95% da próxima geração serão compostos de indivíduos provenientes de reprodução e mutação, em proporções de 80% e 20%, respectivamente.

Para a seleção dos indivíduos que irão reproduzir utiliza-se a função *selectionstochunif*. Para a função de cruzamento, que determina o modo que dois indivíduos pais são combinados para criar um indivíduo filho, é utilizada a função *crossoverscattered*. Para a mutação, a função aplicada é a *mutationgaussian*.

Esses operadores são aplicados em cada geração, proporcionando a evolução da população até que a convergência seja atingida e os valores ótimos das variáveis de otimização sejam obtidos, chegando à solução do problema e, conseqüentemente, ao fim da simulação do caso.

4. SIMULAÇÕES E RESULTADOS

4.1. INTRODUÇÃO

Este capítulo apresenta as simulações realizadas para validar o método proposto, assim como os resultados obtidos. Primeiramente, são definidos os casos de teste utilizados nas simulações.

Nas simulações, serão determinados a alocação e o gerenciamento de SOC ótimos de baterias, considerando os objetivos, limites e parâmetros descritos anteriormente. Serão realizadas simulações em três sistemas de distribuição, com baterias de quatro possíveis capacidades, utilizando quatro diferentes conjuntos de curvas de carga e solucionando o problema por meio de cinco métodos de otimização. Os casos simulados são sumarizados na Tabela 3.

Tabela 3 – Casos simulados.

<i>Sistema</i>	<i>Grupo de Casos</i>	<i>Critério de Comparação</i>	<i>Função Objetivo</i>	<i>Número de Casos</i>
IEEE 13 barras	S13.A	Capacidade de armazenamento	Custos	4
	S13.B	Curva de carga	Custos	12
	S13.C	Método de otimização	Custos	30
	S13.D	Capacidade de armazenamento	Perdas	4
IEEE 34 barras	S34.A	Capacidade de armazenamento	Custos	4
	S34.B	Curva de carga	Custos	12
	S34.C	Método de otimização	Custos	30
	S34.D	Capacidade de armazenamento	Perdas	4
IEEE 123 barras	S123.A	Capacidade de armazenamento	Custos	4
	S123.B	Curva de carga	Custos	12
	S123.C	Método de otimização	Custos	30
	S123.D	Capacidade de armazenamento	Perdas	4

Fonte: Elaborado pelo autor (2025).

Para cada um dos sistemas de distribuição, foram simulados quatro grupos de casos, para comparar os resultados em função das diferentes capacidades de armazenamento das baterias, das curvas de carga e dos métodos de otimização, e considerando as funções de minimização de custos e de perdas. Esses casos serão vistos com mais detalhes à frente.

4.1.1. Curvas adotadas

4.1.1.1. Curvas de carga

Neste trabalho considera-se a operação do sistema ao longo do tempo, resolvendo fluxos de potência com séries temporais. Essa abordagem é necessária para simular as dinâmicas do sistema de distribuição ao longo dos intervalos horários, bem como para avaliar os impactos das decisões de operação. Para isso, curvas de carga são aplicadas às cargas dos sistemas de distribuição simulados, as quais representam a variação do consumo de energia elétrica ao longo do tempo, capturando flutuações e refletindo fatores como hábitos de consumo, padrões energéticos de setores industriais e comerciais, sazonalidades climáticas e outros aspectos característicos das regiões analisadas.

Como a carga do sistema varia não só ao longo do dia, mas também da semana e entre estações do ano, a aplicação de curvas de carga precisas é um fator importante para representar adequadamente as condições do sistema e otimizar decisões de operação. A qualidade dessas curvas tem influência direta nos resultados das simulações e, por isso, é crucial que elas sejam baseadas em previsões robustas ou dados históricos confiáveis, trazendo um grau maior de realismo e aplicabilidade para as simulações realizadas.


Os casos propostos neste trabalho utilizaram diferentes configurações de curvas de carga, todas elaboradas a partir do histórico de operação do subsistema elétrico do Sudeste, utilizando dados fornecidos pelo Operador Nacional do Sistema Elétrico (ONS, 2024a) referentes aos anos de 2022 e 2023. Diferentes abordagens foram adotadas para modelar as curvas de carga, com níveis crescentes de detalhamento e variabilidade temporal, com o objetivo de avaliar o impacto dessas variações nos resultados da otimização.

Com isso, o período base para análise dos resultados observados pelo uso das baterias neste trabalho é de dois anos. Desse modo, é possível construir conjuntos de curvas que

representam porções deste período, o que permite aumentar ou diminuir a precisão e a representatividade das curvas de carga. Por exemplo, uma curva diária única que representa o comportamento médio de todos os dias ao longo dos dois anos é uma abordagem menos precisa, enquanto o uso de uma curva para cada dia – totalizando mais de 700 curvas – seria uma abordagem significativamente mais precisa, mas completamente inviável do ponto de vista computacional.

Portanto, inicialmente foi adotada a abordagem simplificada, com a construção de uma curva única representativa da operação de todo o período de 2022-2023. Essa curva foi obtida pela média dos perfis horários de todos os dias desse período, resultando em um conjunto de 24 intervalos horários que sintetiza o comportamento diário médio do sistema. Apesar de sua simplicidade e ampla utilização, essa estratégia não captura variações semanais ou sazonais, o que pode limitar sua precisão em cenários com maior dinâmica de carga. A Figura 19 apresenta o perfil dessa curva única.

Figura 19 – Curva de carga diária única.




Fonte: Elaborado pelo autor (2025).

Em seguida, foi desenvolvida uma curva semanal composta por 168 intervalos horários (24 horas x 7 dias), calculada a partir da média de todas as semanas dos dois anos analisados. Embora ainda seja uma curva média e não faça diferenciação entre semanas ao longo de grandes períodos de tempo, essa abordagem agrega maior detalhamento ao diferenciar padrões de

consumo entre cada um dos dias úteis e dos finais de semana. Na Figura 20, observa-se o perfil da curva semanal, na qual observam-se as variações de carga entre os dias ao longo da semana.


Figura 20 – Curva de carga semanal.



Fonte: Elaborado pelo autor (2025).

Mantendo a precisão da análise, foi adotada uma abordagem baseada na separação dos dias da semana. Foram construídas sete curvas de carga distintas, uma para cada dia, considerando a média dos perfis horários registrados para segundas-feiras, terças-feiras e assim por diante. Com isso, cada dia específico passou a ser modelado individualmente, e o método de otimização foi executado separadamente para cada uma dessas curvas. A Figura 21 mostra cada uma dessas curvas, que em outras palavras são apenas a divisão da curva semanal anterior. A partir dessa separação é possível comparar as duas abordagens de escopo semanal em termos de eficiência e esforço computacional.

Figura 21 – Curvas de carga dos dias da semana.




Fonte: Elaborado pelo autor (2025).

Na prática, a diferença entre essas duas abordagens é a seguinte: com a curva semanal, é formulado um único problema de otimização com um número de variáveis correspondente a todo o período da semana, ou seja, sete vezes maior do que os problemas de horizonte diário; já na abordagem em que os dias da semana são separados, cada problema de otimização possui um número menor de variáveis (por se tratar de simulações diárias), contudo é necessário formular e resolver sete problemas de otimização separados.

Por fim, a abordagem mais detalhada introduziu a separação sazonal, segmentando as curvas de carga com base nas quatro estações do ano (verão, outono, inverno e primavera) e diferenciando entre dias úteis, sábados e domingos. Isso resultou em 12 curvas distintas, refletindo tanto as variações sazonais quanto os padrões semanais. Essa estratégia, apresentada na Figura 22 e na Figura 23, mostra que existem diferenças entre os perfis sazonais, a exemplo do aumento da demanda em dias de semana no verão em comparação ao inverno. Apesar de ser a metodologia que necessita do maior número de simulações por caso, essa segmentação fornece a maior precisão e está alinhada às práticas de planejamento adotadas pelos operadores de sistemas reais.


As quatro abordagens variam em termos de simplicidade, precisão e custo computacional. Cada uma delas foi implementada com o objetivo de avaliar como o nível de detalhamento das curvas de carga impacta o equilíbrio entre esses fatores na execução dos métodos de otimização aplicados.

Figura 22 – Curvas de carga do verão e do outono.



Fonte: Elaborado pelo autor (2025).

Figura 23 – Curvas de carga do inverno e da primavera.



Fonte: Elaborado pelo autor (2025).

As simulações realizadas em diferentes escalas de tempo e quantidades de simulações podem ser comparadas entre si ao extrapolar o resultado das simulações diárias ou semanais ao longo do mesmo período de tempo para todas. Para isso, será adotado o horizonte de dois anos, em conformidade com a base de dados a partir da qual as curvas foram formadas.

Dessa forma, quando é utilizada a curva diária única, o resultado é multiplicado por 730, o total de dias dos dois anos. Já na curva semanal, multiplica-se por $\frac{730}{7}$, ou aproximadamente 104,3, que é o total de semanas dos dois anos. Nas situações em que, para cada caso, são realizadas múltiplas simulações com curvas de carga diferentes, como acontece com as curvas por dia da semana e com as curvas sazonais, é necessário multiplicar o resultado de cada simulação pelo respectivo número de vezes que aquele tipo de dia se repete. Assim, nas curvas por dia da semana, o resultado de cada uma das sete simulações foi multiplicado pela mesma constante $\frac{730}{7}$, considerando que cada dia ocorre o mesmo número de vezes que os outros. Por fim, nas curvas sazonais, o número de dias para cada curva é visto na Tabela 4, segundo a base de dados históricos da operação.

Tabela 4 – Número de dias das curvas de carga sazonais.

<i>Estação</i>	<i>Dias analisados</i>	<i>Número de dias</i>
Verão	Dias de semana	129
Verão	Sábado	25
Verão	Domingo	26
Outono	Dias de semana	130
Outono	Sábado	26
Outono	Domingo	26
Inverno	Dias de semana	131
Inverno	Sábado	26
Inverno	Domingo	27
Primavera	Dias de semana	130
Primavera	Sábado	27
Primavera	Domingo	27


Fonte: (ONS, 2024a)

4.1.1.2. *Curvas de custo de energia*

Considerando a relevância da variação temporal dos preços de energia nas decisões de operação, esta seção apresenta as curvas de custo utilizadas nas simulações. Neste trabalho foram utilizadas duas curvas de preços, ambas derivadas de dados históricos de operação do submercado Sudeste, disponibilizados pela Câmara de Comercialização de Energia Elétrica (CCEE, 2024), referentes ao período do outono do ano de 2018. Foram adotadas duas abordagens distintas para modelar os custos da energia ao longo do tempo, alinhando-se à estrutura das curvas de carga utilizadas nas simulações.

A primeira abordagem, aplicada às simulações com curvas de carga diárias, foi construída a partir da média dos valores de PLD registrados em cada horário ao longo de todos os dias do outono de 2018. Composta por 24 intervalos, ela reflete o custo médio da energia elétrica em cada período do dia, capturando variações típicas como aumentos em horários de pico e reduções em momentos de menor consumo. Por ser uma curva única, essa abordagem não diferencia os preços entre dias da semana. A Figura 24 apresenta esse perfil de variação diária.

Figura 24 – Curva de custo diária.




Fonte: Elaborado pelo autor (2025).

A segunda curva de custo, utilizada nas simulações semanais, possui 168 intervalos horários (24 horas $\times$ 7 dias) e foi construída a partir da média dos preços de PLD registrados

em cada horário ao longo de todas as semanas do mesmo período. Essa abordagem permite capturar padrões de variação ao longo da semana, como a tendência de custos mais baixos em finais de semana devido à redução do consumo, além das variações sutis entre manhãs, tardes e noites. A curva semanal é vista na Figura 25.

Figura 25 – Curva de custo semanal.



Fonte: Elaborado pelo autor (2025).


Ao comparar as duas figuras é possível observar que o perfil semanal não é composto da repetição exata do perfil diário em todos os dias. Assim, é esperado que o custo de operação do sistema varie entre as simulações diárias e as semanais, tanto nos casos base de cada simulação, quanto após a inserção das baterias no sistema.

4.1.1.3. Curvas de geração fotovoltaica

Por fim, as curvas de geração do gerador fotovoltaico alocado no sistema também foram construídas a partir de dados históricos. Especificamente, foi considerada a média da geração fotovoltaica registrada no subsistema Sudeste durante o mês de junho de 2022 (ONS, 2024b).

Para as simulações diárias, adotou-se a média horária da geração ao longo de todo o período analisado, resultando em uma curva com 24 intervalos, apresentada em laranja na Figura 26.

Figura 26 – Curva de geração fotovoltaica diária.



Fonte: Elaborado pelo autor (2025).


Na mesma figura, observa-se em azul a curva de carga diária do sistema, incluída para fins comparativos. Nota-se que a potência máxima da geração fotovoltaica alcança o valor de 10% da potência máxima do sistema ou 0,1 p.u. Além disso, a curva representada em amarelo ilustra o perfil da carga líquida, obtida pela subtração entre o valor da carga e o valor da geração fotovoltaica correspondente em cada intervalo.

Observa-se que o maior afastamento entre essa curva equivalente e a curva de carga ocorre exatamente no horário de pico da geração solar, refletindo o impacto da fonte fotovoltaica na redução da carga líquida do sistema. Nota-se também que o gerador produz energia apenas nos horários em que há incidência solar, de modo que, nos primeiros e últimos intervalos do dia, a geração fotovoltaica é muito próxima de zero. Consequentemente, a curva líquida nesses períodos praticamente se sobrepõe à curva de carga, como visto na figura, apresentando um comportamento coerente com a natureza intermitente da fonte.

Como a curva de geração fotovoltaica é determinada principalmente por fatores climáticos e naturais, independente de variações nos perfis de consumo ao longo da semana, optou-se por utilizar a mesma curva diária de geração para todos os dias na composição da curva semanal. Dessa forma, a curva de geração fotovoltaica foi simplesmente repetida sete vezes, resultando na curva semanal apresentada na Figura 27. Nessa figura, assim como na

anterior, são exibidas a curva de carga do sistema, a curva de geração fotovoltaica e a curva líquida obtida pela subtração entre a geração e a carga.

Figura 27 – Curva de geração fotovoltaica semanal.




Fonte: Elaborado pelo autor (2025).

4.1.2. Casos S13 – Sistema IEEE 13 Barras

Nos casos dos grupos S13A, S13B e S13C, são alocadas baterias no sistema teste IEEE 13 barras, visto na Figura 28, o qual é amplamente utilizado como referência em estudos de análise de sistemas de distribuição devido à sua complexidade relativa em um modelo compacto.

Figura 28 – Sistema IEEE 13 barras.




Fonte: (IEEE PES, 2017).

O sistema é relativamente curto em extensão, mas apresenta um carregamento elevado. Operando a 4,16 kV, esse sistema apresenta uma configuração radial que inclui linhas aéreas e subterrâneas, carga desequilibrada, um regulador de tensão localizado na subestação, capacitores *shunt* para suporte reativo e um transformador posicionado ao longo do circuito.

4.1.3. Casos S34 – Sistema IEEE 34 Barras

Nos casos dos grupos S34A, S34B e S34C, são alocadas baterias no sistema teste IEEE 34 barras, visto na Figura 29. Esse sistema é radial e caracterizado por um longo alimentador com tensão nominal de 24,9 kV.

Figura 30 – Sistema IEEE 123 barras.



Fonte: Modificado de IEEE PES (2017).

O circuito opera com uma tensão nominal de 4,16 kV e inclui um transformador para uma seção curta de 480 V. Devido às quedas de tensão, quatro reguladores de tensão são utilizados. O alimentador também conta com bancos de capacitores e carregamento desequilibrado, com modelos de cargas dos tipos potência, corrente e impedância constante.

4.1.5. Casos A – Comparação por Capacidade de Armazenamento

Os grupos de casos S13.A, S34.A e S123.A têm como objetivo comparar o uso de baterias de capacidades de armazenamento variadas, agrupando os resultados e avaliando o desempenho do sistema em cada caso.

Para isso, a capacidade de armazenamento será variada entre os quatro valores possíveis (100, 500, 1000 e 1500 kWh), enquanto os demais parâmetros permanecerão fixos: o sistema elétrico será o correspondente a cada grupo de casos; o método de otimização escolhido será o algoritmo genético; e a curva de carga aplicada será a curva única.

4.1.6. Casos B – Comparação por Curva de carga

Os grupos de casos S13.B, S34.B e S123.B têm como finalidade avaliar como a utilização de curvas de carga em diferentes níveis de detalhamento afeta o desempenho do sistema e o planejamento da operação das baterias.

Neste conjunto, a curva de carga será a variável de interesse, sendo testadas quatro configurações (curva única, curva semanal, curvas por dia da semana e curvas sazonais). Dentre os demais parâmetros, as capacidades de armazenamento analisadas serão as de 500, 1000 e 1500 kWh, o sistema elétrico será conforme o respectivo grupo de casos, e o método de otimização adotado continuará sendo apenas o algoritmo genético.

4.1.7. Casos C – Comparação por Método de Otimização

Os grupos de casos S13.C, S34.C e S123.C têm como objetivo comparar os resultados obtidos de operação de baterias a partir da aplicação de diferentes possíveis métodos de otimização.

Portanto, neste conjunto, as variações ocorrerão no método utilizado para resolver o problema de otimização, sendo testados ao todo cinco métodos distintos: o Algoritmo Genético (função *ga* no Matlab), a Otimização por Enxame de Partículas (PSO – função *particleswarm*), o método de Nelder–Mead (função *fminsearch*), o método de busca direta (função *patternsearch*), e um método em cascata incluindo o *ga* e o *patternsearch*. Todas as funções são nativas do Matlab.

Para avaliar como cada método se comporta com as variações dos outros parâmetros de simulação, as curvas de carga e capacidades de armazenamento também serão variadas. Serão analisadas as curvas única, semanal e dos dias da semana, e as capacidades de 500 e 1000 kWh.

4.1.8. Casos D – Minimização de Perdas

Os grupos de casos S13.D, S34.D e S123.D buscam avaliar o impacto da capacidade de armazenamento das baterias sobre as perdas elétricas no sistema de distribuição. A diferença central em relação aos casos do grupo A está na função objetivo adotada, uma vez que, aqui, busca-se a minimização das perdas elétricas, não dos custos operacionais com energia.

Serão testadas quatro capacidades distintas de armazenamento (100, 500, 1000 e 1500 kWh), enquanto os demais parâmetros permanecerão fixos. O sistema elétrico será o correspondente a cada grupo de casos, a curva de carga aplicada será a curva única, e o método de otimização utilizado será o algoritmo genético.

4.2. RESULTADOS OBTIDOS


A seguir, serão apresentados os resultados obtidos nas simulações dos casos propostos.

4.2.1. Sistema IEEE 13 Barras

4.2.1.1. Casos S13.A

Inicialmente, para o sistema IEEE 13 barras, foram simulados os quatro casos que compõem o grupo S13.A. Cada um desses casos possui uma capacidade de armazenamento diferente, e a FOB é de minimização dos custos. Como a curva de carga é única, só é necessário rodar um AG em cada caso. Os resultados obtidos são vistos na Figura 31.

Figura 31 – Resultado dos casos S13.A.



Fonte: Elaborado pelo autor (2025).

A figura apresenta os impactos da alocação de baterias no custo total de operação do sistema analisado ao longo dos dois anos abrangidos pela curva de carga. No eixo vertical à esquerda, são representados os custos totais com energia elétrica, enquanto à direita é apresentada a diminuição percentual dos custos de cada caso em relação ao caso base, sem a utilização de baterias. O eixo horizontal, por sua vez, mostra a capacidade dos BESS instalados, variando entre 100 e 1500 kWh.

Na figura, observa-se inicialmente uma linha azul superior de valor constante, que mostra o custo de energia do sistema no caso base, sem a alocação de BESS. Em seguida, são vistas duas curvas que comparam os resultados dos casos, sendo a primeira referente ao custo de energia com a alocação de baterias (em azul), e a segunda, à diminuição percentual desse custo em relação ao caso base (em laranja).

Nota-se que o custo do sistema sem a presença de baterias é fixo, relativo ao caso base. Por outro lado, a alocação de baterias traz reduções progressivas nos custos de energia, com reduções da ordem de 0,2% para baterias de 100 kWh, chegando a aproximadamente 2,4% para baterias de 1500 kWh.


A diferença entre os custos com e sem BESS em cada caso evidencia que a estratégia de operação obtida por meio do algoritmo genético é eficaz em explorar o potencial de arbitragem energética das baterias, e a curva laranja mostra que a redução percentual de custo cresce com o aumento da capacidade dos BESS.

É importante destacar que apenas as quatro capacidades de BESS foram simuladas e que as linhas entre esses pontos apenas têm o objetivo de facilitar a visualização, não necessariamente representando o comportamento do sistema com baterias de outras capacidades. Ao passo que parece existir uma tendência de crescimento linear, por outro lado não há provas concretas de que isso de fato ocorre. Seria necessário realizar mais simulações para verificar esse comportamento, mas isso não faz parte do escopo do trabalho.

Os resultados obtidos indicam que o uso de BESS no sistema IEEE 13 barras tem resultados econômicos positivos, mesmo para capacidades relativamente modestas. Esses ganhos ainda poderiam ser potencializados se fossem considerados outros benefícios não monetizados diretamente nesta análise, como serviços ancilares e aumento da confiabilidade.

Na Figura 32, são vistas as curvas de estado de carga das três baterias monofásicas alocadas no caso com as capacidades de 1500 kWh. Também são vistas as curvas de carga e de custos para este caso. Na legenda do gráfico, observa-se que as baterias foram alocadas nas três fases da barra 671. Estes e os demais locais de alocação de baterias são vistos em tabelas no Anexo C.

Figura 32 – SOC das baterias no caso S13.A com capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).

A figura mostra que o perfil de operação das baterias tende a carregar nas primeiras horas do dia – em que os custos de energia são mais baixos, assim como a demanda – e descarregar apenas entre as 18 e as 22 horas, quando há o pico de demanda e os custos são maiores. Esse comportamento é similar entre as três baterias. Dessa maneira, é possível aproveitar o potencial de arbitragem energética das baterias para obter benefícios econômicos.


4.2.1.2. Casos S13.B

Os casos do grupo S13.B foram simulados para comparar, com a função de minimização de custos, as quatro abordagens de curva de carga propostas: única, semanal, dos dias de semana, e das estações. Esses cenários foram aplicados a três valores distintos de capacidade de armazenamento (500 kWh, 1000 kWh e 1500 kWh), totalizando 12 casos simulados.

Para cada um desses casos, o número de problemas de otimização variou a depender da quantidade de curvas da respectiva abordagem de curva de carga: nos casos com as curvas única e semanal apenas um AG é executado, enquanto com as curvas de dias da semana e estações o AG precisa ser rodado sete e doze vezes por caso, respectivamente.

A Figura 33 compara os resultados obtidos nos casos com baterias com capacidade de 500 kWh.

Figura 33 – Resultado dos casos S13.B com a capacidade de 500 kWh.



Fonte: Elaborado pelo autor (2025).

A figura apresenta no eixo horizontal as quatro estratégias de curva de carga e, nos eixos verticais, os custos do sistema (à esquerda) e a redução percentual observada (à direita). Para cada abordagem, são vistas três barras, da esquerda para a direita: em azul, os custos do sistema sem BESS (caso base) e com BESS (resultado do caso) e, em laranja, a diminuição percentual entre esses dois custos.


Observa-se que, embora os custos absolutos do caso base sejam semelhantes entre os cenários, há pequenas variações associadas à diferença nas curvas de carga e de custo utilizadas. A maior discrepância foi observada no caso com curva semanal, que se destaca dos demais por adotar uma curva de preços diferenciada em relação à curva diária dos outros casos. Esse resultado evidencia que o detalhamento tanto da curva de carga quanto da curva de custos influencia os resultados da análise econômica.

Em todos os cenários, a inclusão de baterias levou à redução do custo total de operação, com ganhos percentuais que ficaram em torno de 0,9%. Apesar de serem observadas economias semelhantes entre os casos, a leve variação entre eles mostra que o detalhamento da curva tem algum impacto, mesmo em sistemas com capacidade de armazenamento modesta. Ainda assim, as diferenças entre as abordagens são pouco expressivas nesse nível de capacidade, indicando

que, para valores reduzidos de armazenamento, o uso de curvas mais simples pode ser suficiente para capturar os principais benefícios econômicos do BESS.

A Figura 34 apresenta os resultados dos casos simulados com baterias de 1000 kWh de capacidade. A estrutura da figura é a mesma da anterior, comparando os custos do sistema (sem e com BESS) e a respectiva redução percentual para cada abordagem de curva de carga.

Figura 34 – Resultado dos casos S13.B com a capacidade de 1000 kWh.



Fonte: Elaborado pelo autor (2025).


Com o dobro da capacidade de armazenamento em relação ao caso anterior, percebe-se um aumento nas reduções percentuais obtidas, que agora se aproximam da marca de 1,6% em todos os cenários. Esse crescimento reforça a tendência de que o potencial de economia cresce com o aumento da capacidade de armazenamento.

Embora os valores absolutos de custo continuem próximos entre si, as diferenças tornam-se um pouco mais evidentes que nos casos com 500 kWh. Destaca-se novamente a influência da curva semanal, cujo caso base apresenta o maior custo, devido principalmente à variação da curva de custos. Dentre as outras abordagens, a curva única se mostra a mais otimista, alcançando os menores valores com e sem BESS, além da maior diminuição percentual.

Já as abordagens mais detalhadas – dias da semana e estações – apresentaram resultados bastante próximos entre si, com reduções levemente inferiores à da curva única. Esses resultados, devido ao detalhamento das curvas, são mais representativos da realidade operacional do sistema. Isso permite avaliar o custo-benefício computacional entre utilizar curvas simplificadas, como a única, e abordagens mais detalhadas, que exigem um esforço computacional significativamente maior. Dado que os resultados são relativamente próximos, pode-se considerar que o uso apenas de curvas simplificadas seria uma alternativa viável e suficiente nos cenários analisados até aqui.

Por fim, a Figura 35 apresenta os resultados obtidos com baterias de 1500 kWh de capacidade.

Figura 35 – Resultado dos casos S13.B com a capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).

Assim como nos casos anteriores, observa-se uma tendência clara de crescimento na economia percentual conforme aumenta a capacidade de armazenamento. Neste cenário, as reduções percentuais ficaram concentradas na faixa entre 2,3% e 2,4%, indicando um ganho adicional em relação às configurações anteriores.

Apesar desse crescimento, a diferença entre os custos absolutos das abordagens permanece relativamente pequena. A curva semanal continua apresentando os maiores custos


operacionais entre os casos base, reforçando sua sensibilidade à curva de preços. A curva única, por sua vez, mantém-se como a abordagem mais otimista: além de gerar os menores custos sem e com BESS, foi a que apresentou a maior redução percentual.

As curvas mais detalhadas, dos dias da semana e das estações, novamente mostraram resultados bastante similares entre si, o que reforça o comportamento observado nos cenários anteriores. A consistência dos resultados permite afirmar que, mesmo com capacidades maiores de armazenamento, as abordagens simplificadas seguem se mostrando suficientemente eficazes.

Assim, para o sistema IEEE 13 barras, permanece válida a avaliação de que, diante de um custo computacional significativamente menor, a adoção de curvas mais simples pode ser preferível quando os ganhos marginais de precisão não justificarem o custo adicional inerente ao aumento do detalhamento. Contudo, é importante destacar que seu uso não exclui a necessidade do uso de curvas mais detalhadas quando se trata de planejamento em curto prazo, uma vez que as características do sistema são bastante variáveis e a operação não deve ser realizada da mesma forma todos os dias.

A Figura 36 mostra as curvas de estado de carga das baterias alocadas no caso com a curva de carga semanal e capacidade de 1500 kWh. Conforme a legenda do gráfico, as baterias foram alocadas nas três fases da barra 671.

Figura 36 – SOC das baterias no caso S13.B com curva semanal e capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).


Observa-se que a operação mantém o perfil de carga nos primeiros horários de cada dia e descarga nos horários de pico. Esse comportamento se repete para todos os dias, e é semelhante entre as três baterias. Novamente, nota-se a curva de custos, a qual é diferente entre os diferentes dias da semana, o que justifica a diferença dos resultados obtidos nos casos com curva semanal em relação aos casos com curvas de horizonte diário.

4.2.1.3. Casos S13.C

A seguir, são apresentados os resultados dos casos do grupo S13.C, os quais têm como objetivo avaliar o desempenho dos cinco métodos de otimização aplicados ao problema em questão. Os testes foram realizados no sistema IEEE 13 barras, com variações entre dois níveis de capacidade de armazenamento (500 kWh e 1000 kWh) e três configurações de curva de carga (única, semanal e por dia da semana), totalizando 30 execuções (6 por método).

A Figura 37 apresenta os resultados para os casos com capacidade de 500 kWh, comparando os cinco métodos de otimização na resolução do problema, inicialmente aplicando apenas a curva única.

Figura 37 – Resultado dos casos S13.C com a capacidade de 500 kWh, com a curva única.




Fonte: Elaborado pelo autor (2025).

A figura compara, em azul, o custo do sistema sem BESS (primeira barra à esquerda) com os custos obtidos com cada método (barras seguintes) e também mostra, em laranja, a diminuição percentual alcançada por cada um. Observa-se que todos os algoritmos chegam a resultados em que há redução de custos em relação ao caso base, com pequenas variações: o *fminsearch* se destacou negativamente, com diminuição de 0,75%, enquanto os outros quatro métodos chegaram a resultados muito semelhantes, todos entre 0,86 e 0,87%.

Para aprofundar a comparação, a Figura 38 apresenta um gráfico tridimensional das economias absolutas obtidas por cada método, utilizando cada uma das três curvas de carga testadas, ainda com baterias de 500 kWh. Assim, é possível realizar a comparação não só entre as abordagens de curva de carga (como nos casos S13.B), mas também entre os métodos.

Figura 38 – Economia nos casos S13.C com a capacidade de 500 kWh.




Fonte: Elaborado pelo autor (2025).

Nesse gráfico, as barras representam as economias obtidas pelos métodos em cada caso, calculada pela diferença entre o respectivo caso com BESS e o caso base ao longo dos dois anos do horizonte. Ao contrário dos gráficos anteriores, que retratam os custos do sistema, aqui os maiores valores de economia indicam um melhor desempenho do método.

Ao observar a figura, nota-se que a tendência observada no grupo de casos anterior (S13.B) continua aqui: a curva de carga semanal proporcionou a maior economia com baterias de 500 kWh nesse sistema, atingindo os maiores valores em cada um dos métodos testados.

Ao comparar os cinco métodos, é possível observar novamente que, com exceção do *fminsearch*, os resultados obtidos foram muito próximos entre si e nenhum deles se sobressaiu aos outros. Porém, para avaliar do ponto de vista da eficiência computacional, foi realizada uma comparação do tempo de simulação necessário para cada um dos métodos chegar a esses resultados. Essa comparação é vista em outro gráfico tridimensional na Figura 39.

Figura 39 – Tempo computacional dos casos S13.C com a capacidade de 500 kWh.




Fonte: Elaborado pelo autor (2025).

Destaca-se imediatamente a eficiência do algoritmo genético (função *ga*) que, para essa configuração específica de sistema e capacidade de baterias, apresentou os menores tempos de simulação em todas as abordagens de curva de carga. O método do enxame de partículas (*pso*) foi o que mais se aproximou, com ótimo desempenho nas curvas única e semanal, mas mediano na dos dias da semana. A *fminsearch*, além de apresentar resultados piores, também gasta um tempo computacional maior, reforçando a ineficiência do método para resolução do problema formulado neste trabalho.

A busca direta (*patternsearch*) chama atenção por ter ótimo desempenho nas abordagens em que o horizonte de simulação é diário (curva única e dias da semana), mas de longe o pior desempenho na curva semanal. Isso ocorre porque o *patternsearch* fica menos eficiente com o aumento do número de variáveis dos problemas de otimização, pois precisa avaliar mais pontos por iteração e costuma exigir mais iterações para convergir. Por fim, o método em cascata sofre deste mesmo efeito, porém em menor grau, visto que o AG já entrega para o *patternsearch* um bom resultado inicial como ponto de partida.

Na sequência, passou-se para os casos com baterias de capacidades de 1000 kWh. Os resultados são exibidos nos mesmos formatos, inicialmente comparando os custos e a diminuição obtidos por cada método para a curva única, conforme a Figura 40.

Figura 40 – Resultado dos casos S13.C com a capacidade de 1000 kWh, com a curva única.




Fonte: Elaborado pelo autor (2025).

A figura mostra que, novamente, todos os métodos chegaram a soluções em que há diminuição dos custos, dessa vez com economias maiores do que com as baterias de 500 kWh, o que pode ser observado tanto pelos valores de custo, em azul, menores e mais distantes do caso base, quanto pelos maiores valores de diminuição percentual, em laranja.

Comparando os métodos entre si, nota-se que o destaque negativo do *fminsearch* se mantém, assim como a equiparação dos outros métodos. Em termos de diminuição percentual dos custos, o *fminsearch* chegou a uma diminuição de 1,47%, enquanto os outros métodos ficaram entre 1,65 e 1,67%. Aqui a diferença entre eles é distinguível visivelmente, mas ainda bastante pequena: o *ga* e o *patternsearch* obtiveram diminuições de 1,65%, e o *pso* e o método em cascata, 1,67%.

Em seguida, na Figura 41 observa-se a comparação dos métodos incluindo as curvas dos dias da semana e a semanal. A comparação novamente é realizada em termos da economia ao longo do horizonte de dois anos.

Figura 41 – Economia nos casos S13.C com a capacidade de 1000 kWh.




Fonte: Elaborado pelo autor (2025).

A figura mostra que o padrão se mantém para as curvas dos dias da semana: o *fminsearch* tem um resultado inferior e os outros quatro métodos tem resultados próximos, com o *ga* e o *patternsearch* apresentando resultados levemente inferiores aos do *pso* e do método em cascata.

Já na curva semanal, há uma diferença mais significativa entre os métodos. O *patternsearch* e o método em cascata tem resultados melhores de economia com a curva semanal do que com as outras, enquanto o *ga* e o *pso* tem o menor resultado com a curva semanal, inclusive se aproximando mais do *fminsearch*.

Para avaliar não só os resultados, mas também a eficiência computacional de cada método, a Figura 42 mostra o tempo utilizado por cada método para chegar nesses resultados.

Figura 42 – Tempo computacional dos casos S13.C com a capacidade de 1000 kWh.



Fonte: Elaborado pelo autor (2025).

Na figura, observa-se que o *ga* e o *pso* apresentaram tempos de simulação parecidos para todas as curvas. Um ponto que chama atenção é que ambos levaram menos tempo na simulação da curva semanal do que até mesmo na curva única. Isso pode indicar uma convergência prematura dos métodos, o que explica o resultado da economia de ambos ter sido visivelmente inferior ao de outros métodos.


O *patternsearch* teve um desempenho parecido ao visto na Figura 39, com alta eficiência nas curvas única e dos dias da semana, mas necessitando de um tempo elevado para a curva semanal. Aqui seu desempenho é ainda mais extremo, com o menor tempo dentre todos os métodos para as duas curvas com horizontes diários, mas o maior tempo na de horizonte semanal, empatado com o método em cascata. Este, por sua vez, apresentou algumas diferenças ao comparar os tempos para as duas capacidades de baterias: enquanto antes os tempos de simulação eram menores do que o *patternsearch*, agora o tempo é maior na curva dos dias da semana, e igual nas outras curvas.

A partir dessas análises, pode-se dizer que o *patternsearch* se mostrou o método mais eficiente com curvas de horizonte diário nestes casos. Já com a curva semanal, os métodos que levaram menos tempo também chegaram a um resultado visivelmente inferior.

4.2.1.4. Casos S13.D

O último grupo de casos simulados no sistema IEEE 13 tem como diferencial o fato de sua função objetivo ser de minimização de perdas elétricas, e não mais de custos de energia. A capacidade das baterias foi variada entre os mesmos valores dos casos S13.A, apenas com a curva de carga diária única, totalizando quatro casos. O método de resolução é apenas o algoritmo genético. Os resultados obtidos são vistos na Figura 43.

Figura 43 – Perdas totais nos casos S13.D.



Fonte: Elaborado pelo autor (2025).


O eixo à esquerda e os gráficos em azul mostram as perdas elétricas no sistema elétrico ao longo de todo o horizonte de simulação, tanto no caso base quanto com o uso das baterias. Em laranja, é vista a diminuição percentual desse valor em relação ao caso base. Esse valor pode ser negativo, significando um aumento no valor das perdas totais, que incluem as perdas de energia nas baterias.

Nota-se que as perdas elétricas totais aumentaram com o aumento da capacidade das baterias, o oposto do que ocorreu com a FOB de minimização de custos. Para as capacidades de 100 e 500 kWh, foi possível chegar a valores de perdas inferiores aos do caso base, o que

mostra que o uso de baterias pode ocasionar a diminuição das perdas elétricas do sistema, dependendo de sua capacidade e localização. Contudo, mesmo nesses casos, as diminuições percentuais tiveram valores baixos, em torno de 0,6 e 0,2%, respectivamente. Já para as capacidades maiores, nesse caso, ocorreram aumentos nas perdas totais (diminuições percentuais negativas), com valores em torno de 0,3 e 0,8%. Ou seja, é preciso cautela na tentativa de utilizar baterias para minimização de perdas.

Como a função objetivo inclui as perdas nas baterias, elas operaram de modo a não realizar cargas e descargas intensas, o que aumentaria as perdas. Assim, uma outra análise interessante é observar o resultado das simulações excluindo as perdas nas baterias – por eficiência e autodescarga. Nesta situação, é possível observar que o uso de baterias, mesmo sem cargas e descargas intensas, diminui as perdas no sistema elétrico, quando desconsideradas as perdas nas baterias. Isso pode ser observado na Figura 44.

Figura 44 – Perdas no sistema elétrico nos casos S13.D.



Fonte: Elaborado pelo autor (2025).

Nota-se que em todos os casos as perdas elétricas no sistema foram menores do que no caso base, com diminuições na faixa dos 0,6% para todas as capacidades. As perdas aumentaram levemente com a capacidade, possivelmente devido ao fato de as baterias operarem

ainda menos devido ao critério de perdas, que fez parte da otimização, mas não está sendo apresentado neste gráfico.

É importante destacar que a diminuição de perdas é comumente associada à alocação de GD, e não de baterias. Isso ocorre porque os geradores distribuídos passam a fornecer energia localmente, diminuindo o fluxo de potência nas linhas desde a subestação. Entretanto, neste trabalho, o gerador distribuído alocado faz parte do caso base, de modo que, ao compará-lo com este caso, os resultados mostram apenas os efeitos provenientes da alocação e do uso das baterias, as quais, por si só, não trazem grandes contribuições para a redução das perdas.


Esses resultados também destacam a importância da consideração das perdas internas das baterias, uma vez que, ao incluí-las, o uso de baterias pode até mesmo piorar o desempenho do sistema. Com isso, pode-se dizer que o uso de baterias com essa finalidade nem sempre é atrativo e precisa ser estudado em cada caso para avaliar se os resultados são positivos e se as perdas nas baterias inviabilizam a operação.

4.2.2. Sistema IEEE 34 Barras

4.2.2.1. Casos S34.A

Os casos simulados no sistema IEEE 34 seguem os mesmos modelos dos anteriores. O grupo S34.A é composto por quatro casos, com variação da capacidade de armazenamento e curva única, todos com FOB de minimização de custos. Os resultados são vistos na Figura 45.

Figura 45 – Resultado dos casos S34.A.



Fonte: Elaborado pelo autor (2025).


Semelhantemente ao sistema anterior, o custo de energia do sistema sem baterias é único, enquanto a alocação de baterias diminui os custos progressivamente com o aumento da capacidade das baterias.

Nos casos S13.A as diminuições de custo ficaram na faixa de 0,2 a 2,4%, enquanto aqui nos casos S34.A os resultados chegaram de 0,5 a 4,5%, indicando que o uso de baterias nesse sistema tem o potencial de trazer benefícios econômicos ainda maiores para todas as capacidades de baterias analisadas.

Outra verificação interessante é que no S13.A a diminuição percentual de custo cresce de forma aproximadamente linear com o aumento da capacidade, enquanto aqui a curva (composta a partir dos quatro pontos, com linhas entre eles para efeito de visualização) tem um perfil mais descendente. Isso parece apontar para um limite a partir do qual o aumento da capacidade das baterias vai se tornando menos vantajoso, sugerindo que o uso de baterias menores pode ter retornos proporcionalmente melhores, e que a alocação de baterias ainda maiores no sistema IEEE 34 pode não valer a pena.

A Figura 46 mostra as curvas de estado de carga das três baterias alocadas no caso com as capacidades de 1500 kWh. Na legenda do gráfico, observa-se que as baterias foram alocadas nas três fases da barra 808.

Figura 46 – SOC das baterias no caso S34.A com capacidade de 1500 kWh.




Fonte: Elaborado pelo autor (2025).

Nesse caso, o perfil de operação das baterias também carregou nas primeiras horas do dia, mas isso ocorreu de modo mais lento em comparação com o caso do sistema 13 barras. Da mesma forma, a descarga ocorre mais lentamente, iniciando com potências menores entre 14 e 17h, com aumento de potência entre 17 e 22h, e finalizando às 23h. Também se observa que houveram mais diferenças entre as baterias, com curvas visualmente mais distintas.

4.2.2.2. Casos S34.B

Em seguida, foram simulados os casos do grupo S34.B, que comparam as quatro abordagens de curva de carga propostas, com FOB de minimização de custos. Aqui também foram utilizadas três capacidades de armazenamento, totalizando 12 casos. Os quatro primeiros casos comparam as quatro curvas com baterias de 500 kWh de capacidade, e seus resultados são vistos na Figura 47.

Figura 47 – Resultado dos casos S34.B com a capacidade de 500 kWh.



Fonte: Elaborado pelo autor (2025).


Na figura, nota-se inicialmente que há pequenas variações de custos com o sistema sem baterias a depender das curvas de carga utilizadas. A maior diferença foi observada com a curva semanal, novamente por causa da curva de custos semanal utilizada nesse caso.

Essas diferenças também são observadas nos custos obtidos pelo AG com baterias em cada caso, levando a diminuições percentuais visivelmente diferentes para cada curva. A menor diminuição foi encontrada com a curva semanal, enquanto as maiores foram encontradas com as curvas de dias da semana e estações. Portanto, nota-se que, nestes casos, ao aumentar o detalhamento das curvas de horizonte diário, há um ganho de desempenho do método em relação à curva única, indicando que o algoritmo foi capaz de aproveitar as características semanais e sazonais das curvas para operar as baterias de maneiras mais vantajosas. Além disso, há o aumento da precisão da análise, uma vez que essas abordagens de curva de carga são mais próximas das metodologias de operação real dos sistemas elétricos.

Ao comparar os resultados com baterias de 500 kWh entre os grupos S13.B e S34.B, nota-se que a economia no sistema de 34 barras chega a valores próximos de 2,3%, maior do que os 0,9% no de 13 barras.

Na Figura 48, são apresentados os resultados dos casos simulados neste sistema com baterias de 1000 kWh de capacidade.

Figura 48 – Resultado dos casos S34.B com a capacidade de 1000 kWh.




Fonte: Elaborado pelo autor (2025).

A figura mostra que, com o aumento da capacidade das baterias, as diminuições chegaram perto de 3,9% nos melhores casos, sendo 70% maiores do que os 2,3% da figura anterior. Contudo, para chegar a esse aumento de 70%, a capacidade de baterias dobrou (de 500 para 1000 kWh), reiterando o que havia sido observado no grupo S34.A, cujos resultados mostram o perfil descendente dos custos em função da capacidade.

Com esse valor de capacidade, o caso com curva semanal continua apresentando a menor diminuição percentual de custos, apesar de estar mais próximo do caso com curva única. Da mesma forma, as duas curvas diárias mais detalhadas continuam chegando aos melhores resultados.

Por último, a Figura 49 mostra os resultados obtidos em cada caso com capacidade de baterias de 1500 kWh.

Figura 49 – Resultado dos casos S34.B com a capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).


A figura mostra, novamente, impactos positivos nos custos do sistema a partir do uso de baterias. Dessa vez, a diminuição encontrada com a abordagem das estações foi um destaque, chegando a 6,5%, enquanto os casos com as outras três curvas chegaram a cerca de 4,5%.

Ao comparar com os valores das duas figuras anteriores, permanece a tendência de diminuição dos custos com o aumento da capacidade das baterias. Entretanto, enquanto os resultados do grupo S34.A pareceram indicar que as baterias de maiores capacidades produziam resultados proporcionalmente menores, aqui, ao utilizar uma das abordagens de curva de carga, chegou-se a uma operação mais vantajosa, indo de encontro com aquele resultado (que havia sido obtido a partir da abordagem de curva única). Com isso, ressalta-se mais uma vez o detalhamento das curvas de carga como um fator que pode ser determinante na obtenção das estratégias ótimas de operação das baterias.

Além disso, comparando os resultados de diminuição percentual obtidos aqui (6,5% no melhor caso) com os do sistema IEEE 13 com baterias de 1500 kWh (2,4%), nota-se uma diminuição mais significativa no IEEE 34. Isso fortalece a tendência observada no grupo S34.A de que esse sistema elétrico se beneficia mais do que o de 13 barras pelo uso de baterias para diminuição de custos de energia.

Na Figura 50, são vistas as curvas de estado de carga das baterias alocadas no caso com a curva de carga semanal e capacidade de 1500 kWh. Conforme a legenda do gráfico, as baterias foram alocadas nas três fases da barra 808.

Figura 50 – SOC das baterias no caso S34.B com curva semanal e capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).


Novamente, observa-se que as baterias carregam nos primeiros intervalos de cada dia, com um comportamento diário similar ao das curvas de horizonte diário (como a da Figura 46).

4.2.2.3. Casos S34.C

Os casos do grupo S34.C comparam o desempenho de diversos métodos de otimização na solução do problema de minimização de custos do sistema por meio do uso de baterias. Os 30 casos que compõem este grupo variam os parâmetros da mesma forma que no sistema anterior: duas capacidades de armazenamento, três abordagens de curva de carga e cinco métodos de otimização.

Na Figura 51 é vista a comparação dos métodos apenas na curva única, com baterias de 500 kWh de capacidade.

Figura 51 – Resultado dos casos S34.C com a capacidade de 500 kWh, com a curva única.




Fonte: Elaborado pelo autor (2025).

Da mesma forma que os casos anteriores, a diminuição da FOB em comparação com o caso base foi alcançada por todos os métodos. O *fminsearch* tem novamente o pior desempenho, com diminuição de 1,7%, enquanto o *pso* e o *patternsearch* chegam aos melhores resultados, na faixa de 2,4%. O *ga* e o método em cascata estão entre esses dois extremos, com valores na faixa dos 2,2%.

Ao comparar com as simulações semelhantes realizadas no sistema IEEE 13, nota-se que essas diminuições são bem maiores do que os 0,86% daqueles casos. Também houve mais variação, com uma amplitude maior entre os melhores e os piores métodos.

Em seguida, os casos com curva semanal e dos dias da semana são incluídos na comparação, observando as economias absolutas obtidas pelos métodos em cada caso. O gráfico 3D com esses dados é visto na Figura 52.

Figura 52 – Economia nos casos S34.C com a capacidade de 500 kWh.



Fonte: Elaborado pelo autor (2025).


Na figura observa-se uma maior variação entre os resultados do que nos casos anteriores. Ao comparar cada método curva por curva, nota-se inicialmente que a curva única apresenta os resultados vistos na figura anterior, com o pior resultado proveniente do *fminsearch* e os melhores do *pso* e do *patternsearch*. Na curva dos dias da semana, a comparação entre os métodos é parecida, com o *ga* à frente apenas do *fminsearch*, mas com o *patternsearch* e o método em cascata um pouco acima do *pso*.

Na curva semanal também não há grandes mudanças, apenas com atenção para o fato de que o *pso* e o *ga* se aproximam mais do resultado inferior obtido pelo *fminsearch* do que dos melhores resultados obtidos pelo *patternsearch* e pelo método em cascata.

De modo geral, os resultados concordaram entre si, com a curva semanal trazendo a menor economia em quase todos os casos, devido à curva de custos. O *patternsearch* foi um destaque positivo, chegando aos melhores resultados em cada uma das curvas. O *ga*, por outro lado, ficou mais distante dos melhores resultados, em comparação com as simulações do grupo S13.C. O *pso* chegou a boas economias em curvas com horizonte diário, mas comparativamente inferiores no caso com curva semanal. E o método em cascata composto pelo *ga* e pelo *patternsearch* se aproximou mais deste último, se igualando a ele com os melhores resultados nas curvas semanal e dos dias da semana.

A comparação dos tempos de simulação destes casos é vista na Figura 53.

Figura 53 – Tempo computacional dos casos S34.C com a capacidade de 500 kWh.




Fonte: Elaborado pelo autor (2025).

Ao observar a figura, nota-se que o *patternsearch*, além de ter os melhores resultados nas três curvas, teve também o melhor tempo nas duas curvas com horizonte diário. Os outros métodos tiveram tempos bem maiores, especialmente na curva dos dias da semana. Na curva semanal, o *ga* e o *pso* obtiveram os menores tempos de simulação, mas não chegaram a resultados tão próximos aos melhores, novamente indicando que esses métodos convergiram prematuramente em uma região subótima de soluções.

Em seguida, passou-se para os casos com baterias de 1000 kWh de capacidade. A Figura 54 compara os custos e a diminuição obtidos por cada método, apenas para a curva única.

Figura 54 – Resultado dos casos S34.C com a capacidade de 1000 kWh, com a curva única




Fonte: Elaborado pelo autor (2025).

Novamente todos os métodos chegaram a custos menores do que os do caso base, com maior diminuição dos custos (3,9% no melhor caso) do que nos casos com baterias menores (2,4%). Porém, enquanto naqueles casos os destaques foram o *pso* e o *patternsearch*, nestes o oposto ocorre, com o método em cascata obtendo os melhores resultados, seguido do *ga*. Além disso, pela primeira vez, o *fminsearch* não teve os piores resultados, superando o *pso*.

Na Figura 55 é vista a economia obtida em cada caso, comparando os métodos com as três curvas analisadas.

Figura 55 – Economia nos casos S34.C com a capacidade de 1000 kWh.




Fonte: Elaborado pelo autor (2025).

A figura mostra que nestes casos os métodos obtiveram resultados mais uniformes e mais próximos entre si. O método em cascata, especialmente, chegou praticamente aos mesmos valores de economia com as três curvas, sendo, nos três casos, o melhor valor dentre os métodos. O *ga* e o *patternsearch* obtiveram economias um pouco menores, próximas entre si, e também bastante semelhantes entre as três curvas. O *pso* teve seus piores resultados, com resultados iguais ou menores que os encontrados pelo *fminsearch*.

Como os resultados foram próximos, torna-se ainda mais importante a análise do tempo computacional gasto pelos métodos em cada caso. Esses dados são vistos na Figura 56.

Figura 56 – Tempo computacional dos casos S34.C com a capacidade de 1000 kWh.



Fonte: Elaborado pelo autor (2025).

Nas curvas de horizonte diário, os resultados são bastante compatíveis com o tempo de cada método: o método em cascata e o *ga* levaram mais tempo para encontrar as melhores economias, enquanto o *pso* convergiu bastante rápido, mas encontrou um ponto comparativamente ruim. O *patternsearch* também levou menos tempo, mas conseguiu um resultado melhor que o do *pso*. Por fim, o *fminsearch* precisou de bastante tempo para se sair igual ou melhor do que o *pso*, mas seus resultados ainda não justificam o tempo gasto.

Já na curva semanal, a situação muda: o *patternsearch* e o método em cascata precisaram de bastante tempo, enquanto o *ga* gastou significativamente menos para chegar a um resultado semelhante. O *pso* e o *fminsearch* novamente gastaram menos tempo do que outros métodos, mas obtiveram resultados inferiores.


Comparando o tempo destas simulações com o das realizadas no sistema de 13 barras, nota-se que o tempo necessário aqui foi maior na grande maioria dos casos. Isso indica que os processos de otimização com baterias neste sistema são mais custosos do ponto de vista computacional, o que pode ocorrer, por exemplo, devido ao maior número de barras candidatas à alocação. Observa-se também que os padrões de tempo gasto por cada métodos nos diferentes cenários são parecidos, como o *ga* e o *pso* levando um tempo bem maior na curva dos dias da semana e o mesmo acontecendo com o *patternsearch* na curva semanal.

Em termos de custo-benefício computacional, o *patternsearch* se destaca com as curvas de horizonte diário de simulação, enquanto o *ga* parece o método mais eficiente na curva semanal. Ambos gastaram tempos comparativamente baixos nesses casos destacados, e foram capazes de chegar perto dos melhores resultados, obtidos pelo método em cascata.

4.2.2.4. Casos S34.D

Este grupo, o último do sistema IEEE 34, avalia a influência da variação da capacidade das baterias nas perdas elétricas do sistema. Os quatro casos são formulados apenas com a curva única e resolvidos com o AG, variando entre as mesmas capacidades dos casos anteriores. As perdas totais encontradas são vistas na Figura 57.

Figura 57 – Perdas totais nos casos S34.D.




Fonte: Elaborado pelo autor (2025).

Novamente, para baterias de capacidades mais baixas – aqui, apenas as de 100 kWh –, foi possível reduzir as perdas elétricas do sistema, enquanto as baterias mais altas ocasionaram aumentos progressivos das perdas, devido à sua eficiência e autodescarga. Nesses casos, as diminuições percentuais (em laranja) são negativas, pois ocorre o aumento das perdas do sistema.

A Figura 58 mostra o efeito das baterias apenas nas perdas do sistema elétrico, excluindo os efeitos de suas perdas internas.

Figura 58 – Perdas no sistema elétrico nos casos S34.D.



Fonte: Elaborado pelo autor (2025).

Observa-se que, até mesmo ao desconsiderar os efeitos das perdas internas, o uso de baterias pode prejudicar o desempenho do sistema. Novamente, o uso de baterias nesse sistema reduz as perdas do sistema apenas no caso com a menor capacidade analisada, chegando a uma diminuição de 0,6%.

Já nos casos com baterias maiores, as perdas do sistema aumentam cerca de 0,1%. Esses aumentos ocorrem de forma regressiva, pois seu valor vai se aproximando de zero ao aumentar a capacidade das baterias, dentre os valores analisados.

Ressalta-se novamente que o processo de otimização é realizado com a inclusão das perdas das baterias na função objetivo, o que desestimula que elas realizem cargas e descargas mais intensas. Também vale destacar, mais uma vez, que estes resultados dizem respeito apenas ao uso das baterias, não estando relacionados com o gerador distribuído alocado, que também faz parte do caso base.

Além disso, ao comparar com os casos simulados no IEEE 13, no qual nota-se que as perdas do sistema elétrico ficaram abaixo do caso base em todas as capacidades de baterias,


diferente dos casos no sistema de 34 barras. Isso pode indicar que esse sistema é menos beneficiado com o uso de baterias com a finalidade de redução de perdas, ou mesmo que o potencial do uso de baterias com essa finalidade é limitado por características do sistema elétrico, sendo necessários estudos posteriores para avaliar essa questão.

4.2.3. Sistema IEEE 123 Barras

4.2.3.1. Casos S123.A

Inicialmente, no grupo S123.A, foram simulados os quatro casos que comparam os custos de energia do sistema a partir da variação das quatro capacidades de baterias analisadas. Os casos foram simulados com a curva única e resolvidos com o AG, e seus resultados são observados na Figura 59.

Figura 59 – Resultado dos casos S123.A.




Fonte: Elaborado pelo autor (2025).

A figura mostra que os resultados da operação desse sistema com baterias são bem semelhantes aos dos sistemas anteriores, especialmente o de 13 barras, diminuindo progressivamente os custos com o aumento das capacidades.

Na Figura 60, são observadas as curvas de estado de carga das três baterias de 1500 kWh alocadas no respectivo caso. Na legenda do gráfico, observa-se que as baterias foram alocadas nas três fases da barra 7.

Figura 60 – SOC das baterias no caso S123.A com capacidade de 1500 kWh.




Fonte: Elaborado pelo autor (2025).

O comportamento das curvas segue o perfil observado nos outros sistemas, em que as baterias carregam nos primeiros intervalos e descarregam nos horários de pico.

4.2.3.2. Casos S123.B

O próximo grupo de casos simulados é o S123.B, que também compara os custos do sistema a partir do uso das quatro diferentes abordagens de curva de carga propostas. Em conjunto com as quatro abordagens, foram utilizadas três diferentes capacidades de baterias, totalizando 12 casos. A Figura 61 compara os custos obtidos em cada caso, com as baterias de 500 kWh de capacidade.

Figura 61 – Resultado dos casos S123.B com a capacidade de 500 kWh.



Fonte: Elaborado pelo autor (2025).


Nota-se, assim como nos outros sistemas, que há alterações pequenas nos custos do caso base, devido às variações das curvas de carga e de custos. De semelhante modo, com uso de baterias, os resultados de custos e diminuições também variam, chegando a valores que, apesar de diferentes, são bem próximos entre si. Mais uma vez, a abordagem semanal foi a que chegou ao valor mais divergente, precisamente devido à diferença em sua curva de custos.

Ao comparar os resultados obtidos nos três sistemas com baterias de 500 kWh, observa-se que o IEEE 123 barras chegou às menores reduções de custos: enquanto o sistema de 34 barras chegou a valores próximos de 2,3% e o de 13 barras, 0,9%, o de 123 barras ficou um pouco atrás, chegando na faixa dos 0,8%.

Nota-se também que, enquanto os casos com curva semanal no IEEE 34 chegaram aos menores valores de diminuição percentual, nos outros dois sistemas essa foi a abordagem de curva de carga que alcançou os melhores resultados. Em todos os três sistemas, a curva de custos utilizada nessa abordagem levou-a a obter os maiores custos, tanto no caso base quanto nos casos simulados com baterias.

A Figura 62 mostra os resultados dos casos simulados nesse sistema utilizando baterias com capacidade de 1000 kWh.

Figura 62 – Resultado dos casos S13.B com a capacidade de 1000 kWh.




Fonte: Elaborado pelo autor (2025).

Nota-se novamente que, ao dobrar a capacidade das baterias, as diminuições percentuais obtidas crescem, chegando aproximadamente a 1,5% em todos os cenários. A curva semanal continua apresentando os maiores custos, mas as diminuições nesse caso são menores, sendo ultrapassadas pela abordagem da curva única. Entre as três abordagens com horizonte diário de simulação, os custos são praticamente iguais, com a curva única chegando a uma diminuição percentual ligeiramente superior.

Ao comparar os três sistemas para esse valor de capacidade das baterias, o padrão dos resultados do IEEE 123 se assemelha bastante ao do IEEE 13, com a curva semanal chegando ao menor valor, a curva única levemente acima, e as outras curvas próximas entre si. Os valores de diminuição continuam bem próximos, com 1,6% no IEEE 13 enquanto o IEEE 123 segue abaixo com reduções de 1,5%.

Por fim, a Figura 63 apresenta os resultados obtidos com baterias de 1500 kWh de capacidade.

Figura 63 – Resultado dos casos S123.B com a capacidade de 1500 kWh.




Fonte: Elaborado pelo autor (2025).

A figura mostra, assim como nos casos anteriores, a tendência de reduções de custo cada vez maiores conforme a capacidade das baterias aumenta: Aqui, a curva semanal chegou ao melhor resultado, com uma redução de custos de aproximadamente 2,2%, maior do que os casos com baterias menores.

Mais uma vez, as abordagens chegaram a resultados bastante semelhantes, especialmente as de horizonte diário. Ainda assim, esses resultados são inferiores aos obtidos nos outros sistemas elétricos simulados, indicando que o sistema de 123 barras se beneficia menos do que eles com o uso de baterias.

Na Figura 64, são vistas as curvas de estado de carga das baterias alocadas no caso com a curva de carga semanal e capacidade de 1500 kWh. Conforme a legenda do gráfico, as baterias foram alocadas nas três fases da barra 7.

Figura 64 – SOC das baterias no caso S123.B com curva semanal e capacidade de 1500 kWh.



Fonte: Elaborado pelo autor (2025).


Observa-se, novamente, que neste caso as baterias carregam ao início de cada dia, com um comportamento diário similar ao das curvas de horizonte diário.

4.2.3.3. Casos S123.C

O próximo grupo de casos simulados é o S123.C, que visa avaliar comparativamente o desempenho dos métodos de otimização aplicados ao problema elaborado neste trabalho. Cada um dos cinco métodos de otimização é avaliado em seis configurações, compostas pelas combinações entre duas capacidades de armazenamento de baterias e três abordagens de curva de carga.

Inicialmente, para as baterias de 500 kWh, é feita a comparação apenas com a abordagem de curva única. Seus resultados são vistos na Figura 65.

Figura 65 – Resultado dos casos S123.C com a capacidade de 500 kWh, com a curva única.




Fonte: Elaborado pelo autor (2025).

A figura mostra, assim como os casos anteriores, que todos os métodos foram capazes de encontrar soluções que reduzem os custos de energia do sistema. Aqui, o *patternsearch* chega aos melhores valores de redução de custos, seguido de perto pelo método em cascata e pelo *pso*, todos com reduções na faixa de 0,8%. Os resultados obtidos pelo *ga*, apesar de visivelmente um pouco inferiores, ainda são próximos, enquanto o *fminsearch* segue com os piores resultados, na faixa dos 0,65%.

Na Figura 66 são comparadas as economias obtidas por cada método, incluindo também as outras duas abordagens de curvas de carga.

Figura 66 – Economia nos casos S13.C com a capacidade de 500 kWh.



Fonte: Elaborado pelo autor (2025).


A figura mostra novamente que o *fminsearch* apresentou os piores resultados com todas as curvas. Os outros métodos apresentaram resultados bastante aproximados entre si para cada abordagem de curva de carga.

A curva semanal apresentou os melhores resultados de todos os métodos, e os melhores resultados dessa abordagem foram obtidos pelo método em cascata. A curva única e a dos dias da semana tiveram resultados menores e próximos entre si. Nas duas abordagens, o *patternsearch* e o *pso* ficaram um pouco acima dos outros métodos.

Ao comparar esses resultados com os obtidos nos sistemas de 13 e 34 barras, nota-se que as economias obtidas nos três casos têm a mesma ordem de grandeza, passando de 100 mil reais em 2 anos na maioria dos casos. Porém, enquanto os sistemas de 13 e 123 barras possuem custos na ordem de 12 milhões de reais, o de 34 barras é menor, cerca de 6 milhões. E, como as economias absolutas são próximas, isso explica porque as diminuições percentuais são maiores no IEEE 34.

Para comparar a eficiência dos métodos para chegar nos resultados encontrados no sistema IEEE 123, a Figura 67 mostra o tempo gasto pelos métodos em cada caso.

Figura 67 – Tempo computacional dos casos S123.C com a capacidade de 500 kWh.




Fonte: Elaborado pelo autor (2025).

Novamente, o *ga* se destaca por sua eficiência, trazendo os menores tempos dentre todos os métodos aplicados, ao mesmo tempo que seus resultados ficaram bem próximos aos melhores em todas as curvas. Aqui, o *patternsearch* e o método em cascata também gastam pouco tempo nas curvas de horizonte diário, além dos melhores resultados. Nessas curvas, o *fminsearch* gastou os maiores tempos e obteve os piores resultados, ao passo que o *pso* gastou mais tempo do que outros métodos mas também chegou aos melhores resultados.

Na curva semanal, o método que chegou às maiores economias foi o composto pela cascata entre o *ga* e o *patternsearch*. Porém, ele também foi o que gastou o maior tempo, seguido de perto pelo *patternsearch*. Os outros métodos também obtiveram bons resultados, próximos entre si, mas o *ga* e o *pso* precisaram de um tempo bem menor do que os outros.

Em seguida, foram simulados os casos com baterias de 1000 kWh de capacidade, cujos resultados são vistos na Figura 68.

Figura 68 – Resultado dos casos S123.C com a capacidade de 1000 kWh, com a curva única.




Fonte: Elaborado pelo autor (2025).

A figura mostra que o aumento das capacidades de baterias novamente produziu uma maior redução de custos com todos os métodos, chegando próxima dos 1,6%. O padrão de comparação entre os métodos é bem parecido com os casos anteriores, com baterias menores: o *fminsearch* obteve os maiores custos com baterias e os outros quatro métodos chegaram a resultados próximos entre si. Aqui, o método que chegou às maiores reduções de custo foi o *pso*.

A seguir, foram incluídos os resultados dos casos simulados por cada método incluindo também as outras curvas de carga. O resultado obtido é visto na Figura 69.

Figura 69 – Economia nos casos S123.C com a capacidade de 1000 kWh.



Fonte: Elaborado pelo autor (2025).

A comparação realizada na curva única se mantém para a abordagem dos dias da semana: o *pso* chega às maiores economias, seguido de perto pelo método em cascata, *patternsearch* e *ga*, enquanto a *fminsearch* se distancia com os piores resultados.


Na curva semanal, porém, o *ga* e o *pso* tem resultados comparativamente piores. Em ambos, com baterias menores, a curva semanal trazia um ganho significativo em comparação às outras, enquanto aqui não ocorre apenas a diminuição desse ganho, mas os valores chegam a ser menores do que os alcançados pela curva única. Já os outros três métodos mantêm bons resultados com a curva semanal, chegando a economias maiores do que com as outras abordagens.

As comparações dos padrões de resultados entre os sistemas elétricos são semelhantes às realizadas nos casos com baterias de 500 kWh. No IEEE 123, em todos os casos, os métodos alcançam resultados parecidos aos do IEEE 13. As maiores diferenças ocorrem na curva semanal, que no sistema de 13 barras tem resultados ainda piores alcançados pelo *ga* e pelo *pso*. O de 34 barras, por sua vez, mantém maior variabilidade entre métodos e curvas, divergindo mais dos resultados dos outros sistemas.

Ao dobrar a capacidade das baterias, as economias obtidas também praticamente dobraram, chegando a valores próximos dos R\$ 200 mil. Os valores alcançados por todos os sistemas elétricos estão nessa mesma ordem de grandeza, reforçando o potencial das baterias nos diversos sistemas simulados, além dos ganhos crescentes à medida que as capacidades das baterias aumentam.

Por fim, na Figura 70 são vistos os tempos gastos por cada método nas simulações realizadas no sistema IEEE 123.

Figura 70 – Tempo computacional dos casos S123.C com a capacidade de 1000 kWh.



Fonte: Elaborado pelo autor (2025).

Assim como nos outros sistemas, o *ga* se mostrou menos eficiente com baterias de 1000 kWh do que com baterias menores, deixando de ter os menores tempos nos casos com curvas de horizonte diário. Nesses cenários, o *patternsearch* apresenta tempos consideravelmente menores do que de todos os outros métodos, além de chegar a resultados bastante semelhantes. Para chegar aos melhores resultados, o *pso* gasta o maior tempo em ambos os casos. Os tempos do *ga* e do método em cascata ficam entre esses extremos, mas esse último chega a resultados melhores. O *fminsearch* novamente chega numa solução pior, mesmo levando mais tempo.

Já na curva semanal, o *ga* novamente leva significativamente menos tempo do que o *patternsearch* e o método em cascata, enquanto o *pso* fica entre o menor e os maiores. Contudo,


apesar de menos eficientes nesse cenário, os dois métodos que levaram mais tempo também chegaram a resultados melhores, enquanto os mais rápidos tiveram desempenho comparativamente menor nessa abordagem.

Em geral, novamente o *patternsearch* se destaca com bons resultados e alta eficiência, especialmente nos casos em que o horizonte de simulação é diário e, portanto, o número de variáveis de otimização é menor. Outros métodos mais rápidos, como o *ga*, se saem bem na maioria das situações, mas em alguns casos podem convergir para soluções inferiores aos outros métodos.

4.2.3.4. Casos S123.D

O último grupo de casos simulados neste trabalho compara quatro casos com diferentes capacidades de baterias em termos da diminuição das perdas do sistema elétrico. Inicialmente, são comparados os valores das perdas totais, que também incluem as perdas internas nas baterias. Essa comparação é vista na Figura 71.

Figura 71 – Perdas totais nos casos S123.D.




Fonte: Elaborado pelo autor (2025).

Na figura, nota-se que, em todos os casos, a alocação de baterias resultou no aumento das perdas elétricas no sistema, pois as perdas com BESS são maiores do que as do caso base para as quatro capacidades simuladas. Outro indicativo é que as diminuições percentuais são negativas em todos eles. O aumento das perdas foi de cerca de 1,7% com baterias de 100 kWh e cresceu ainda mais para as maiores capacidades de baterias, chegando a 3,1% para baterias de 1500 kWh.

Excluindo os efeitos das perdas internas das baterias, a Figura 72 compara os resultados apenas em termos das perdas dos componentes do sistema elétrico.

Figura 72 – Perdas no sistema elétrico nos casos S123.D.



Fonte: Elaborado pelo autor (2025).

As perdas obtidas nesses casos foram aproximadamente constantes apesar do aumento da capacidade das baterias, sendo superiores às perdas do sistema no caso base. Vale destacar mais uma vez que as perdas internas não são apresentadas neste gráfico, mas elas foram consideradas na otimização. Lembra-se, também, que os casos consideram apenas os efeitos da alocação de baterias, não observando o efeito do gerador fotovoltaico que faz parte do caso base.

Contudo, a diferença entre esses dois gráficos mostra que o aumento da capacidade das baterias afeta significativamente as perdas totais, mesmo que não afete as perdas no sistema

nesses casos. Este fato aponta para a necessidade da consideração das perdas internas das baterias, uma vez que, ao desconsiderá-las, o resultado poderia ser mais otimista, mas ao mesmo tempo mais distante da realidade.

Por fim, retoma-se novamente a comparação entre os resultados obtidos nos casos em que são minimizadas as perdas elétricas em todos os sistemas simulados. Em todos os casos, a função objetivo leva em conta as perdas internas das baterias, contudo, os resultados nas perdas elétricas do sistema variam de um sistema para o outro. Ao observar as perdas elétricas dos componentes do sistema de 13 barras, nota-se que o efeito do uso das baterias é sempre de redução desse valor, enquanto no de 123 barras é sempre de aumento desse valor, e no de 34 barras isso varia de acordo com a capacidade das baterias. Isso parece indicar, mais uma vez, que esses dois sistemas possuem características que limitam o potencial do uso de baterias com essa finalidade, fazendo que eles sejam menos beneficiados por elas. Contudo, estudos posteriores são necessários para melhor avaliar essas comparações.

5. CONSIDERAÇÕES FINAIS

5.1. CONCLUSÕES

Este trabalho apresentou o desenvolvimento e a aplicação de um método para alocação e operação de baterias em sistemas de distribuição de energia elétrica, com foco em minimizar os custos de energia e as perdas elétricas. Para isso, foi estruturado um modelo de otimização com acoplamento temporal, incorporando restrições operacionais e permitindo diferentes configurações de carga, tarifas e diversos outros parâmetros.

O modelo de baterias que foi utilizado é composto principalmente por um armazenamento ideal e pela representação das perdas por eficiência e autodescarga. Seu despacho foi realizado por meio do controle do estado de carga (SOC) das baterias em cada intervalo, cujos valores foram determinados pelos métodos de otimização.

A metodologia proposta, implementada em Matlab e OpenDSS, consiste em uma ferramenta flexível, capaz de gerar diversos cenários de simulação para análise comparativa. Por meio dela, buscou-se avaliar benefícios econômicos e técnicos provenientes do uso de baterias e observar os efeitos das variações de parâmetros de simulação.

Os resultados obtidos validam o método proposto. Os casos de teste foram construídos a partir de simulações realizadas em três sistemas teste do IEEE (13, 34 e 123 barras), variando a capacidade de armazenamento das baterias, as curvas de carga e os métodos de otimização, com funções objetivo de minimização de custos ou de perdas.

Na minimização de custos operacionais, o aumento da capacidade das baterias resultou em reduções progressivas nos custos de energia em todos os sistemas simulados. Em relação às curvas de carga, o detalhamento das curvas pode influenciar os resultados, sendo que, em alguns casos, abordagens mais detalhadas levaram a maiores ganhos de desempenho em comparação com a curva única, pois permitiram que o algoritmo explorasse características semanais e sazonais mais vantajosas. Porém, em diversos casos, curvas mais simples se mostraram eficazes, chegando a resultados próximos com o custo computacional menor, de certa forma justificando o uso de abordagens menos detalhadas.

Já na comparação dos métodos de otimização, foi possível observar alguns padrões em termos de eficiência computacional. O *fminsearch* consistentemente apresentou os piores

resultados em termos de redução de custos e tempo computacional. O *patternsearch* destacou-se pela eficiência com curvas de horizonte diário, enquanto o GA e o PSO foram mais eficientes em curvas semanais. No sistema IEEE 34, o *patternsearch* e o método em cascata frequentemente alcançaram os melhores resultados de economia, enquanto no IEEE 123 o GA se destacou pela eficiência geral – embora o *patternsearch* e o método em cascata tenham alcançado resultados ligeiramente melhores com maior tempo de execução.

Na minimização das perdas elétricas, o cenário foi distinto. Quando consideradas as perdas totais, observou-se um aumento líquido, especialmente em capacidades maiores, devido ao aumento das perdas por eficiência e autodescarga das baterias. Por outro lado, ao analisar apenas as perdas na rede elétrica, houve redução em alguns cenários (por exemplo, com baterias 100 kWh no IEEE 13 e no IEEE 34), mas aumentos ou estagnação em outros. Como a geração distribuída já está presente no caso base, os efeitos observados refletem exclusivamente o impacto das baterias, que, isoladamente, mostraram contribuição limitada para a redução das perdas. A inclusão das perdas internas na função objetivo, embora importante para a modelagem realista, desincentiva estratégias mais agressivas de uso das baterias, limitando seus benefícios nesse aspecto.

Foram utilizadas meta-heurísticas para solucionar o problema de otimização, as quais não garantem a obtenção da solução ótima global. Alguns métodos podem ser sensíveis às condições iniciais ou à configuração de parâmetros. Outra desvantagem é o elevado esforço computacional necessário, uma vez que a avaliação de cada indivíduo exige a execução de fluxos de potência com múltiplos intervalos, dificultando a aplicação em sistemas maiores ou com horizontes temporais extensos. Por outro lado, uma vantagem da abordagem proposta é que há facilidade em utilizar diferentes métodos de otimização, oferecendo flexibilidade para investigar heurísticas e meta-heurísticas diversas. Além disso, a estrutura facilita a substituição ou o incremento da função objetivo, permitindo estudar diferentes impactos da inserção das baterias.

Diante dos resultados obtidos é possível concluir que as baterias mostraram a capacidade de melhorar o desempenho do sistema de um ponto de vista econômico. Também foi possível observar que a minimização de perdas não é uma aplicação promissora desses equipamentos. De modo geral, considera-se que os objetivos do trabalho foram cumpridos e que os testes realizados validam a metodologia proposta.

5.2. TRABALHOS FUTUROS

Este trabalho tratou separadamente de dois objetivos específicos: redução de custos de energia e perdas técnicas. Diversas outras direções de pesquisa neste tema são promissoras, no que diz respeito a aplicações, objetivos, modelagem, otimização, entre outros. As principais delas foram elencadas nos tópicos a seguir:

- Considerar outros possíveis benefícios do uso de BESS, como prestação de serviços ancilares, aumento da confiabilidade e adiamento de investimentos em infraestrutura;
- Implementar uma abordagem multiobjetivo, otimizando simultaneamente múltiplos aspectos operacionais do sistema e possibilitando o acúmulo de receitas;
- Reduzir o intervalo de simulação para menos de uma hora, registrando eventos mais dinâmicos;
- Ampliar o horizonte de simulação para incluir períodos anuais, capturando variações operativas de forma mais realista;
- Desenvolver uma metodologia para a programação da operação dos BESS em tempo real, após a fase de planejamento;
- Simular cenários com curvas de carga e geração variando por barra ou com características estocásticas;
- Incluir outras fontes renováveis, como turbinas eólicas, além de realizar a alocação e analisar outros aspectos do uso de geradores distribuídos, como o fator de potência e o efeito dos inversores na distorção harmônica;
- Incorporar restrições adicionais do sistema de distribuição, como limites de tensão e distorção harmônica;
- Estudar o uso de outras restrições relacionadas à operação das baterias para aumento de sua vida útil;
- Considerar a degradação das baterias ao longo de sua vida útil, com redução progressiva da capacidade energética;
- Incluir previsões de crescimento de carga em análises com horizonte ampliado;
- Aplicar os métodos propostos em sistemas de teste distintos, incluindo redes reais e/ou de maior porte, como forma de validação dos resultados.

REFERÊNCIAS

- AANDRÉASSON, Niclas; EVGRAFOV, A.; PATRIKSSON, M. An Introduction to Optimization: Foundations and Fundamental Algorithms. 2005.
- ALMEHIZIA, Abdullah A. *et al.* Assessment of battery storage utilization in distribution feeders. **Energy Transitions**, v. 4, n. 1, p. 101–112, 1 jun. 2020.
- ALVES, Mayara das Neves. **Aplicação de sistemas de armazenamento de energia em redes de distribuição com elevada penetração de geração solar fotovoltaica distribuída**. Rio de Janeiro: COPPE, 2020.
- ANEEL. **Sistemas de micro e minigeração distribuída beneficiam 5,4 milhões de consumidores**. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/noticias/2025/sistemas-de-micro-e-minigeracao-distribuida-beneficiam-5-4-milhoes-de-consumidores>>. Acesso em: 14 jul. 2025.
- ANEKE, Mathew; WANG, Meihong. Energy storage technologies and real life applications – A state of the art review. **Applied Energy**, v. 179, p. 350–377, 1 out. 2016.
- BABACAN, O.; TORRE, W.; KLEISSL, J. Optimal Allocation of Battery Energy Storage Systems in Distribution Networks Considering High PV Penetration. **IEEE PES General Meeting 2016**, 2016.
- BARBOSA, Marger Wanderley. **Método para alocação dimensionamento e operação de baterias em sistemas de distribuição com redução de perda e análise econômica**. Juiz de Fora: UFJF, 2020. Disponível em: <<https://repositorio.ufjf.br/jspui/handle/ufjf/11552>>. Acesso em: 22 jul. 2024.
- BARROS, Benjamim Ferreira de; BORELLI, Reinaldo; GEDRA, Ricardo Luis. **Geração, Transmissão, Distribuição e Consumo de Energia Elétrica**. São Paulo: Erica, Iatria, 2014.
- BARUKČIĆ, Marinko *et al.* Optimal Allocation and Energy Management of Units in Distribution Networks with Multiple Renewable Energy Sources and Battery Storage Based on Computational Intelligence. **Energies**, v. 16, n. 22, p. 7567, jan. 2023.
- BOONLUK, Panyawoot *et al.* Optimal Siting and Sizing of Battery Energy Storage Systems for Distribution Network of Distribution System Operators. **Batteries**, v. 6, n. 4, p. 56, dez. 2020.
- BOONLUK, Panyawoot *et al.* Optimal Siting and Sizing of Battery Energy Storage: Case Study Seventh Feeder at Nakhon Phanom Substation in Thailand. **Energies**, v. 14, n. 5, p. 1458, jan. 2021.
- BRODERICK, Robert *et al.* **New Rapid QSTS Simulation Methods for High-Resolution Comprehensive Assessment of Distributed PV**. Albuquerque, New Mexico: Sandia National Laboratories, 2021. Disponível em: <https://www.researchgate.net/publication/350099816_New_Rapid_QSTS_Simulation_Methods_for_High-Resolution_Comprehensive_Assessment_of_Distributed_PV>. Acesso em: 10 jul. 2025.

BRODERICK, Robert J. *et al.* **Time Series Power Flow Analysis for Distribution Connected PV Generation**. Albuquerque, New Mexico: Sandia National Laboratories, 2013. Disponível em:

<https://www.researchgate.net/publication/264338486_Time_Series_Power_Flow_Analysis_for_Distribution_Connected_PV_Generation>. Acesso em: 8 jul. 2025.

CAMARGO, Alison Rudá de. **Alocação e operação ótimas de dispositivos de armazenamento de energia em sistemas de distribuição considerando a preservação da vida útil de baterias**. Campinas: UNICAMP, 2016. Disponível em: <<https://repositorio.unicamp.br/acervo/detalhe/979545>>. Acesso em: 22 jul. 2024.

CCEE. **Painel de Preços**. Câmara de Comercialização de Energia Elétrica, 2024. Disponível em: <<https://www.ccee.org.br/web/guest/precos/painel-precos>>. Acesso em: 15 jul. 2024

CHEN, Haisheng *et al.* Progress in electrical energy storage system: A critical review. **Progress in Natural Science**, v. 19, n. 3, p. 291–312, 10 mar. 2009.

DAS, CK *et al.* Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality. **Renewable and Sustainable Energy Reviews**, v. 91, p. 1205–1230, 2018.

DATTA, Ujjwal; KALAM, Akhtar; SHI, Juan. The relevance of large-scale battery energy storage (BES) application in providing primary frequency control with increased wind energy penetration. **Journal of Energy Storage**, v. 23, p. 9–18, 1 jun. 2019.

DG ENER. **Database of the European Energy Storage Technologies and Facilities**. E.U. Directorate-General for Energy, 2020. Disponível em: <<http://data.europa.eu/88u/dataset/database-of-the-european-energy-storage-technologies-and-facilities>>. Acesso em: 13 mar. 2024

DOE. **DOE Global Energy Storage Database: Projects**. U. S. Department of Energy, 2023. Disponível em: <<https://gesdb.sandia.gov/projects.html>>. Acesso em: 8 mar. 2024

DUGAN, R. C.; MONTENEGRO, D.; BALLANTI, A. **Reference Guide: The Open Distribution System Simulator (OpenDSS)**. Palo Alto, CA: Electric Power Research Institute, 2021.

EASE. **Energy Storage Applications Summary**. European Association for Storage of Energy, 2020. Disponível em: <<https://ease-storage.eu/publication/energy-storage-applications-summary/>>. Acesso em: 7 mar. 2024

EPE. **Recursos Energéticos Distribuídos - Documento de Apoio ao PNE 2050**. Rio de Janeiro: Empresa de Pesquisa Energética, 2019.

EPE. **Roadmap Tecnológico de Recursos Energéticos Distribuídos - Tendências tecnológicas e curvas de custo para a geração e armazenamento distribuídos**. Disponível em: <<http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/roadmap-tecnologico-de-recursos-energeticos-distribuidos>>. Acesso em: 9 ago. 2025.

EPRI. **Storage Modeling**. OpenDSS Documentation. Electric Power Research Institute, 2024a. Disponível em: <<https://opendss.epri.com/Modeling1.html>>. Acesso em: 22 jul. 2024

EPRI. **Storage Element**. OpenDSS Documentation. Electric Power Research Institute, 2024b. Disponível em: <<https://opendss.epri.com/Storage.html>>. Acesso em: 21 jul. 2024

EPRI. **Storage Dispatch Modes**. OpenDSS Documentation. Electric Power Research Institute, 2024c. Disponível em: <<https://opendss.epri.com/DispatchModes.html>>. Acesso em: 22 jul. 2024

EPRI. **Storage Controller Element**. OpenDSS Documentation. Electric Power Research Institute, 2024d. Disponível em: <<https://opendss.epri.com/StorageController.html>>. Acesso em: 22 jul. 2024

EPRI. **InvControl Element**. OpenDSS Documentation. Electric Power Research Institute, 2024e. Disponível em: <<https://opendss.epri.com/InvControl1.html>>. Acesso em: 22 jul. 2024

EYER, J.; COREY, G. **Energy storage for the electricity grid: Benefits and market potential assessment guide**. Albuquerque: Sandia National Laboratories, 2010.

FACELI, Katti *et al.* **Inteligência Artificial-Uma Abordagem De Aprendizado De Máquina**. 2. ed. Rio de Janeiro, RJ: Ltc-Livros Tecnicos E Cientificos Editora Lda, 2022.

GANTZ, Jesse Martin. Optimal implementation of energy storage systems in power distribution networks. 2012.

GARCIA-GARCIA, L.; PAASO, E. A.; AVENDANO-MORA, M. Assessment of battery energy storage for distribution capacity upgrade deferral. *In*: 2017 IEEE POWER & ENERGY SOCIETY INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE (ISGT). **2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)**. abr. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8086030>>. Acesso em: 26 mar. 2024

GODINHO, Joanna Ferreira *et al.* **Tópicos Especiais em Físico-Química: Cinética e Eletroquímica**. Porto Alegre, RS: Sagah, 2022.

GOLDBARG, Marco Cesar; GOLDBARG, Elizabeth Gouvêa; LUNA, Henrique Pacca Loureiro. **Otimização combinatória e meta-heurísticas: algoritmos e aplicações**. Rio de Janeiro: Elsevier, 2016.

HOPPECKE. **Sun.power pack: Battery storage system to optimise photovoltaic self-consumption**. Disponível em: <http://www.go-pure.eu/download/sun.power_pack.pdf>. Acesso em: 12 out. 2022.

HU, Xiaosong *et al.* Technological Developments in Batteries: A Survey of Principal Roles, Types, and Management Needs. **IEEE Power and Energy Magazine**, v. 15, p. 20–31, 17 ago. 2017.

IEA. **Annual grid-scale battery storage additions, 2017-2022**. International Energy Agency, 2023. Disponível em: <<https://www.iea.org/data-and-statistics/charts/annual-grid-scale-battery-storage-additions-2017-2022>>. Acesso em: 13 mar. 2024

IEA. **Renewables 2023 – Analysis**. Paris: International Energy Agency, 2024. Disponível em: <<https://www.iea.org/reports/renewables-2023>>. Acesso em: 16 abr. 2025.

IEA. **World Energy Investment 2025 – Analysis**. Paris: International Energy Agency, 2025. Disponível em: <<https://www.iea.org/reports/world-energy-investment-2025>>. Acesso em: 29 jul. 2025.

IEEE PES. **IEEE PES Test Feeder**. Institute of Electrical and Electronics Engineers: Power & Energy Society, 2017. Disponível em: <<https://cmte.ieee.org/pes-testfeeders/resources/>>. Acesso em: 5 out. 2022

IRENA. **Battery Storage for Renewables Market Status and Technology Outlook**. Abu Dhabi: International Renewable Energy Agency, 2015. Disponível em: <<https://www.irena.org/Publications/2015/Jan/Battery-Storage-for-Renewables-Market-Status-and-Technology-Outlook>>. Acesso em: 22 jul. 2024.

IRENA. **Battery storage and renewables: costs and markets to 2030**. Abu Dhabi: International Renewable Energy Agency, 2017. Disponível em: <<https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>>. Acesso em: 22 jul. 2024.

IRENA. **Renewable Energy Outlook for ASEAN: Towards a Regional Energy Transition (2nd Edition)**. Abu Dhabi: International Renewable Energy Agency, 2022. Disponível em: <<https://www.irena.org/Publications/2022/Sep/Renewable-Energy-Outlook-for-ASEAN-2nd-edition>>. Acesso em: 15 abr. 2025.

KAGAN, Nelson; OLIVEIRA, Carlos César Barioni de; ROBBA, Ernesto João. **Introdução a sistemas elétricos de potência: componentes simétricas**. 2. ed. rev. e ampl ed. São Paulo: Edgard Blücher, 2000.

KASTURI, Kumari; NAYAK, Chinmay Kumar; NAYAK, Ranjan. Analysis of Photovoltaic & Battery Energy Storage System Impacts on Electric Distribution System Efficacy. **International Journal on Electrical Engineering and Informatics**, v. 12, n. 4, p. 1001–1015, 31 dez. 2020.

KHAJEH, Hosna *et al.* Optimized siting and sizing of distribution-network-connected battery energy storage system providing flexibility services for system operators. **Energy**, v. 285, p. 129490, 15 dez. 2023.

LOUREIRO, Eduardo Mendes. **Alocação e Operação Ótimas de Baterias em Sistemas de Distribuição**. Juiz de Fora: UFJF, 2022.

LUO, Xing *et al.* Overview of current development in electrical energy storage technologies and the application potential in power system operation. **Applied Energy**, v. 137, p. 511–536, 1 jan. 2015.

MATHWORKS. **Mathematics and Optimization**. Disponível em: <<https://www.mathworks.com/help/overview/mathematics-and-optimization.html>>. Acesso em: 11 jul. 2025.

MAZZA, Andrea *et al.* Location and Sizing of Battery Energy Storage Units in Low Voltage Distribution Networks. **Energies**, v. 13, n. 1, p. 52, jan. 2020.

NADEEM, Furqan *et al.* Comparative Review of Energy Storage Systems, Their Roles, and Impacts on Future Power Systems. **IEEE Access**, v. 7, p. 4555–4585, 2019.

NKEMBI, Armel Asongu *et al.* Comprehensive Review of Energy Storage Systems Characteristics and Models for Automotive Applications. **Batteries**, v. 10, n. 3, p. 88, 2024.

OCTAVIANO, Maria Elisa Fernandes. **Alocação ótima de baterias em sistemas de distribuição considerando a vida útil e redução de perdas**. Juiz de Fora: UFJF, 2021. Disponível em: <<https://repositorio.ufjf.br/jspui/handle/ufjf/12427>>. Acesso em: 22 jul. 2024.

OLABI, A. G. *et al.* Critical Review of Energy Storage Systems. **Energy**, v. 214, p. 118987, 1 jan. 2021.

OLIVEIRA, Iberê Carneiro de *et al.* **Transmissão e distribuição de energia**. Porto Alegre, RS: Sagah, 2021.

OLIVEIRA, Tatiana Tostes de. **Método para alocação e operação ótima de baterias em sistemas de distribuição com restrições de tensão e redução das perdas**. Juiz de Fora: UFJF, 2018. Disponível em: <<https://repositorio.ufjf.br/jspui/handle/ufjf/8220>>. Acesso em: 22 jul. 2024.

ONS. **Histórico da Operação: Curva de Carga Horária**. Operador Nacional do Sistema Elétrico, 2024a. Disponível em: <http://www.ons.org.br:80/Paginas/resultados-da-operacao/historico-da-operacao/curva_carga_horaria.aspx>. Acesso em: 23 maio. 2024

ONS. **Dados da geração solar fotovoltaica no SIN**. Operador Nacional do Sistema Elétrico, 2024b. Disponível em: <<http://www.ons.org.br:80/Paginas/resultados-da-operacao/boletim-geracao-solar.aspx>>. Acesso em: 15 jul. 2024

PEDERSEN, Jaap *et al.* Distribution System Planning with Battery Storage using Multiperiod Optimal Power Flow. *In: 14TH INTERNATIONAL RENEWABLE ENERGY STORAGE CONFERENCE 2020 (IRES 2020)*. **Anais...** Atlantis Press, 4 fev. 2021. Disponível em: <<https://www.atlantis-press.com/proceedings/ires-20/125952211>>. Acesso em: 4 ago. 2025

PHAM, Thai Dinh; NGUYEN, Thang Trung; KIEN, Le Chi. Minimization of total costs for distribution systems with battery energy storage systems and renewable energy sources. **Scientific Reports**, v. 15, n. 1, p. 17147, 17 maio 2025.

PICCIANO, Nicholas. Battery Aging and Characterization of Nickel Metal Hydride and Lead-Acid Batteries. 2007.

POCOLA, Tudor Octavian *et al.* Optimal Sizing and Control of a Grid-Connected Battery in a Stacked Revenue Model Including an Energy Community. **Applied Energy**, v. 397, p. 126122, 2025.

POKHRIYAL, Anukriti; RUEDA-GARCIA, Daniel; GÓMEZ-ROMERO, Pedro. A perspective on large-scale stationary electrochemical energy storage. **ResearchGate**, 2023.

PRAKASH, K. *et al.* A review of battery energy storage systems for ancillary services in distribution grids: Current status, challenges and future directions. **Frontiers in Energy Research**, v. 10, 2022.

RAHMAN, Md Mustafizur *et al.* Assessment of energy storage technologies: A review. **Energy Conversion and Management**, v. 223, p. 113295, 2020.

RAZALI, Nur Syifa Nasyrah *et al.* Optimal location and sizing of battery energy storage system using grasshopper optimization algorithm. **International Journal of Advances in Applied Sciences**, v. 13, n. 3, p. 647–654, 1 set. 2024.

ROBBA, Ernesto João. **Análise de sistemas de transmissão de energia elétrica**. São Paulo: Editora Edgard Blucher, 2020.

SAHA, Deepjyoti; GANGULY, Sanjib. Optimal Allocation of Battery Energy Storage Systems in Active Distribution Network. *In*: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE TECHNIQUES FOR ELECTRICAL ENGINEERING SYSTEMS (AITEES 2022). **Anais...** Atlantis Press, 5 dez. 2022. Disponível em: <<https://www.atlantispress.com/proceedings/aitees-22/125977374>>. Acesso em: 2 ago. 2025

SANTOS, André Lopes Marinho dos. **Planejamento de bancos de baterias em sistemas de distribuição de energia**. Juiz de Fora: UFJF, 2018.

SELIM, Ali *et al.* A modified Runge–Kutta optimization for optimal photovoltaic and battery storage allocation under uncertainty and load variation. **Soft Computing**, v. 28, n. 17, p. 10369–10389, 1 set. 2024.

SILVA, Pedro Henrique Rodrigues da; BRANDÃO, Milena Almeida Leite. Alguns Métodos Clássicos De Otimização. **Blucher Mathematical Proceedings**, v. 1, p. 384–392, 16 abr. 2015.

SILVA, Tatiana de Fátima Bruce da *et al.* **Recursos energéticos distribuídos**. [S.l.]: FGV Energia, 2016. Disponível em: <<https://repositorio.fgv.br/items/aa941281-e7d4-4a94-8402-9965dd75ab3f>>. Acesso em: 12 jul. 2025.

SINGH, Bharat; RAWAT, Satyaveer Singh. Impact of Storage Devices with Renewable Integrated Distribution Network for Power Loss Minimization. **International Journal of Engineering and Advanced Technology (IJEAT)**, v. 10, n. 3, p. 180–192, 28 fev. 2021.

SUYAMBU, Muthuvel Raj; VISHWAKARMA, Pawan Kumar. Improving grid reliability with grid-scale Battery Energy Storage Systems (BESS). **International Journal of Science and Research Archive**, v. 13, n. 1, p. 776–789, 2024.

VIAN, Ângelo *et al.* **Armazenamento de Energia Fundamentos Tecnologia e Aplicações**. São Paulo, SP: Open Access, 2021.

VICENTE, Amarildo; RIZZI, Rogério Luis. Utilizando um Algoritmo Genético para Encontrar os Zeros de uma Função Real. 2010.

WONG, Ling Ai *et al.* Review on the optimal placement, sizing and control of an energy storage system in the distribution network. **Journal of Energy Storage**, v. 21, p. 489–504, 1 fev. 2019.

WÜLLNER, Johannes *et al.* Review of Stationary Energy Storage Systems Applications, Their Placement, and Techno-Economic Potential. **Current Sustainable/Renewable Energy Reports**, v. 8, n. 4, p. 263–273, 2021.

ZIDAR, Matija *et al.* Review of energy storage allocation in power distribution networks: applications, methods and future research. **IET Generation, Transmission & Distribution**, v. 10, n. 3, p. 645–652, 2016.

ANEXO A – DETALHES DE MODELAGEM DAS BATERIAS

O modelo analisado apresenta capacidade de simulação em múltiplas escalas temporais, abrangendo os modos *snapshot*, *dutyCycle*, *daily* (diário) e *yearly* (anual), oferecidos pelo OpenDSS.

No contexto geral do OpenDSS, o modo de simulação instantânea (*snapshot*) é útil quando se busca refletir a condição do sistema em um determinado momento, sem que o comportamento transitório ou dinâmico do sistema seja considerado durante a análise. Porém, ao realizar simulações instantâneas com baterias, estas serão interpretadas pelo sistema como geradores (caso estejam operando no estado de descarga no instante analisado) ou como cargas (caso as baterias estejam sendo carregadas e/ou tenham suas perdas supridas pela rede). Como não há escalas de tempo nesse modo, diversos aspectos do uso das baterias não são aplicáveis, o que torna seu uso menos interessante.

No modo *dutyCycle*, a simulação é conduzida em escalas de segundos, sendo adequada para modelar flutuações rápidas de potência, como variações de geração em parques eólicos ou solares devido a transientes climáticos, ou para analisar o comportamento de sistemas que requerem controle dinâmico em tempo real, como processos industriais. A bateria pode ser modelada para seguir uma curva de carga predefinida (*Duty loadshape*), realizando ajustes rápidos e sequenciais no fluxo de potência. Esse modo é particularmente útil para compensar variações rápidas de energia e avaliar a capacidade de resposta do sistema de armazenamento para lidar com flutuações de curto prazo (EPRI, 2024b).

As simulações nos modos diário e anual são particularmente adequadas para a avaliação de aspectos energéticos ao longo do tempo, utilizando intervalos que variam de minutos a horas. Conforme EPRI (2024c), o elemento Storage apresenta diversos modos de despacho para operação em simulações variáveis no tempo, permitindo a flexibilidade no controle de potência ativa e reativa. Esses modos são divididos em duas categorias principais: modos controlados externamente e modos de autodespacho (*self-dispatch*). Os modos controlados externamente dependem de elementos externos (*StorageController*, *InvControl*) para comandar suas funções, enquanto nos modos de *self-dispatch* o próprio elemento define sua operação com base em parâmetros predefinidos. Cada categoria inclui diferentes abordagens de despacho que podem ser configuradas para atender a requisitos específicos de cada aplicação e sistema elétrico.

O *StorageController* é o controlador externo responsável por coordenar o despacho de potência ativa de dispositivos de armazenamento, realizando funções como o acompanhamento de carga e alívio de picos, e ajustando a operação dos elementos com base em informações de demanda do sistema. Esse controlador pode gerenciar múltiplos dispositivos de armazenamento, ajustando sua operação de acordo com o comportamento da carga ou outras condições de operação definidas (EPRI, 2024d).

O *InvControl*, por sua vez, é um elemento de controle dedicado à gestão de inversores em sistemas de energia, com ênfase em funções como controle de fator de potência e resposta reativa dinâmica. Ele é o controlador externo responsável por coordenar o despacho de potência reativa dos elementos *Storage*. Para isso, o *InvControl* gerencia funções dependentes de tensão, como Volt-Var (VV), Volt-Watt (VW) e Corrente Reativa Dinâmica (DRC), sendo fundamental para controlar o comportamento do inversor de acordo com as condições de tensão da rede elétrica (EPRI, 2024e). Ele opera de forma independente ou em conjunto com o *StorageController*, permitindo o controle simultâneo dos elementos de armazenamento e suas interações com o inversor.

Dentre os modos de autodespacho, três – *Default*, *LoadLevel* e *Price* – operam com base em gatilhos de carga (*ChargeTrigger*) e descarga (*DischargeTrigger*). O elemento permanece em um estado definido até que uma condição específica seja alcançada: quando um dos gatilhos é disparado, o elemento transiciona para o estado correspondente; já quando a energia armazenada atinge a capacidade máxima ou o limite mínimo de reserva, a bateria automaticamente entra em estado de ociosidade. Esses modos permitem o controle autônomo do armazenamento com base em critérios previamente configurados pelo usuário.

O modo *follow* é o quarto e último modo de *self-dispatch* disponível no modelo, sendo a escolha de despacho adotada neste trabalho. Nesse modo, a operação das baterias é conduzida com base em uma curva de despacho predefinida, representada pelo vetor *daily*. Isso permite um gerenciamento preciso da operação das baterias conforme o desejado.

Mais informações sobre os modos de operação de baterias são encontradas em (EPRI, 2024c).

ANEXO B – EXEMPLO DE APLICAÇÃO DO MODELO DE BATERIA


Para exemplificar os processos vistos nas equações anteriores, propõe-se um exemplo didático de aplicação. Uma bateria fictícia, cujos dados nominais são vistos na Tabela 5, é conectada a uma barra de um sistema elétrico.

Tabela 5 – Dados nominais da bateria fictícia.

<i>Parâmetro</i>	Valor
E_{nom}	100 kWh
P_{nom}	100 kW
η	0,8 ou 80%
$P_{autodescarga}$	1 kW

Esta bateria deve ser operada de forma que seu SOC siga a curva vista na Figura 73.

Figura 73 – Exemplo de SOC e das operações das baterias.



Fonte: Elaborado pelo autor (2025).

Na figura, observa-se que ao longo do intervalo de três horas ocorrem respectivamente as operações de carga (entre as horas 1 e 2), ociosidade (entre as horas 2 e 3) e descarga (entre

as horas 3 e 4) da bateria. Assim, a energia armazenada na bateria é a mesma no início do primeiro intervalo e ao final do último.

De posse dos dados nominais fornecidos, é possível utilizar as Equações (6) a (11) para obter as grandezas de interesse e, por fim, compor o vetor de potências normalizadas que será fornecido ao OpenDSS para realizar a operação da bateria. Desse modo, tem-se que as potências vistas internamente pela bateria em cada intervalo são:

$$P_{bat,1}^{int.} = \frac{(0,6 - 0,5) \cdot 100 [kWh]}{1 [h]} = 10 kW \quad (34)$$

$$P_{bat,2}^{int.} = \frac{(0,6 - 0,6) \cdot 100 [kWh]}{1 [h]} = 0 \quad (35)$$

$$P_{bat,3}^{int.} = \frac{(0,5 - 0,6) \cdot 100 [kWh]}{1 [h]} = -10 kW \quad (36)$$

No primeiro intervalo ocorre a operação de carga. Assim, tem-se que a potência fornecida pelo sistema (vista externamente) é de:

$$P_{bat,1}^{ext.} = \frac{10 [kW]}{0,8} + 1 [kW] = 13,5 kW \quad (37)$$

No segundo intervalo, a bateria está ociosa. Assim a potência fornecida pelo sistema é de:

$$P_{bat,2}^{ext.} = \frac{0}{0,8} + 1 [kW] = 1 kW \quad (38)$$

No terceiro intervalo ocorre a operação de descarga. A potência fornecida ao sistema pela bateria é de:

$$P_{bat,3}^{ext.} = -10 [kW] \cdot 0,8 + 1 [kW] = -7 kW \quad (39)$$

Por fim, para obter o vetor de potências normalizadas basta inverter o sinal de cada uma dessas potências e dividir o valor resultante pela potência nominal. Assim, o vetor resultante neste exemplo é:

$$P_n = [-0,135; -0,01; 0,07] \quad (40)$$

Para comprovar na prática que estes cálculos estão corretos, essa bateria foi simulada no OpenDSS, sendo alocada na fase B da barra 634 do sistema IEEE 13 barras. Foram inseridos os dados nominais e os dados de operação da bateria, e foi realizada uma simulação no modo *daily*. Na Figura 74, é visto um recorte do código utilizado, com destaque para as linhas de criação da curva de despacho, da bateria e do monitor utilizado para observar o comportamento do estado de carga da bateria ao longo dos intervalos simulados.

Figura 74 – Trecho do código utilizado no exemplo de aplicação.

```
New LoadShape.batprofile1 npts=4 interval=1 mult=(0   -0.135   -0.01   0.07)

New Storage.Battery1 phases=1 bus1=634.2 kv=0.28 kwrated=100.00 kwhrated=100.00
~ pf=1.00 %Effcharge=80.000000 %Effdischarge=80.000000 %Idling=1.000000
~ %reserve=20.00 %stored=50.0000 dispmode=follow daily=batprofile1

New Monitor.BatState1 element=Storage.Battery1 mode=3


[...]

Plot monitor object= batstate channels=(1 )
```

Fonte: Elaborado pelo autor (2025).

Ao executar a última linha deste código, é exibida a curva do estado de carga da bateria. Esta curva é vista na Figura 75.

Figura 75 – Curva do estado de carga da bateria.



Fonte: Elaborado pelo autor (2025).

Portanto, nota-se que, ao compor o vetor de potências normalizadas com os valores calculados nas equações acima e fornecê-lo como curva de despacho da bateria fictícia, o comportamento do estado de carga da bateria visto na Figura 75 segue o perfil desejado inicialmente (Figura 73).

Para encontrar as perdas por eficiência, seu valor deve ser calculado de acordo com a potência útil em cada intervalo. No primeiro intervalo, no qual ocorre a operação de carga, as perdas por eficiência são:

$$P_{perdas(carga)}^{efic.} = 10 [kW] \cdot \frac{(1 - 0,8)}{0,8} = 2,5 kW \quad (41)$$

No segundo intervalo a bateria está ociosa. Logo as perdas por eficiência são nulas:


$$P_{perdas(ocios.)}^{efic.} = 0 \quad (42)$$

No último intervalo, para a operação de descarga da bateria, as perdas obtidas são:

$$P_{perdas(descarga)}^{efic.} = 10 [kW] \cdot (1 - 0,8) = 2 kW \quad (43)$$

Finalmente, para observar de forma clara e resumida a operação dessa bateria, foi elaborado um diagrama do modelo de bateria com todas as potências e perdas e seus valores calculados em cada intervalo, o qual é visto na Figura 76.

Figura 76 – Diagrama com as potências para cada intervalo.



Fonte: Elaborado pelo autor (2025).

ANEXO C – BARRAS DE ALOCAÇÃO DAS BATERIAS

As tabelas abaixo trazem os locais de alocação das três baterias monofásicas em cada um dos casos simulados neste trabalho. Em cada grupo de casos, também é apresentada uma tabela com a contagem das vezes que as baterias foram alocadas em cada nó (barra e fase).

- Grupo de Casos A

Tabela 6 – Alocação de baterias nos casos do grupo A.

<i>Sistema</i>	<i>Capacidade (kWh)</i>	<i>Alocação Bateria 1</i>	<i>Alocação Bateria 2</i>	<i>Alocação Bateria 3</i>
IEEE 13 barras	100	671.1	680.3	671.3
	500	671.1	671.2	671.3
	1000	671.1	671.2	692.3
	1500	671.1	671.2	671.3
IEEE 34 barras	100	890.2	862.2	848.1
	500	808.1	854.2	812.1
	1000	808.1	808.2	808.3
	1500	808.1	808.2	808.3
IEEE 123 barras	100	99.1	40.1	78.1
	500	7.1	7.2	7.3
	1000	53.1	7.2	7.3
	1500	7.1	7.2	7.3

Tabela 7 – Contagem das barras em que houve alocação nos casos do grupo A.

Sistema 13		Sistema 34		Sistema 123	
Nó	Contagem	Nó	Contagem	Nó	Contagem
671.1	4	808.1	3	7.1	2
671.2	3	808.2	2	7.2	3
671.3	3	808.3	2	7.3	3
680.3	1	812.1	1	40.1	1
692.3	1	848.1	1	53.1	1
Total Geral	12	854.2	1	78.1	1
		862.2	1	99.1	1
		890.2	1	Total Geral	12
		Total Geral	12		

- Grupo de Casos B

Tabela 8 – Alocação de baterias nos casos do grupo B.

<i>Sistema</i>	<i>Curva de Carga</i>	<i>Capacidade (kWh)</i>	<i>Alocação Bateria 1</i>	<i>Alocação Bateria 2</i>	<i>Alocação Bateria 3</i>
IEEE 13 barras	Única	500	671.1	671.2	671.3
		1000	671.1	671.2	692.3
		1500	671.1	671.2	671.3
	Semanal	500	671.1	671.2	671.3
		1000	671.1	671.2	671.3
		1500	671.1	671.2	671.3
	Dias da semana	500	671.1	671.2	671.3
		1000	671.1	671.2	692.3
		1500	671.1	671.2	671.3
	Estações	500	671.1	671.2	671.3
		1000	671.1	671.2	671.3
		1500	671.1	671.2	671.3
IEEE 34 barras	Única	500	808.1	854.2	812.1
		1000	808.1	808.2	808.3
		1500	808.1	808.2	808.3
	Semanal	500	808.1	808.2	808.3
		1000	808.1	808.2	808.3
		1500	808.1	808.2	808.3
	Dias da semana	500	808.1	808.2	860.3
		1000	852.1	808.2	836.3
		1500	808.1	808.2	808.3
	Estações	500	808.1	850.2	834.3
		1000	808.1	808.2	808.3
		1500	834.1	808.2	808.3
IEEE 123 barras	Única	500	7.1	7.2	7.3
		1000	53.1	7.2	7.3
		1500	7.1	7.2	7.3
	Semanal	500	81.1	7.2	7.3
		1000	7.1	7.2	7.3
		1500	7.1	7.2	7.3
	Dias da semana	500	55.1	7.2	7.3
		1000	197.1	7.2	7.3
		1500	7.1	7.2	7.3
	Estações	500	7.1	7.2	7.3
		1000	7.1	7.2	7.3
		1500	7.1	7.2	7.3

Tabela 9 – Contagem das barras em que houve alocação nos casos do grupo B.

Sistema 13		Sistema 34		Sistema 123	
Nó	Contagem	Nó	Contagem	Nó	Contagem
671.1	12	808.1	10	7.1	8
671.2	12	808.2	10	7.2	12
671.3	10	808.3	8	7.3	12
692.3	2	812.1	1	53.1	1
Total Geral	36	834.1	1	55.1	1
		834.3	1	81.1	1
		836.3	1	197.1	1
		850.2	1	Total Geral	36
		852.1	1		
		854.2	1		
		860.3	1		
		Total Geral	36		

- Grupo de Casos C

Tabela 10 – Alocação de baterias nos casos do grupo C.

<i>Sistema</i>	<i>Método de Otimização</i>	<i>Curva de Carga</i>	<i>Capacidade (kWh)</i>	<i>Alocação Bateria 1</i>	<i>Alocação Bateria 2</i>	<i>Alocação Bateria 3</i>
IEEE 13 barras	<i>ga</i>	Única	500	671.1	671.2	671.3
			1000	671.1	671.2	692.3
		Semanal	500	671.1	671.2	671.3
			1000	671.1	671.2	671.3
		Dias da semana	500	671.1	671.2	671.3
			1000	671.1	671.2	692.3
	<i>pso</i>	Única	500	671.1	671.2	671.3
			1000	671.1	671.2	671.3
		Semanal	500	671.1	671.2	671.3
			1000	671.1	671.2	671.3
		Dias da semana	500	671.1	671.2	671.3
			1000	671.1	671.2	671.3
	<i>fminsearch</i>	Única	500	671.1	671.3	671.3
			1000	671.1	671.2	671.3
		Semanal	500	671.1	671.3	671.3
			1000	671.1	671.2	671.3
		Dias da semana	500	671.1	671.3	671.3
			1000	671.1	671.2	671.3
	<i>patternsearch</i>	Única	500	675.1	692.2	692.3
			1000	675.1	692.2	692.3
		Semanal	500	675.1	692.2	671.3
			1000	675.1	692.2	671.3
		Dias da semana	500	675.1	692.2	671.3
			1000	675.1	692.2	671.3
	<i>ga + patternsearch</i>	Única	500	675.1	692.2	692.3
			1000	675.1	671.2	692.3
		Semanal	500	675.1	692.2	671.3
			1000	692.1	692.2	671.3
		Dias da semana	500	675.1	671.2	692.3
			1000	675.1	692.2	692.3
IEEE 34 barras	<i>ga</i>	Única	500	808.1	854.2	812.1
			1000	808.1	808.2	808.3
		Semanal	500	808.1	808.2	808.3
			1000	808.1	808.2	808.3
		Dias da semana	500	808.1	808.2	860.3
			1000	852.1	808.2	836.3
	<i>pso</i>	Única	500	832.2	836.3	840.1
			1000	808.1	808.3	812.2
		Semanal	500	808.1	808.2	808.3
			1000	808.1	808.2	808.3
		Dias da semana	500	842.2	834.1	858.3
			1000	808.1	808.2	808.3
	<i>fminsearch</i>	Única	500	808.1	808.2	808.3
			1000	808.1	808.2	808.3

IEEE 123 barras		Semanal	500	808.1	808.2	808.3
			1000	808.1	808.2	808.3
		Dias da semana	500	808.1	808.2	812.1
			1000	808.1	808.2	808.3
	<i>patternsearch</i>	Única	500	808.1	834.3	834.2
			1000	852.1	808.2	808.3
		Semanal	500	808.1	828.2	832.1
			1000	808.1	808.2	808.3
		Dias da semana	500	842.3	834.2	844.1
			1000	824.1	832.2	808.3
	<i>ga + patternsearch</i>	Única	500	812.1	808.2	828.3
			1000	816.1	808.2	808.3
		Semanal	500	808.1	808.2	808.3
			1000	808.1	808.2	808.3
		Dias da semana	500	888.1	858.2	808.3
			1000	808.1	858.2	808.3
	<i>ga</i>	Única	500	7.1	7.2	7.3
			1000	53.1	7.2	7.3
		Semanal	500	81.1	7.2	7.3
			1000	7.1	7.2	7.3
		Dias da semana	500	55.1	7.2	7.3
			1000	197.1	7.2	7.3
	<i>pso</i>	Única	500	67.1	76.3	13.2
			1000	13.1	7.2	7.3
		Semanal	500	18.1	18.3	8.1
			1000	7.1	7.2	7.3
		Dias da semana	500	60.1	13.3	18.1
			1000	13.1	7.2	7.3
	<i>fminsearch</i>	Única	500	7.1	7.2	7.3
			1000	7.1	7.2	7.3
		Semanal	500	7.2	7.2	7.3
			1000	7.1	7.2	7.3
		Dias da semana	500	7.2	7.2	7.3
			1000	7.1	7.2	7.3
	<i>patternsearch</i>	Única	500	197.3	197.1	67.2
			1000	13.1	8.2	13.3
		Semanal	500	72.3	72.2	76.1
			1000	7.1	7.2	7.3
		Dias da semana	500	197.1	13.2	13.3
			1000	8.1	13.2	13.3
	<i>ga + patternsearch</i>	Única	500	67.1	13.2	13.3
			1000	13.1	13.2	13.3
		Semanal	500	76.1	76.2	72.3
			1000	54.1	7.2	7.3
		Dias da semana	500	7.1	99.1	99.3
			1000	8.1	8.2	8.3

Tabela 11 – Contagem das barras em que houve alocação nos casos do grupo C.

Sistema 13		Sistema 34		Sistema 123	
Nó	Contagem	Nó	Contagem	Nó	Contagem
671.1	18	808.1	21	7.1	9
671.2	17	808.2	20	7.2	19
671.3	25	808.3	20	7.3	17
675.1	11	812.1	3	8.1	3
692.1	1	812.2	1	8.2	2
692.2	10	816.1	1	8.3	1
692.3	8	824.1	1	13.1	4
Total Geral	90	828.2	1	13.2	5
		828.3	1	13.3	6
		832.1	1	18.1	2
		832.2	2	18.3	1
		834.1	1	53.1	1
		834.2	2	54.1	1
		834.3	1	55.1	1
		836.3	2	60.1	1
		840.1	1	67.1	2
		842.2	1	67.2	1
		842.3	1	72.2	1
		844.1	1	72.3	2
		852.1	2	76.1	2
		854.2	1	76.2	1
		858.2	2	76.3	1
		858.3	1	81.1	1
		860.3	1	99.1	1
		888.1	1	99.3	1
		Total Geral	90	197.1	3
				197.3	1
				Total Geral	90

- Grupo de Casos D

Tabela 12 – Alocação de baterias nos casos do grupo D.

<i>Sistema</i>	<i>Capacidade (kWh)</i>	<i>Alocação Bateria 1</i>	<i>Alocação Bateria 2</i>	<i>Alocação Bateria 3</i>
IEEE 13 barras	100	671.1	671.2	671.3
	500	671.1	671.2	671.3
	1000	671.1	671.2	671.3
	1500	671.1	671.2	671.3
IEEE 34 barras	100	860.1	888.2	848.3
	500	808.1	808.2	812.1
	1000	808.1	808.3	808.3
	1500	808.1	808.3	808.3
IEEE 123 barras	100	7.1	7.2	7.3
	500	7.1	7.2	7.3
	1000	7.1	7.2	7.3
	1500	7.1	7.2	7.3

Tabela 13 – Contagem das barras em que houve alocação nos casos do grupo D.

Sistema 13		Sistema 34		Sistema 123	
Nó	Contagem	Nó	Contagem	Nó	Contagem
671.1	4	808.1	3	7.1	4
671.2	4	808.2	1	7.2	4
671.3	4	808.3	4	7.3	4
Total Geral	12	812.1	1	Total Geral	12
		848.3	1		
		860.1	1		
		888.2	1		
		Total Geral	12		