



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E
TERRITÓRIO (ILATIT)**

ENGENHARIA DE ENERGIA

**METAHEURÍSTICAS APLICADAS PARA MINIMIZAÇÃO DE PERDAS
TÉCNICAS EM REDES DE DISTRIBUIÇÃO COM GERAÇÃO
FOTOVOLTAICA E BATERIAS**

MARÍLIA LUIZA BERTI PERUZZO

Foz do Iguaçu,
2025



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E
TERRITÓRIO (ILATIT)**

ENGENHARIA DE ENERGIA

**METAHEURÍSTICAS APLICADAS PARA MINIMIZAÇÃO DE PERDAS
TÉCNICAS EM REDES DE DISTRIBUIÇÃO COM GERAÇÃO
FOTOVOLTAICA E BATERIAS**

MARÍLIA LUIZA BERTI PERUZZO

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Tecnologia, Infraestrutura e Território, como requisito parcial à obtenção do título de Bacharel em Engenharia de Energia.

Orientador: Jorge Javier Gimenez Ledesma

Foz do Iguaçu
2025

MARÍLIA LUIZA BERTI PERUZZO

**METAHEURÍSTICAS APLICADAS PARA MINIMIZAÇÃO DE PERDAS
TÉCNICAS EM REDES DE DISTRIBUIÇÃO COM GERAÇÃO
FOTOVOLTAICA E BATERIAS**

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Tecnologia, Infraestrutura e Território, como requisito parcial à obtenção do título de Bacharel em Engenharia de Energia.

BANCA EXAMINADORA

Orientador: Jorge Javier Gimenez Ledesma
UNILA

Prof. Dr. Rodrigo Delfim Guarizi
UNILA

Prof. Dr. Raphael Paulo Braga Poubel
CEFET-MG

Prof. Dr. Oswaldo Hideo Ando Junior
UFPB

Foz do Iguaçu, _____ de _____ de _____.

AGRADECIMENTOS

Agradeço, primeiramente, à minha irmã Cecília, à minha mãe Jacinta da Graça e ao meu pai Edilson, que sempre estiveram comigo, ajudando-me em todas as etapas da graduação, oferecendo todo suporte e apoio.

Agradeço também ao meu orientador, Jorge Javier Gimenez Ledesma, por todas as orientações, conselhos e pela ajuda fundamental na elaboração deste projeto. Estendo meus agradecimentos à professora Claudia Leites Luchese, que contribuiu significativamente para o meu aprendizado e crescimento no meio acadêmico.

Por fim, agradeço a todos os amigos que fiz durante o curso, em especial à Andrielli e à Samira, que tornaram a trajetória universitária mais leve e divertida, fazendo com que os dias fossem menos cansativos e proporcionando lembranças que levarei comigo para sempre.

RESUMO

Este trabalho buscou minimizar as perdas técnicas considerando dois sistemas de distribuição teste, IEEE 13 e 34 barras, em ambos sistemas foi considerando a integração de geração fotovoltaica e armazenamento de energia por baterias. Os modelos empregados foram representados no *software OpenDSS*, e os resultados exportados para o *software Matlab*, permitindo a geração de 32 e 74 cenários de incerteza para o sistema de 13 e 34 barras, respectivamente, por meio da técnica *Two-Point Estimate Method*. Aplicou-se duas metaheurísticas para otimização, (i) Algoritmo Genético e (ii) *Grey Wolf Optimization*, determinando o despacho ótimo da bateria que minimiza as perdas ao longo de um dia. Os resultados indicaram que, nos sistemas IEEE 13 e 34 barras, o algoritmo genético apresenta melhor desempenho no despacho de energia. Contudo, seu tempo de convergência foi aproximadamente 50% e 37% maior em comparação ao *Grey Wolf Optimization*. A redução de perdas, em relação ao sistema base sem geração distribuída, foi de cerca de 27% para o sistema IEEE 13 barras e 75% para o sistema IEEE 34 barras, demonstrando a melhoria do desempenho e eficiência dos sistemas de distribuição com geração distribuída e armazenamento de energia.

Palavras-chave: Sistemas de distribuição; Algoritmo Genético; Grey Wolf Optimization; Two-Point Estimate Method; Geração distribuída.

LISTA DE FIGURAS

Figura 1 – Tecnologias de Armazenamento de Energia.....	11
Figura 2 – Estrutura de funcionamento do <i>software OpenDSS</i>	13
Figura 3 – Diagrama do modelo <i>PVsystem</i>	13
Figura 4 – Estrutura do elemento <i>Storage</i>	14
Figura 5 – Despacho de energia pelo modo <i>default</i>	15
Figura 6 – Despacho de energia pelo modo <i>follow</i>	16
Figura 7 – Fluxograma de funcionamento do algoritmo genético.....	19
Figura 8 – Método de seleção roleta viciada	20
Figura 9 – Exemplo do método cruzamento por um ponto	20
Figura 10 – Exemplo do processo de mutação	21
Figura 11 – Fluxograma da metodologia proposta	24
Figura 12 – Curva de operação diário do BESS.....	27
Figura 13 – Curvas de carga residencial e industrial consideradas	31
Figura 14 – Diagrama unifilar do sistema de distribuição IEEE 13 barras.....	32
Figura 15 – Diagrama unifilar do sistema de distribuição IEEE 34 barras.....	33
Figura 16 – Cenários de incertezas para geração fotovoltaica e demanda.....	34
Figura 17 – Despacho ótimo da bateria para redução de perdas por AG.....	34
Figura 18 – Despacho ótimo da bateria para redução de perdas por GWO	35
Figura 19 – Comparação da redução das perdas elétricas.....	36
Figura 20 – Cenários de incertezas para geração fotovoltaica e demanda.....	38
Figura 21 – Despacho ótimo da bateria para redução de perdas por AG.....	38
Figura 22 – Despacho ótimo da bateria para redução de perdas por GWO	39
Figura 23 – Despacho ótimo médio da bateria para redução de perdas por AG e GWO	40
Figura 24 -Variação de potência da bateria considerando todas as simulações	40
Figura 25 – Comparação da redução das perdas elétricas.....	41

LISTA DE TABELAS

Tabela 1 – Parâmetros típicos do AG encontrados na literatura.....	21
Tabela 2 – Parâmetros para aplicação do GWO encontrados na literatura	23
Tabela 3 – Parâmetros do sistema fotovoltaico	26
Tabela 4 – Irradiância e temperatura do painel.....	26
Tabela 5 – Curvas do sistema fotovoltaico.....	27
Tabela 6 – Parâmetros do sistema BESS.....	27
Tabela 7 – Parâmetros utilizados na aplicação do algoritmo genético	30
Tabela 8 – Comparação do tempo de simulação entre as metaheurísticas AG e GWO.....	36
Tabela 9 – Comparação do tempo de simulação entre as metaheurísticas AG e GWO.....	41

LISTA DE ABREVIATURAS E SIGLAS

2PEM	<i>Two-Point Estimate Method</i> , pág. 11,
AG	Algoritmo genético, pág. 11
ANEEL	<i>Agência Nacional de Energia Elétrica</i> , pág. 18
BESS	<i>Battery Energy Storage System</i> , pág. 10
COM	<i>Component Object Model</i> , pág. 21
DLL	<i>Dynamic-Link Library</i> , pág. 21
EPRI	<i>Electric Power Research Institute</i> , pág. 21
ES	<i>Energy Storage</i> , pág. 21
SAEs	Sistemas de Armazenamento de Energia, pág. 10
GD	Geração distribuída, pág. 10
GWO	<i>Grey Wolf Optimization</i> , pág. 11
IEEE	<i>Institute of Electrical and Electronics Engineers</i> , pág. 12
MMGD	Micro e Minigeração Distribuída, pág. 18
PSO	<i>Particle Swarm Optimization</i> , pág. 15
PV	<i>Photovoltaic</i> , pág. 15
SEP	Sistema Elétrico de Potência, pág. 21

SUMÁRIO

1. INTRODUÇÃO	1
1.1. JUSTIFICATIVA.....	2
1.2. MOTIVAÇÃO	3
1.3. OBJETIVOS	3
1.4. ESTRUTURA DO TRABALHO	4
1.5. PUBLICAÇÕES ORIUNDAS.....	4
1.6. ESTADO DA ARTE	5
2. EMBASAMENTO TEÓRICO.....	9
2.1. GERAÇÃO FOTOVOLTAICA	9
2.2. SISTEMAS DE ARMAZENAMENTO DE ENERGIA	10
2.3. <i>SOFTWARE OPENDSS</i>	12
3. MÉTODOS UTILIZADOS	17
3.1. <i>TWO-POINT ESTIMATE METHOD (2PEM)</i>	17
3.2. ALGORITMO GENÉTICO (AG).....	18
3.3. <i>GREY WOLF OPTIMIZER (GWO)</i>	22
4. METODOLOGIA APLICADA.....	24
4.1. NATUREZA DA PESQUISA	24
4.2. MÉTODO PROPOSTO.....	24
4.3. PARÂMETROS EMPREGADOS	26
4.4. PERFIL DE CARGA.....	30
5. RESULTADOS	32
5.1. SISTEMAS ANALISADOS	32
5.2. SISTEMA IEEE 13 BARRAS	33
5.3. SISTEMA IEEE 34 BARRAS	38
6. CONCLUSÕES	43
REFERÊNCIAS.....	44

1. INTRODUÇÃO

As redes de distribuição de energia elétrica ocupam uma posição central nos sistemas de distribuição de energia, principalmente devido à sua proximidade com os usuários finais. Permitindo, nos últimos anos, a integração de inúmeras tecnologias inovadoras, evoluindo de redes passivas para redes ativas através da incorporação de diferentes tipos de Geração Distribuída (GD) juntamente com resposta à demanda e [Sistemas de Armazenamento de Energia \(SAE\)](#) que permitem uma participação mais ativa dos usuários (FARHANGI, 2010; KAUR; KUMBHAR; SHARMA, 2014).

Os SAEs surgiram como uma tecnologia pronta para assumir um papel vital no futuro iminente do setor energético. Espera-se que os mesmos forneçam eletricidade com a máxima eficiência de custos e o nível de qualidade necessário. Esses sistemas abrangem desde baterias convencionais até tecnologias avançadas, como o armazenamento hidrelétrico por bombeamento e o armazenamento térmico (KAUR; KUMBHAR; SHARMA, 2014).

O planejamento, a implantação e a gestão desses sistemas estão no cerne da transição energética, permitindo-nos aproveitar todo o potencial dos recursos renováveis e aumentar a resiliência da rede (ALGUHI; ALOTAIBI; AL-AMMAR, 2024). Especialmente em redes elétricas locais, nas quais a porcentagem de geração solar é maior do que a de outras tecnologias de geração convencionais, tornando-se um desafio para a gestão da energia, por serem tecnologias de geração de energia não gerenciáveis. Visto que se a porcentagem gerada de energia fotovoltaica for alta, a variabilidade da eletricidade produzida e de seu consumo torna-se um problema considerável, ocasionando a desestabilização do sistema elétrico (SHEIKH; RATHI; SOOMRO, 2022).

Nos últimos anos, diversos autores têm abordado as questões do despacho de potência ótimo em redes de distribuição com *Battery Energy Storage System* (BESS) integrados. Esses estudos têm se concentrado em vários aspectos principais, como: modelagem, definição da função na rede, funções objetivo do problema de otimização, definição de variáveis de controle, variáveis dependentes e restrições técnicas, e escolha de métodos de solução (RADOSAVLJEVIĆ *et al.*, 2023).

A alocação e operação ótima de BESS em redes de distribuição é um problema complexo de otimização não linear envolvendo variáveis de decisão contínuas e discretas, o que constitui um tópico ativo de pesquisa que será explorado neste trabalho. Visto que um planejamento inadequado pode levar ao aumento de perdas ou sobretensão em alguns pontos da rede (DA SILVA; BELATI; LÓPEZ-LEZAMA, 2023; SOUZA *et al.*, 2022).

Segundo Radosavljević *et al.*, (2023) esse problema pode ser resolvido por duas

abordagens: métodos clássicos de otimização que utilizam fundamentos matemáticos rigorosos, sendo eficazes em problemas convexos e bem definidos e métodos metaheurísticos que buscam soluções aproximadas por meio de estratégias inspiradas em processos naturais ou sociais, sendo mais adequados a problemas complexos e não lineares. No presente trabalho será utilizado o Algoritmo Genético (AG), e o *Grey Wolf Optimization* (GWO) que são métodos metaheurísticos baseados respectivamente na evolução natural e no comportamento social e de caça de lobos cinzentos. Essas técnicas são amplamente empregadas em problemas de otimização para operação ótima de sistemas de armazenamento de energia, sendo descritas em detalhes na sequência.

A instalação do BESS na rede pode aumentar a eficiência dos sistemas de distribuição, desde que seu posicionamento e capacidade sejam adequadamente definidos. Sendo uma importante tarefa para melhorar o desempenho dos sistemas de distribuição, aumentar a confiabilidade da geração de energia e minimizar os custos de operação do sistema. Diversos estudos vêm investigando métodos para determinar de maneira ótima o posicionamento e a capacidade desses sistemas, utilizando técnicas de otimização complexas e não lineares para alcançar o despacho ótimo de energia (DA SILVA *et al.*, 2025; POMPERN *et al.*, 2023).

Diante desse contexto, destaca-se a importância de investigar estratégias eficientes para o dimensionamento e o posicionamento ótimo de sistemas de armazenamento em redes de distribuição, com o objetivo de maximizar o aproveitamento das fontes renováveis, além de ampliar a capacidade e confiabilidade da rede. O presente trabalho propõe a aplicação do método probabilístico *Two-Point Estimate Method* (2PEM), que considera as incertezas associadas à geração fotovoltaica e à demanda de energia, aliado ao uso de técnicas de otimização: Algoritmo Genético (AG) e Grey Wolf Optimizer (GWO), as quais avaliam os cenários de incerteza gerados para buscar as soluções que minimizam as perdas técnicas de energia.

1.1. JUSTIFICATIVA

A escolha deste tema justifica-se pela crescente instalação de geradores distribuídos nas redes de distribuição, sendo uma das alternativas mais promissoras para aumentar a utilização de fontes de energia renováveis e garantir o atendimento da demanda por energia elétrica. Contudo, essas fontes introduzem incertezas ao sistema devido à sua natureza intermitente que depende das condições climáticas, podendo ocasionar a desestabilização do sistema elétrico. Além disso, a integração desses geradores deve considerar dimensionamento e localização adequados, para não ocasionar efeitos adversos ao sistema maximizando perdas de energia e

custos (DA SILVA *et al.*, 2025; KAMEL *et al.*, 2020).

1.2. MOTIVAÇÃO

A crescente busca pela maior utilização de fontes renováveis para a geração de energia, contribui para o suprimento da demanda energética e para a redução das emissões de gases de efeito estufa. Com isso, impulsionou-se o uso da geração distribuída, com fontes conectadas e espalhadas no sistema elétrico, trazendo diversos benefícios para a rede, como a diversidade da matriz energética e a confiabilidade. Contudo, as fontes renováveis apresentam grandes variações de geração, trazendo desafios para o sistema elétrico que deve se manter estável e lidar com fluxos bidirecionais de energia elétrica, onde consumidores também podem ser geradores.

Dessa forma, é essencial avaliar estratégias que permitam a maior utilização das fontes renováveis, proporcionando conexão segura e eficiente. Os sistemas de armazenamento de energia, surgem como componentes suavizadores, minimizando as variações de energia. Possibilitando o armazenamento de energia em horários de baixa demanda para a utilização em períodos de alta demanda que não possui geração suficiente de energia renovável.

Portanto, esse trabalho se motiva em otimizar a operação de baterias conectadas em sistemas de distribuição. Para validar os resultados, foram utilizados os sistemas de distribuição IEEE 13 barras e 34 barras com integração de geração fotovoltaica, buscando reduzir as perdas técnicas da rede elétrica.

1.3. OBJETIVOS

1.3.1. Objetivo Geral

Minimizar as perdas técnicas em sistemas de distribuição IEEE 13 e 34 barras, por meio de metaheurísticas que determinam o despacho ótimo diário de um sistema de armazenamento por bateria (BESS), considerando a integração de geração fotovoltaica e incertezas de carga e geração. Para isso, alguns objetivos específicos devem ser alcançados;

1.3.2. Objetivos Específicos

- Modelar no *OpenDSS* os sistemas de distribuição IEEE 13 barras e IEEE 34 barras, incluindo geração fotovoltaica e sistema de armazenamento de energia por baterias (BESS).
- Implementar no *Matlab* o método probabilístico 2PEM para a geração de cenários de incerteza de carga e de irradiação solar nos dois sistemas de distribuição.

- Aplicar no *Matlab* em conjunto com o *OpenDSS*, as duas técnicas de otimização *Grey Wolf Optimizer* (GWO) e Algoritmo Genético (AG) por meio de uma função objetivo que encontre o despacho ótimo da bateria visando a redução das perdas técnicas na rede.
- Comparar e analisar os resultados obtidos por meio das duas técnicas de otimização (AG e GWO) nos dois sistemas de distribuição.

1.4. ESTRUTURA DO TRABALHO

A estrutura do trabalho, está organizada em cinco seções. Inicialmente, apresenta-se um embasamento teórico que fornece uma fundamentação sobre a evolução e a utilização da energia solar fotovoltaica e dos sistemas de armazenamento de energia, incluindo também a operação do *software OpenDSS*. Em seguida é apresentado as técnicas utilizadas para a otimização do problema, iniciando pela descrição do método probabilístico 2PEM e a estrutura e o funcionamento das metaheurísticas AG e GWO. A quarta seção descreve a natureza da pesquisa e a metodologia empregada para a realização do trabalho, sendo sucedida pela apresentação e análise dos resultados obtidos. Na última seção está apresentado as conclusões e sugestões para pesquisas futuras.

1.5. PUBLICAÇÕES ORIUNDAS

- Análise preliminar dos impactos da integração de geração distribuída e baterias no sistema elétrico. Trabalho apresentado no formato de pôster no evento denominado: VI Congresso de Tecnologias, Engenharias e Ciências Exatas, promovido pelo Centro de Engenharias e Ciências Exatas, realizado no período de 1 a 3 de julho de 2025, na Universidade Estadual do Oeste do Paraná – Campus de Foz do Iguaçu, Brasil.
- Análisis de pérdidas eléctricas considerando la integración de generación fotovoltaica y almacenamiento de energía. Artigo apresentado no congresso denominado: XXI Encuentro Científico Tecnológico, realizado no período de 6 a 10 de outubro de 2025, na Universidad Nacional del Este (UNE), Cidade do Leste, Paraguai. O trabalho foi publicado na revista eletrônica FPUNE Scientific, ISSN: 2313-4135.
- Redução de perdas técnicas em sistemas de distribuição com integração de geração fotovoltaica e armazenamento de energia. Trabalho apresentado no formato de pôster no evento denominado: II Encontro de física aplicada na tríplice fronteira, promovido pelo Programa de Pós Graduação em Física Aplicada, realizado no período de 4 a 6 de novembro de 2025, na Universidade Federal da Integração Latino-Americana - UNILA. Campus – Itaipu Parquetec, Foz do Iguaçu, Brasil.

1.6. ESTADO DA ARTE

Este capítulo tem como objetivo apresentar artigos encontrados na literatura que estão relacionados à aplicação de metaheurísticas em sistemas de distribuição com integração de geração renovável e sistema de armazenamento por baterias (BESS). São abordados estudos que exploram diferentes estratégias de otimização, evidenciando as principais abordagens, contribuições e lacunas encontradas na literatura recente.

Freitas, (2015) analisou o fluxo de potência no sistema IEEE 13 barras utilizando o *software OpenDSS*, considerando a integração de diferentes fontes de geração distribuída: fotovoltaica, eólica e sistemas de armazenamento de energia por baterias (BESS). O estudo definiu duas curvas de carga, residencial e comercial, as quais serão utilizadas no presente trabalho. Os resultados foram aplicados a um sistema real de distribuição, com o objetivo de avaliar os impactos da penetração de fontes renováveis sobre os níveis de tensão. Embora o trabalho contemple a inserção de múltiplas fontes de geração distribuída e armazenamento, a análise se restringe ao desempenho elétrico do sistema, sem incorporar metodologias de tratamento de incertezas ou técnicas de otimização.

Em Rangel *et al.*, (2018), a metodologia proposta analisa a seleção do tipo de sistema de armazenamento de energia (SAE) e o gerenciamento ótimo da energia em redes de distribuição que possuam geração distribuída (GD). A abordagem considera tanto as limitações de fluxo reverso quanto penalidades associadas a custos, utilizando algoritmo genético como ferramenta de otimização. A formulação permite avaliar diferentes cenários de alocação e operação do SAE, comparando sua performance técnica e econômica. Os resultados demonstram que a aplicação da metodologia possibilita reduzir perdas técnicas na rede, mitigar problemas de fluxo reverso causados pela geração distribuída e, ao mesmo tempo, otimizar os custos relacionados à operação. Contudo, o estudo não aborda métodos probabilísticos para geração de cenários de incerteza de geração e carga.

Alzahrani; Alharthi; Khalid, (2020) apresentaram a utilização de um algoritmo genético para alocar o sistema de armazenamento em baterias de forma otimizada, considerando alta penetração de energia fotovoltaica em um sistema de distribuição teste de 33 barras, a fim de minimizar as perdas de energia. Como resultado, foi alcançada uma redução anual significativa nas perdas de energia em comparação com o caso base. Neste estudo, o sistema de armazenamento foi projetado para fornecer apenas energia ativa à rede.

Abou El-Ela *et al.*, (2022) propuseram uma metodologia de otimização multiobjetivo para a alocação ótima do BESS em redes de distribuição IEEE 30 e 69 barras. O trabalho buscou equilibrar simultaneamente a redução de perdas elétricas e a maximização da vida útil das

baterias, utilizando *Multi-Objective Equilibrium Optimization Technique* (MOEOT). Os resultados mostraram que a abordagem contribuiu para determinar o posicionamento e tamanho ótimo da energia fotovoltaica e BESS, reduzindo os custos de operação e investimento de instalação dos sistemas, bem como a redução das perdas totais de energia e a maximização dos ciclos da bateria. Entretanto, o estudo não aborda a operação em sistemas de distribuição com geração renovável sob incertezas.

Pompern *et al.*, (2023) investigaram a alocação e dimensionamento ótimo de sistemas de armazenamento em baterias (BESS) em redes de distribuição IEEE 33 e 69 barras, integradas com geração fotovoltaica (PV) e veículos elétricos. Para isso, os autores utilizaram diferentes algoritmos metaheurísticos, como *Particle Swarm Optimization* (PSO), *African Vultures Optimization Algorithm* (AVOA) e *Salp Swarm Slgorithm* (SSA), com o objetivo de minimizar os custos do sistema, incluindo instalação, substituição e custos de operação e manutenção do BESS. Os resultados demonstraram que a instalação do BESS melhora o perfil de tensão, reduz as perdas na transmissão e diminui o pico de demanda, enquanto que as técnicas de otimização apresentam bom desempenho destacando-se a PSO para ganhos técnicos e a AVOA para benefícios econômicos. No entanto, o estudo foca na alocação e dimensionamento das baterias, sem analisar cenários de incerteza de carga e geração.

Da Silva; Belati; López-Lezama, (2023) apresentaram uma abordagem para a coordenação ótima entre geração fotovoltaica, geração eólica, geração convencional e BESS em redes de distribuição, aplicando em uma rede teste IEEE 33 barras e em uma rede real de 141 barras, considerando a *Multi-period Optimal Power Flow* (MOPF). O modelo foi desenvolvido por *Modeling Language for Mathematical Programming* (AMPL), visando equilibrar fatores como redução de perdas de energia, melhoria do perfil de tensão e custos de operação. Os resultados evidenciaram redução significativa das perdas e achatamento do perfil de tensão. No entanto, a análise concentra-se em metodologias de alocação e controle, sem incorporar explicitamente cenários de incerteza de carga e geração que refletem condições reais do sistema elétrico.

Radosavljević *et al.*, (2023) analisaram o despacho ótimo de potência ativa e reativa em um sistema IEEE 13 barras com cargas desbalanceadas e integração de geração fotovoltaica e BESS. Considerando uma otimização híbrida entre PSO e *Chaotic Gravitational Search Algorithm* (CGSA), chamado de algoritmo PSOS-CGSA estratégias de otimização multiobjetivo para melhorar o desempenho técnico e econômico do sistema. A abordagem utiliza também a simulação de Monte Carlo (MCS) para avaliar a incerteza de geração e carga. Os resultados apresentam grande redução nos custos diários de eletricidade, redução das perdas

de energia e taxa de desequilíbrio de tensão de fase abaixo do limite máximo de 2% para todas as barras trifásicas.

Grisales-Noreña *et al.*, (2024) abordam o problema de operação ótima de baterias de íon-lítio em redes de distribuição CC, avaliando aspectos técnicos, econômicos e ambientais, por meio do método de *Sparse Nonlinear Optimization* (SNOPT), comparando seu desempenho com metaheurísticas, como *Continuous genetic algorithm* (CGA), PSO e *Vortex search algorithm* (VSA). O desempenho da metodologia proposta é validado em redes autônomas e conectadas à rede, demonstrando que a abordagem alcança resultados mais consistentes, com menor tempo de processamento e desvio padrão nulo, ou seja, as metaheurísticas convergem para valores iguais, garantindo soluções globais ótimas em diferentes cenários. Apesar dessas contribuições, o trabalho concentra-se em redes CC e não aborda aplicações em sistemas de distribuição CA com múltiplas fontes e condições de incerteza.

Alguhi; Alotaibi; Al-Ammar, (2024) propuseram um planejamento para otimizar as decisões de carga e descarga do sistema de armazenamento em baterias (BESS) em uma rede de distribuição 69 barras, considerando a integração de fontes renováveis com foco na análise da intermitência da irradiação solar, a velocidade do vento e as demandas do sistema. A técnica de otimização utilizada é a PSO, a qual permite encontrar o dimensionamento, localização e operação ideal do BESS. Os resultados analisaram quatro cenários: sem geração distribuída, com geração fotovoltaica, com geração eólica e geração fotovoltaica e eólica, considerando dentro dos diferentes cenários tipos de baterias distintos, destacando-se que a inserção de BESS em sistemas de distribuição em conjunto com as duas fontes renováveis apresentaram impacto significativo na redução de perdas, sendo as baterias de íons de lítio a opção mais econômica.

Júnior, (2025) propôs uma metodologia para a operação ótima de baterias em um sistema de distribuição IEEE 13 barras, incorporando incertezas de carga e geração decorrentes da integração de geração fotovoltaica, por meio do método *Two Point Estimate Method* (2PEM). O trabalho utilizou a metaheurística *Grey Wolf Optimization* (GWO), com o objetivo de reduzir as perdas técnicas ao longo de 24 horas, demonstrando que a abordagem é eficiente mesmo sob cenários incertos. Os sistemas utilizados neste trabalho serão utilizados como base nesta pesquisa, contudo, será avaliado também a utilização de Algoritmo Genético (AG) como alternativa de otimização, possibilitando a comparação de desempenho e eficiência em relação a utilização do GWO.

Da Silva *et al.*, (2025) apresentaram um estudo sobre a alocação e operação ótima de sistemas de armazenamento em baterias (BESS) com geração fotovoltaica em dois sistemas testes IEEE 33 e 141 barras. A metodologia apresenta uma abordagem híbrida entre a técnica

de otimização *Modified Grey Wolf Optimisation* (MGWO) e uma programação matemática rotulada como MGWO-H, a abordagem proposta foi implementada em *A Modelling Language for Mathematical Programming* (AMPL) e tratada através do solucionador comercial Knitro. Os resultados indicaram redução das perdas ao comparar com o GWO, ao considerar que o BESS pode fornecer potência ativa e reativa a redução das perdas é mais significativa. Além disso, no caso de um único BESS as perdas foram equivalentes entre os métodos de otimização utilizados, reforçando a tendência de convergência a resultados similares.

Elseify *et al.*, (2025) apresentam um modelo de agendamento ótimo de sistemas fotovoltaicos (PV) e de baterias (BESS) em redes de distribuição, considerando incertezas de irradiância solar e cargas dinâmicas. Os autores desenvolvem uma versão aprimorada da técnica de otimização *Sand Cat Swarm Optimization* (ASCAO), associando dois algoritmos: o *Orthogonal Learning*, para gerar diversidade entre soluções candidatas, e o *Local Random Sand Cat Strategy* que aumenta a capacidade de exploração, prevenido convergência prematura. O método foi aplicado em sistemas de 33 e 69 barras, reduzindo perdas técnicas e demonstrando viabilidade econômica em diferentes cenários de carga (leve, normal e pesado). Os resultados mostraram que o ASCAO supera algoritmos de referência, obtendo menores perdas e menores custos anuais de operação e investimento. No entanto, o artigo não utiliza um método probabilístico para tratar as incertezas de irradiância solar.

2. EMBASAMENTO TEÓRICO

2.1. GERAÇÃO FOTOVOLTAICA

No Brasil, o século XX foi marcado pela industrialização, urbanização, expansão das redes de transporte, guerras mundiais e desenvolvimento de novas tecnologias, as quais mudaram o panorama energético do país. Iniciando pelo intenso uso da lenha, evoluiu para a incorporação do carvão mineral e sobretudo derivados de petróleo e da hidroeletricidade, que se tornou dominante a partir da década de 1950 com a construção de grandes usinas. Por volta de 1970 com a crise do petróleo e o início das preocupações ambientais, foi criado o Programa Nacional do Álcool (Proálcool) em 1974, fortalecendo o uso do etanol e da biomassa. Neste período as descobertas de petróleo *offshore* intensificaram o consumo de petróleo e gás natural, especialmente a partir dos anos 1990. Já em 2001, o Brasil possuía 85% de potência instalada proveniente de usinas hidrelétricas, entretanto, a crise hídrica desse ano evidenciou a vulnerabilidade do sistema, resultando em um apagão que impulsionou a diversificação da matriz energética, com políticas públicas como o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA) e, mais recentemente, incentivos à energia solar, usinas eólicas, pequenas centrais hidrelétricas e à geração distribuída (ANEEL, 2024).

Atualmente, a matriz de geração de energia elétrica Brasileira passou por grande transformação, tornando-se mais diversificada e majoritariamente renovável. Destacando-se a energia solar fotovoltaica que vem aumentando sua produção de forma centralizada e distribuída, posicionando o país como o sexto maior produtor mundial, enquanto que a fonte hidráulica ainda representa aproximadamente 50% da capacidade instalada de geração (ANEEL, 2024).

O marco do crescimento de geração solar, se deu a partir de 2012 através da Resolução Normativa ANEEL nº 482/2012 que estabeleceu a criação do processo de compensação de energia, permitindo que o excedente de geração de energia elétrica possa ser compensado como créditos de energia. Tal lei foi revogada em 2023 pela Resolução Normativa ANEEL nº 1.059/2023 que aprimora as regras para a conexão e o faturamento de centrais de Microgeração e Minigeração Distribuída (MMGD) em sistemas de distribuição de energia elétrica, bem como as regras do Sistema de Compensação de Energia Elétrica. Em janeiro de 2022 instituiu-se a Lei nº 14.300 que implementa o marco legal da microgeração e minigeração distribuída, o Sistema de Compensação de Energia Elétrica (SCEE) e o Programa de Energia Renovável Social (PERS) (ANEEL, 2012, 2023; BRASIL, 2022).

Dentre as fontes renováveis, a geração fotovoltaica destaca-se pelo alto potencial e

facilidade de instalação de forma distribuída. A possibilidade de pequenos consumidores instalarem esses sistemas em telhados residenciais ou comerciais, com custos relativamente acessíveis, impulsiona sua expansão como fonte predominantemente distribuída (SCOLARI; URBANETZ, 2018).

Apesar de que a maior contribuição e crescimento em números absolutos em potência instalada, seja proveniente de origem hidrelétrica, a maior expansão proporcional ocorreu na geração solar. Segundo a EPE, (2024), em 2023 o destaque foi para as plantas de geração solar fotovoltaica, que aumentaram sua capacidade instalada em cerca de 55% em relação a 2022, deste total, cerca de 70% correspondeu à capacidade em MGD.

Entretanto, as fontes renováveis apresentam variabilidade temporal em diferentes escalas, que podem ocorrer de minuto a minuto, até variações sazonais ou interanuais, influenciadas principalmente pelas condições climáticas. Na geração solar, além dos aspectos meteorológicos a variabilidade está diretamente associada a irradiação solar, impactando o sistema elétrico no curto e longo prazo. No curto prazo a preocupação está no equilíbrio entre carga e geração, enquanto que no longo prazo a variabilidade pode afetar a viabilidade econômica da rede (IEA, 2014; JÚNIOR, 2025).

Essa característica acarreta na necessidade de manter outras fontes de geração operando em conjunto, a fim de garantir o atendimento a demanda, o que aumenta os custos de energia. Além disso, a intensidade de radiação solar não pode ser prevista completamente, por depender de inúmeros fatores meteorológicos, impondo desafios ao sistema elétrico que desde sua concepção, em 1882, têm como função principal o fornecimento de energia elétrica ininterrupta e com qualidade adequada aos seus consumidores (JÚNIOR, 2025; KAGAN; OLIVEIRA; ROBBA, 2005).

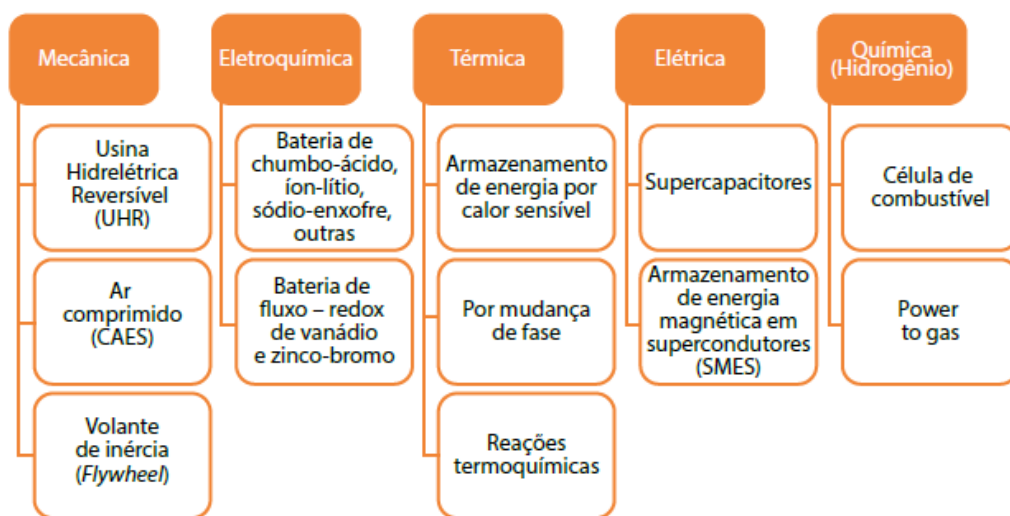
2.2. SISTEMAS DE ARMAZENAMENTO DE ENERGIA

No mercado global, há várias tecnologias de armazenamento disponíveis, em diversos estágios de maturidade, desde pesquisa até aplicações comerciais. Como regra, o armazenamento elétrico ocorre quando a energia elétrica é armazenada diretamente em um campo elétrico ou magnético, estas tecnologias convertem a energia elétrica em outra forma de energia armazenável (química, mecânica ou térmica), durante o processo de carga, e no processo de descarga, a energia armazenada é novamente transformada em energia elétrica e entregue a rede. Em todas as tecnologias, há uma perda de energia no processo de carga-descarga, o que determinará a eficiência do sistema de armazenamento (BUENO; BRANDÃO, 2016).

O Energy Storage (ES) é uma tecnologia promissora devido à sua capacidade de desacoplar a oferta da demanda, permitindo que o fornecimento de energia seja deslocado no tempo. Essa característica possibilita a compensação de descompassos temporários entre a geração e o consumo de eletricidade, tornando o armazenamento uma ferramenta estratégica de alto valor para o sistema elétrico (LUND *et al.*, 2015).

Dentre as diversas formas de armazenamento de energia (figura 1), duas tecnologias se apresentam como candidatas potenciais para aplicação no setor elétrico brasileiro: Usinas Hidrelétricas Reversíveis (UHRs) e baterias (CANTANE; ANDO; HAMERSCHMIDT, 2020).

Figura 1 – Tecnologias de Armazenamento de Energia



Fonte: CANTANE; ANDO; HAMERSCHMIDT, (2020)

Baseado em baterias, já se discute como estes sistemas podem impactar na questão do planejamento energético nacional Além da redução de custos, alguns fatores justificam o interesse neste tipo de tecnologia, incluindo alta densidade de energia, eficiência, baixo tempo de resposta, flexibilidade tanto em capacidade de instalação quanto em possibilidade de alocação física, versatilidade de aplicações e rápida instalação (EPE, 2019).

Apesar de que a justificativa, os benefícios e a redução de custos de fabricação dos Sistemas de armazenamento de energia baseados em baterias já estejam consolidados na literatura, o Brasil ainda se encontra em um patamar inicial de aplicação (CANTANE; ANDO; HAMERSCHMIDT, 2020)

A regulação dos Sistemas de Armazenamento de Energia (SAEs) no Brasil tem avançando sob coordenação da Agência Nacional de Energia Elétrica (ANEEL). A Consulta Pública nº 39/2023, publicada no fim de 2024, marcou a transição para a fase de regulamentação, incluindo também usinas hidrelétricas reversíveis. Em 5 de agosto de 2025, a agência publicou a Nota Técnica Conjunta nº 13/2025, que estabelece diretrizes conceituais e

jurídicas para a integração dos SAEs ao setor elétrico, possibilidade de operação como produtores independentes de energia, além de critérios para contratos e aplicação tarifária (ANEEL, 2024b, 2025).

O armazenamento de energia age como *buffer*, tornando a rede elétrica mais flexível para acomodar mais geração renovável. Assim, tornam o Sistema Elétrico de Potência (SEP) mais flexível para acomodar variações da geração e da carga, como ocorre no caso da energia renovável (BUENO; BRANDÃO, 2016).

Os SAEs possuem importantes benefícios ao setor elétrico, tanto em sistemas isolados como em redes interligadas, aumentando a flexibilidade operacional, permitindo estabilizar a geração renovável variável, contribuindo para maior penetração de fontes limpas devido ao fornecimento mais constante de energia. Também, podem reduzir o uso de geradores a diesel, contribuindo para a diminuição dos custos operacionais e das emissões (CANTANE; ANDO; HAMERSCHMIDT, 2020).

2.3. SOFTWARE OPENDSS

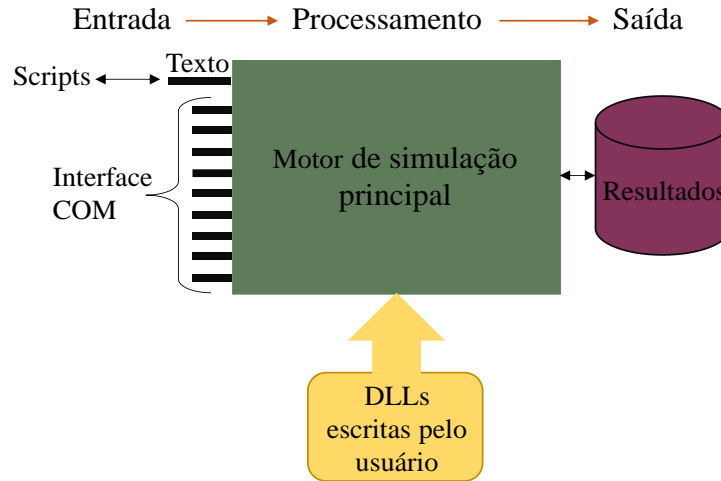
Segundo a *Electric Power Research Institute - EPRI, (2024)*, o desenvolvimento do *software OpenDSS* iniciou em abril de 1997 na *Electrotek Concepts*, chamado inicialmente de *Distribution System Simulator – DSS*, desenvolvido principalmente por Roger Dugan, apoiado por Tom McDermott. O DSS foi adquirido pela *EPRI Solutions* em 2004, a qual foi unida à EPRI em 2007. Dessa forma, a EPRI lançou o software em 2008, como uma licença de código aberto para cooperar com a modernização da rede na área de *Smart Grid*.

O *OpenDSS* é um mecanismo de simulação no domínio da frequência de uso geral que possui recursos especiais para criar modelos de sistemas de distribuição de energia elétrica e realizar vários tipos de análises relacionadas ao planejamento da distribuição e à qualidade da energia. O *software* realiza simulações que envolvem condições permanentes, como fluxo de carga, perdas, harmônicos e séries temporais quase-estáticas (QSTS), além disso, o *OpensDSS* é capaz de simular comportamentos dinâmicos lentos como a atuação de sistemas fotovoltaicos e de armazenamento com controle de potência, tensão ou frequência em redes de média e baixa tensão (EPRI, 2024).

A partir da interface *Component Object Model (COM)* e a interface DLL de chamada direta (criada pelo usuário), o *software* permite que seus recursos sejam utilizados para realizar novos tipos de estudos. Através dela, os usuários podem executar modos e recursos de solução personalizados a partir de um programa externo como *Mathworks MATLAB, Python, C#, R* e outras linguagens. Dessa forma, os resultados podem ser exportados e utilizados facilmente em

outras ferramentas, para pós-processamento. A figura 2 apresenta a estrutura e configuração do funcionamento do *software* (EPRI, 2024).

Figura 2 – Estrutura de funcionamento do *software* *OpenDSS*




Fonte: Adaptado de EPRI, 2024.

Vale ressaltar que segundo Barouche, (2017), historicamente diversos métodos foram utilizados para quantificar as perdas de energia em redes de distribuição no Brasil, porém em 2015 no início do 4º Ciclo de Revisões Tarifárias Periódicas (CTRP), a ANEEL reconheceu o método de cálculo por fluxo de carga no *OpenDSS* através de sua nota técnica nº 0104/2014.

2.3.1. Modelo do sistema Fotovoltaico (*PVSystem*)

No *OpenDSS*, o sistema fotovoltaico, é composto pela combinação entre painel fotovoltaico e inversor, apresentado na figura 3. Neste modelo o inversor é capaz de rastrear rapidamente o ponto de máxima potência (MPPT) permitindo o uso adequado das simulações QSTS, facilitando a modelagem fotovoltaica e sendo válido para a maioria dos estudos de impacto de interconexão (EPRI, 2024).

Figura 3 – Diagrama do modelo *PVsystem*



Fonte: Adaptado de EPRI, 2024.

A potência gerada pelo sistema é representada pela equação 1, já a potência entregue ao sistema elétrico é dada pela equação 2.

$$P_{DC}(t) = P_{pmp} * E_b * E(t) * FC(T(t)) \quad (1)$$

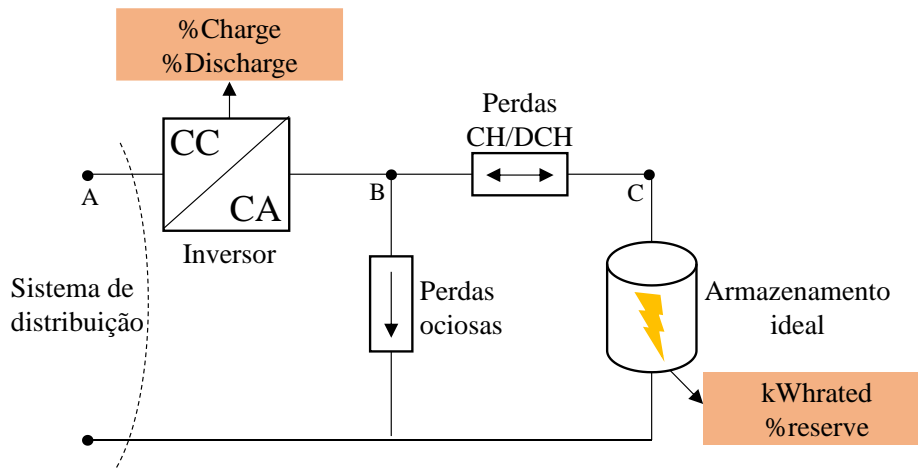
$$P_{AC}(t) = P_{DC}(t) * \eta_{inversor} \quad (2)$$

Onde, P_{pmp} representa a potência nominal no ponto de máxima potência, E_b corresponde à irradiância solar de referência para normalizar a potência gerada, $E(t)$ é o valor da irradiância no instante t , $FC(T(t))$ representa o fator de correção da potência P_{pmp} em função da temperatura do módulo. $\eta_{inversor}$ refere-se a eficiência do inversor em determinada potência, dado que a eficiência varia com a carga (JÚNIOR, 2025).

2.3.2. Modelo do sistema de Armazenamento (*Storage*)

O elemento *Storage* no *OpenDSS* (figura 4), é composto essencialmente por um gerador que pode ser utilizado para despachar energia elétrica (descarga, entregando energia para a rede) ou consumir energia elétrica (carga, demanda energia da rede), dentro de seus parâmetros como potência nominal e capacidade de armazenamento de energia. O modelo possui medidor de energia e uma interface DLL escrita pelo usuário, podendo agir de forma independente ou ser controlado por um elemento *StorageController* (EPRI, 2024).

Figura 4 – Estrutura do elemento *Storage*



Fonte: Adaptado de EPRI, 2024.

Conforme a figura 4, observa-se que o sistema de armazenamento está conectado à rede por meio de um inversor CC-CA, estando sujeito a perdas no processo de conversão e a perdas ociosas. Além disso, o sistema só irá descarregar se o nível da carga atual estiver acima do valor definido por *%reserve*, garantindo sempre tenha uma reserva mínima de energia. A carga só ocorre se a energia armazenada estiver abaixo da capacidade máxima (*kWhrated*). As propriedades *%Charge* e *%Discharge*, são as taxas de carga e descarga que definem a

porcentagem utilizada da potência nominal do sistema.

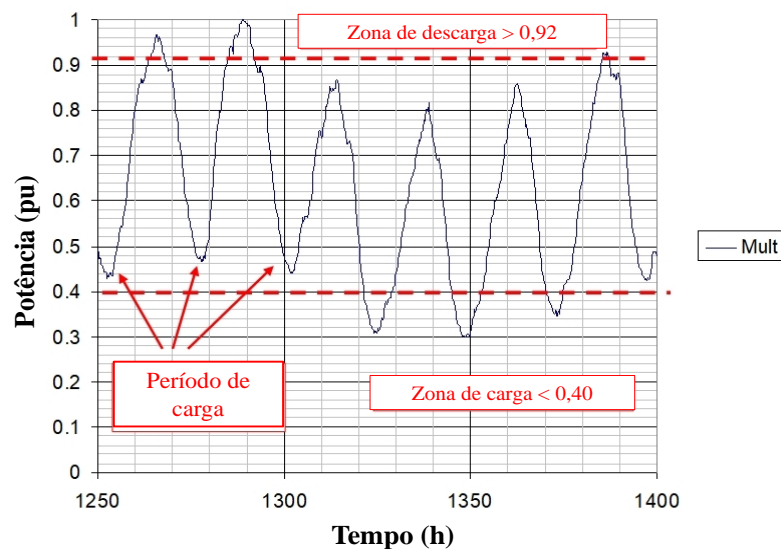
O modelo possui modos de simulação que variam no tempo, sendo: *Daily*, *Yearly* e *DutyCycle*. Os modos *Daily* ou *Yearly* analisam questões em escala de tempo de vários minutos a uma hora. Já o modo *DutyCycle* busca estudar a eficácia do armazenamento de energia para compensar variações de potência de curto prazo, por exemplo, sombreamento causado por nuvens que afetam a geração da energia solar fotovoltaica (EPRI, 2024)

O elemento de armazenamento também pode produzir ou absorver potência reativa dentro da classificação kVA do inversor. Ou seja, um objeto *StorageController* solicita uma certa quantidade de kVAr e o elemento de armazenamento a fornece, podendo produzir/absorver kVAr enquanto estiver em marcha lenta (EPRI, 2024).

As perdas são importantes ao avaliar os esquemas de armazenamento, permitindo especificar separadamente as eficiências de carga e descarga. O sistema de armazenamento possui cinco modos de despacho de energia que são ativados por dois gatilhos *ChargeTrigger* (gatilho de carga) e *DischargeTrigger* (gatilho de descarga), os gatilhos variam conforme o modo de despacho, sendo eles (EPRI, 2024):

- 1- *Default*: neste modo, figura 5, o *Storage* segue uma curva de carga (*Loadshape*) definida pelo usuário. A descarga ocorre quando o valor da curva excede a zona de descarga e continua até atingir o nível de reserva ou até a curva cair abaixo da zona de carga, onde é iniciado o processo de carregamento até atingir 100%

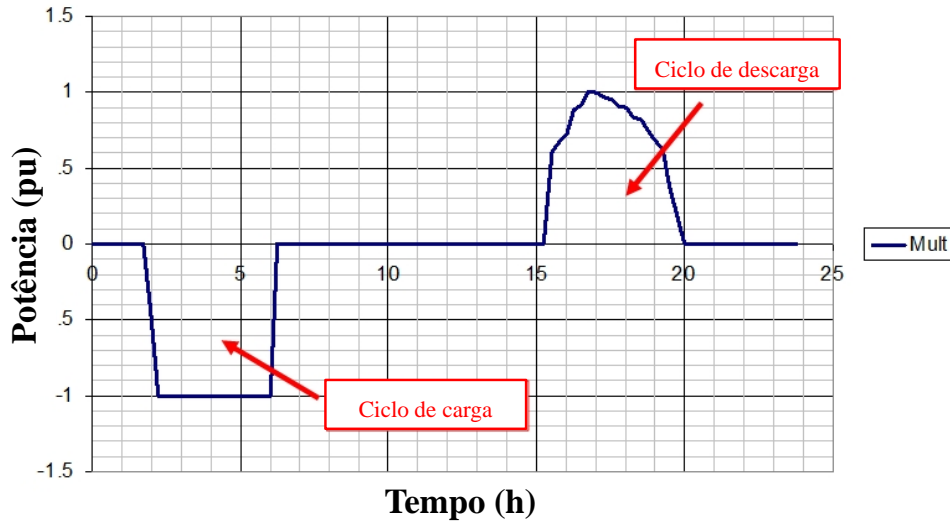
Figura 5 – Despacho de energia pelo modo *default*



Fonte: Adaptado de EPRI, 2024.

- 2- *Follow*: neste modo, figura 6, o *Storage* segue uma curva de carga, fornecendo potência ativa quando o valor da curva é positivo (descarga) e consumindo potência ativa quando o valor for negativo (carga). O qual será utilizado no presente trabalho.

Figura 6 – Despacho de energia pelo modo *follow*



Fonte: Adaptado de EPRI, 2024.

- 3- *Loadlevel*: O controle é feito com base em um nível de carga global definido no circuito (*LoadMult*). A descarga ou carga ocorre se esse nível ultrapassar os limites definidos por *DischargeTrigger* ou *ChargeTrigger*.
- 4- *Price*: O controle segue um sinal de preço da energia, definido por uma curva (*PriceShape*). A bateria descarrega quando o preço ultrapassa o *DischargeTrigger* e carrega quando está abaixo do *ChargeTrigger*.
- 5- *External*: O *Storage* não atua de forma independente, a operação é controlada externamente por um elemento *StorageController* ou por um *script* (manual ou via interface COM). Sendo ideal para simulações em tempo real ou controladas por lógica personalizada.

3. MÉTODOS UTILIZADOS

3.1. TWO-POINT ESTIMATE METHOD (2PEM)

O método de estimativa por dois pontos (2PEM), desenvolvido por Rosenblueth, é utilizado para calcular os momentos de uma quantidade aleatória que depende de uma ou mais variáveis aleatórias. No caso de uma única variável aleatória X , com função densidade de probabilidade $f(x)$, quando $Z=h(X)$ o método substitui $f(x)$ por duas concentrações de probabilidade que reproduzem os três primeiros momentos da distribuição. Já quando Z é função de n variáveis aleatórias, o 2PEM utiliza 2^n concentrações de probabilidade, localizadas em 2^n pontos, de modo a substituir a função densidade conjunta original das variáveis, correspondendo até os momentos não cruzados de segunda e terceira ordem (HONG, 1998).

É uma técnica estatística simplificada que permite resolver métodos mais complexos de forma eficiente. O qual considera dois pontos representativos um otimista (β_{sup}) e um pessimista (β_{inf}) (equação 3) em torno do valor médio de uma variável aleatória, cada um com um peso probabilístico associado. Muito aplicado em situações em que uma variável de interesse pode ser afetada por incertezas como no caso da demanda de energia ou geração de energia renovável.

$$\beta_{sup} = \sqrt{m} \quad (3)$$

$$\beta_{inf} = -\sqrt{m}$$

O número de variáveis de entrada incertezas a serem analisadas (m) é obtido conforme a equação 4 (JÚNIOR, 2025).

$$m=2.(n_{barras}+n_{pv}) \quad (4)$$

Em que, n_{barras} corresponde ao número de barramentos com carga presentes no sistema e n_{pv} são o número de unidades de geração fotovoltaica.

Cada variável incerta é avaliada separadamente, variando-a em torno da média enquanto as demais permanecem fixas. Assim, é possível identificar a influência de cada variável e compreender a sensibilidade do sistema às incertezas (JÚNIOR, 2025).

As duas concentrações para a variável "i", c_1 e c_2 , são posicionadas em ambos os lados do valor médio (μ_i) por meio do desvio padrão (σ_i), definidas pelas equações 5 e 6.

$$c_1 = \mu_i + \beta_{\text{sup}} \cdot \sigma_i \quad (5)$$

$$c_2 = \mu_i + \beta_{\text{inf}} \cdot \sigma_i \quad (6)$$

Em seguida são determinadas duas amostras, conforme as equações 7 e 8.

$$C_1 = [\mu_1, \mu_2, \dots, c_1, \dots, \mu_m]^T \quad (7)$$

$$C_2 = [\mu_1, \mu_2, \dots, c_2, \dots, \mu_m]^T \quad (8)$$

Após a obtenção das duas amostras, o problema de planejamento é resolvido individualmente, e os valores são armazenados, repetindo-se para todas as variáveis incertas. O procedimento permite avaliar o impacto das incertezas no sistema, apresentando uma compreensão mais precisa das variações (JÚNIOR, 2025).

3.2. ALGORITMO GENÉTICO (AG)

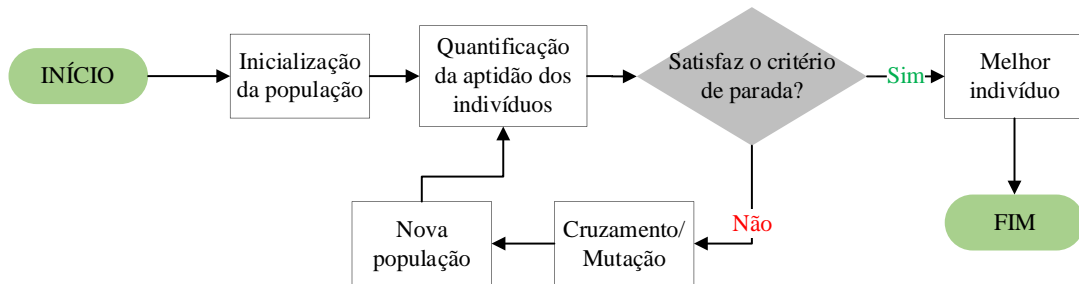
Segundo Sheikh *et al.*, (2022), algoritmos genéticos (AG) são técnicas utilizadas para resolver problemas de otimização não lineares ou não diferenciáveis, utilizando conceitos da biologia evolutiva para buscar um mínimo global. O algoritmo funciona iniciando uma geração inicial de soluções candidatas que são testadas em relação à função objetivo, gerando, em seguida, gerações subsequentes de pontos da primeira geração por meio de processos como cruzamento de seleção e mutação.

Uma das principais vantagens dos AGs é a capacidade de realizar uma busca global no espaço de soluções, o que os diferencia de métodos locais, que podem ficar presos em máximos ou mínimos locais. Dessa forma, a mutação realiza variações aleatórias nos indivíduos, mantendo a diversidade da população. Essa diversidade evita que o algoritmo se concentre cedo demais em uma única região do espaço, permitindo que ele explore novas possibilidades e aumente as chances de encontrar o ótimo global (LINDEN, 2008).

Como analisado em Afshan; Salehi, (2018), o algoritmo genético, apresenta excelente desempenho na otimização do dimensionamento e da estratégia de operação de sistemas PV-bateria em microrredes. A técnica demonstrou-se eficiente para explorar grandes espaços de solução não lineares, evitar mínimos locais e alcançar resultados próximos do ótimo global, fatores essenciais em problemas complexos de gerenciamento de energia com incertezas associadas à geração renovável. A figura 7 apresenta um fluxograma básico de como

os AGs funcionam.

Figura 7 – Fluxograma de funcionamento do algoritmo genético



Fonte: Adaptado de Kühn; Severin; Salzwedel, (2013)

Conforme apresentado em Blaiñi *et al.*, (2016), o algoritmo é iniciado com a geração da população inicial, onde cada cromossomo é um vetor composto pelo número de parâmetros empregado (n) (genes), conforme a equação 9.

$$X_i = [X_1, X_2, X_3, \dots, X_n] \quad (9)$$

O comprimento total de cada cromossomo é dado pela equação 10.

$$M = n \cdot N_b \quad (10)$$

Onde N_b representa o número de bits por parâmetro que formam os genes, permitindo que sejam representados em binário para facilitar a manipulação dos dados. Após isso, cada parâmetro (P_i) é obtido convertendo o bloco de N_b bits $[a_0, a_1, \dots, a_{N_b-1}]$ por meio de um vetor de conversão primária, representado pela equação 11 e 12.


$$\text{Conv} = [2^{n_i}, 2^{n_i-1}, \dots, 2^2, 2^1, \dots, 2]^{(n_i - N_b + 1)} \quad (11)$$

$$P_i = [a_0, a_1, \dots, a_{N_b-1}] \cdot \text{Conv}^T \quad (12)$$

Essa codificação e decodificação limita o domínio de busca de cada parâmetro durante a inicialização. Após isso é analisada a aptidão de cada indivíduo pela função objetivo.

Para criar a nova geração é necessário escolher dois cromossomos para formar filhos. Conforme apresentado em Blaiñi *et al.*, (2016), o método de seleção é o *Roulette Wheel Selection* (Roleta viciada), apresentado na figura 8, neste processo todos os cromossomos podem ser escolhidos, porém os que tiverem maior aptidão tem maior probabilidade de seleção. A probabilidade de seleção ($P_s(i)$) é calculada pela equação 13.

Figura 8 – Método de seleção roleta viciada




Fonte: Elaboração própria

$$P_s(i) = \frac{\sum_{k=1}^i \text{Aptidão}(X_k)}{\sum_{j=1}^N \text{Aptidão}(X_j)} \quad (13)$$

Onde, $\sum_{k=1}^i \text{Aptidão}(X_k)$ é o valor da aptidão de determinado indivíduo k e $\sum_{j=1}^N \text{Aptidão}(X_j)$ é a soma de toda a aptidão, normalizando a equação para que fique no intervalo de 0 a 1. Após o isso, o algoritmo sorteia um número aleatório $P_r \in [0,1]$ e verifica em qual intervalo acumulado esse valor se encontra. O primeiro cromossomo onde $P_s(i) \geq P_r$ é selecionado para gerar a próxima geração.

Na próxima etapa, o AG gera um filho a partir de dois cromossomos selecionados (pais), o par de cromossomos é selecionado sorteando um número aleatório P_r , assim se o pai escolhido tiver uma probabilidade $P_r < P_c$ e aplicado o método de cruzamento de um ponto (figura 9), para formar um filho, caso contrário mantém-se o mesmo cromossomo para a geração seguinte.

Figura 9 – Exemplo do método cruzamento por um ponto



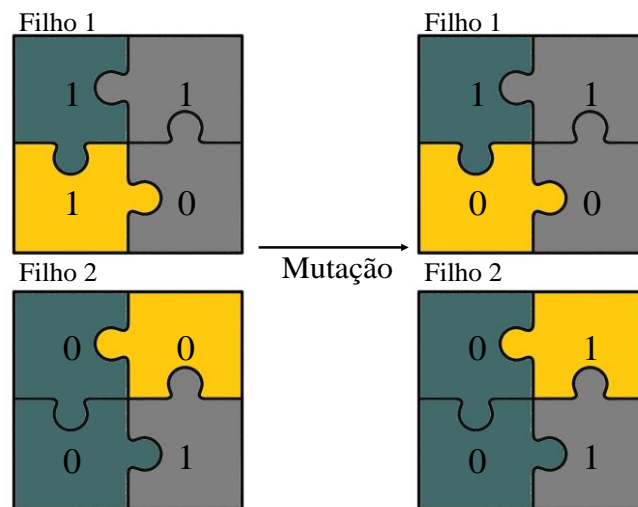
Fonte: Elaboração própria

Conforme observado na imagem, o método consiste em escolher aleatoriamente um

ponto de corte na sequência e em seguida trocar os pontos após o corte.

Para garantir a continuidade da diversidade da genética, seja ela boa ou ruim, é fundamental aplicar a mutação, a qual faz a alteração em alguns genes do cromossomo caso a geração inicial não se enquadre no ótimo global. No código binário a mutação apenas troca o caractere de 0 para 1 e vice-versa. Gera-se uma probabilidade aleatória (P_r), que será comparada com a probabilidade de mutação (P_m), caso $P_r < P_m$ a mutação é aplicada conforme a figura 10.

Figura 10 – Exemplo do processo de mutação



Fonte: Elaboração própria

De modo geral, a formulação do AG contém muitos parâmetros e operações elementares de otimização, tais como número de gerações, tamanho da população, função objetivo, seleção, parâmetro e probabilidade de cruzamento, e parâmetro e probabilidade de mutação, os quais requerem uma configuração específica dependendo do problema de otimização considerado (MI *et al.*, 2018). Trabalhos clássicos sobre AG, apresentam taxas ótimas de operação para probabilidade de cruzamento e mutação, bem como tamanho da população, conforme apresentado na tabela 1.

Tabela 1 – Parâmetros típicos do AG encontrados na literatura

Referência	População	Taxa de cruzamento	Taxa de mutação
De Jong, (1975)	50 a 100 indivíduos	60%	0,1%
Grefenstette, (1986)	Cerca de 30 indivíduos	95%	1%
Schaffer <i>et al.</i> , (1989)	20 a 30 indivíduos	75 a 95%	0,5 a 1%

Fonte: Elaboração própria

Com base nas considerações apresentadas, a escolha do conjunto de parâmetros de controle para o AG deve priorizar robustez e o desempenho. Embora De Jong, (1975) tenha

sugerido valores clássicos, evidências seguintes indicam que desempenhos ótimos podem ser obtidos com populações menores e taxas de mutação levemente maiores como apresentado em Grefenstette, (1986) e posteriormente confirmado por Schaffer *et al.*, (1989). Contudo, artigos mais recentes voltados para otimização ótima de baterias apresentam algumas variações na escolha desses parâmetros.

3.3. GREY WOLF OPTIMIZER (GWO)

O GWO é uma metaheurística baseada no comportamento social dos lobos cinzentos em matilha, utilizada para resolver problemas de otimização, simulando o comportamento de caça e a hierarquia de lobos cinzentos. Essa técnica é muito utilizada por sua estrutura simples, que possui menos parâmetros que requerem ajuste em comparação com o *Particle Swarm Optimization* (PSO) e o *Genetic Algorithms* (AG) por exemplo (DA SILVA *et al.*, 2025).

Essa metaheurística tem sido amplamente utilizada para resolver problemas de otimização complexos, incluindo a operação ótima de baterias e a alocação de recursos sob incertezas (JÚNIOR, 2025).

A abordagem segue três aspectos: a hierarquia é uma estrutura de liderança dividida em alfa (α), beta (β), delta (δ) e ômega (ω); a estratégia de caça acontece cercando e perseguindo a presa refinando suas posições ao longo de tempo; a exploração e aproveitamento equilibra a busca global e local convergindo em soluções próximas do ótimo (JÚNIOR, 2025).

A posição de cada lobo representa uma solução candidata X_i , conforme a equação 14, a aptidão dessa solução é obtida pela função objetivo e definida pela hierarquia de liderança dos lobos (JÚNIOR, 2025).

$$X_i=[X_1, X_2, X_3, \dots, X_n] \quad (14)$$

A equação 15 representa cada indivíduo dentro do problema de despacho ótimo de energia por baterias. Onde cada indivíduo é um vetor composto pelas variações do estado de carga da bateria (ΔSoC) ao longo do dia (JÚNIOR, 2025).

$$\text{Indivíduo}=[\Delta\text{SoC}^1, \Delta\text{SoC}^2, \Delta\text{SoC}^3, \dots, \Delta\text{SoC}^{24}] \quad (15)$$

A tabela 2 apresenta alguns valores para o número de iterações e indivíduos (população) encontrados na literatura relacionados ao tema desta pesquisa.

Tabela 2 – Parâmetros para aplicação do GWO encontrados na literatura

Referência	Iterações	Indivíduos	Repetição
Mirjalili; Mirjalili; Lewis, (2014)	-	5 – 12	30
(Bendriss; Sayah; Hamouda, 2024)	Depende do problema	200	30
Da Silva <i>et al.</i> , (2025)	100	40 – 90	15

Fonte: Elaboração própria.

A busca de possíveis soluções é definida pelo comportamento de caça dos lobos. Admite-se que os lobos α , β e δ possuem maior conhecimento na localização das presas, dessa forma, as soluções encontradas são armazenadas. Enquanto que os lobos ω representam soluções menos favoráveis, os quais ajustam suas posições com base nas soluções armazenadas, exemplificado pela equação 16 (JÚNIOR, 2025).

$$X_{\omega}^{p+1} = \frac{X_{\alpha}^{p+1} + X_{\beta}^{p+1} + X_{\delta}^{p+1}}{3} \quad (16)$$

Onde p representa a iteração atual e $X_{\alpha}^{p+1} + X_{\beta}^{p+1} + X_{\delta}^{p+1}$ corresponde à colaboração dos lobos alfa, beta e delta para atualizar a posição de ômega. Essa estrutura garante que a busca seja guiada por soluções mais promissoras, acelerando a convergência do algoritmo para o ótimo global ou uma solução próxima do ótimo (JÚNIOR, 2025).

A colaboração de cada lobo é determinada pela equação 17, que garante que o ajuste seja baseado pelas melhores soluções conhecidas até o momento.

$$\begin{aligned} X_{\alpha}^{p+1} &= X_1^p - (2 \cdot z \cdot r_1 - z) \cdot |2 \cdot r_2 \cdot X_{\alpha} - X_1^p| \\ X_{\beta}^{p+1} &= X_1^p - (2 \cdot z \cdot r_1 - z) \cdot |2 \cdot r_2 \cdot X_{\beta} - X_1^p| \\ X_{\delta}^{p+1} &= X_1^p - (2 \cdot z \cdot r_1 - z) \cdot |2 \cdot r_2 \cdot X_{\delta} - X_1^p| \end{aligned} \quad (17)$$

Em que z é um parâmetro que reduz linearmente de 2 a 0 ao longo das iterações e r_1 e r_2 são números aleatórios entre 0 e 1. As atualizações são aplicadas a cada iteração até ser atingido o critério de parada, definido, neste trabalho, como o número máximo de iterações estabelecido (JÚNIOR, 2025).

4. METODOLOGIA APLICADA

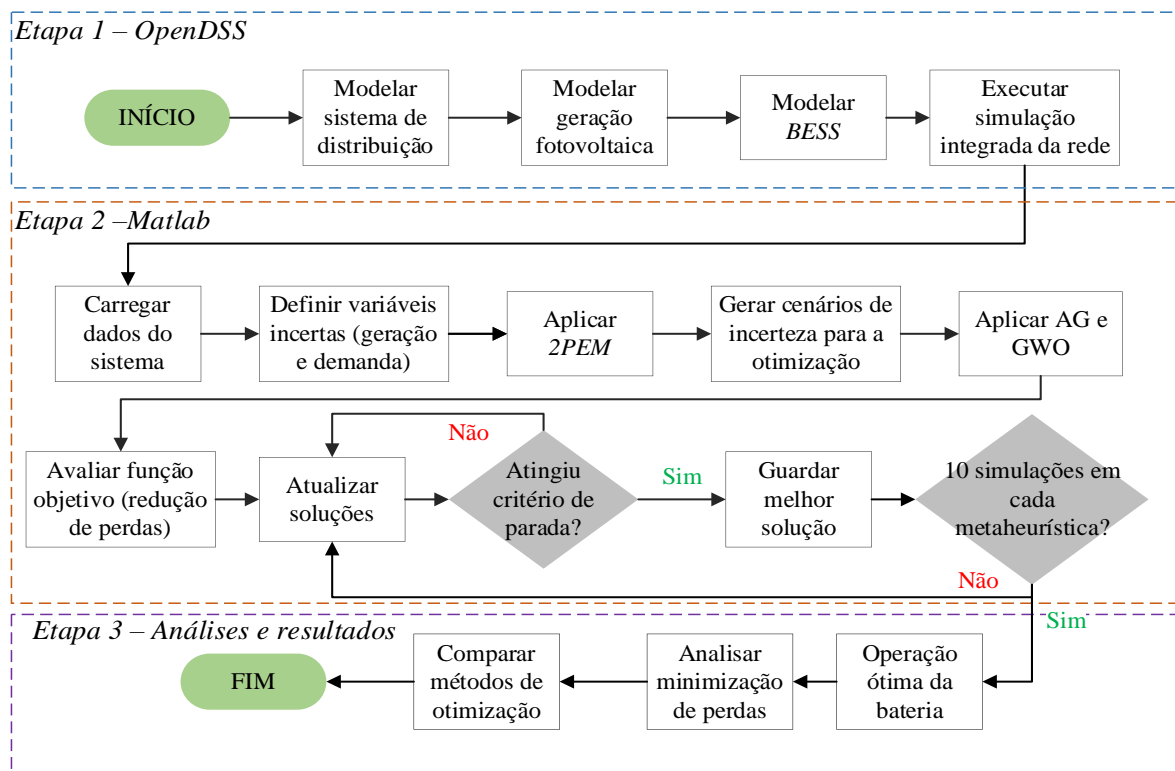
4.1. NATUREZA DA PESQUISA

Conforme classificado por Tripodi, *et al.* (1975, apud MARCONI; LAKATOS, 2003), a pesquisa possui natureza quantitativa - descritiva. As pesquisas quantitativo-descritivas buscam analisar e descrever características de fatos ou fenômenos por meio de dados numéricos, utilizando métodos formais e modelos matemáticos, possuindo coleta sistemática de informações e a análise objetiva de variáveis relevantes.

4.2. MÉTODO PROPOSTO

A metodologia utilizada baseia-se em Júnior (2025), que propôs a modelagem dos sistemas PV e BESS, e a aplicação da técnica de otimização GWO. No entanto, o presente trabalho replica as etapas desenvolvidas por Júnior (2025) no sistema IEEE 13 barras e a amplia ao aplicar no sistema IEEE 34 barras, incluindo a técnica de AG. Permitindo a análise da otimização em cada sistema e a comparação entre os métodos de otimização quanto à sua eficiência na redução de perdas ativas e tempo de convergência. O fluxograma, figura 11, exemplifica as etapas da análise desenvolvida.

Figura 11 – Fluxograma da metodologia proposta



Fonte: Elaboração própria

4.2.1. Etapa 1 – *OpenDSS*

Os sistemas de distribuição IEEE 13 e 34 barras foram modelados separadamente no *software OpenDSS*. Em cada um deles foram integrados o sistema de geração fotovoltaica e o sistema de armazenamento de energia por baterias, cujas características e parâmetros dos mesmos foram definidas com base em Júnior (2025) e descritas na seguinte seção.

Após a conexão dos sistemas, é realizada a simulação integrada da rede, permitindo avaliar o comportamento conjunto do sistema de distribuição integrado com o sistema fotovoltaico e com o sistema de armazenamento. Com isso, a execução das simulações é realizada por meio do *Matlab* que estabelece interface diretamente com o *OpenDSS*, extraindo os dados necessários para a implementação das outras etapas. Esse processo é realizado para cada sistema de distribuição separadamente.

4.2.2. Etapa 2 – *Matlab*

No *Matlab* inicialmente são modelados os cenários de incerteza, considerando a variabilidade da irradiação solar e da demanda na barra que conecta os sistemas distribuídos e a rede de distribuição. Essas incertezas foram tratadas por meio do método probabilístico 2PEM.

Na sequência, cada metaheurística (AG e GWO), é aplicada no *Matlab*, para determinar a operação ótima de baterias ao longo do dia, com foco na redução de perdas, considerando os cenários de incerteza. Os parâmetros de cada modelo de otimização estão detalhados na seguinte seção e são utilizados nos dois sistemas, 13 e 34 barras.

Por se tratarem de técnicas estocásticas, as quais utilizam elementos aleatórios no processo de decisão, foram realizadas 10 simulações para cada metaheurística, permitindo obter a operação máxima, média e mínima da bateria.

4.2.3. Etapa 3 – Análises e resultados

Após a conclusão das 10 simulações de cada metaheurística em cada sistema de distribuição, foram obtidos os resultados de despacho ótimo da bateria ao longo do dia por meio da minimização de perdas, as quais foram comparadas com as perdas base de cada rede, considerado sem a presença de geração fotovoltaica e bateria. Em seguida, analisou-se o desempenho de cada técnica de otimização, o tempo de convergência e a redução das perdas, em cada sistema de distribuição.

4.3. PARÂMETROS EMPREGADOS

4.3.1. Sistema Fotovoltaico (PV)

Para a implementação do sistema PV no software *OpenDSS*, por meio do *PVSystem*, é necessário definir características técnicas do sistema, as quais foram baseadas em Júnior, (2025) e estão apresentados a seguir. A tabela 3 apresenta os parâmetros do sistema fotovoltaico.

Tabela 3 – Parâmetros do sistema fotovoltaico

P_{pmp} (kW)	$S_{inversor}$ (kVA)	FP	E_b (pu)
1500	2000	1	0,98

Fonte: Adaptado de JÚNIOR, 2025

A tabela 4 expõe o perfil diário de irradiância solar normalizada e a temperatura do painel fotovoltaico, utilizada para definir a curva do fator de correção da potência. O ponto máximo de irradiância e temperatura ocorre às 12 h.

Tabela 4 – Irradiância e temperatura do painel

Horas	Irradiância (p.u.)	Temperatura (°C)	Horas	Irradiância (p.u.)	Temperatura (°C)
00:00-05:00	0	25	13:00	1	55
06:00	0,1	25	14:00	0,98	40
07:00	0,2	35	15:00	0,9	35
08:00	0,3	40	16:00	0,7	30
09:00	0,5	45	17:00	0,4	25
10:00	0,8	50	18:00	0,1	25
11:00	0,9	60	18:00	0,1	25
12:00	1	60	19:00-23:00	0	25

Fonte: Adaptado de JÚNIOR, 2025

A tabela 5 apresenta as curvas de variações da temperatura ao longo do tempo e a eficiência do inversor. A variação da temperatura é ajustada por um fator de multiplicação para definir a potência do painel, dessa forma, na temperatura nominal tem-se a potência nominal do painel. Em relação a eficiência do inversor, esta varia com a potência de entrada, calculada pela equação 1. As curvas são definidas no *software OpenDSS* como um objeto da classe *XYCurve*, que consiste em dois eixos com quantidade de pontos definidas pelo usuário, onde os pontos que não são definidos são estimados por meio de interpolação linear (JÚNIOR, 2025).

Tabela 5 – Curvas do sistema fotovoltaico

Curva da variação da Potência em função da temperatura		Curva da eficiência do inversor em função da potência de entrada	
Temperatura (°C)	Fator de multiplicação (adimensional)	Potência de entrada (pu)	Eficiência do inversor (%)
0	1,2	0,1	86
25	1,0	0,2	90
75	0,8	0,4	93
100	0,6	1,0	97

Fonte: Adaptado de JÚNIOR, 2025

4.3.2. Sistema de armazenamento de energia por bateria (BESS)

O sistema de armazenamento é modelado no *OpenDSS* por meio do elemento *Storage*, e baseado em Júnior, (2025). Para isso, é necessária a definição dos principais parâmetros do BESS, os quais estão apresentados na tabela 6.

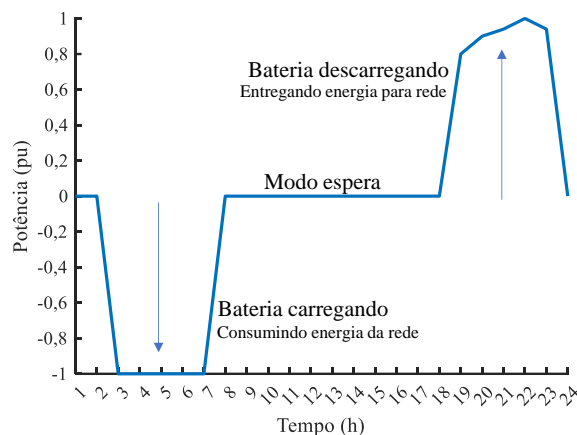
Tabela 6 – Parâmetros do sistema BESS

Capacidade (kWh)	Descarga Máx. (kW)	SoC ⁰ (kWh)	Potência nominal (kVA)	%Charge	%Discharge
2000	200	1000	250	20	80

Fonte: Adaptado de JÚNIOR, 2025

Para o sistema de armazenamento, foi adotado o modo de despacho *Follow* (figura 12), onde o carregamento e o descarregamento da bateria acompanham a curva de carga do sistema.

Figura 12 – Curva de operação diário do BESS



Fonte: Elaboração própria

Pode-se observar que entre 2 h e 8 h, o sistema apresenta potência negativa, indicando que o BESS está carregando, ou seja, se comporta como uma carga armazenando energia da rede. Das 8 h às 18 h, a potência se mantém em zero, caracterizando um estado de espera pois

parte da demanda está sendo suprida pela geração fotovoltaica. Já entre 18 h e 22 h, a potência é positiva, representando o modo de descarga, no qual o BESS fornece energia à rede, funcionando como um gerador.

4.3.3. Análise de incertezas – 2PEM

Assim como analisado em Júnior, (2025) devido a intermitência das fontes renováveis não é possível prever a geração de energia, dessa forma, é preciso considerar as incertezas de geração de energia para que possíveis estratégias de gerenciamento sejam tomadas para garantir a confiabilidade e eficiência do sistema de distribuição. Para isso, considerou-se uma variável incerta para cada barramento do sistema que não possui geração distribuída e duas variáveis incertas para os barramentos que possuem geração distribuída, referentes à potência ativa da fonte renovável e à potência aparente da barra (S_{barra_k}).

Ademais, foi considerada uma simplificação de que todas as cargas de um mesmo barramento possuem comportamento semelhante, de forma que a redução de potência ativa (P_k) implica na redução proporcional de potência reativa (Q_k), mantendo o fator de potência unitário e constante (equação 18), apesar da variação dos valores médios P_k^m e Q_k^m , denotados por P_k^* e Q_k^* (equação 19). Assim, as variáveis incertas são reduzidas, considerando apenas a potência ativa como variável incerta no barramento, enquanto que a potência reativa é obtida a partir do fator de potência original, conforme a equação 20 (JÚNIOR, 2025).

$$\tan(\alpha) = \frac{Q_k}{P_k} \quad (18)$$

$$\tan(\alpha) = \frac{Q_k^m}{P_k^m} = \frac{Q_k^*}{P_k^*} \quad (19)$$

$$Q_k^* = Q_k^m \cdot \frac{P_k^*}{P_k^m} \quad (20)$$

Com isso cada barramento de carga possui uma variável incerta S_{barra_k} , obtido pela incerteza na variável P_k e cálculo da variável correspondente Q_k (JÚNIOR, 2025).

Para a implementação do método 2PEM, conforme proposto em Júnior, (2025) foi considerado um desvio padrão de 10% em torno do valor médio, nas variáveis incertas.

4.3.4. Modelo de otimização

O problema de otimização foi elaborado conforme feito em Júnior, (2025), tendo como

foco a maximização da eficiência operacional da bateria ao longo de um dia, gerenciando o carregamento e descarregamento da bateria de modo a atender as condições da rede, incertezas de geração renovável e carga e restrições operacionais do sistema, minimizando as perdas ativas na rede elétrica, conforme apresentado na equação 21.

$$\min \sum_{t=1}^{24} \text{Perdas}(t) \quad (21)$$

As restrições do sistema são estabelecidas pelas equações 22 a 25. Na equação 22 está apresentado como a potência injetada ou absorvida pela bateria ($P_{k_{\text{bateria}}}^t$) influencia no balanço de potência ativa do barramento no sistema em determinado instante t .

$$P_k^t + P_{k_{\text{bateria}}}^t + P_{k_{\text{PV}}}^t - P_{k_{\text{demanda}}}^t = 0 \quad (k \in \Omega_B) \quad (22)$$

Onde, P_k^t representa a injeção de potência ativa calculada a partir das tensões nodais e da matriz de admitância de barras, $P_{k_{\text{PV}}}^t$ é a potência gerada pela fonte fotovoltaica não despachável e $P_{k_{\text{demanda}}}^t$ indica a potência ativa demandada na barra.

A potência instantânea da bateria a cada hora é definida pela equação 23, quando a potência da bateria é injetada na rede, inicia-se um processo de descarga ($P_{k_{\text{bateria}}}^t > 0$), já o processo de carga acontece quando a potência da bateria é absorvida ($P_{k_{\text{bateria}}}^t \leq 0$). Quando $P_{k_{\text{bateria}}}^t = 0$ a operação é ociosa, mas ainda consome potência associada às perdas em vazio (P_{idl}).

$$P_{k_{\text{bateria}}}^t = \begin{cases} \Delta\text{SoC}^t \cdot kW_{\text{rated}}, & \text{se } \Delta\text{SoC}^t \neq 0 \\ -P_{\text{idl}}, & \text{se } \Delta\text{SoC}^t = 0 \end{cases} \quad (23)$$

Em que kW_{rated} representa a potência nominal da bateria, estabelecendo os limites máximos de carga e descarga, evitando sobrecargas ou descargas excessivas que possam comprometer a vida útil da bateria. ΔSoC indica os estados operacionais da bateria, conforme a inequação 24, onde valores positivos referem-se ao processo de carga, valores negativos correspondem ao processo de descarga e o valor zero representa ociosidade da bateria, ou seja, quando não está sendo utilizada.

$$-1 \leq \Delta\text{SoC} \leq 1 \quad (24)$$

O balanço energético da bateria no processo de otimização, é definido pelo estado de carga da bateria somado com as variações horárias de carga e descarga, garantindo que

permaneça sempre dentro dos limites físicos, fornecendo uma operação viável e realista da bateria ao longo do dia, conforme a inequação 25.

$$0 \leq \Delta\text{SoC}^0 + \sum_{t=1}^{24} (\Delta\text{SoC}^t \cdot kW_{\text{rated}}) \leq kWh_{\text{rated}} \quad (25)$$

4.3.5. Algoritmo genético (AG)

A tabela 7 apresenta os parâmetros utilizados na aplicação do AG utilizados neste trabalho para os dois sistemas de distribuição (IEEE 13 e 34 barras), a fim de obter-se o despacho ótimo da bateria ao longo do dia.

Tabela 7 – Parâmetros utilizados na aplicação do algoritmo genético

Parâmetros do GA	Valores	Referência
Número de gerações	100	(Blaifi <i>et al.</i> , 2016)
Tamanho da população	30	(Grefenstette, 1986)
Taxa de cruzamento	70%	(Blaifi <i>et al.</i> , 2016)
Taxa de mutação	20%	(Blaifi <i>et al.</i> , 2016)

Fonte: Elaboração própria

Neste trabalho, assim como em Rangel *et al.*, (2018), o critério de parada é definido por um número máximo de gerações, dessa forma, quando as 100 gerações são calculadas, o critério é atingido e o algoritmo encerra sua execução, exibindo a população final com o melhor resultado.

4.3.6. Grey Wolf Optimizer (GWO)

Os parâmetros utilizados para a implementação da técnica de otimização GWO, foi de 24 indivíduos e 100 iterações, conforme utilizado em Júnior, (2025). Assim como no AG o critério de parada é atingido ao completar o número total de iterações exibindo a melhor resposta.

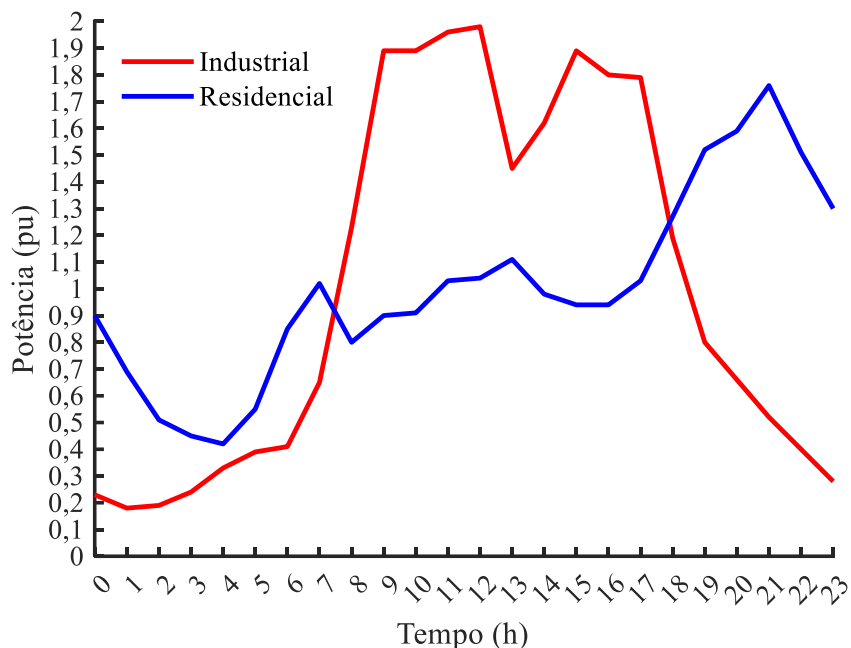
4.4. PERFIL DE CARGA

Segundo Kagan; Oliveira; Robba, (2005), as cargas são classificadas em (i) residenciais, (ii) comerciais (iluminação, condicionamento de ar, edifício de escritório, entre outros), (iii) industriais (geralmente trifásicas com predomínio de motores de indução), (iv) rurais (irrigação

e agroindústrias), (v) municipais e governamentais (serviços e poderes públicos) e (vi) carga de iluminação pública. Esses critérios de classificação permitem identificar hábitos de consumo, como variação de tensão produzida e demanda.

Neste trabalho foram consideradas as curvas de carga industrial e residencial, sem distinção para estação do ano ou dias da semana. Nos sistemas de distribuição utilizados, somente as barras que possuem geração distribuída tem carga industrial, as outras barras possuem características de carga residencial. A figura 13 apresenta o comportamento diário dos perfis de carga conforme proposto em Freitas, (2015).

Figura 13 – Curvas de carga residencial e industrial consideradas



Fonte: Adaptado de FREITAS, (2015).

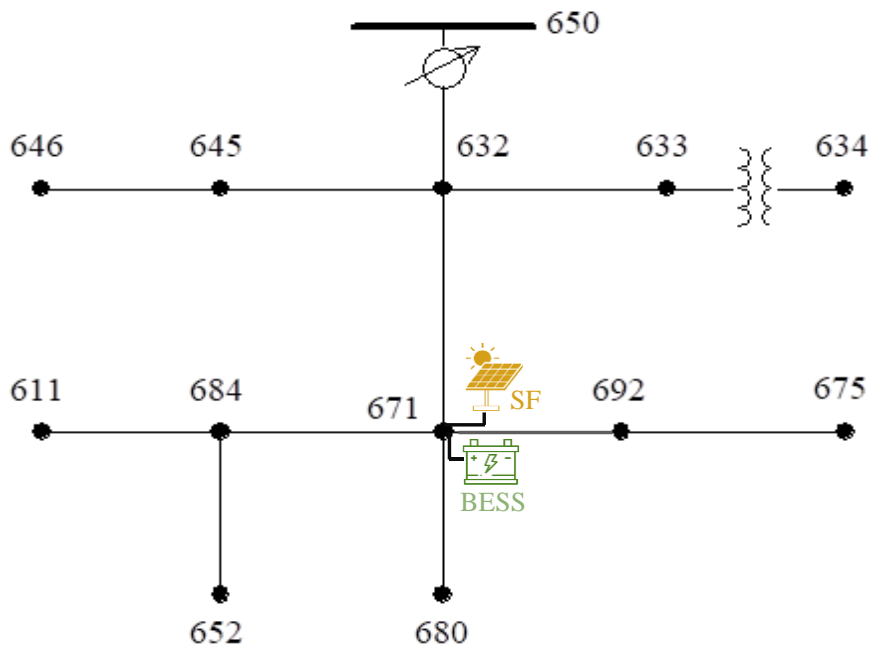
A barra que possui carga industrial no sistema IEEE 13 barras foi definida conforme Júnior (2025), correspondendo à barra 671, na qual estão conectados o sistema fotovoltaico e o sistema de armazenamento. No sistema IEEE 34 barras, seguindo a abordagem de Saldanha *et al.*, (2024), o sistema PV e o BESS foram conectados na barra 890, estrategicamente posicionada em nós situados distantes da subestação, maiores detalhes serão apresentados no capítulo de resultados. Geralmente, nós caracterizados por correntes de carga mais altas se destacam como locais ideais para a instalação de GD, mitigando efetivamente as perdas de energia.

5. RESULTADOS

5.1. SISTEMAS ANALISADOS

A pesquisa considerou dois sistemas de distribuição IEEE 13 barras e IEEE 34 barras. O sistema IEEE 13 barras, apresentado na figura 14, é amplamente adotado para o estudo de redes de distribuição, desenvolvido pelo *IEEE Distribution Test Feeder Working Group*, utilizado para avaliar metodologias de análise de redes elétricas, fluxos de potência, otimização e impactos da geração distribuída. Devido ao seu número reduzido de barras, esse sistema permite análises mais detalhadas (JÚNIOR, 2025). Este sistema está disponível no arquivo de instalação do *OpenDSS*.

Figura 14 – Diagrama unifilar do sistema de distribuição IEEE 13 barras




Fonte: Adaptado de IEEE, 2004.

O sistema 13 barras possui linhas trifásicas aéreas e subterrâneas desbalanceadas, ramais monofásicos, bifásicos e trifásicos, dois transformadores trifásicos de distribuição, cargas localizadas e uma distribuída, dois bancos de capacitores shunt e um regulador conectado em estrela (FREITAS, 2015).

O sistema de 34 barras (figura 15), atua como um alimentador real localizado no estado Arizona- Estados Unidos, com uma tensão nominal de 24,94 kV. É caracterizado por ter cargas desbalanceadas, possuir dois reguladores de tensão, um transformador abaixador e capacitores em paralelo (IEEE, 2017). Esse sistema complementa a análise, possibilitando o estudo de cenários mais realistas.

Figura 15 – Diagrama unifilar do sistema de distribuição IEEE 34 barras



Fonte: Adaptado de Institute of Electrical and Electronic Engineers (IEEE), 2017

As simulações foram realizadas em um computador com processador Intel® Core™ i5 1035G1 CPU @ 1.00 GHz, utilizando os *softwares* *OpenDSS*, versão 10.2.0.1, 64-bit, e o *Matlab*, versão 9.12.0.1884302 (R2022a), empregados para a execução e análise dos sistemas e técnicas de otimização.

5.2. SISTEMA IEEE 13 BARRAS

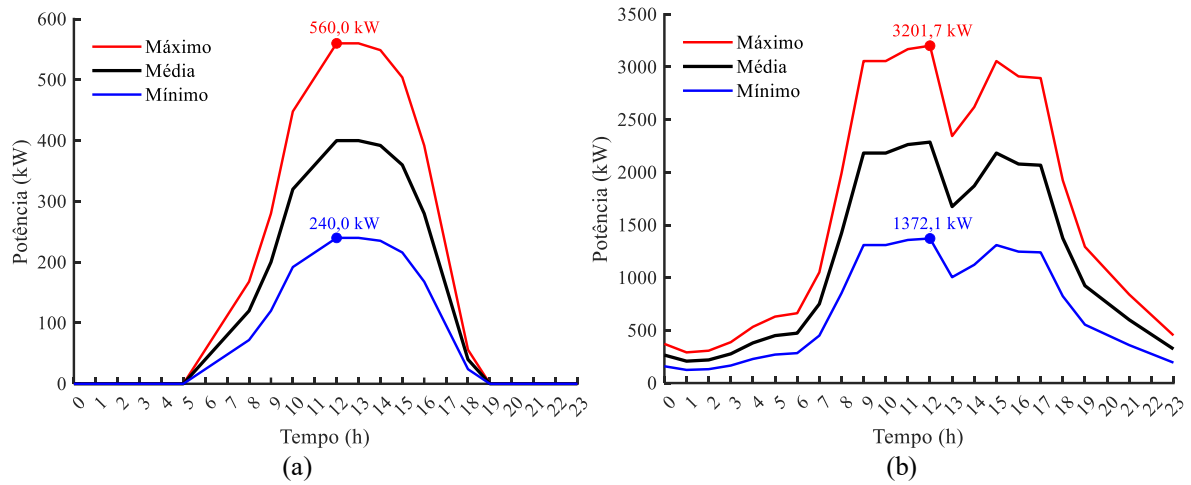
5.2.1. 2PEM

Para o sistema IEEE 13 barras, o número de cenários de incertezas obtidos pelo método 2PEM depende da quantidade barras consideradas, neste caso foram contabilizadas 16 barras do sistema (13 barras originais do sistema, à barra da fonte (*sourcebus*) e à conexão do BESS) e a barra associada ao sistema fotovoltaico, totalizando 16 barras e conseqüentemente 32 cenários de incerteza conforme a equação 3.

Dessa forma, a figura 16 (a) representa todas as combinações possíveis das variações máximas e mínimas em relação a geração média fotovoltaica. A figura 16 (b) ilustra a variação do comportamento da demanda no barramento 671, que possui a conexão do sistema de armazenamento de energia e do sistema fotovoltaico.

Vale ressaltar que a demanda apresentada na figura 16 (b), representa a demanda total do alimentador, onde a linha média representa a demanda esperada, enquanto as linhas superior e inferior representam o intervalo de incerteza gerado pelo método 2PEM.

Figura 16 – Cenários de incertezas para geração fotovoltaica e demanda

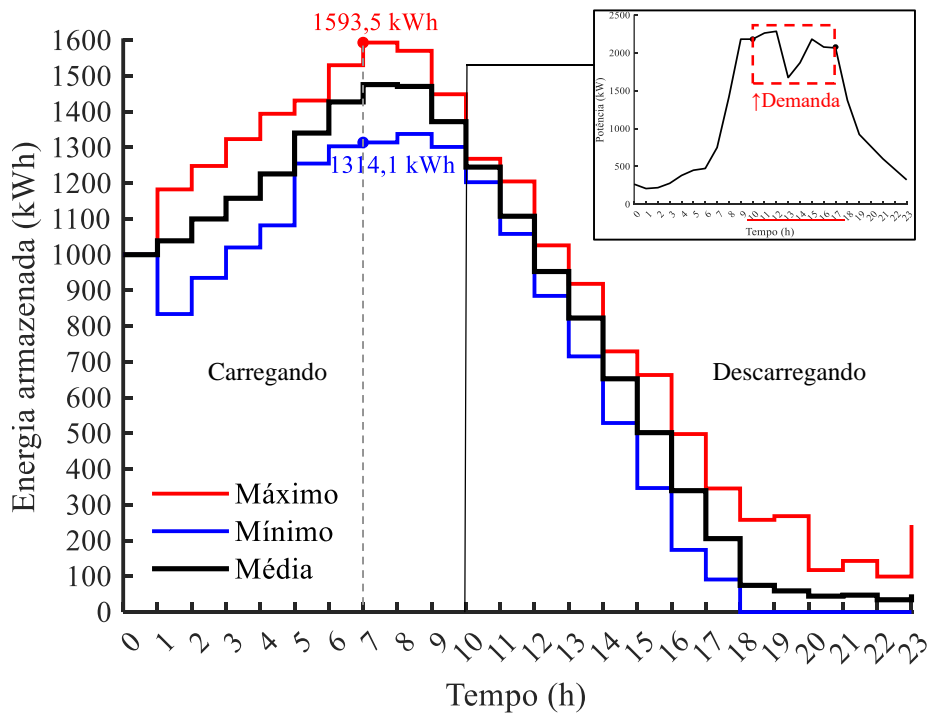


Fonte: Elaboração própria

5.2.2. Algoritmo Genético

Aplicando-se o modelo de otimização AG e considerando as variações de geração e demanda, foi possível encontrar a operação de despacho ótimo da bateria ao longo do dia. A figura 17 apresenta a operação otimizada da bateria ao longo do dia. Para a construção do gráfico foram realizadas 10 simulações, a fim de obter os cenários máximo, médio e mínimo.

Figura 17 – Despacho ótimo da bateria para redução de perdas por AG



Nesta abordagem, a operação da bateria acompanha a curva de carga previamente

definida para o barramento na qual está conectada, iniciando o processo de descarga apenas após as 10 h, horário em que a demanda aumenta, obtendo, somente no cenário mínimo, a descarga completa às 18 h, enquanto que os cenários médio e máximo não descarregam completamente.

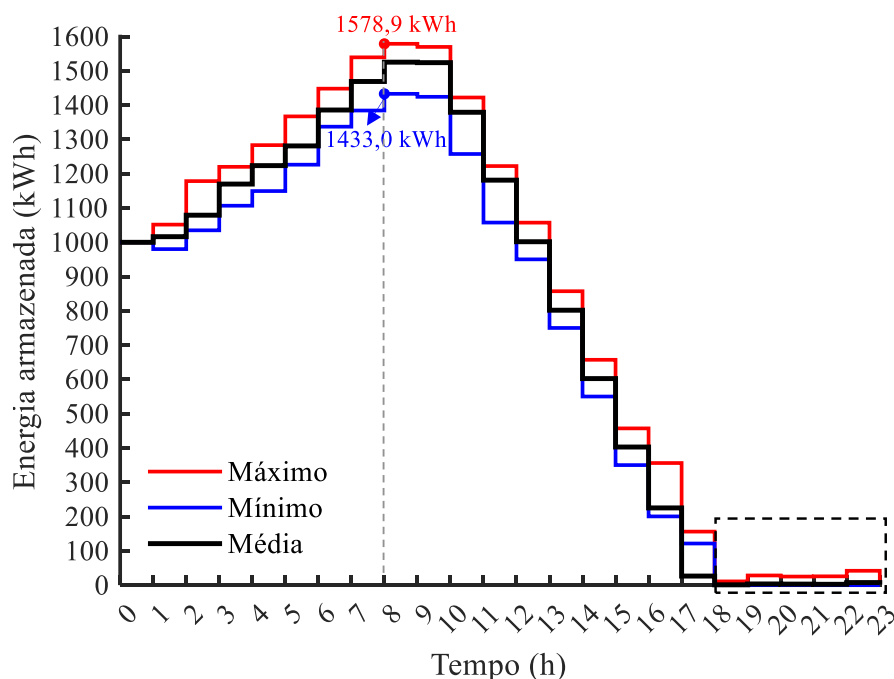
Esse resultado é corroborado pela curva de carga apresentada na figura 17, na qual observa-se que a demanda inicia seu aumento por volta das 7 h, atingindo seu pico próximo ao meio dia, e começa a reduzir a partir das 17 h. A bateria permanece em processo de carregamento até as 10 h, sem fornecer energia à rede, uma vez que nesse período têm-se geração fotovoltaica suficiente para suprir a demanda.

Os pontos destacados no gráfico indicam o carregamento máximo da bateria nos cenários máximo e mínimo que ocorre às 7 h. O tempo total de otimização das 10 simulações foi de aproximadamente 4 h e 22 min, resultando em um tempo médio de 26,21 min por simulação. Nesta simulação foi exigido a resolução de 96.000 fluxos de potência por simulação.

5.2.3. Grey Wolf Optimization

A figura 18 apresenta a operação otimizada da bateria utilizando o GWO como técnica de otimização. Para a elaboração do gráfico foram realizadas 10 simulações, a fim de determinar os cenários máximo, médio e mínimo, assim como realizado para o AG.

Figura 18 – Despacho ótimo da bateria para redução de perdas por GWO



Fonte: Elaboração própria

Como observado em Júnior (2025), a operação inicia com metade da sua capacidade e carrega até as 10 h, período onde a demanda é reduzida. A partir das 10 h a bateria inicia um processo de descarga até as 17 h, ocasionado pelo aumento da demanda. Após as 17 h a bateria encontra-se totalmente descarregada, coincidindo com a redução da carga. Vale ressaltar que a bateria descarrega completamente uma hora antes em relação à operação otimizada pelo AG.

Conforme indicado no gráfico, o ponto de máxima potência em ambos os cenários, ocorre às 8 h, uma hora depois da operação otimizada pelo AG. O tempo total de otimização foi de aproximadamente 2 h e 10 min, sendo que, desse total, cada uma das 10 simulações apresentou um tempo médio de cerca de 13 minutos. Nesta simulação é exigida a resolução de 76.800 fluxos de potência por simulação.

A tabela 8, apresenta a comparação entre as duas metaheurísticas em relação ao tempo de convergência total e em cada simulação

Tabela 8 – Comparação do tempo de simulação entre as metaheurísticas AG e GWO

Metaheurística	t de otimização total (h)	t médio por simulação (min)
AG	4,22	26,21
GWO	2,10	13,00

Fonte: Elaboração própria

5.2.4. Minimização das perdas

A figura 19 apresenta as perdas minimizadas por hora comparadas ao cenário base do circuito IEEE 13 barras, que mostra a redução das perdas no sistema de distribuição.

Figura 19 – Comparação da redução das perdas elétricas



Fonte: Elaboração própria

A área destacada no gráfico indica que nas primeiras horas do dia até as 9 h, a otimização apresenta perdas iguais ou maiores que as obtidas no cenário base, isso porque a bateria se comporta como carga neste período, ou seja, consome potência ativa do sistema, aumentando o fluxo de corrente e conseqüentemente aumentando as perdas técnicas do sistema. As barras mais translúcidas evidenciam a redução de perdas, oriunda do suporte da bateria, principalmente no período de 10 h às 22 h. Às 12 h, período de maior demanda, a otimização reduz em aproximadamente 27% as perdas técnicas.

Vale ressaltar que a minimização das perdas obtida tanto pela técnica de otimização GWO quanto pelo AG apresentou os mesmos resultados, o que sugere uma possível convergência para o ótimo global. A obtenção de reduções de perdas semelhantes ao aplicar diferentes técnicas de otimização, está em conformidade com a literatura, que mostra que diversos métodos heurísticos e determinísticos tendem a alcançar resultados muito próximos ou iguais em termos de perdas, diferindo principalmente no tempo de convergência e no esforço computacional, assim como observado em Grisales-Noreña *et al.*, (2024) e Da Silva *et al.*, (2025) que reforçam a tendência de convergência a resultados similares.

Conforme observado, as abordagens diferem no tempo de otimização. A técnica GWO apresentou um tempo médio de 13 minutos por simulação, apresentando menor esforço computacional, com um tempo de convergência cerca de 50% menor que o AG, resultando em convergência mais rápida e menor tempo de processamento. Possuindo vantagem principalmente em aplicações que exijam execução repetitiva ou em tempo quase real.

Na técnica de otimização AG (figura 18, destacado pela linha tracejada cinza) a bateria atinge sua carga máxima às 7 h, uma hora antes do que ocorre com o GWO (figura 19, destacado pela linha tracejada cinza), e zera sua carga, apenas no cenário mínimo, uma hora depois do GWO, indicando uma utilização mais eficiente da bateria.

Assim como analisado em Rangel *et al.*, (2018) e Pompern *et al.*, (2023), do ponto de vista econômico o despacho mais eficiente, como obtido utilizando a técnica de AG, favorece a utilização da bateria, reduzindo os custos de operação ao completar sua carga mais cedo e descarregar mais tarde, tendo um maior aproveitamento de energia.

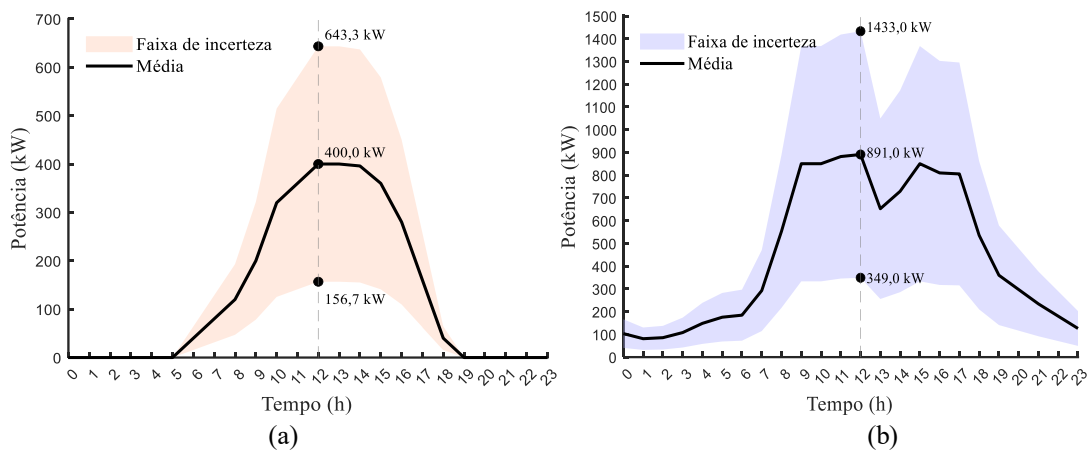
O atraso na descarga da bateria reduz a profundidade dos ciclos de vida da bateria, prolongando a vida útil do BESS, conforme observado em Abou El-Ela *et al.*, (2022). Além disso, na operação do sistema, a descarga mais tardia auxilia na redução dos picos de carga e das perdas na rede, promovendo uma operação mais estável e eficiente (Da Silva; Belati; López-Lezama, 2023).

5.3. SISTEMA IEEE 34 BARRAS

5.3.1. 2PEM

O sistema IEEE 34 barras, resultou na obtenção de 74 cenários de incerteza, conforme equação 3. Na figura 20 (a), está representado as incertezas relacionadas a geração fotovoltaica ao longo do dia e na (b) está apresentado as incertezas ao longo do dia relacionados a demanda, especificadamente na barra 890 em que está conectado ao sistema fotovoltaico.

Figura 20 – Cenários de incertezas para geração fotovoltaica e demanda

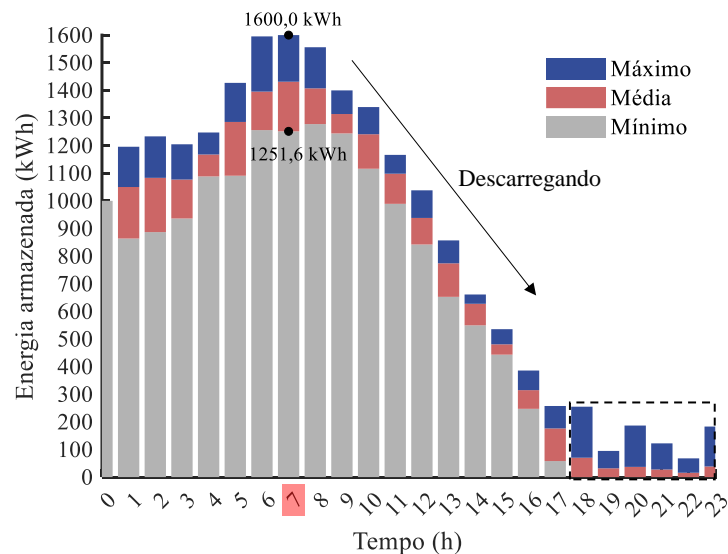


Fonte: Elaboração própria

5.3.2. Algoritmo Genético

Assim como realizado no sistema IEEE 13 barras as metaheurísticas foram aplicadas para obter o despacho ótimo da bateria (figura 21) que minimiza as perdas técnicas.

Figura 21 – Despacho ótimo da bateria para redução de perdas por AG



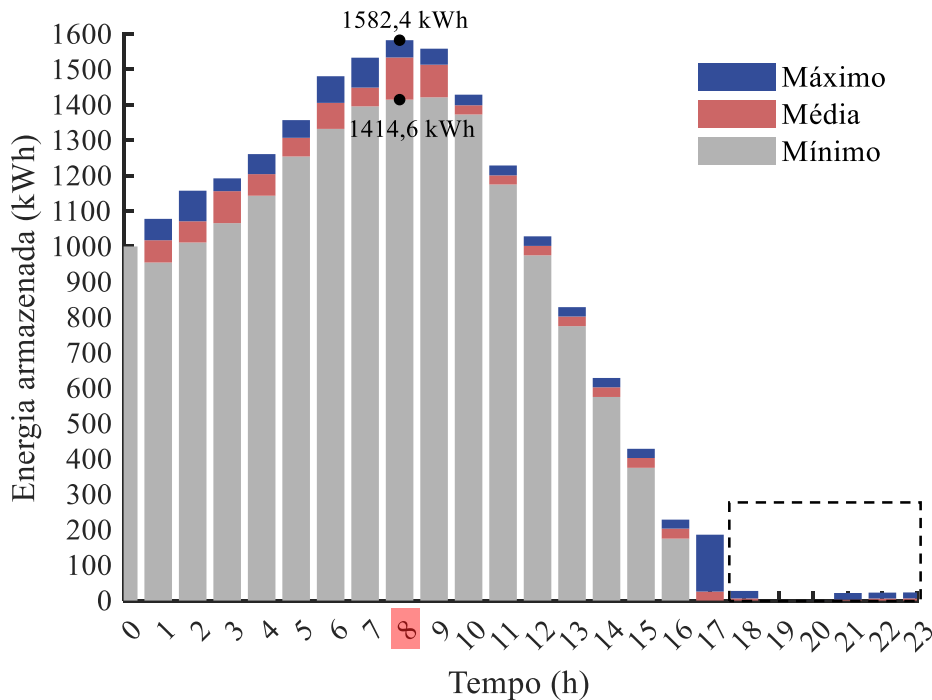
Fonte: Elaboração própria

Neste cenário a bateria atinge a carga máxima nominal às 7 h, sendo obtida a potência máxima de operação no cenário máximo. A operação otimizada também segue a curva de carga, iniciando o descarregamento progressivo de energia às 10 h, ocasionado pelo aumento da demanda. Nesta operação a bateria atinge descarga completa, no cenário mínimo, às 18 h. Para esta simulação é exigida a resolução de 222.000 fluxos de potência por simulação.

5.3.3. Grey Wolf Optimization

A figura 22 apresenta a curva de operação otimizada da bateria por meio da técnica de otimização por GWO.

Figura 22 – Despacho ótimo da bateria para redução de perdas por GWO

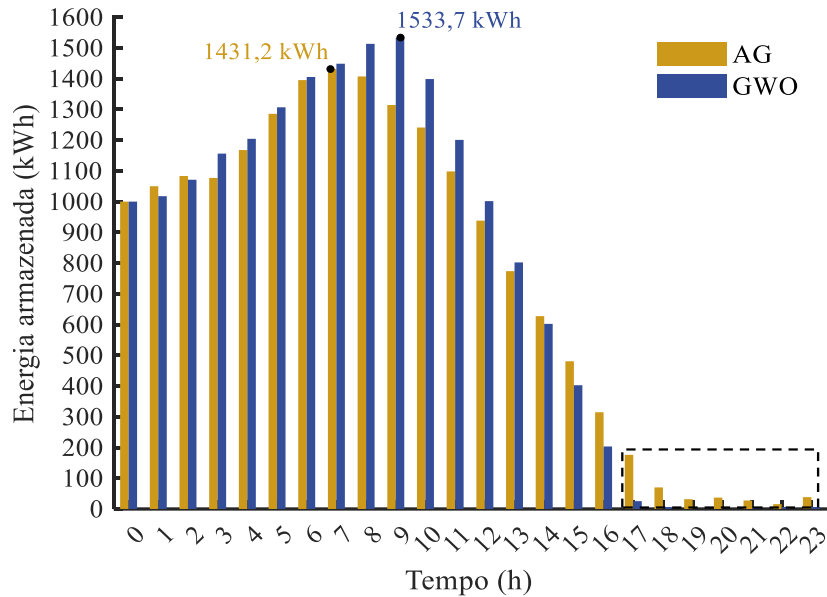


Fonte: Elaboração própria

Neste cenário a bateria não atinge a carga máxima, mas chega bem próximo, apresentando seu valor máximo às 8 h, uma hora depois da operação obtida na otimização por AG. A bateria descarrega completamente em todos os cenários às 17 h, período em que a demanda começa a reduzir. Nesta simulação é exigida a resolução de 177.600 fluxos de potência por simulação.

A figura 23 ilustra a comparação entre os cenários médios obtidos por ambas as metaheurísticas.

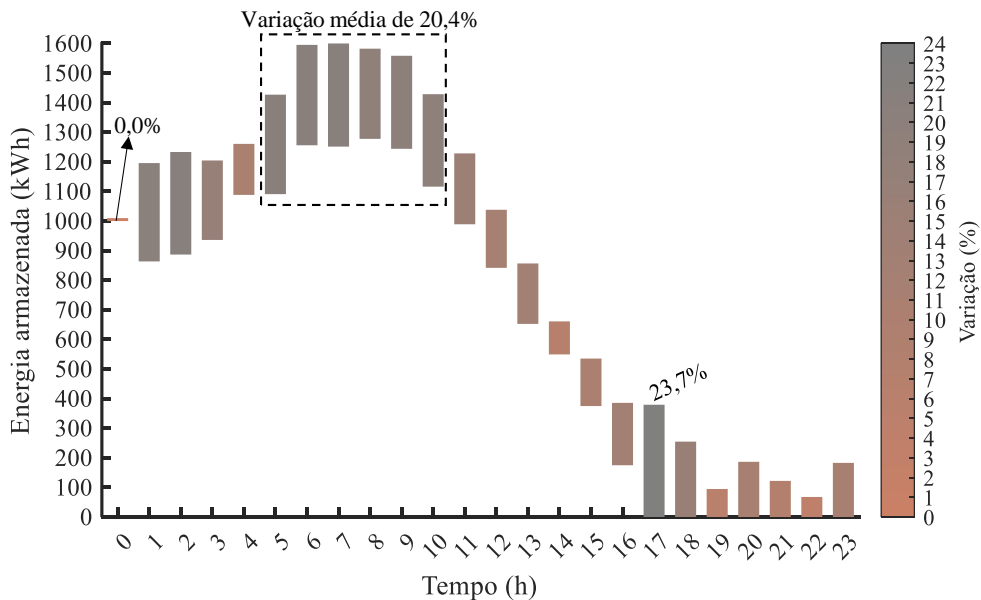
Figura 23 – Despacho ótimo médio da bateria para redução de perdas por AG e GWO



Fonte: Elaboração própria

A figura 24 apresenta a variação horária obtida a partir de todas as simulações, independentemente da metaheurística utilizada, evidenciando a faixa de potência em que a bateria pode operar em cada hora, juntamente com a respectiva variação percentual.

Figura 24 -Variação de potência da bateria considerando todas as simulações



Fonte: Elaboração própria

Pode-se observar que a maior variação acontece às 17 h, período em que a diferença entre os resultados obtidos pelas técnicas AG e GWO é maior. No período de 5 h a 10 h, a variação é semelhante, permanecendo entre 21% a 19%. Vale ressaltar que, às 0 h não há variação, uma vez que, o estado inicial de carga da bateria é de 1000 kWh (indicado na tabela 6),

sendo o ponto de partida de todas as simulações. A tabela 9 apresenta a comparação entre o tempo de simulação alcançado em cada metaheurística.

Tabela 9 – Comparação do tempo de simulação entre as metaheurísticas AG e GWO

Metaheurística	t de otimização total (h)	t médio por simulação (min)
AG	4,32	25,9
GWO	2,72	16,4

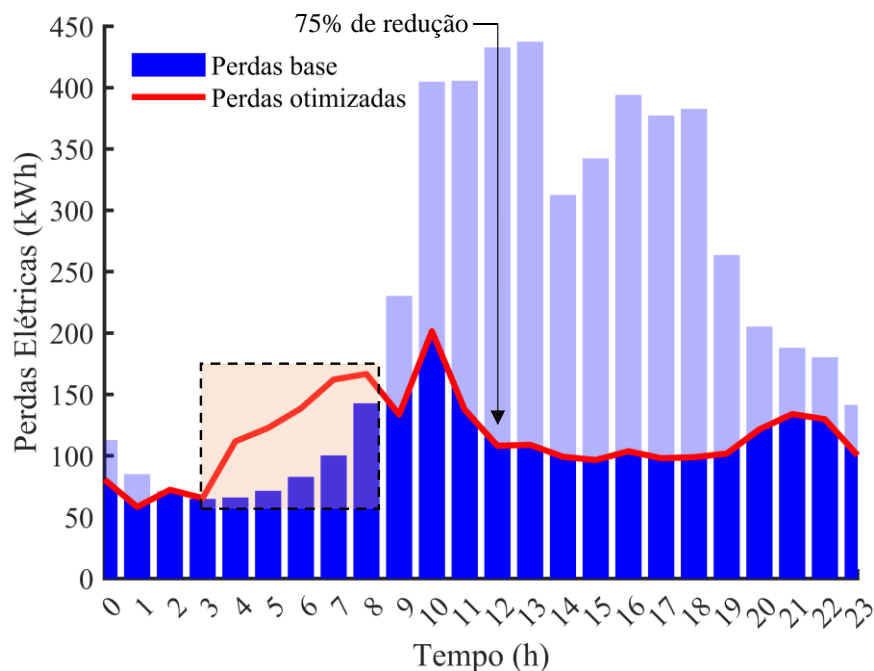
Fonte: Elaboração própria

Assim como observado para o sistema IEEE 13 barras, o sistema IEEE 34 barras apresentou comportamento semelhante em relação ao desempenho das metaheurísticas e ao despacho do BESS. A técnica GWO manteve o menor tempo de convergência, sendo 37% mais rápida em comparação ao AG, evidenciando menor esforço computacional, enquanto que o algoritmo genético continuou apresentando maior eficiência no gerenciamento do estado de carga da bateria, evitando ciclos completos de descarga e aumentando da vida útil do BESS, essa observação pode ser explorada em trabalhos futuros, por meio de uma análise mais aprofundada para compreender os fatores que contribuem para esse comportamento.

5.3.4. Minimização das perdas

A figura 25 apresenta comparação horária das perdas minimizadas em relação ao cenário base do circuito IEEE 34 barras.

Figura 25 – Comparação da redução das perdas elétricas



Fonte: Elaboração própria

Observa-se uma redução das perdas a partir das 9 h até o fim do dia, apresentando maior redução no período em que possui geração fotovoltaica, indicado nas barras translúcidas do gráfico. No entanto, nas primeiras horas do dia (área destacada no gráfico), a otimização resulta em perdas superiores às do cenário base, uma vez que, a bateria opera em modo de carregamento comportando-se como carga. Às 12 h, período de maior demanda a otimização reduz em aproximadamente 75% as perdas técnicas.

6. CONCLUSÕES

O presente Trabalho de Conclusão de Curso (TCC), permitiu verificar a influência da integração de sistemas fotovoltaicos e de armazenamento de energia por baterias na redução das perdas técnicas em redes de distribuição. A modelagem dos sistemas IEEE 13 e 34 barras no *software OpenDSS*, associada à geração de cenários de incerteza e à aplicação de técnicas metaheurísticas de otimização no *Matlab*, se mostrou eficiente para a avaliação do desempenho operacional dessas redes de distribuição.

Os resultados evidenciaram que o Algoritmo Genético apresentou melhor desempenho da operação da bateria ao longo do dia, prolongando o despacho de energia em uma hora a mais quando comparado ao *Grey Wolf Optimization*. Contudo, a técnica GWO apresenta um tempo de convergência menor. Além disso, verificou-se que as duas metaheurísticas atingiram resultados equivalentes de minimização de perdas, encontrando os mesmos valores para a redução das perdas técnicas diárias dos sistemas de distribuição analisados.

De modo geral, foi possível constatar que a integração coordenada de geração distribuída e armazenamento de energia contribui significativamente para o aumento da eficiência energética, proporcionando o melhor aproveitamento de recursos renováveis e conseqüentemente uma operação mais sustentável das redes de distribuição. Portanto, este trabalho apresenta a relevância do uso de técnicas de otimização na busca de soluções mais eficientes, promovendo o desenvolvimento e a consolidação das redes inteligentes (*smart grids*).

Vale ressaltar que a pesquisa apresenta algumas limitações quanto a posição da geração distribuída que foi mantida fixa em uma única barra de cada sistema analisado, não sendo avaliado o impacto da realocação desses sistemas. Além disso, o estudo foi considerado um período limitado a 24 h, e perfis específicos de carga e geração, não contemplando variações mais amplas de comportamento sazonal ou eventos extremos.

Para trabalhos futuros, sugere-se, a avaliação de diferentes perfis de carga com o objetivo de analisar a variação da demanda ao longo do tempo. Também recomenda-se investigar o impacto da alteração da localização dos sistemas distribuídos na minimização de perdas técnicas. Além disso, pode-se estudar a relação entre a redução das perdas e os custos de instalação e operação desses sistemas, bem como aplicar e comparar outras metaheurísticas de otimização. É relevante também considerar outros períodos de tempo como semanas, meses ou períodos sazonais, feriados e estações do ano, a fim de avaliar como essas variações influenciam a geração fotovoltaica e o comportamento da demanda de energia elétrica.

REFERÊNCIAS

ABOU EL-ELA, Adel A. *et al.* A multi-objective equilibrium optimization for optimal allocation of batteries in distribution systems with lifetime maximization. **Journal of Energy Storage**, v. 55, p. 1–20, 28 set. 2022.

AFSHAN, R.; SALEHI, J. Optimal Scheduling of Battery Energy Storage System in Distribution Network Considering Uncertainties Using Hybrid Monte Carlo-Genetic Approach. **Journal of Operation and Automation in Power Engineering**, v. 6, n. 1, p. 1–12, 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **TRANSIÇÃO ENERGÉTICA NO SETOR ELÉTRICO BRASILEIRO**. Brasília: Núcleo de Biblioteca e Arquivo – NBA, 2024a. v. 6

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Nota Técnica nº 266/2024**. , 5 dez. 2024b. . Acesso em: 6 out. 2025

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **NOTA TÉCNICA CONJUNTA Nº 13/2025**, 2025. Acesso em: 6 out. 2025

ALGUHI, Ahmed A.; ALOTAIBI, Majed A.; AL-AMMAR, Essam A. Probabilistic Planning for an Energy Storage System Considering the Uncertainties in Smart Distribution Networks. **Sustainability (Switzerland)**, v. 16, p. 1–23, 28 dez. 2024.

ALZHRANI, Ahmed; ALHARTHI, Hussain; KHALID, Muhammad. Minimization of power losses through optimal battery placement in a distributed network with high penetration of photovoltaics. **Energies**, v. 13, p. 1–16, 27 dez. 2019.

BAROUCHE, IURI DE OLIVEIRA. **ANÁLISE COMPARATIVA E PROPOSIÇÕES DE METODOLOGIAS DE CÁLCULO DE PERDAS TÉCNICAS**. Campinas - SP: Universidade Estadual de Campinas (UNICAMP), 2017.

BLAIFI, S. *et al.* An enhanced dynamic model of battery using genetic algorithm suitable for photovoltaic applications. **Applied Energy**, v. 169, p. 888–898, 1 maio 2016.

BRASIL. **LEI Nº 14.300**. https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2022/lei/114300.htm, 6 jan. 2022.

BRASIL. AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Resolução Normativa ANEEL n. 482/2012**. <https://www2.aneel.gov.br/cedoc/ren2012482.pdf>, , 17 abr. 2012.

BRASIL. AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **RESOLUÇÃO NORMATIVA ANEEL Nº 1.059**. <https://www2.aneel.gov.br/cedoc/ren20231059.html>, 7 fev. 2023.

BUENO, A. F. M.; BRANDÃO, C. A. L. **VISÃO GERAL DE TECNOLOGIA E MERCADO PARA OS SISTEMAS DE ARMAZENAMENTO DE ENERGIA ELÉTRICA NO BRASIL**. Belo Horizonte: Associação Brasileira de Armazenamento e Qualidade de Energia - ABAQUE, 2016.

CANTANE, Daniel Augusto; ANDO, Oswaldo Hideo Junior; HAMERSCHMIDT, Márcio Biehl. **Tecnologias de Armazenamento de Energia Aplicadas ao Setor Elétrico Brasileiro**. 1. ed. São Carlos - SP: Editora Scienza, 2020. v. 1

DA SILVA, Diego Jose *et al.* Optimal Allocation and Operation of Battery Energy Storage Systems With Photovoltaic Generation in Modern Distribution Networks: A New Hybrid Approach. **IET Renewable Power Generation**, v. 19, p. 1–20, 30 jul. 2025.

DA SILVA, Diego Jose; BELATI, Edmarcio Antonio; LÓPEZ-LEZAMA, Jesús M. A Mathematical Programming Approach for the Optimal Operation of Storage Systems, Photovoltaic and Wind Power Generation. **Energies**, v. 16, n. 3, p. 1–24, 1 fev. 2023.

DE JONG, Kenneth Alan. **Analysis of the behavior of a class of genetic adaptive systems**. Hampton: The University of Michigan, 1975.

ELECTRIC POWER RESEARCH INSTITUTE (EPRI). Introduction to OpenDSS. <https://opendss.epri.com/IntroductiontoOpenDSS.html>, 2024.

ELSEIFY, Mohamed A. *et al.* Optimal scheduling of photovoltaic and battery energy storage in distribution networks using an ameliorated sand cat swarm optimization algorithm: Economic assessment with different loading scenarios. **Journal of Energy Storage**, v. 116, 30 abr. 2025.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Sistemas de Armazenamento em Baterias**. 2019.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **ANUÁRIO ESTATÍSTICO DE ENERGIA ELÉTRICA**, 2024.

FARHANGI, H. The path of the smart grid. **IEEE Power and Energy Magazine**, v. 8, n. 1, p. 18–28, jan. 2010.

FREITAS, Paulo Ricardo Radatz. **Modelos avançados de análise de redes elétricas inteligentes utilizando o software OpenDSS**. São Paulo: Universidade de São Paulo - USP, 2015.

GRFENSTETTE, John. Optimization of Control Parameters for Genetic Algorithms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 16, n. 1, p. 122–128, jan. 1986.

GRISALES-NOREÑA, Luis Fernando *et al.* Enhancing DC distribution network efficiency through optimal power coordination in lithium-ion batteries: A sparse nonlinear optimization approach. **Journal of Energy Storage**, v. 96, p. 1–15, 15 ago. 2024.

HONG, H. P. An efficient point estimate method for probabilistic analysis. **Reliability Engineering and System Safety**, v. 59, p. 261–267, 1998.

INSTITUTE OF ELECTRICAL AND ELECTRONIC ENGINEERS (IEEE). **IEEE PES Test Feeder**.

INTERNATIONAL ENERGY AGENCY (IEA). **The power of transformation: wind, sun and the economics of flexible power systems**. França: OECD/IEA, 2014. v. 1

JÚNIOR, Hernani Gonçalves Campos. **Operação ótima de baterias em presença de incertezas de carga e geração**. Belo Horizonte: Centro Federal de Educação Tecnológica de Minas Gerais, 2025.

KAGAN, Nelson; OLIVEIRA, Carlos César Barioni; ROBBA, Ernesto João. **Introdução aos Sistemas de Distribuição de Energia Elétrica**. 1. ed. São Paulo: Editora Edgar Blucher, 2005.

KAMEL, Salah *et al.* Single- and multi-objective optimization for photovoltaic distributed generators implementation in probabilistic power flow algorithm. **Electrical Engineering**, v. 102, n. 1, p. 331–347, 4 mar. 2020.

KAUR, Sandeep; KUMBHAR, Ganesh; SHARMA, Jaydev. A MINLP technique for optimal placement of multiple DG units in distribution systems. **International Journal of Electrical Power and Energy Systems**, v. 63, p. 609–617, 2014.

KÜHN, Matthias; SEVERIN, Thomas; SALZWEDEL, Horst. Variable Mutation Rate at Genetic Algorithms: Introduction of Chromosome Fitness in Connection with Multi-Chromosome Representation. **International Journal of Computer Applications**, v. 72, n. 17, p. 31–38, 17 jun. 2013.

LINDEN, Ricardo. **Algoritmos Genéticos: teoria e implementação**. Rio de Janeiro: Brasport, 2008.

LUND, Peter D. *et al.* Review of energy system flexibility measures to enable high levels of variable renewable electricity. **Renewable and Sustainable Energy Reviews**, v. 45, p. 785–807, fev. 2015.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de Metodologia Científica**. 5. ed. São Paulo: Atlas S.A., 2003.

MI, Zengqiang *et al.* Optimal scheduling strategies of distributed energy storage aggregator in energy and reserve markets considering wind power uncertainties. **Energies**, v. 11, n. 5, 2018.

POMPERN, Natsawat *et al.* Optimal Placement and Capacity of Battery Energy Storage System in Distribution Networks Integrated With PV and EVs Using Metaheuristic Algorithms. **IEEE Access**, v. 11, p. 68379–68394, 2023.

RADOSAVLJEVIĆ, Jordan *et al.* Dynamic Optimal Power Dispatch in Unbalanced Distribution Networks with Single-Phase Solar PV Units and BESS. **Energies**, v. 16, n. 11, 1 jun. 2023.

RANGEL, Camilo Alberto Sepulveda *et al.* Methodology for ESS-type selection and optimal energy management in distribution system with DG considering reverse flow limitations and cost penalties. **IET Generation, Transmission & Distribution**, v. 12, n. 5, p. 1164–1170, 19 mar. 2018.

SALDANHA, John J. A. *et al.* AI-based optimal allocation of BESS, EV charging station and DG in distribution network for losses reduction and peak load shaving. **Electric Power Systems Research**, v. 234, 1 set. 2024.

SCHAFFER, J. *et al.* A Study of Control Parameters Affecting Online Performance of Genetic

Algorithms for Function Optimization. *In*: set. 1989.

SCOLARI, Bruno Sabino; URBANETZ, Jair Jr. Vista do panorama dos sistemas fotovoltaicos conectados à rede elétrica amparados pela REN nº482/2012 da ANEEL no Brasil. **VII Congresso Brasileiro de Energia Solar**, p. 1–10, 2018.

SHEIKH, Hafsa Imra; RATHI, Mahesh Kumar; SOOMRO, Amir Mahmood. Optimal integration of battery energy-storage system with high penetration of renewable energy in radial distribution network. **Clean Energy**, v. 6, n. 3, p. 404–411, 1 jun. 2022.

SOUZA, João Paulo Assunção de *et al.* Analysis of Reactive Power Control Using Battery Energy Storage Systems for a Real Distribution Feeder. **Journal of Control, Automation and Electrical Systems**, v. 33, n. 4, p. 1198–1216, 9 ago. 2022.