



Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação
Programa de Pós-Graduação em Engenharia Elétrica e de Computação

Saymon Fonseca Santos Mendes

Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos

Goiânia
2025



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

Saymon Fonseca Santos Mendes

3. Título do trabalho

Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(a) autor(a) e ao(a) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Lina Paola Garces Negrete, Professora do Magistério Superior**, em 04/04/2025, às 10:01, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Saymon Fonseca Santos Mendes, Discente**, em 04/04/2025, às 10:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5288849** e o código CRC **E7995D2F**.

Referência: Processo nº 23070.061470/2024-05

SEI nº 5288849

Saymon Fonseca Santos Mendes

Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos

Dissertação apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Elétrica e de Computação como requisito para a obtenção do Título de Mestre em Engenharia Elétrica.

Área de Concentração: Engenharia Elétrica

Linha de Pesquisa: Sistemas Eletroeletrônicos

Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação

Programa de Pós-Graduação em Engenharia Elétrica e de Computação

Orientador: Professora Doutora Lina Paola Garcés Negrete

Goiânia

2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Mendes, Saymon Fonseca Santos

Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos [manuscrito] / Saymon Fonseca Santos Mendes. - 2025.

CXXXVI, 136 f.: il.

Orientador: Profa. Dra. Lina Paola Garces Negrete.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia, 2025.

Bibliografia.

Inclui siglas, abreviaturas, símbolos, gráfico, tabelas, algoritmos, lista de figuras, lista de tabelas.

1. Algoritmos Genéticos. 2. Estratégias Evolutivas. 3. Geração Distribuída. 4. Recursos Energéticos Distribuídos. 5. Sistemas de Armazenamento de Energia. I. Negrete, Lina Paola Garces, orient. II. Título.

CDU 621.3



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 1 da sessão de Defesa de Dissertação de **Saymon Fonseca Santos Mendes**, que confere o título de Mestre em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia Elétrica**.

Aos **vinte e quatro dias do mês de janeiro de dois mil e vinte e cinco**, a partir das **08h30min.**, na **sala Caryocar Brasiliensis** da **Escola de Engenharia Elétrica, Mecânica e de Computação**, realizou-se a sessão pública de Defesa de Dissertação intitulada “**Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos**”. Os trabalhos foram instalados pela Orientadora, Professora Doutora **Lina Paola Garces Negrete - (EMC/UFG)** com a participação dos demais membros da Banca Examinadora: Doutor **Igor Morro Mello - (SENAI GO)**, Professor Doutor **Igor Kopcak - (EMC/UFG)** e Professor Doutor **Gelson A. A. Brigatto - (EMC/UFG)**, membros titulares externos. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **APROVADO** pelos seus membros. Proclamados os resultados pela Professora Doutora **Lina Paola Garces Negrete**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos **vinte e quatro dias do mês de janeiro de dois mil e vinte e cinco**.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Lina Paola Garces Negrete, Professora do Magistério Superior**, em 04/04/2025, às 10:02, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Igor Kopcak, Professor do Magistério Superior**, em 04/04/2025, às 10:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gelson Antonio Andrea Brigatto, Professor do Magistério Superior**, em 04/04/2025, às 10:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Saymon Fonseca Santos Mendes, Discente**, em 07/04/2025, às 09:10, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Igoor Morro Mello, Usuário Externo**, em 07/04/2025, às 09:11, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5288889** e o código CRC **F484C79B**.

Referência: Processo nº 23070.061470/2024-05

SEI nº 5288889

Saymon Fonseca Santos Mendes

Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos

Dissertação apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Elétrica e de Computação como requisito para a obtenção do Título de Mestre em Engenharia Elétrica.

Área de Concentração: Engenharia Elétrica
Linha de Pesquisa: Sistemas Eletroeletrônicos

Trabalho Aprovado. Goiânia, 24 de janeiro de 2025:

**Profa. Dra Professora Doutora Lina
Paola Garcés Negrete**
PPGEEC/EMC/UFG

Dr. Igoor Morro Mello
SENAI-GO

Prof. Dr. Igor Kopcak
EMC/UFG

Prof. Dr. Gelson A. A. Brigatto
EMC/UFG

Goiânia
2025

Dedico este trabalho à minha amada companheira, cuja presença e apoio foram indispensáveis; aos meus familiares, que sempre me ofereceram amparo e incentivo; aos amigos, que compartilharam momentos desta trajetória; e a todos que, de alguma forma, contribuíram para a realização desta jornada acadêmica.

Agradecimentos

Expresso minha mais profunda gratidão a Deus, por caminhar ao meu lado ao longo desta jornada, concedendo-me paciência, serenidade e determinação para alcançar a conclusão desta etapa e a obtenção do título de mestre.

Agradeço à amada companheira, Maria Gabriela Alves, cuja presença constante foi fonte de inspiração e apoio inabalável, proporcionando-me as condições necessárias para continuar meus estudos e aprimorar minha qualificação. Manifesto também minha gratidão à minha família, especialmente à minha mãe, Joana, e ao meu irmão, Samuel, que, com seu suporte emocional, me mantiveram motivado a perseverar diante dos desafios.

Registro aqui meus mais sinceros agradecimentos aos amigos que estiveram ao meu lado, oferecendo apoio e ajuda inestimáveis em todos os momentos, especialmente nos períodos mais desafiadores. Destaco, com gratidão especial, Carlos Henrique, Erik Ely, Fábio Assis, Hudson Cândido, Vinicius de Castro, Jeovana Pires e Tifanne Castro, cuja presença e disposição foram essenciais em minha trajetória. Foram pilares fundamentais que me ampararam nos momentos em que não enxergava solução, tornando esta conquista possível graças à relevância de cada um em minha vida.

Expresso minha profunda gratidão aos professores que, ao longo do mestrado, contribuíram significativamente para minha formação acadêmica e intelectual. Manifesto, em especial, meu sincero agradecimento à minha orientadora, Lina Paola, cuja dedicação e prontidão em me instruir transcenderam o papel acadêmico, tornando-a não apenas uma mentora, mas também uma amiga valiosa. Sua orientação, conselhos e apoio constante foram essenciais para meu desenvolvimento e consistência durante esta jornada.

Por fim, expresso minha gratidão à Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, pela excelência do programa de pós-graduação instituído e pela oportunidade ímpar de aprimorar minha formação acadêmica e profissional. Este percurso não apenas me proporcionou qualificação, mas também a possibilidade de retribuir à sociedade o conhecimento e o desenvolvimento adquiridos ao longo desta jornada.

*“Só o conhecimento liberta o homem,
Só através do conhecimento o homem é livre e em sendo livre:
Ele pode aspirar uma condição melhor de vida para ele e todos os seus semelhantes.”*
(Enéas Carneiro)

Trabalhos Publicados

- MENDES, S. F. S., SILVA, C. H. S., NEGRETE, L. P.G. *Restrições Espaciais no Planejamento de Sistemas de Distribuição de Energia Elétrica*. 20º Congresso de Ensino, Pesquisa e Extensão - CONPEEX, 2023, Goiânia, GO.
- MENDES, S. F. S., SILVA, C. H. S., NEGRETE, L. P. G. *Impacto do Dimensionamento dos Recursos Energéticos Distribuídos aplicado a um Sistema de Distribuição*. XIX Encontro Regional Ibero-americano do CIGRE - ERIAC, 2023, Foz do Iguaçu, PR.
- MENDES, S. F. S., SILVA, C. H. S., NEGRETE, L. P. G. *Avaliação do Impacto da Conexão de Recursos Energéticos Distribuídos na Rede de Distribuição*. VIII Congresso Brasileiro de Geração Distribuída - CBGD, 2023, Belo Horizonte, MG.
- MENDES, S. F. S., NEGRETE, L. P.G. *Aplicação de Algoritmos Evolutivos na Alocação de Recursos Energéticos Distribuídos*. 21º Congresso de Ensino, Pesquisa e Extensão - CONPEEX, 2024, Goiânia, GO.
- MENDES, S. F. S., VERGARA, G. C., SANTOS JR, G. S., NEGRETE, L. P. G. *Power Generation in Goiás: Infrastructure Limitations and Opportunities for Distributed Generation*. International Symposium on Energy: Energy Transition, Green Hydrogen and Sustainable Industry - ISE, 2024, Goiânia, GO.

Prêmios e Distinções:

- **Menção Honrosa e Premiação no VIII Congresso Brasileiro de Geração Distribuída (CBGD 2023)**
Recebida pela apresentação do artigo intitulado “*Avaliação do Impacto da Conexão de Recursos Energéticos Distribuídos na Rede de Distribuição*”, de autoria de MENDES, S. F. S. e coautoria de SILVA, C. H. S. e NEGRETE, L. P. G., durante o VIII Congresso Brasileiro de Geração Distribuída - CBGD, realizado em Belo Horizonte, MG, nos dias 16 e 17 de novembro de 2023. A coordenação científica do congresso destacou o artigo entre os 10 melhores apresentados no evento e concedeu uma premiação em reconhecimento à sua relevância acadêmica e técnica.

Resumo

Este estudo investiga a integração de geração distribuída e sistemas de armazenamento de energia em redes elétricas operando em média tensão. A proposta envolve o desenvolvimento de algoritmos evolutivos para determinar, de forma otimizada, os pontos de conexão para diversas cargas, além de fornecer as injeções ótimas de potência ativa de múltiplas unidades geradoras em diferentes pontos da rede. A alocação de Recursos Energéticos Distribuídos no Sistema Elétrico de Potência envolve um balanço intrínseco entre benefícios e desafios. Entre os benefícios destacam-se a redução significativa de perdas elétricas, a atração de investimentos no setor energético, a diversificação e expansão da matriz elétrica com ênfase em fontes renováveis, e impactos socioeconômicos positivos, como a geração de empregos. Contudo, os desafios incluem dificuldades relacionadas à tarifação pelo uso do sistema, necessidade de revisões nos procedimentos operacionais, elevação descontrolada do perfil de tensão em casos de alta penetração de REDs alocados de forma arbitrária, aumento nos níveis de curto-circuito e comprometimento do desempenho dos sistemas de proteção. A formulação do modelo de otimização adotou como função objetivo a minimização das perdas totais de potência ativa no sistema. O estudo considerou como principais recursos distribuídos, a geração distribuída solar fotovoltaica e sistemas de armazenamento em baterias para as simulações. As condições operacionais da rede foram analisadas por meio do estudo do fluxo de potência do caso base. Os algoritmos evolutivos propostos e desenvolvidos foram aplicados a dois sistemas de teste: o sistema IEEE de 34 barras e o Sistema Alimentador Real PD004. Os resultados obtidos evidenciam a eficiência, robustez e rápida convergência do Algoritmo Genético Híbrido proposto em comparação com outras abordagens implementadas, demonstrando sua superioridade na resolução do problema. O programa computacional desenvolvido apresenta elevado potencial de aplicação prática para concessionárias de energia elétrica, configurando-se como uma ferramenta estratégica no planejamento de redes de distribuição. A utilização dos resultados fornecidos pelos algoritmos permite realizar conexões de unidades geradoras e cargas de maneira otimizada, respeitando os limites de geração estabelecidos.

Palavras-chave: Algoritmos Genéticos. Estratégias Evolutivas. Geração Distribuída. Recursos Energéticos Distribuídos. Sistemas de Armazenamento de Energia. Sistemas Elétricos de Potência.

Abstract

This study investigates the integration of distributed generation and energy storage systems in medium-voltage electrical networks. The proposed approach involves the development of evolutionary algorithms to optimally determine connection points for various loads and provide the optimal active power injections from multiple generating units at different network locations. The allocation of Distributed Energy Resources (DERs) in Power Systems presents an intrinsic balance between benefits and challenges. Among the benefits, significant reductions in electrical losses, attraction of investments in the energy sector, diversification and expansion of the energy matrix with a focus on renewable sources, and positive socioeconomic impacts, such as job creation, stand out. However, challenges include difficulties related to system usage tariffs, the need for revisions in operational procedures, uncontrolled voltage profile elevation in cases of high penetration of arbitrarily allocated DERs, increased short-circuit levels, and compromised performance of protection systems. The optimization model formulation adopted the minimization of total active power losses in the system as its objective function. The study considered solar-based distributed generation and battery storage systems for simulations. Network operating conditions were analyzed using power flow studies of the base case. The developed algorithms were applied to two test systems: the IEEE 34-bus system and the Real Feeder System PD004. The results highlight the efficiency, robustness, and rapid convergence of the Hybrid Genetic Algorithm (HGA) compared to other implemented approaches, demonstrating its superiority in solving the problem. The developed computational tool shows significant practical potential for application in electric utility companies, serving as a strategic tool for distribution network planning. Utilizing the algorithm's results enables the optimized connection of generating units and loads while respecting established generation limits.

Keywords: Genetic Algorithms. Evolutionary Strategies. Distributed Generation. Distributed Energy Resources. Energy Storage Systems. Power Systems.

Lista de ilustrações

Figura 1.1 – Projeção da Capacidade Instalada.	23
Figura 2.1 – Sistemas Elétricos: Cenários Atuais e Perspectivas Futuras	43
Figura 2.2 – Estrutura do software OpenDSS.	49
Figura 2.3 – Diagrama de blocos do elemento <i>PVSystem</i> no OpenDSS.	50
Figura 2.4 – Esquemático do Modelo do Elemento <i>PVSystem</i> no OpenDSS.	51
Figura 2.5 – Diagrama de blocos do elemento <i>Storage</i> no OpenDSS.	53
Figura 2.6 – Indicador de Estado do SAEB.	56
Figura 2.7 – Método de Evolução típica de uma EE, ilustrada de acordo com a distribuição da população.	59
Figura 2.8 – Esquemático geral de um Algoritmo Evolutivo.	62
Figura 2.9 – Ilustração do Método da Roleta para seleção de indivíduos.	64
Figura 3.1 – Exemplo de Diagrama Unifilar do Perfil de Carregamento.	83
Figura 3.2 – Exemplo de Diagrama Unifilar do Perfil de Tensão.	84
Figura 3.3 – Fluxograma para determinar a capacidade máxima dos REDs.	86
Figura 3.4 – Percentual de redução de perdas em função da potência incremental injetada pelos Recursos Energéticos Distribuídos.	87
Figura 3.5 – Fluxograma da Estratégia Evolutiva Híbrida.	93
Figura 3.6 – Fluxograma do Algoritmo Elitismo Híbrido.	96
Figura 4.1 – Diagrama Unifilar do Sistema IEEE 34 Barras.	99
Figura 4.2 – Análise do Perfil de Tensão no Sistema IEEE de 34 Barras.	100
Figura 4.3 – Análise do Perfil de Carregamento no Sistema IEEE de 34 Barras.	101
Figura 4.4 – Análise do Perfil de Tensão do Sistema IEEE de 34 Barras após Cresci- mento de 30%.	102
Figura 4.5 – Análise do Perfil de Carregamento do Sistema IEEE de 34 Barras após Crescimento de 30%	103
Figura 4.6 – Sistema IEEE 34 Barras: Desempenho da Configuração 1.	105
Figura 4.7 – Sistema IEEE 34 Barras: Perfil de Tensão do Sistema para a Configura- ção 1	106
Figura 4.8 – Sistema IEEE 34 Barras: Perfil de carregamento do Sistema para a configuração 1	107
Figura 4.9 – Sistema IEEE 34 Barras: Comportamento do Melhor Indivíduo na EEH	108
Figura 4.10–Sistema IEEE de 34 Barras: Análise do Perfil de Tensão na Aplicação da Estratégia Evolutiva Híbrida	110
Figura 4.11–Sistema IEEE de 34 Barras: Análise do Perfil de Carregamento na Aplicação da Estratégia Evolutiva Híbrida	111
Figura 4.12–Sistema IEEE 34 Barras: Comportamento do Melhor Indivíduo no AGH	113

Figura 4.13–Sistema IEEE de 34 Barras: Análise do Perfil de Tensão na Aplicação do Algoritmo Genético Híbrido	114
Figura 4.14–Sistema IEEE de 34 Barras: Análise do Perfil de Carregamento na Aplicação do Algoritmo Genético Híbrido	115
Figura 4.15–Alimentador Real PD04: Representação Georreferenciada	118
Figura 4.16–Alimentador Real PD04: Análise do Perfil de Tensão	119
Figura 4.17–Alimentador Real PD04: Análise do Perfil de Carregamento	120
Figura 4.18–Alimentador Real PD04: Análise do Perfil de Tensão com 30% de Crescimento	121
Figura 4.19–Alimentador PD04: Comportamento do Melhor Indivíduo no AGH	123
Figura 4.20–Perfil de Tensão Alimentador PD04 - AGH Elitismo	125
Figura 4.21–Perfil de Carregamento Alimentador PD04 - AGH Elitismo	126

Lista de tabelas

Tabela 2.1 – Parâmetros utilizados para modelagem do SAEB no OpenDSS.	55
Tabela 2.2 – Descrição dos Parâmetros utilizados para modelagem do SAEB no OpenDSS.	55
Tabela 2.3 – Variáveis do SAEB no OpenDSS utilizadas para aplicação da metodologia.	56
Tabela 3.1 – Exemplo de Geração 1 com 3 indivíduos	89
Tabela 3.2 – Exemplo de Cruzamento entre dois indivíduos	91
Tabela 4.1 – Sistema IEEE 34 Barras - Configurações de Barramentos com GD e SAEB: Mitigação das Perdas Totais e Conformidade com Limites de Tensão	104
Tabela 4.2 – Sistema IEEE 34 Barras: Desempenho da Integração de Usina Fotovoltaica e SAEB nos Barramentos da Linha L08	104
Tabela 4.3 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de GD na Estratégia Evolutiva Híbrida	109
Tabela 4.4 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de SAEB na Estratégia Evolutiva Híbrida	109
Tabela 4.5 – Sistema IEEE 34 Barras: Avaliação do Desempenho do Melhor Indivíduo na Estratégia Evolutiva Híbrida	109
Tabela 4.6 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de GD no Algoritmo Genético Híbrido	112
Tabela 4.7 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de SAEB no Algoritmo Genético Híbrido	112
Tabela 4.8 – Sistema IEEE 34 Barras: Avaliação do Desempenho do Melhor Indivíduo no Algoritmo Genético Híbrido	112
Tabela 4.9 – Análise Comparativa do Desempenho dos Melhores Indivíduos de cada Metodologia	116
Tabela 4.10–Alimentador Real PD04 - Configurações de Barramentos com GD e SAEB: Mitigação das Perdas Totais e Conformidade com Limites de Tensão	122
Tabela 4.11–Alimentador PD04: Configuração do Melhor Indivíduo com Composição de GD no Algoritmo Genético Híbrido	124
Tabela 4.12–Alimentador PD04: Configuração do Melhor Indivíduo com Composição de SAEB no Algoritmo Genético Híbrido	124
Tabela 4.13–Alimentador PD04: Avaliação do Desempenho do Melhor Indivíduo no Algoritmo Genético Híbrido	124

Lista de abreviaturas e siglas

AG	<i>Algoritmo Genético</i>
AGH	<i>Algoritmo Genético Híbrido</i>
AE	<i>Algoritmos Evolutivos</i>
ANEEL	<i>Agência Nacional de Energia Elétrica</i>
BDGD	<i>Base de Dados Geográfica da Distribuidora</i>
BESS	<i>Battery Energy Storage Systems</i>
DERs	<i>Distributed Energy Resources</i>
EE	<i>Estratégia Evolutiva</i>
EEH	<i>Estratégia Evolutiva Híbrida</i>
EPE	<i>Empresa de Pesquisa Energética</i>
EPRI	<i>Electric Power Research Institute</i>
FO	<i>Função Objetivo</i>
FPI	<i>Fluxo de Potência Intervalar</i>
GD	<i>Geração Distribuída</i>
HGA	<i>Hybrid Genetic Algorithm</i>
IEA	<i>International Energy Agency</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
INEE	<i>Instituto Nacional de Eficiência Energética</i>
ISOS	<i>Improved Symbiotic Organisms Search</i>
MOPSO	<i>Multiobjective Particle Swarm Optimization Algorithm</i>
ONS	<i>Operador Nacional do Sistema</i>
OpenDSS	<i>Distribution System Simulator</i>
PRODIST	<i>Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional</i>

PSO	<i>Particle Swarm Optimization</i>
QOCSOS	<i>Quasi-Oppositional Chaotic Symbiotic Organisms Search</i>
REDs	<i>Recursos Energéticos Distribuídos</i>
SAE	<i>Sistemas de Armazenamento de Energia</i>
SAEB	<i>Sistemas de Armazenamento de Energia em Baterias</i>
SDEE	<i>Sistemas de Distribuição de Energia Elétrica</i>
SEP	<i>Sistema Elétrico Brasileiro</i>
SGA	<i>Search Group Algorithm</i>
SIG	<i>Sistema de Informações Geográficas</i>
SIG-R	<i>Sistema de Informação Geográfica Regulatório</i>
SIN	<i>Sistema Interligado Nacional</i>
SOA	<i>Sunflower Optimization</i>
SOS	<i>Symbiotic Organisms Search</i>
SSA	<i>Salp Swarm Algorithm</i>
TS	<i>Tabu search</i>

Lista de símbolos

P_m	<i>Probabilidade de mutação</i>
P_c	<i>Probabilidade de crossover</i>
P_i	<i>Probabilidade de seleção do i-ésimo indivíduo</i>
$f(i)$	<i>Aptidão do i-ésimo indivíduo</i>
V_j	<i>Níveis de tensão por linhas do sistema base</i>
$P_{\text{perdas},j}^{\text{base}}$	<i>Perdas de energia ativa nas linhas j do sistema base</i>
$C_{\text{max},j}$	<i>Níveis de carregamento nas linhas do sistema base</i>
$P_{\text{perdas}}^{\text{base}}$	<i>Perdas totais do sistema base</i>
P_{Δ}^{RED}	<i>Potência incremental</i>
$P_{\text{inj},j}^{\text{RED}}$	<i>Potência injetada pelos Recursos Energéticos Distribuídos</i>
P_{perdas}^k	<i>Perdas de energia dos indivíduos</i>

Sumário

1	Introdução	22
1.1	Justificativa	26
1.2	Objetivos	27
1.3	Estrutura do Texto	29
2	Estado da Arte	31
2.1	Sistemas de Armazenamento de Energia	31
2.1.1	Sistemas de Armazenamento de Energia em Baterias	35
2.1.1.1	Baterias de chumbo-ácido (PbA)	36
2.1.1.2	Baterias de níquel-cádmio (NiCd) e níquel-hidreto metálico (NiMH)	37
2.1.1.3	Baterias de sódio-enxofre (NaS)	38
2.1.1.4	Baterias de íons de lítio (Li)	39
2.2	Geração Distribuída	40
2.3	Recursos Energéticos Distribuídos	41
2.3.1	Impactos da conexão dos Recursos Energéticos Distribuídos	43
2.4	Qualidade do Fornecimento de Energia Elétrica	44
2.5	Base de Dados Geográfica da Distribuidora (BDGD)	46
2.6	Software QGIS	47
2.7	Software OpenDSS	48
2.7.1	Modelagem do Sistema Fotovoltaico no OpenDSS - PVSystem	50
2.7.2	Modelagem do Sistema de Armazenamento de Energia - Storage	52
2.7.2.1	Sistema de Armazenamento com Baterias - Metodologia	55
2.8	Métodos de Otimização	56
2.8.1	Estratégias Evolutivas	57
2.8.2	Algoritmos Genéticos	62
2.8.3	Estratégia Evolutiva e Algoritmo Genético	64
2.8.3.1	Metodologia Híbrida	66
2.8.4	Estratégia Evolutiva (μ, λ)	66
2.8.5	Estratégia Evolutiva ($\mu + \lambda$)	68
2.8.6	Algoritmo Genético Híbrido: Elitismo com (μ, λ)	69
2.8.7	Algoritmo Genético Híbrido: Elitismo com ($\mu + \lambda$)	71
2.9	Revisão Bibliográfica	74
3	Metodologia	80
3.1	DADOS DO SISTEMA E DEFINIÇÃO DO CASO BASE	80
3.1.1	Estudo do sistema original	81
3.1.1.1	Elaboração dos Diagramas Unifiliares	81

3.1.1.2	Elaboração do Diagrama Unifilar do Perfil de Carregamento do Sistema	82
3.1.1.3	Elaboração do Diagrama Unifilar do Perfil de Tensão do Sistema	83
3.2	DETERMINAÇÃO DO ESPAÇO DE BUSCA	84
3.3	APLICAÇÃO DAS ESTRATÉGIAS DE OTIMIZAÇÃO	87
3.3.1	Construção do Indivíduo e População Inicial	88
3.3.2	Capacidade da Geração	89
3.3.3	Seleção de Indivíduos	89
3.3.4	Cruzamento de Indivíduos	90
3.3.5	Mutação de Indivíduos	90
3.3.6	Estratégia Evolutiva Híbrida	91
3.3.7	Algoritmo Genético Híbrido	94
3.3.8	Identificação do Melhor Indivíduo nas Estratégias de Otimização	97
3.3.8.1	Análise de Desempenho	97
3.3.8.2	Comparação de Desempenho	97
3.3.8.3	Seleção do Melhor Indivíduo	97
4	Testes e Resultados	99
4.1	Sistema IEEE 34 Barras	99
4.1.1	Modificações Implementadas	101
4.1.2	Desempenho do Espaço de Busca	103
4.1.3	Desempenho da Estratégia Evolutiva Híbrida	107
4.1.4	Desempenho do Algoritmo Genético Híbrido	112
4.1.5	Comparação dos Melhores Indivíduos	115
4.2	Sistema Alimentador Real - PD04	116
4.2.1	Modificações Implementadas	120
4.2.2	Desempenho do Espaço de Busca	122
4.2.3	Otimização da Configuração de Recursos Energéticos Distribuídos e Identificação do Melhor Indivíduo	123
5	Conclusão	127
	Referências	129

1 Introdução

O aumento da demanda energética ao longo dos anos torna-se cada vez mais vital para o progresso e bem-estar da sociedade global. Esse crescimento, aliado às transformações no setor elétrico, desafia os profissionais responsáveis pela operação, manutenção e estabilidade dos sistemas elétricos a assegurar elevados padrões de confiabilidade, respeitando os critérios estabelecidos por órgãos reguladores nacionais, como o Operador Nacional do Sistema Elétrico (ONS, 2024). Em um cenário de crescente eletrificação e inovação tecnológica, a confiabilidade no fornecimento de energia tornou-se um pilar indispensável para sustentar as transformações estruturais e tecnológicas das redes elétricas.

Os REDs, que abrangem tecnologias como a geração distribuída (GD) e sistemas de armazenamento de energia em baterias (SAEB), têm desempenhado um papel crucial na melhoria das condições operacionais das redes de distribuição. Dentre os benefícios técnicos mais significativos, destacam-se a melhoria do perfil de tensão, a redução das perdas de potência ativa e reativa, e a capacidade de atender, de forma eficiente, à crescente demanda por eletrificação (GRISALES-NOREÑA; MONTOYA; RAMOS-PAJA, 2018; MONTOYA et al., 2019). Esses recursos não apenas otimizam a operação do sistema elétrico, mas também viabilizam a integração de novos usuários e tecnologias, como veículos elétricos e sistemas de armazenamento doméstico, contribuindo para a criação de um ecossistema energético mais resiliente e sustentável.

Essa evolução é acompanhada por uma transição paradigmática nas redes elétricas, que estão passando de um modelo vertical clássico, com fluxo unidirecional de energia proveniente de grandes usinas geograficamente distantes dos centros de consumo, para um modelo horizontal e bidirecional. Nesse novo formato, cargas e geradores estão localizados de maneira mais próxima, promovendo maior integração e flexibilidade operacional (MONTOYA et al., 2017). Tal mudança é impulsionada pelos avanços da eletrônica de potência e pela crescente incorporação de recursos energéticos distribuídos (REDs) nos níveis de distribuição, configurando oportunidades de modernização e descentralização das redes tradicionais (GRISALES-NOREÑA; MONTOYA; RAMOS-PAJA, 2018; MONTOYA et al., 2019).

Adicionalmente, os recursos energéticos distribuídos tradicionais, como geradores locais, desempenham um papel fundamental ao fornecer energia ativa e, em cenários específicos, energia reativa. Essa capacidade dupla amplifica os impactos positivos na redução das perdas de potência e na melhoria do desempenho das redes de distribuição (BOCANEGRA; MONTOYA, 2019). No Brasil, a adoção de geração distribuída tem crescido exponencialmente, impulsionada por incentivos à diversificação da matriz energética

e pela busca por maior eficiência e sustentabilidade, conforme apontado pela Agência Nacional de Energia Elétrica (ANEEL) (ANEEL, 2022a).

A Empresa de Pesquisa Energética (EPE) divulgou no documento "Estudos do Plano Decenal de Expansão de Energia (PDE) 2032" (EPE, 2022), focado em geração distribuída (GD) e baterias, que até o ano de 2032 a geração residencial deverá ultrapassar 15 gigawatts (GW). Esse valor supera a geração a plena carga de grandes usinas como Itaipu e Belo Monte, que possuem capacidades instaladas de 14 GW (BINACIONAL, 2024) e 11,2 GW (ENERGIA, 2024), respectivamente. A previsão de crescimento da capacidade instalada de geração distribuída (GD) está ilustrada na Figura 1.1.




Figura 1.1 – Projeção da Capacidade Instalada.

Fonte: (EPE, 2022)

No entanto, essa transição para redes bidirecionais e mais integradas não está isenta de desafios. A integração dos REDs requer a modernização da infraestrutura elétrica existente, a adaptação de regulamentações e o desenvolvimento de metodologias avançadas para otimizar a alocação e o controle desses recursos. Além de ser uma evolução técnica, essa transformação representa uma mudança de paradigma na forma como a energia é gerada, distribuída e consumida. Estudos apontam que a alocação inadequada e o dimensionamento dos recursos pode não apenas neutralizar os benefícios esperados, mas também resultar em um aumento nas perdas do sistema em relação ao cenário sem a alocação (MITHULANANTHAN; OO; PHU, 2015). Esse efeito adverso representa um desafio significativo para concessionárias que já enfrentam problemas com elevadas perdas

de energia e perfis de tensão inadequados. Nessas circunstâncias, qualquer incremento nas perdas é inaceitável, exigindo estratégias cuidadosamente planejadas para a inserção dos REDs. Quando a alocação é realizada de forma otimizada, as concessionárias conseguem maximizar os benefícios dos REDs, como a redução das perdas no sistema, a regulação eficaz dos níveis de tensão, a melhoria na confiabilidade do fornecimento e o alívio nos sistemas de transmissão e distribuição. Esses efeitos positivos, por sua vez, permitem o adiamento de novos investimentos em infraestrutura, reduzindo os custos globais (MITHULANANTHAN; OO; PHU, 2015).

Os Recursos Energéticos Distribuídos (REDs) têm sido amplamente reconhecidos como uma solução viável e promissora para enfrentar os múltiplos desafios impostos aos sistemas elétricos modernos, atendendo simultaneamente à crescente demanda por energia de forma sustentável. Sua modularidade e dimensões compactas conferem vantagens significativas em comparação às soluções tradicionais, como as grandes usinas centralizadas, possibilitando uma instalação mais ágil e com custos reduzidos. No entanto, para que tais benefícios sejam plenamente concretizados, é essencial que os REDs sejam alocados em posições estratégicas e dimensionados de maneira otimizada. Alocações inadequadas não apenas comprometem os objetivos técnicos e econômicos associados à sua implementação, mas também podem ocasionar impactos adversos na operação e na confiabilidade do sistema elétrico.

Portanto, torna-se essencial o desenvolvimento de ferramentas avançadas que auxiliem no planejamento estratégico dos REDs, considerando a análise da alocação e dimensionamento para instalação, (ACHARYA; MAHAT; MITHULANANTHAN, 2006). Essas ferramentas devem ser capazes de identificar as condições ótimas para a inserção, maximizando os benefícios técnicos, econômicos e ambientais enquanto minimizam os impactos adversos (ACHARYA; MAHAT; MITHULANANTHAN, 2006). Tais soluções não apenas contribuem para o fortalecimento dos sistemas elétricos existentes, mas também promovem um modelo energético mais resiliente e sustentável, alinhado às demandas atuais e futuras da sociedade.

A instalação de recursos energéticos distribuídos em locais ótimos e sua operação eficiente em sistemas de distribuição de média tensão enfrentam uma série de desafios que precisam ser abordados para garantir o máximo aproveitamento técnico. Esses desafios incluem:

- **Alocação ótima das GDs:** Determinar o posicionamento mais apropriado para as unidades de GD, considerando a topologia da rede elétrica e as condições de carga, de forma a minimizar perdas e maximizar os benefícios operacionais.
- **Alocação ótima dos Sistemas de Armazenamento em Baterias:** Determinar o posicionamento mais apropriado para as unidades de BESS, considerando a topologia

da rede elétrica e as condições de carga, de forma a minimizar perdas e maximizar os benefícios operacionais e complementar as GDs.

- **Integração de recursos de energia renovável:** Incorporar perfis diários de geração de energia renovável, como solar e eólica, para garantir um despacho energético confiável e alinhado às demandas do sistema, respeitando as características de intermitência dessas fontes.
- **Solução do modelo de otimização:** Resolver modelos de programação matemática, como a programação não linear inteira mista (Mixed Integer Nonlinear Programming - MINLP), que representam de maneira precisa tanto a localização ótima quanto a operação do sistema de distribuição. Esses modelos devem ser resolvidos com tempos de processamento adequados para aplicações práticas.
- **Convergência das técnicas de otimização meta-heurísticas:** Lidar com os problemas de convergência e a introdução de incertezas associadas às técnicas meta-heurísticas amplamente empregadas para resolver esses problemas. A natureza não determinística dessas técnicas pode afetar a confiabilidade dos resultados e requer estratégias para mitigação de incertezas no planejamento.

A alocação ótima de Sistemas de Armazenamento de Energia em Baterias e Geração Distribuída é abordada como um problema de otimização de compensação de potência ativa. Na Seção 2.8, são descritas as meta-heurísticas desenvolvidas para determinar o dimensionamento ideal de GD e BESS em cada barra de carga candidata. Essas barras são avaliadas como potenciais locais para a implementação de Recursos Energéticos Distribuídos, desde que apresentem condições técnicas que viabilizem sua aplicação de forma eficiente e segura.

Essa abordagem reveste-se de elevada relevância acadêmica e prática, considerando que fatores técnicos, como restrições geográficas desfavoráveis, elevados custos de implantação ou limitações específicas da infraestrutura existente, podem inviabilizar a integração de GD e dos BESS em determinadas barras do sistema. Diante disso, é imperativo identificar não apenas as localizações ideais para a instalação, mas também os limites de viabilidade técnica e econômica que condicionam a alocação desses recursos. Essa análise é essencial para assegurar que o planejamento do sistema de distribuição seja realizado com máxima eficiência, confiabilidade operacional e alinhamento às diretrizes de sustentabilidade energética.

Neste trabalho, propõem-se duas estratégias de otimização: a Estratégia Evolutiva Híbrida (EEH) e o Algoritmo Genético Híbrido (AGH). Ambas as abordagens são concebidas com o propósito de determinar o dimensionamento ótimo e identificar as localizações ideais para a alocação de Recursos Energéticos Distribuídos em sistemas de

distribuição. O foco central dessas estratégias está na minimização das perdas de potência ativa, promovendo maior eficiência no sistema elétrico. Vale destacar que, na formulação do problema, não foram considerados os custos associados aos REDs. Adicionalmente, assumiu-se uma demanda fixa no sistema, desconsiderando possíveis variações temporais nas cargas.

De acordo com informações disponibilizadas pelo Operador Nacional do Sistema Elétrico (ONS, 2024), o consumo de energia elétrica no Brasil apresenta um comportamento sazonal, caracterizado por variações horárias significativas ao longo do dia. Nesse contexto, a Resolução 1000/2023 da Agência Nacional de Energia Elétrica (ANEEL, 2023) estabelece a segmentação dos postos tarifários em três categorias: Horário de Ponta, Fora de Ponta e Horário Reservado. O Horário de Ponta corresponde aos períodos de maior demanda de energia elétrica, enquanto os períodos Fora de Ponta e Reservado englobam intervalos de menor carregamento do sistema. Essa segmentação tarifária é particularmente relevante, pois, durante os períodos de maior consumo, as perdas técnicas nos sistemas elétricos tendem a ser substancialmente mais elevadas. Esse comportamento ressalta a importância de estratégias eficazes de gestão da demanda e alocação de recursos energéticos para mitigar os impactos associados ao aumento das perdas e à sobrecarga do sistema.

Embora a sazonalidade da carga seja um elemento fundamental no planejamento energético, sua consideração não foi incorporada ao modelo desenvolvido neste trabalho. Essa exclusão se deve à complexidade adicional que a inclusão das variações horárias acarretaria, uma vez que exigiria a execução do fluxo de potência para cada hora do dia. Tal abordagem aumentaria significativamente o volume de cálculos necessários, resultando em uma elevação substancial do tempo computacional. Como perspectiva para trabalhos futuros, propõe-se a aplicação da estratégia de otimização com melhor desempenho identificada neste estudo, incorporando a sazonalidade da carga na modelagem. Essa extensão permitirá analisar de forma mais precisa os impactos das flutuações horárias na demanda sobre as perdas no sistema elétrico, proporcionando uma solução ainda mais robusta e alinhada às condições reais de operação. Tal aprimoramento contribuirá para o desenvolvimento de estratégias mais eficazes no planejamento de redes de distribuição.

1.1 Justificativa

A crescente integração de Recursos Energéticos Distribuídos (REDs) no Sistema de Distribuição de Energia Elétrica (SDEE) tem gerado impactos significativos no perfil de tensão, no fluxo de carga e nas perdas elétricas do sistema. Esses impactos estão diretamente relacionados à localização e à capacidade dos REDs, evidenciando a importância de uma alocação estratégica. Estudos mostram que a instalação inadequada de geração distribuída (GD) em termos de posicionamento e capacidade pode aumentar as

perdas de energia e os custos operacionais, impactando negativamente o desempenho do sistema e a viabilidade financeira para as concessionárias (FANG-ZONG; JING, 2011; SEDIGHIZADEH; REZAZADEH, 2008).

O planejamento e a operação do Sistema Elétrico de Potência (SEP) enfrentam desafios significativos para atender ao crescimento contínuo da demanda e às flutuações sazonais e diárias das cargas. Para garantir um fornecimento de energia elétrica confiável e eficiente, torna-se imprescindível a realização de uma análise detalhada do fluxo de potência, complementada pelo uso de ferramentas computacionais avançadas e confiáveis. Essa análise desempenha um papel estratégico ao viabilizar a identificação de alternativas para a expansão e modernização da rede elétrica, além de subsidiar o planejamento de investimentos em geração, transmissão e distribuição. Tais ações visam não apenas aprimorar a eficiência energética, mas também promover a compensação reativa necessária para assegurar o desempenho operacional do sistema. (JÚNIOR, 2005).

Nos sistemas de transmissão, que operam como uma ponte entre os centros de produção e consumo, e nos sistemas de distribuição, que atendem diretamente os consumidores em média e baixa tensão, as perdas técnicas são inevitáveis. Essas perdas decorrem de fenômenos como efeito Joule nos condutores, perdas nos núcleos dos transformadores e perdas dielétricas. Embora não possam ser eliminadas, as perdas técnicas devem ser minimizadas por meio de soluções de engenharia adequadas. As concessionárias enfrentam ainda perdas não técnicas, como furtos e fraudes, que comprometem a eficiência geral do sistema e impactam os custos repassados aos consumidores (KAGAN; OLIVEIRA; ROBBA, 2005; ANEEL, 2022b; PRODIST, 2022).

Diante desse cenário, a alocação de REDs em pontos estratégicos das redes de transmissão e distribuição surge como uma solução eficaz para a redução de perdas elétricas. A inserção de REDs, como sistemas de geração distribuída e armazenamento de energia, pode ser realizada de forma otimizada utilizando ferramentas computacionais avançadas, como meta-heurísticas e inteligência artificial. Essas ferramentas permitem identificar os nós ideais e as potências ótimas para a injeção de potência, otimizando o desempenho do sistema e minimizando as perdas (PRODIST, 2022; ANEEL, 2022b). Além disso, algoritmos computacionais, como os baseados em métodos evolutivos, vêm sendo amplamente aplicados para resolver problemas de otimização em redes radiais, oferecendo soluções para o dimensionamento e posicionamento adequados de REDs (ACHARYA; MAHAT; MITHULANANTHAN, 2006).

1.2 Objetivos

O principal objetivo deste trabalho é desenvolver e implementar estratégias de otimização voltadas à integração de geração distribuída e sistemas de armazenamento de

energia em baterias em redes de distribuição operando em média tensão. A proposta centra-se no desenvolvimento de algoritmos baseados em meta-heurísticas capazes de determinar, de forma ideal, os pontos de conexão das unidades geradoras, bem como as injeções ótimas de potência ativa. A abordagem proposta busca minimizar as perdas técnicas do sistema e aprimorar indicadores operacionais fundamentais, como o perfil de tensão, o fator de potência e o carregamento das linhas de distribuição. Esses aprimoramentos visam promover uma maior eficiência energética e contribuir para a confiabilidade e sustentabilidade das redes de distribuição elétrica

Para alcançar este objetivo geral, os seguintes objetivos específicos foram delineados:

1. **Dados do sistema e definição do caso base:** Identificar e caracterizar o sistema em análise, abrangendo sua configuração, topologia, cargas, capacidade atual de geração e outros aspectos essenciais. Essa fase define os parâmetros iniciais indispensáveis para as etapas posteriores.
2. **Determinação do espaço de busca:** O objetivo primordial desta etapa é estabelecer os valores de potência máxima que pode ser injetada em cada barramento candidato, visando as mínimas perdas de energia totais do sistema obtidas ao alocar uma usina solar e/ou sistema de armazenamento de energia em baterias nesse barramento específico.
3. **Aplicação das estratégias de otimização:** Implementar duas abordagens específicas de otimização – Estratégia Evolutiva Híbrida e Algoritmo Genético Híbrido – para identificar as alocações ideais de GD e Baterias. As etapas incluem:
 - **Definição de um indivíduo:** Representação de uma solução potencial na população, configurando a alocação de GD e Baterias nos barramentos do sistema.
 - **Seleção:** Escolha dos indivíduos mais aptos com base em critérios como redução de perdas, melhoria do perfil de tensão e eficiência do carregamento.
 - **Mutação:** Introdução de pequenas variações nos indivíduos selecionados para explorar novas soluções e evitar convergência prematura.
 - **Cruzamento:** Combinação de características de diferentes indivíduos para aumentar a diversidade e gerar novas soluções promissoras.
4. **Implementação e validação da metodologia proposta:** Conduzir estudos de caso em dois sistemas distintos – o Sistema IEEE de 34 Barras e um alimentador real, cujos dados foram obtidos do Banco de Dados Geográfico da Distribuidora, disponibilizado pela ANEEL em 2023. Esses sistemas foram escolhidos por sua relevância e complexidade, possibilitando uma avaliação abrangente da eficácia

e aplicabilidade das estratégias desenvolvidas. A análise incluirá a representação geográfica no software QGIS e uma avaliação dos resultados obtidos.

5. **Avaliação comparativa e análise de resultados:** Realizar a comparação dos resultados obtidos pelas diferentes estratégias de otimização, utilizando métricas como perdas técnicas, eficiência energética, perfil de tensão e robustez do sistema. Avaliar os desempenhos para identificar a estratégia que demonstrou os melhores resultados no sistema de distribuição analisado.

Além de fornecer um programa computacional eficiente que pode ser utilizado por concessionárias no planejamento do sistema, esta tese visa contribuir com uma abordagem abrangente e rigorosa para a otimização da alocação de REDs. A aplicação dos resultados busca garantir operações mais eficientes e sustentáveis, com menor impacto técnico, promovendo avanços no gerenciamento dos sistemas de distribuição de energia elétrica.

1.3 Estrutura do Texto

Para garantir uma melhor compreensão deste trabalho, sua estrutura será organizada em cinco capítulos.

- O Capítulo 1 apresenta a introdução ao tema, destacando as justificativas, a descrição do problema e o objetivo a ser alcançado.
- O Capítulo 2 apresenta uma revisão abrangente da literatura relacionada à Geração Distribuída (GD), com foco em temas como microgeração e minigeração distribuída, bem como no Sistema de Armazenamento de Energia. São explorados aspectos relevantes, incluindo a Base de Dados Geográfica da Distribuidora, o uso do software QGIS, a análise da qualidade do fornecimento de energia elétrica e o software OpenDSS, com ênfase na modelagem de geradores fotovoltaicos e sistemas de armazenamento de energia em baterias. Além disso, o capítulo examina diferentes algoritmos de otimização, destacando estratégias evolutivas e algoritmos genéticos, complementados por uma revisão bibliográfica.
- O Capítulo 3 apresenta a metodologia adotada no trabalho, com ênfase em duas estratégias de otimização: a Estratégia Evolutiva Híbrida e o Algoritmo Genético Híbrido. São descritas as filosofias de cada meta-heurística, acompanhadas de seus pseudocódigos e fluxogramas, detalhando os principais passos e processos de implementação das técnicas.
- O Capítulo 4 apresenta os testes realizados e os resultados obtidos com a aplicação da metodologia nos sistemas IEEE de 34 barras e no Alimentador Real PD04. Os dados

são organizados em gráficos e tabelas, permitindo uma análise clara e comparativa dos algoritmos utilizados..

- O Capítulo 5 sintetiza as principais conclusões do trabalho, enfatizando os avanços alcançados e as limitações identificadas. Também são apresentadas propostas para pesquisas futuras, com o objetivo de dar continuidade e aprimorar os estudos relacionados à otimização da alocação de REDs em sistemas de distribuição elétrica.

2 Estado da Arte

2.1 Sistemas de Armazenamento de Energia

Os sistemas de armazenamento de energia (SAE) desempenham um papel crucial na transição para sistemas elétricos mais eficientes e sustentáveis. Esses sistemas permitem armazenar o excedente de geração produzido durante períodos de baixa demanda, viabilizando sua utilização em momentos de maior necessidade. Essa estratégia promove um uso racional e estratégico da energia elétrica, minimizando desperdícios e otimizando os recursos disponíveis, conforme destacado por (FERREIRA, 2020). Essa abordagem minimiza desperdícios e otimiza os recursos disponíveis, contribuindo significativamente para a eficiência energética.

Nas últimas décadas, diversas tecnologias de armazenamento têm sido desenvolvidas e continuamente aprimoradas, incluindo baterias de íons de lítio, supercapacitores e sistemas baseados em hidrogênio. Essas inovações não apenas reduzem perdas energéticas, mas também oferecem soluções eficazes para os desafios operacionais enfrentados pelos sistemas elétricos modernos, como as intermitências associadas a fontes renováveis e as flutuações nos parâmetros da rede, como tensão e frequência. Esses avanços são fundamentais para garantir a estabilidade e a confiabilidade de redes elétricas com alta penetração de geração distribuída.

Adicionalmente, os sistemas de armazenamento exercem um papel estratégico em todas as etapas do sistema elétrico, abrangendo geração, transmissão e distribuição de energia. Eles fornecem serviços essenciais que incrementam a confiabilidade e a qualidade da energia, além de promoverem um balanceamento eficiente entre carga e demanda. Esses sistemas também possibilitam a utilização otimizada da infraestrutura elétrica existente, reduzindo a necessidade de investimentos imediatos em sua expansão. Sua aplicação se estende desde redes de transmissão e distribuição até sistemas isolados, bem como soluções inovadoras voltadas para a mobilidade urbana, como veículos elétricos, reforçando sua relevância no contexto de um setor energético em transformação.

De maneira ampla, os sistemas de armazenamento oferecem uma variedade de serviços que beneficiam o sistema elétrico como um todo, independentemente de sua integração com fontes renováveis (LABORATORIES, 2010; IRENA, 2017). Entre esses serviços, destacam-se:

1. **Regulação:** Promove o balanceamento em tempo real entre a geração e o consumo de energia, garantindo a estabilidade do sistema.

2. Reserva Operacional:

- **Reserva Girante (Spinning Reserve):** Capacidade de geração conectada ao sistema, mas sem carga, que pode ser acionada para compensar interrupções imprevistas na geração ou transmissão.
 - **Reserva Suplementar (Supplemental Reserve):** Capacidade de geração adicional, geralmente não sincronizada ao sistema, que pode ser conectada para atender a demandas emergenciais.
3. **Suporte à Tensão (Voltage Support):** Consiste na geração ou absorção de energia reativa para manter a tensão do sistema dentro dos parâmetros estabelecidos.
 4. **Adiamento de Investimentos em Transmissão e Distribuição:** A capacidade dos sistemas de armazenamento de energia pode postergar a necessidade de novos investimentos em expansão da infraestrutura, ao fornecer energia adicional durante períodos específicos de alta demanda.
 5. **Qualidade de Energia (Power Quality):** Garante a manutenção de parâmetros essenciais, como forma de onda, estabilidade de tensão, níveis de harmônicos e fator de potência, para o funcionamento adequado do sistema.
 6. **Gerenciamento da Demanda (Demand Management):** Permite o ajuste do perfil de consumo energético, incentivando a redução da demanda em horários de pico por meio do armazenamento e utilização de energia em momentos estratégicos.

De acordo com (FRANCO, 2018), a ampla integração de fontes intermitentes no sistema elétrico brasileiro, assim como em outros países, como Portugal, apresenta desafios significativos, particularmente devido à imprevisibilidade e à vulnerabilidade inerentes ao suprimento de energia. Nesse contexto, embora o Brasil disponha de um expressivo potencial para o desenvolvimento e a implementação de soluções de armazenamento de energia elétrica, ainda não há projetos-piloto, demonstrativos ou experimentais que se equiparem às iniciativas avançadas observadas em outros países. (ANEEL, 2016).

Com o intuito de mitigar essa lacuna, a Agência Nacional de Energia Elétrica (ANEEL) lançou a Chamada Pública nº 21/2016, intitulada "Arranjos Técnicos e Comerciais para a Inserção de Sistemas de Armazenamento de Energia no Setor Elétrico Brasileiro". Esse programa de Pesquisa e Desenvolvimento (P&D) tem como propósito estimular iniciativas voltadas à avaliação e à integração sustentável de sistemas de armazenamento de energia no setor elétrico nacional. Além disso, busca promover o avanço tecnológico, fomentar a geração de propriedade intelectual—como o desenvolvimento de patentes—e incentivar a criação de uma infraestrutura de produção nacional, consolidando a base tecnológica do setor no Brasil (ANEEL, 2017). No início de 2017, após a análise preliminar

das propostas submetidas, a Agência Nacional de Energia Elétrica aprovou 23 projetos (ANEEL, 2017), predominantemente oriundos de concessionárias e distribuidoras de energia do Brasil. Essas iniciativas contemplam uma ampla gama de tecnologias, incluindo baterias de íons de lítio e sistemas de armazenamento de energia por compressão de ar em cavernas de sal (Compressed Air Energy Storage - CAES), destacando-se pela diversidade e pelo potencial de inovação no setor elétrico nacional.

Os sistemas de armazenamento de energia apresentam uma ampla gama de aplicações, características e limitações, que estão diretamente condicionadas pela tecnologia utilizada. Esse cenário ressalta a importância de uma análise criteriosa para assegurar que a solução selecionada esteja alinhada às especificidades e demandas da aplicação pretendida. A seguir, são apresentadas as definições dos parâmetros fundamentais que compõem essa avaliação, conforme descrito por (GALLO et al., 2016), proporcionando uma base técnica para a escolha e implementação eficiente dos SAE.

- **Capacidade de Armazenamento:** Refere-se à quantidade máxima de energia que o sistema é capaz de armazenar, expressa em Wh. Essa capacidade pode diminuir ao longo da vida útil do sistema devido a fatores como ciclos de operação, condições térmicas, entre outros.
- **Potência de Carga e Descarga:** Define a taxa máxima na qual a energia pode ser carregada ou descarregada do sistema, incluindo possíveis transformações de energia. Esse parâmetro é expresso em watts (W) e é frequentemente usado para classificar os sistemas de armazenamento, compatibilizando-os com as cargas conectadas.
- **Tempo de (Re)carga e Descarga:** Representa o período necessário para que o sistema atinja sua capacidade total de carga ou esvazie toda a energia armazenada.
- **Taxa de Autodescarga:** Relaciona-se à redução da capacidade de armazenamento ao longo do tempo devido a perdas intrínsecas à tecnologia, como atrito, dissipação térmica ou vazamentos. É geralmente expressa em Wh/h, Wh/dia, %/h ou %/dia.
- **Tempo de Resposta:** Refere-se ao intervalo necessário para que o sistema atinja a energia nominal solicitada a partir de uma condição estacionária (sem carga ou descarga). Expresso em segundos ou menos, este é um dos parâmetros mais relevantes na escolha de tecnologias para conexão ao sistema elétrico.
- **Taxa de Resposta (Ramp Rate):** Medida do tempo necessário para o sistema aumentar ou reduzir sua potência de saída durante a operação. Este parâmetro é expresso em W/s.
- **Densidade de Energia:** Relação entre a capacidade de armazenamento e o volume ou a massa do sistema, expressa em Wh/m³, Wh/l ou Wh/kg.

- **Densidade de Potência:** Relação entre a potência de descarga e o volume ou a massa do sistema, expresso em W/m^3 , W/l ou W/kg .
- **Densidade de Área (Footprint):** Relação entre a área ocupada pelo sistema e sua capacidade de armazenamento, expressa em m^2/Wh .
- **Eficiência Energética:** Relação entre a energia descarregada pelo sistema e a energia consumida para carregá-lo, representando a eficiência global do processo.
- **Vida Útil:** Indica a longevidade do sistema, que pode ser expressa em número de ciclos (especialmente para baterias eletroquímicas), energia fornecida de forma acumulada ou tempo de operação.
- **Profundidade de Descarga (DOD – Depth of Discharge):** Representa a quantidade máxima de energia que pode ser extraída do sistema sem comprometer sua durabilidade. Por exemplo, baterias de chumbo-ácido podem ter sua vida útil reduzida se descarregadas completamente.
- **Nível de Maturidade da Tecnologia:** Refere-se ao grau de consolidação da tecnologia no mercado. Tecnologias maduras possuem maior confiabilidade, pois já passaram por múltiplas aplicações e problemas conhecidos foram mitigados, reduzindo os riscos para investidores.
- **Flexibilidade de Implantação:** Avaliação de restrições geográficas (como relevo ou características do subsolo) e técnicas (como conectividade ao sistema elétrico), além de seus impactos na viabilidade do sistema.
- **Impactos Ambientais:** Considera os efeitos ambientais associados à instalação, operação e manutenção, bem como os desafios relacionados ao descarte ou reciclagem de materiais obsoletos no descomissionamento.
- **Custo de Investimento:** Engloba os custos de aquisição de equipamentos, dispositivos e outros elementos necessários para a implementação do sistema.
- **Custos Operacionais:** Abrange as despesas com manutenção, operação e atividades administrativas essenciais para o funcionamento adequado do sistema.

Atualmente, os Sistemas de Armazenamento de Energia (SAEs) apresentam uma ampla variedade de soluções tecnológicas, desenvolvidas com o objetivo de gerenciar o fornecimento de energia de maneira mais eficiente e confiável. Essas tecnologias desempenham um papel fundamental na estruturação de sistemas energéticos mais resilientes, conforme destacado por (OLABI, 2017). Entre as principais tecnologias de armazenamento de energia, destacam-se:

- **Sistemas de Armazenamento Magnéticos Supercondutores (SMES);**
- **Capacitores e Supercapacitores;**
- **Baterias de Ácido-Chumbo (PbA);**
- **Baterias de Níquel-Cádmio (NiCd) e Níquel-Hidreto Metálico (NiMH);**
- **Baterias de Sódio-Enxofre (NaS);**
- **Baterias de Íons de Lítio (Li);**
- **Hidrogênio como vetor energético;**
- **Centrais Hidrelétricas Reversíveis (PHS);**
- **Ar Comprimido (CAES – Compressed Air Energy Storage);**
- **Volantes de Inércia;**
- **Sistemas de Armazenamento Térmico.**

Nas próximas seções, será realizado um aprofundamento sobre o armazenamento de energia por meio de baterias, que representa o principal foco deste estudo. A análise abordará os diferentes tipos de baterias, suas características específicas e aplicações no contexto de sistemas elétricos e energéticos, enfatizando sua relevância e potencial no cenário atual.

2.1.1 Sistemas de Armazenamento de Energia em Baterias

O funcionamento das baterias fundamenta-se em reações químicas que possibilitam a conversão reversível de energia química em elétrica e vice-versa (SILVA, 2008). Essa propriedade lhes confere alta versatilidade, tornando-as essenciais para uma ampla gama de aplicações energéticas.

De acordo com (SILVA, 2008), as baterias possuem vantagens como baixas emissões de poluentes, operação silenciosa e reduzida necessidade de manutenção. No entanto, conforme o relatório da International Renewable Energy Agency (IRENA, 2015), o custo e o desempenho dessas tecnologias variam significativamente em função de fatores como condições de uso, local de instalação, características ambientais, custos de fabricação, disponibilidade de materiais e despesas de manutenção.

Embora existam desafios inerentes, o mercado global de armazenamento em baterias tem registrado um crescimento notável nos últimos anos. Segundo a International Energy Agency (IEA, 2022), a capacidade instalada em escala de rede atingiu aproximadamente 16 GW até o final de 2021, com a maior parte desse total adicionada ao sistema durante

os últimos cinco anos. Em 2021, observou-se um incremento de 60% em relação ao ano anterior, com 6 GW de nova capacidade instalados globalmente. No panorama regional, os Estados Unidos lideraram esse crescimento em 2021, adicionando 1,90 GW e alcançando uma capacidade total de 5,20 GW, um avanço expressivo em comparação aos 0,20 GW registrados em 2015. A China, que não apresentava capacidade instalada em 2015, alcançou 0,10 GW em 2016 e atingiu impressionantes 3,70 GW em 2021, com um acréscimo de 1,90 GW apenas nesse último ano, segundo a (IEA, 2022). Paralelamente, a Europa consolidou sua posição como um dos mercados mais relevantes para o armazenamento em baterias, reafirmando seu papel de destaque nesse setor em ascensão.

2.1.1.1 Baterias de chumbo-ácido (PbA)

As baterias de ácido-chumbo são amplamente utilizadas em sistemas de armazenamento de energia de curto e médio prazo, com aplicação destacada em redes isoladas (FUCHS et al., 2012). De acordo com a (IEC, 2011), essas baterias também são empregadas em sistemas fotovoltaicos e na mitigação de flutuações na geração de energia eólica.

Conforme observado por (FUCHS et al., 2012), as baterias de chumbo-ácido são comercializadas por diversos fabricantes em escala global, permitindo atender às demandas do setor. No entanto, apesar de sua disponibilidade no mercado, sua produção ainda não alcançou níveis de larga escala industrial. Ressalta-se que o custo de instalação dessas baterias varia entre 560,00 R\$/kWh e 1.120,00 R\$/kWh (FUCHS et al., 2012). Além disso, essas baterias possuem uma ampla gama de potência, variando de 1 kW a 10 MW, conforme descrito por (GAUTAM, 2018).

Segundo (LUO et al., 2015), as baterias de chumbo-ácido apresentam baixa taxa de autodescarga (inferior a 0,3%) e um custo competitivo em relação a outros tipos de baterias. Adicionalmente, a (IEC, 2011) aponta que sua vida útil está entre 6 e 15 anos, com aproximadamente 1.500 ciclos de carga e descarga a uma profundidade de 80% (quantidade de capacidade efetivamente utilizável). Os níveis de eficiência de ciclo podem alcançar valores entre 80% e 90%, dependendo das condições de operação. Contudo, a durabilidade dessas baterias está diretamente relacionada à profundidade de descarga e ao estado de carga durante sua utilização.

Por outro lado, as baterias de chumbo-ácido apresentam limitações importantes. A (IEC, 2011) e (FUCHS et al., 2012) destacam sua baixa densidade de energia, variando entre 50 Wh/L e 100 Wh/L, além do uso do chumbo, um material tóxico e regulamentado em várias regiões. Devido a essas restrições e à toxicidade do chumbo, a reciclagem dessas baterias é essencial. Conforme (FUCHS et al., 2012), o chumbo contido nas baterias pode ser reciclado e reutilizado na fabricação de novas unidades, contribuindo para a redução de impactos ambientais e garantindo maior sustentabilidade ao ciclo de vida do produto.

2.1.1.2 Baterias de níquel-cádmio (NiCd) e níquel-hidreto metálico (NiMH))

De acordo com (LUO et al., 2015), as baterias de níquel-cádmio (NiCd) utilizam hidróxido de níquel e cádmio metálico como eletrodos, em combinação com uma solução aquosa alcalina como eletrólito. Há uma ampla variedade de materiais combinados com o níquel, que resultam em diferentes tipos de baterias, com características, desempenho e custos variados (LUO et al., 2015). No entanto, as baterias de NiCd e níquel-hidreto metálico (NiMH) são as mais difundidas, e, por essa razão, esta pesquisa aborda exclusivamente essas duas tecnologias.

As baterias de níquel-cádmio apresentam vantagens significativas em relação às baterias de chumbo-ácido, como maior densidade de potência, densidade de energia e número de ciclos, mantendo uma vida útil comparável, entre 5 e 15 anos (IEC, 2011). Conforme (GAUTAM, 2018), a potência das baterias NiCd pode variar entre 1 kW e 500 kW, o que amplia suas possibilidades de aplicação.

Sob o ponto de vista técnico, as baterias NiCd seladas possuem alta confiabilidade no mercado. Segundo a (IEC, 2011), são as únicas capazes de operar eficientemente em temperaturas extremas, entre -20 °C e -40 °C, sem comprometimento significativo de desempenho. (FUCHS et al., 2012) corroboram que essas baterias mantêm sua funcionalidade mesmo em condições ambientais adversas. Já as baterias NiCd ventiladas operam de forma semelhante às baterias de chumbo-ácido e são amplamente utilizadas para estabilizar a energia proveniente de fontes intermitentes, como a eólica (FATHIMA; PALANISAMY, 2016). Contudo, devido à toxicidade do cádmio, o uso dessas baterias foi restringido na Europa, sendo atualmente aplicadas apenas em sistemas estacionários (IEC, 2011).

Uma limitação importante das baterias de NiCd é o chamado "efeito memória". Segundo (LUO et al., 2015), quando recarregadas repetidamente após descargas parciais, sua capacidade máxima pode ser significativamente reduzida, limitando sua eficiência a longo prazo.

As baterias de níquel-hidreto metálico (NiMH) compartilham todas as vantagens das baterias de NiCd, mas com densidade de energia substancialmente superior, variando entre 170 e 420 Wh/L (LUO et al., 2015). Além disso, possuem uma energia específica moderada, de 70 a 100 Wh/kg, tornando-as ideais para sistemas que exigem alta densidade energética e apresentam restrições de peso (LUO et al., 2015).

Embora as baterias de NiMH estejam sendo gradualmente substituídas pelas de íons de lítio, elas ainda desempenham um papel importante em veículos híbridos. Segundo (IEC, 2011), as baterias NiMH seladas são amplamente utilizadas nesses veículos devido à sua maior segurança em comparação com as de lítio, além de apresentarem custos equivalentes. Essa combinação de características torna as baterias NiMH uma opção confiável para aplicações específicas, mesmo em um mercado dominado por tecnologias mais modernas.

2.1.1.3 Baterias de sódio-enxofre (NaS)

As baterias de sódio-enxofre (NaS) utilizam um eletrólito sólido, em vez de um fluido, composto por cerâmica de beta-alumina (IEC, 2011). Segundo a (IEC, 2011), essas baterias são constituídas por enxofre líquido fundido no anodo e sódio líquido fundido no catodo.

Para alcançar a alta condutividade iônica necessária e manter os eletrodos em estado líquido, as baterias devem operar em temperaturas elevadas, entre 270°C e 350°C (FUCHS et al., 2012). De acordo com (FUCHS et al., 2012), quando resfriadas, as baterias tornam-se incapazes de realizar os processos de carga e descarga, além de haver risco de rachaduras no eletrólito cerâmico.

Em aplicações cotidianas, (FUCHS et al., 2012) observam que a temperatura de operação pode ser sustentada pelo calor gerado pelas reações químicas da bateria, desde que o isolamento térmico seja adequadamente projetado. Isso torna as baterias NaS adequadas para aplicações com ciclagem diária, mas limitadas para sistemas que demandam energia ininterrupta (*UPS*) com longos períodos de espera. Em geral, essas baterias são utilizadas para armazenamento de energia de médio prazo.

As baterias NaS possuem ciclos de vida estimados em cerca de 4.500 ciclos (IEC, 2011) e vida útil entre 15 e 20 anos, (FUCHS et al., 2012). Conforme a (IEC, 2011), o tempo de descarga varia entre 6 e 7,2 horas, com eficiência de 75% e resposta rápida na ordem de milissegundos. Essas baterias suportam altas potências, variando de 500 kW a 50 MW, apresentam densidade de energia moderada (150 a 300 Wh/L) e praticamente nenhuma autodescarga diária (LUO et al., 2015). Outro ponto positivo é a profundidade de descarga de 100%, conforme destacado por (FUCHS et al., 2012). (LUO et al., 2015) também ressaltam a vantagem do uso de materiais não tóxicos, o que contribui para sua alta reciclabilidade, estimada em 99%.

As características dessas baterias permitem sua aplicação em sistemas de melhoria da qualidade da energia e em projetos que demandam alta densidade de energia (IEC, 2011). Adicionalmente, elas podem atender aos requisitos de estabilização da rede elétrica, sendo atrativas para concessionárias e grandes consumidores. Essas baterias são uma tecnologia comercialmente viável e têm sido empregadas no suporte à integração de fontes renováveis, como energia eólica e solar (FATHIMA; PALANISAMY, 2016).

Embora estejam disponíveis comercialmente, as baterias NaS ainda enfrentam desafios relacionados à sua difusão. De acordo com (FUCHS et al., 2012), a oferta limitada por parte dos fabricantes restringe sua adoção em larga escala. Entretanto, há iniciativas na Europa para ampliar a produção desse tipo de bateria (FUCHS et al., 2012). Sistemas operacionais já estão em uso na Alemanha, França, Estados Unidos e Emirados Árabes Unidos, com finalidades diversas, como armazenamento de energia renovável em ilhas,

recarga de veículos em trânsito e nivelamento de carga, incluindo projetos com potência nominal de 40 MW (LUO et al., 2015).

Uma desvantagem significativa dessas baterias é a necessidade de manutenção rigorosa das temperaturas operacionais, já que o desempenho é comprometido fora da faixa especificada (IEC, 2011). Além disso, o custo elevado, entre 2.800,00 R\$/kWh e 3.920,00 R\$/kWh (FUCHS et al., 2012), reflete a necessidade de sistemas adicionais para manter as condições térmicas adequadas.

2.1.1.4 Baterias de íons de lítio (Li)

De acordo com Fuchs et al. (2012), as baterias de íons de lítio são compostas por um eletrodo positivo de óxido metálico de lítio e um eletrodo negativo de carbono grafitico. O eletrólito consiste em sais de lítio dissolvidos em carbonatos orgânicos. Durante o carregamento, os íons de lítio migram do eletrodo positivo para o negativo, sendo intercalados entre as camadas de grafite. No processo de descarga, o movimento é invertido, com os íons retornando ao eletrodo positivo e se alojando na estrutura cristalina (FUCHS et al., 2012).

As baterias de íons de lítio são amplamente utilizadas para armazenamento de energia de médio prazo, embora também possam ser aplicadas em sistemas de curto prazo. Segundo a *International Electrotechnical Commission* (IEC, 2011), elas têm substituído as baterias de níquel-hidreto metálico (NiMH) seladas devido à sua superioridade técnica. Uma célula de íons de lítio pode atingir tensões de até 3,7 V, enquanto as baterias de NiMH possuem tensão limitada a 1,2 V, permitindo que uma célula de íons de lítio substitua três células de NiMH (IEC, 2011).

Entre as vantagens das baterias de íons de lítio, destacam-se a alta densidade energética, variando de 200 Wh/L a 350 Wh/L (FUCHS et al., 2012), e a elevada eficiência, que atinge entre 95% e 98% (IEC, 2011). Além disso, essas baterias apresentam grande flexibilidade, com tempos de descarga que podem variar de segundos a semanas, tornando-as adequadas para uma ampla gama de aplicações. (LUO et al., 2015) apontam que as baterias de íons de lítio são ideais para aplicações que exigem tempo de resposta rápido, dimensões compactas ou baixo peso, com tempos de resposta variando entre 3 ms e 5 ms (FUCHS et al., 2012). Outro destaque é a possibilidade de suportar até 5.000 ciclos de carga e descarga, com ciclos adicionais dependendo dos materiais empregados nos eletrodos (IEC, 2011). (GAUTAM, 2018) acrescenta que essas baterias podem alcançar potências de até 5 MW.

De acordo com (FUCHS et al., 2012), as baterias de íons de lítio apresentam uma ampla variedade de combinações de materiais para eletrodos e eletrólitos, o que resulta em características distintas. Essa diversidade possibilita aplicações específicas, mas também mantém o desenvolvimento em curso, uma vez que não há um arranjo definitivo que se

destaque para grandes sistemas de armazenamento de energia.

([LUO et al., 2015](#)) relatam que a AES Energy Storage, sediada em Nova Iorque, opera sistemas comerciais de armazenamento com baterias de íons de lítio. Em 2010, a empresa implementou um sistema com potência nominal de 8 MW, ampliado para 16 MW em 2011, destinado ao fornecimento de regulação de frequência.

Apesar das vantagens, as baterias de íons de lítio enfrentam desafios significativos. Segundo ([FUCHS et al., 2012](#)), a vida útil é limitada, variando em torno de 5 anos, e os custos permanecem elevados, acima de 3.000 R\$/kWh, devido à necessidade de embalagem especial e circuitos internos de proteção. Além disso, questões de segurança são críticas, pois os eletrodos de óxido metálico são termicamente instáveis e podem liberar oxigênio em altas temperaturas, gerando risco de fuga térmica ([IEC, 2011](#)). Para mitigar esses problemas, as baterias são equipadas com sistemas de monitoramento que evitam sobrecarga e descarga excessiva. A ([IEC, 2011](#)) também aponta que a redução de custos pode ser alcançada com a produção em larga escala, o que tornaria essas baterias mais acessíveis para aplicações comerciais.

2.2 Geração Distribuída

O conceito de "Geração Distribuída"(GD) tem se tornado cada vez mais relevante, impulsionado pela crescente demanda por energia elétrica e pelos avanços tecnológicos que facilitaram sua integração nos sistemas elétricos. No Brasil, o Decreto-Lei 5.163/2004 ([BRASIL, 2004](#)) define GD como a produção de energia elétrica conectada diretamente ao sistema de distribuição, estabelecendo, no entanto, restrições quanto à inclusão de grandes hidrelétricas e termelétricas de baixa eficiência energética.

“Art. 14. Para os fins deste Decreto, considera-se geração distribuída a produção de energia elétrica proveniente de empreendimentos de agentes concessionários, permissionários ou autorizados, incluindo aqueles tratados pelo art. 8º da Lei no 9.074, de 1995, conectados diretamente no sistema elétrico de distribuição do comprador, exceto aquela proveniente de empreendimento:

I - hidrelétrico com capacidade instalada superior a 30 MW; e

II - termelétrico, inclusive de cogeração, com eficiência energética inferior a setenta e cinco por cento, conforme regulação da ANEEL, a ser estabelecida até dezembro de 2004.

Parágrafo único. Os empreendimentos termelétricos que utilizem biomassa ou resíduos de processo como combustível não estarão limitados ao percentual de eficiência energética prevista no inciso II do caput.”([BRASIL, 2004](#)).

Além disso, a REN 482/2012 ([BRASIL, 2012](#)) introduziu conceitos específicos de microgeração e minigeração distribuída, destacando a importância das fontes renováveis, conforme apresentado no Art. 2º, inciso I e II.

"I - microgeração distribuída: central geradora de energia elétrica, com potência instalada menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras; (Redação dada pela REN ANEEL 687, de 24.11.2015.)

II - minigeração distribuída: central geradora de energia elétrica, com potência instalada superior a 75 kW e menor ou igual a 5MW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras; (Redação dada pela REN ANEEL 786, de 17.10.2017)". (BRASIL, 2012)

O estudo de (GONZALEZ-LONGATT; FORTOUL, 2005) apresenta uma definição abrangente e qualitativa de Geração Distribuída (GD), caracterizando-a como qualquer fonte de energia elétrica conectada diretamente à rede de distribuição ou instalada no local do consumidor. Essa definição destaca a escala reduzida da GD em comparação às grandes usinas geradoras centrais, enfatizando sua descentralização. Essa visão está alinhada com a definição proposta pelo Instituto Nacional de Eficiência Energética (INEE), que conceitua a GD como a geração de energia elétrica realizada nas proximidades ou diretamente no ponto de consumo, independentemente da potência instalada, da tecnologia empregada ou da fonte energética utilizada.

Os avanços tecnológicos no setor têm permitido que as soluções de GD incorporem sistemas de potências cada vez menores, ampliando sua aplicabilidade e diversidade. Dentre as tecnologias que integram a GD, destacam-se:

- Cogeração;
- Centrais Geradoras Hidroelétricas (CGH);
- Centrais Geradoras Eólicas (EOL);
- Centrais Geradoras Solares Fotovoltaicas (UFV);
- Usinas Termelétricas (UTE).

Essa abordagem flexível e tecnológica tem contribuído para o aumento da adoção da GD, promovendo benefícios como a descentralização da geração, maior eficiência no uso de recursos e redução de perdas na transmissão de energia.

2.3 Recursos Energéticos Distribuídos

Os Recursos Energéticos Distribuídos (RED, ou *Distributed Energy Resources* – DER em inglês) são definidos como tecnologias de geração e/ou armazenamento de energia

elétrica localizadas dentro da área de concessão de uma distribuidora, normalmente junto às unidades consumidoras e instaladas "atrás do medidor" (*behind-the-meter*). Conforme destacado pela (FGV, 2016), essa definição tem sido ampliada para incluir também iniciativas como eficiência energética, resposta da demanda (RD) e gerenciamento pelo lado da demanda (GLD).

Com base nesse conceito, os RED podem ser classificados em cinco categorias principais:

- geração distribuída (GD),
- armazenamento de energia,
- veículos elétricos (VE) e suas infraestruturas de recarga,
- eficiência energética e
- resposta da demanda (RD).

Essas tecnologias desempenham um papel essencial na promoção de uma maior participação dos consumidores, tanto na geração quanto na gestão do consumo de sua própria energia, fomentando a descentralização dos sistemas elétricos (FGV, 2016).

O crescimento acelerado dos Recursos Energéticos Distribuídos, associado às suas características inovadoras, destaca o potencial transformador dessas tecnologias, capazes de provocar mudanças significativas nos sistemas elétricos, tradicionalmente estruturados em grandes unidades centralizadas. O (COUNCIL, 2017) prevê que, no período de 2017 a 2025, muitos países passarão por uma transição de sistemas majoritariamente centralizados para configurações híbridas. Essa evolução rumo a um modelo mais distribuído deve reconfigurar os fluxos de energia e incrementar substancialmente a complexidade operacional dos sistemas elétricos, como ilustrado na Figura 2.1.

A inserção massiva de RED no setor elétrico exigirá a adoção de novas práticas de planejamento para expansão e operação das redes e da geração de energia. Embora representem desafios consideráveis, os RED também trazem inúmeros benefícios ao sistema elétrico. Primeiramente, a proximidade entre geração e consumo possibilita a redução significativa de perdas elétricas. Além disso, conforme (PEREZ-ARRIAGA et al., 2016), os RED, quando posicionados em locais estratégicos e operados em momentos oportunos, podem oferecer níveis elevados de confiabilidade ao sistema, especialmente em situações extremas.

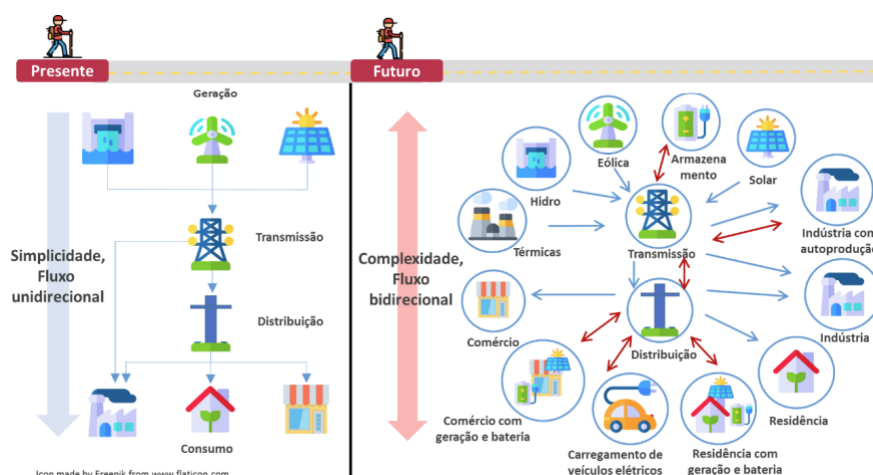


Figura 2.1 – Sistemas Elétricos: Cenários Atuais e Perspectivas Futuras

Fonte: (NYISO, 2017)

2.3.1 Impactos da conexão dos Recursos Energéticos Distribuídos

Os incentivos aos Recursos Energéticos Distribuídos (RED) são fundamentados nos diversos benefícios que essas tecnologias podem proporcionar ao sistema elétrico. De acordo com (PEREZ-ARRIAGA et al., 2016), a integração dessas soluções à rede elétrica pode gerar impactos relevantes nas dimensões econômica, ambiental e social. Entre os principais efeitos observados, destacam-se:

1. Expansão da matriz elétrica: Os Recursos Energéticos Distribuídos (REDs) promovem uma rápida ampliação da oferta de eletricidade no país, contribuindo para a redução de custos e o aumento da disponibilidade de energia elétrica, (SOLAR, 2022);
2. Mitigação de perdas elétricas: A descentralização da geração permite que a energia seja produzida no local de consumo ou em sua proximidade imediata. Essa estratégia reduz significativamente as perdas por efeito Joule nos condutores dos sistemas de transmissão e distribuição, que tradicionalmente ocorrem devido ao transporte de eletricidade por longas distâncias, elevando, assim, a eficiência do sistema elétrico;
3. Incremento nos investimentos: Os REDs incentivam indivíduos e empresas a se tornarem produtores de energia, com investimentos oriundos de capital próprio ou financiamento. Esse movimento reduz a necessidade de aportes financeiros por parte do governo ou de concessionárias, que tradicionalmente investem em grandes usinas ou na infraestrutura de rede por meio de leilões onerosos e burocráticos, (SOLAR, 2022);

4. Desafios na tarifação do uso do sistema elétrico: A legislação e os incentivos relacionados aos REDs tornam a formulação de políticas tarifárias complexa, envolvendo diferentes interpretações entre entes federativos e gerando incertezas jurídicas, (EPBR, 2022);
5. Possibilidade de incidência tributária: Algumas concessionárias têm aplicado tributos sobre a energia gerada, ao invés da energia injetada na rede. Esse procedimento resulta na tarifação de energia autoproduzida, mesmo sem sua comercialização ou transporte pela rede elétrica, (EPBR, 2022);
6. Adequação dos procedimentos das distribuidoras: A transição de um fluxo de potência unidirecional para bidirecional nas redes de distribuição exige que as concessionárias adaptem suas operações. Esse processo demanda a implementação de equipamentos modernos e sensíveis, capazes de garantir a segurança operacional e a proteção do sistema e de seus trabalhadores;
7. Impactos na tensão do sistema: A inserção indiscriminada de geração distribuída, especialmente em altas penetrações, pode elevar os níveis de tensão para além dos limites regulamentares. Essa situação compromete a funcionalidade de dispositivos conectados ao sistema e pode inviabilizar sua operação segura, (SANTOS; NEGRETE; BRITO, 2021);
8. Impactos de curto-circuito: Embora REDs de pequeno porte apresentem impactos limitados nos níveis de curto-circuito, a integração de múltiplas unidades de pequeno e médio porte pode alterar significativamente esses níveis, ocasionando desafios na coordenação da proteção em redes de distribuição, (QUIRIOGA, 2019);
9. Impactos nos sistemas de proteção: A potência e localização dos REDs influenciam diretamente as contribuições de curto-circuito, alterando a seletividade, coordenação e sensibilidade dos sistemas de proteção. Para garantir a segurança e a confiabilidade, é essencial a modernização para sistemas de proteção baseados em tecnologias microprocessadas, (Júnior; FERREIRA, 2017).

2.4 Qualidade do Fornecimento de Energia Elétrica

O Módulo 8 do PRODIST (ANEEL, 2021a) estabelece diretrizes específicas que as concessionárias de energia elétrica devem seguir para garantir a qualidade na distribuição de energia. Essas diretrizes abrangem tanto os atributos técnicos relacionados ao fornecimento de energia elétrica quanto a excelência na prestação de serviços. Os objetivos delineados no módulo incluem a regulamentação de procedimentos voltados à qualidade do fornecimento, com destaque para a conformidade das ondas de tensão e a continuidade do serviço.

O conjunto normativo descrito no Módulo 8 define indicadores de desempenho, valores de referência, metodologias de medição e mecanismos para a gestão de reclamações associadas a eventos que possam comprometer a qualidade do produto. Além disso, o módulo estipula padrões e responsabilidades no que tange à qualidade do serviço, abordando aspectos como a continuidade do fornecimento e o atendimento em situações emergenciais.

Outro elemento de relevância é o detalhamento dos procedimentos de gestão de reclamações, incluindo diretrizes para a apuração e comunicação de incidentes relacionados a acidentes de trabalho e eventos que envolvam terceiros. Adicionalmente, o módulo estabelece regras para a compensação de consumidores afetados e a obrigação do envio regular de relatórios à ANEEL, promovendo transparência, eficiência e aprimoramento contínuo na regulação do setor elétrico.

As disposições apresentadas no Módulo 8 possuem ampla aplicabilidade, abrangendo não apenas as distribuidoras de energia elétrica, mas também consumidores, centrais geradoras, agentes importadores e exportadores de energia, transmissoras e o Operador Nacional do Sistema Elétrico (ONS). Essa abrangência visa assegurar uniformidade e eficácia na gestão da qualidade do fornecimento em todo o território nacional.

A conformidade com os limites de variação de tensão e do fator de potência em regime permanente é essencial para o desempenho eficiente e confiável dos sistemas elétricos. A (ANEEL, 2021a) aborda essas questões de forma detalhada, destacando a importância de critérios rigorosos para garantir a estabilidade operacional do fornecimento.

Em relação às variações de tensão em regime permanente, o Módulo 8 define parâmetros rigorosos para garantir que os níveis de tensão no ponto de conexão estejam classificados como adequados, precários ou críticos, conforme os limites estabelecidos. As distribuidoras são responsáveis pelo monitoramento contínuo desses parâmetros em toda a rede de distribuição, devendo utilizar tecnologias avançadas e implementar estratégias preventivas para assegurar que os níveis de tensão permaneçam dentro dos padrões regulamentados.

No tocante às tensões contratadas com as distribuidoras, são aplicados critérios específicos para consumidores com tensão nominal igual ou superior a 2,3 kV. A tensão contratada no ponto de conexão deve estar dentro da faixa de 95% a 105% da tensão nominal de operação do sistema, garantindo compatibilidade com os valores especificados ou recomendados para o transformador da unidade consumidora.

No que diz respeito ao fator de potência em regime permanente, o Módulo 8 estabelece faixas específicas com o objetivo de promover a eficiência energética e a estabilidade do sistema elétrico. Para consumidores do Grupo A ou pontos de conexão com tensão nominal inferior a 230 kV, o fator de potência deve permanecer dentro do intervalo entre 0,92 e 1,00 indutivo ou entre 1,00 e 0,92 capacitivo, conforme definido nas Regras de

Prestação do Serviço Público de Distribuição de Energia Elétrica.

Essas normas desempenham um papel crucial na garantia da estabilidade, confiabilidade e eficiência do sistema elétrico, ao assegurar um fornecimento contínuo e de elevada qualidade para os consumidores. Além disso, contribuem diretamente para o equilíbrio operacional da rede de distribuição, reduzindo perdas e otimizando a utilização da infraestrutura elétrica.

2.5 Base de Dados Geográfica da Distribuidora (BDGD)

A Base de Dados Geográfica da Distribuidora (BDGD) configura-se como um elemento fundamental no escopo do Sistema de Informação Geográfica Regulatório (SIG-R), regulamentado pela Agência Nacional de Energia Elétrica (ANEEL). Essa base é concebida para representar, de forma simplificada, o sistema elétrico real das distribuidoras, destacando a condição dos ativos e reunindo informações técnicas e comerciais de interesse estratégico.

A BDGD é composta por dados fornecidos pelas concessionárias à ANEEL, abrangendo informações detalhadas sobre a base de consumidores, ativos operacionais e o consumo de energia elétrica, entre outros aspectos relevantes (SANTOS et al., 2024). Esses dados, quando integrados a outras bases informacionais da ANEEL e de instituições correlatas, formam o SIG-R, contribuindo para a regulação e o monitoramento eficiente do setor elétrico brasileiro (ANEEL, a).

O Módulo 10 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) estabelece os padrões para o formato, a organização e o envio das informações contidas na Base de Dados Geográfica da Distribuidora (BDGD), além de especificar os prazos e métodos de submissão à Agência Nacional de Energia Elétrica (ANEEL, a). De acordo com as diretrizes do PRODIST, os dados da BDGD são classificados em dois grupos principais: entidades geográficas e não geográficas.

As entidades geográficas compreendem elementos e atributos georreferenciados, como subestações, unidades consumidoras e redes elétricas, enquanto as entidades não geográficas consistem em tabelas de informações, incluindo registros de perdas técnicas e não técnicas. No total, a BDGD é composta por 45 entidades distintas, abrangendo um amplo espectro de dados relevantes para a regulação do setor elétrico (SANTOS et al., 2024).

Para garantir a padronização e a integração das informações incorporadas ao Sistema de Informação Geográfica Regulatório (SIG-R), as concessionárias devem observar os modelos, requisitos e especificações estabelecidos no Módulo 10 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) e no Manual de

Instruções da BDGD. ([ANEEL, b](#); [ANEEL, c](#)). A estrutura da Base de Dados Geográfica da Distribuidora (BDGD) abrange entidades que representam diversos elementos estratégicos, desde os ativos físicos da rede elétrica até as perdas estimadas pelos agentes do setor. Essas entidades são descritas com base na codificação normatizada pelo Dicionário de Dados ANEEL do SIG-R (DDA), que fornece padrões regulamentares para a organização e uniformização das informações, assegurando consistência e compatibilidade na gestão dos dados ([ANEEL, a](#)).

As informações cartográficas são fornecidas pelas concessionárias por meio de arquivos no formato Geodatabase (.gdb). O Manual de Instruções da BDGD, em conjunto com o Módulo 10 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), estabelece diretrizes detalhadas sobre as entidades incluídas nesses arquivos, bem como especificações precisas para os seus respectivos campos. Essas orientações asseguram a padronização e a integridade dos dados, facilitando sua integração ao Sistema de Informação Geográfica Regulatório ([ANEEL, b](#); [ANEEL, c](#)).

2.6 Software QGIS

O QGIS é uma ferramenta de Sistema de Informações Geográficas (SIG) de acesso gratuito e código aberto, amplamente reconhecida por oferecer suporte à visualização, edição e análise de dados geoespaciais. O nome QGIS tem origem na biblioteca Qt ("Q") e no conceito de Sistema de Informação Geográfica ("GIS"). A plataforma é fruto de uma colaboração global de desenvolvedores e, desde 2007, integra o portfólio de projetos da Open Source Geospatial Foundation, consolidando-se como uma referência no desenvolvimento de tecnologias geoespaciais de código aberto, ([MARQUES, 2021](#)).

Este sistema é fundamental para a manipulação e análise de dados espaciais, abrangendo todas as etapas do gerenciamento e aplicação de informações geográficas digitais, como os formatos vetoriais e raster, amplamente empregados em software SIG ([MARQUES, 2021](#)). A plataforma foi originalmente idealizada em 2002 por Gary Sherman, tendo sua primeira versão oficial lançada em 2009 sob o nome Quantum GIS ([FRANÇA, 2021](#)).

A plataforma disponibiliza um conjunto robusto de ferramentas voltadas para o processamento de dados espaciais ([FRANÇA, 2021](#)), permitindo não apenas a visualização e edição, mas também a execução de análises espaciais e temporais. Entre suas funcionalidades, destacam-se o acesso a bancos de dados, a utilização de recursos integrados à internet, a visualização tridimensional de mapas e a realização de análises multicritério. Adicionalmente, o QGIS permite a criação, redimensionamento, remodelagem, medição e fusão de múltiplas camadas de dados, entregando resultados de elevada qualidade técnica e precisão cartográfica, ([MARQUES, 2021](#); [FRANÇA, 2021](#)).

Um dos diferenciais do QGIS é sua interface amigável e intuitiva, que facilita o aprendizado e o uso das funcionalidades disponíveis, (FRANÇA, 2021), proporcionando a realização de tarefas como a visualização, organização, edição e análise de dados, além da elaboração de mapas para impressão. Entre as inúmeras possibilidades que a ferramenta oferece, destacam-se a criação de mapas temáticos, cartas geográficas e plantas topográficas com diferentes tipos de camadas e projeções cartográficas, bem como a coleta, edição e análise de dados geoespaciais. Adicionalmente, o software possibilita a execução de operações avançadas de geoprocessamento, como buffer, interseção, recorte, diferença e união de dados espaciais.

2.7 Software OpenDSS

O software OpenDSS (Distribution System Simulator) é uma ferramenta abrangente de simulação de sistemas de energia elétrica, voltada especificamente para sistemas de distribuição de energia. Seu desenvolvimento teve início em 1997 na Electrotek Concepts, Inc., sob a liderança de Roger Dugan e Thomas McDermott, com o objetivo principal de apoiar as análises de redes que envolvem geração distribuída (GD). Utilizando uma linguagem de programação orientada a objetos, o software foi baseado nas linguagens e sistemas de conversão existentes na época.

Em 2004, o DSS foi adquirido pelo Electric Power Research Institute (EPRI) e, em 2008, o EPRI lançou o software sob uma licença de código aberto (open source). No setor elétrico brasileiro, o OpenDSS se destacou como o simulador recomendado pela ANEEL para cálculos de fluxo de carga, destinados à estimativa de perdas técnicas em sistemas de distribuição de média e baixa tensão, conforme a Nota Técnica nº 0057/2014-SRD (ANEEL, 2014).

Para o fluxo de potência, o OpenDSS oferece diversos modos de solução, incluindo: fluxo de potência instantâneo (Snapshot Power Flow), fluxo de potência diário (Daily Power Flow) e fluxo de potência anual (Yearly Power Flow). O cálculo do fluxo de carga é realizado pelo método de injeção de correntes, que utiliza a técnica de decomposição da matriz de admitâncias nodais (ANEEL, 2014).

Além de sua eficácia, o OpenDSS foi escolhido pela ANEEL por várias razões: é um software de código aberto, permitindo personalizações via programação, e é expansível, possibilitando adaptações conforme as necessidades do usuário. No entanto, apesar de suas muitas vantagens, o OpenDSS apresenta algumas limitações, como a ausência de uma interface gráfica, a necessidade de um alto nível de conhecimento técnico por parte do analista, e o domínio da sintaxe de cada linha de comando (ANEEL, 2014).

Para suprir essas necessidades e limitações, é possível utilizar softwares externos que trabalham em conjunto com o OpenDSS, graças à interface COM existente em sua

base (EPRI, 2022). A interface COM do OpenDSS possibilita o desenvolvimento de algoritmos em outros programas, como VBA Excel, MATLAB, Python, entre outros, com o objetivo de controlar o OpenDSS e implementar funcionalidades que não estão diretamente incorporadas em seu código fonte. Por exemplo, algoritmos específicos de otimização podem ser desenvolvidos externamente, mesmo que apenas alguns estejam atualmente implementados no software (EPRI, 2022).

Esses algoritmos complexos externos utilizam o OpenDSS para modelar o comportamento do sistema de distribuição, ajustando as variáveis que se deseja otimizar. Uma capacidade destacada da interface COM é a capacidade de realizar loops nos códigos externos, algo que não é nativamente suportado na linguagem de programação do OpenDSS (EPRI, 2022).

O comando mais próximo de um loop na linguagem do OpenDSS é o comando `Next`, que simplifica a iteração temporal. Mesmo que loops fossem possíveis na linguagem do OpenDSS, sua execução seria mais lenta devido à necessidade de interpretação contínua do loop. Por outro lado, códigos com loops são facilmente escritos em outras linguagens de programação e geralmente executados com maior eficiência. A estrutura do OpenDSS é apresentada na Figura 2.2.

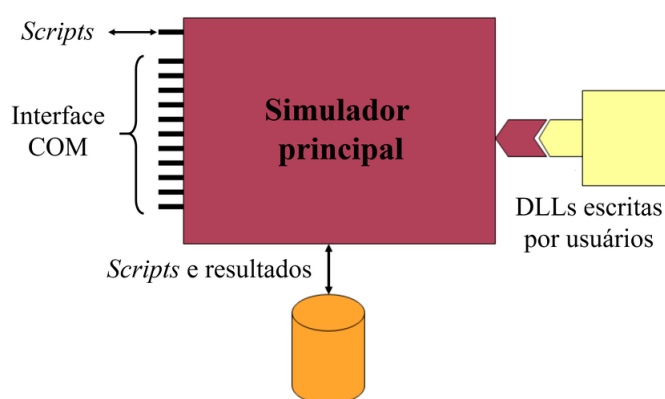


Figura 2.2 – Estrutura do software OpenDSS.

Fonte: (EPRI, 2022)

O OpenDSS modela sistemas elétricos para simulações no regime permanente senoidal (RPS), utilizando cálculos algébricos no domínio fasorial. Além dos componentes elétricos, o sistema inclui uma rede de comunicação que interconecta controles e medições (DUGAN; MONTENEGRO, 2020).

Os blocos fundamentais para construção de um circuito são os elementos de transporte de energia (PD - Power Delivery) e os elementos de conversão de energia (PC - Power Conversion). Os principais PDs compreendem linhas e transformadores, enquanto os PCs englobam cargas e geradores.

Elementos adicionais como controle, medição e características gerais, como curvas de carga, são designados como elementos de suporte, podendo ser criados para aprimorar os modelos de PDs e PCs. A conexão entre esses elementos é realizada por barras que contêm nós. É importante observar que essas barras são criadas como uma consequência da introdução de um elemento, o que representa uma mudança significativa de paradigma em relação aos programas tradicionais de fluxo de potência, nos quais as barras desempenham um papel central (FREITAS, 2015).

As simulações realizadas nesta pesquisa foram conduzidas utilizando o modo **Fluxo de Potência Diário** (*Daily Power Flow*) do OpenDSS. Esse modo permite a análise do comportamento do sistema elétrico ao longo de um ciclo de 24 horas, considerando as variações temporais nas cargas (*loadshape*), na geração distribuída e no armazenamento de energia. Dessa forma, foi possível avaliar a operação do sistema em diferentes períodos do dia, garantindo uma modelagem mais realista das condições de operação.

2.7.1 Modelagem do Sistema Fotovoltaico no OpenDSS - PVSystem

O OpenDSS modela o módulo fotovoltaico juntamente com o inversor que o conecta à rede elétrica por meio do elemento PVSystem, conforme ilustrado nas Figuras 2.3 e 2.4.

No contexto das simulações, o OpenDSS assume que o inversor é capaz de rastrear rapidamente o ponto de máxima potência do painel solar. Isso permite simulações diárias com intervalos de tempo pequenos, como segundos, garantindo uma representação precisa do comportamento dinâmico do sistema fotovoltaico integrado à rede.

O OpenDSS utiliza uma interface de texto simples e opera com uma linguagem de script própria. As propriedades do elemento PVSystem no OpenDSS são categorizadas em três grupos principais: (1) características do arranjo fotovoltaico, como orientação e eficiência dos módulos; (2) especificações do inversor, incluindo sua capacidade de rastrear o ponto de máxima potência; e (3) condições operacionais que afetam o desempenho do sistema fotovoltaico durante as simulações.




Figura 2.3 – Diagrama de blocos do elemento *PVSystem* no OpenDSS.

Fonte: Adaptado de (DUGAN; MONTENEGRO, 2020; FREITAS, 2015).

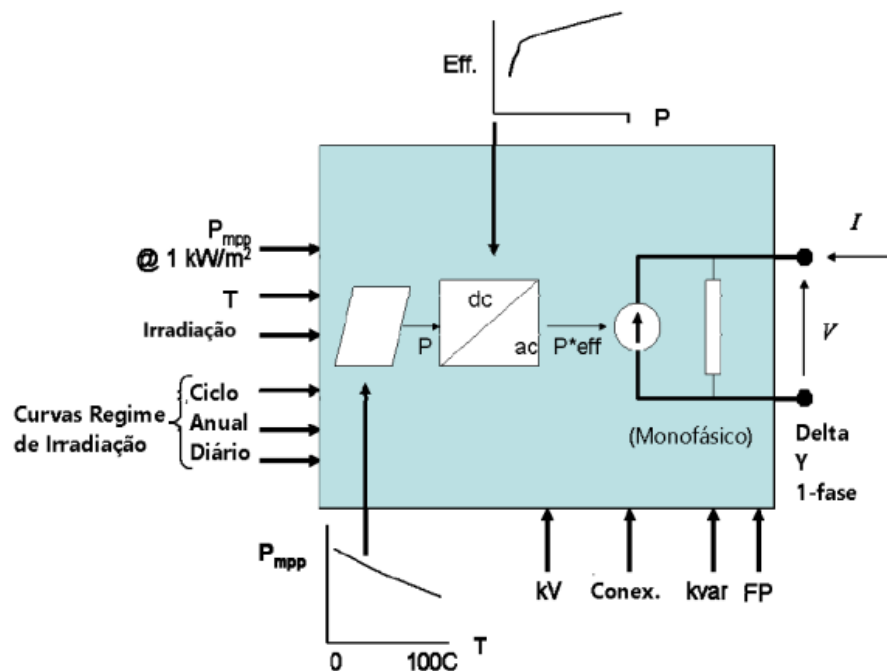


Figura 2.4 – Esquemático do Modelo do Elemento *PVSystem* no OpenDSS.

Fonte: Adaptado de (DUGAN; MONTENEGRO, 2020; FREITAS, 2015).

As propriedades do arranjo fotovoltaico podem ser definidas da seguinte maneira (DUGAN; MONTENEGRO, 2020; FREITAS, 2015):

- P_{mpp} : Representa a potência máxima nominal do arranjo fotovoltaico, medida em kW, para uma irradiância de 1 kW/m^2 e uma temperatura específica definida pelo usuário. A propriedade P-TCurve deve ser configurada em relação a esta temperatura.
- P-TCurve: Refere-se à curva de correção do fator de potência do arranjo fotovoltaico, que varia conforme a temperatura. Esta curva é ajustada de modo que o fator seja 1.0 na temperatura em que P_{mpp} é especificada, garantindo que os painéis solares gerem sua máxima potência nesse ponto exato.
- kVA: Representa a potência aparente nominal do inversor em kVA.
- kV: Tensão nominal do elemento *PVSystem*, especificada em kV de acordo com o tipo de conexão.
- Phases: Indica o número de fases do elemento *PVSystem*.
- bus1: Refere-se à barra de conexão do elemento *PVSystem*.
- conn: Define o tipo de conexão do elemento *PVSystem* na rede elétrica.

- %Pmpp: Limite superior para a potência ativa de saída do inversor, expresso como um percentual da Pmpp (potência máxima do arranjo fotovoltaico).
- VarFollowInverter: Variável booleana que determina se o inversor pode fornecer ou absorver reativos da rede, mesmo quando o arranjo fotovoltaico não está gerando potência ativa.
- WattPriority: Variável booleana que define se o inversor prioriza a entrega de potência ativa ou reativa quando sua potência nominal em kVA é excedida.
- %PminNoVars: Estabelecido como uma porcentagem de Pmpp, é o valor mínimo de potência ativa que deve ser atingido para que o inversor comece a fornecer potência reativa à rede.
- EffCurve: Curva de eficiência do inversor, que descreve como a eficiência do inversor varia com a potência do arranjo fotovoltaico (Pdc), normalizada pela potência nominal total do equipamento.
- irradiance: Valor base de irradiância, em kW/m² para simulação.
- daily: Curva diária de irradiância, definida em valores por unidade relativos ao valor da propriedade irradiance.
- Tshape: Curva de temperatura, em °C, do arranjo fotovoltaico durante o tempo de simulação do sistema.

2.7.2 Modelagem do Sistema de Armazenamento de Energia - Storage

Assim como o gerador fotovoltaico, os armazenadores de energia são tratados como elementos conversores de energia no OpenDSS. Eles são modelados para funcionar como geradores durante a descarga e como cargas durante o carregamento (consumindo energia) (DUGAN; MONTENEGRO, 2020; EPRI, 2022).

O elemento Storage possui três modos operacionais distintos, similares ao PVSystem, devido à inclusão de um inversor integrado: carga, descarga e ocioso, sendo utilizados para simular o funcionamento de um banco de baterias. O Esquemático do elemento Storage é apresentado na Figura 2.5.

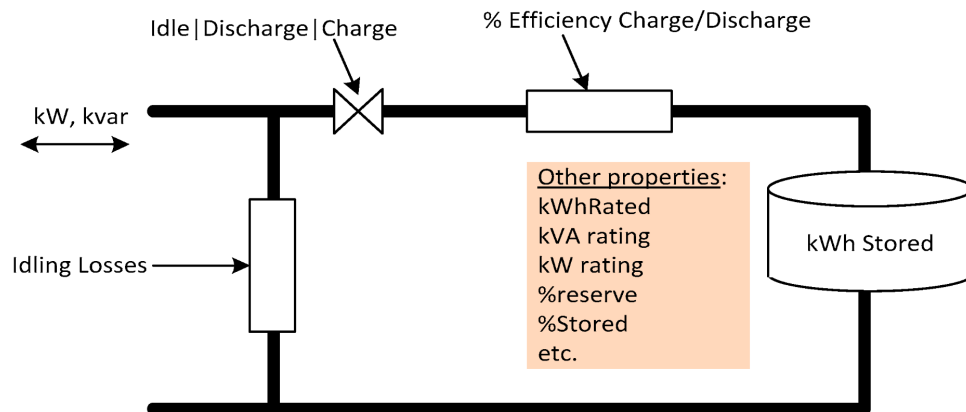


Figura 2.5 – Diagrama de blocos do elemento *Storage* no OpenDSS.

Fonte: Adaptado de (DUGAN; MONTENEGRO, 2020; EPRI, 2022).

A seguir, apresenta-se uma explicação dos parâmetros exibidos na Figura 2.5 (DUGAN; MONTENEGRO, 2020; EPRI, 2022):

- Potência aparente: Refere-se à potência aparente nominal do Sistema de Armazenamento de Energia (SAE), medida em kVA (kilovolt-amperes). Este parâmetro indica a capacidade total de potência que o sistema é capaz de manipular, abrangendo tanto a potência ativa quanto a potência reativa.
- Perdas por inatividade: Representam a energia necessária para manter os controles internos e os sistemas de refrigeração do SAE em funcionamento durante os períodos em que não está em operação ativa de carga ou descarga. Estas perdas são inevitáveis e devem ser consideradas na avaliação da eficiência global do sistema.
- Indicador de estado: Mostra o estado atual de operação do SAE, podendo estar em um dos seguintes estados: carga (quando o sistema está armazenando energia), descarga (quando o sistema está liberando energia) ou inatividade (quando o sistema não está realizando nenhuma das operações anteriores).
- Eficiência de carga/descarga: Representa a eficiência do sistema durante as operações de carga e descarga, expressa em porcentagem (%). Estes valores indicam a eficiência da conversão de energia do SAE nesses processos, considerando as perdas inerentes às operações de carga e descarga.
- Nível de carga: Indica a quantidade de energia armazenada no SAE, medida em kWh (kilowatt-horas). Este parâmetro mostra a capacidade de armazenamento utilizada no momento e quanta energia o sistema ainda pode armazenar.

De acordo com (EPRI, 2022), o elemento armazenador funciona essencialmente como um gerador de energia que pode ser acionado tanto para produzir quanto para consumir energia, respeitando certos valores de potência e capacidade nominais. Este elemento pode operar em dois modos distintos: o modo Snapshot e o modo de simulação com variação temporal.

No modo Snapshot, um fluxo de carga é computado considerando apenas um estado específico do armazenador, proporcionando uma visão instantânea do comportamento do sistema. Por outro lado, no modo de simulação com variação do tempo, o comportamento do sistema é analisado ao longo de um período, permitindo um estudo detalhado dos fenômenos dinâmicos que ocorrem durante esse intervalo. Adicionalmente, é importante destacar que o elemento armazenador também possui a capacidade de produzir ou absorver potência reativa, desde que dentro dos limites da capacidade nominal do inversor. Esta funcionalidade permanece disponível mesmo quando o sistema está em estado de inatividade, aumentando a flexibilidade e a eficiência operacional do sistema de armazenamento de energia.

A seguir, apresenta-se uma explicação sobre os modos de despacho, ou seja, o controle de carga e descarga do Sistema de Armazenamento de Energia (SAE), conforme descrito em (EPRI, 2022):

- **Modo Padrão (Default mode):** Neste modo, o sistema de armazenamento descarrega a uma taxa específica e fixa sempre que o objeto Loadshape excede o valor de disparo de descarga. O sistema permanece nesse estado até que o valor do Loadshape caia abaixo do valor de disparo mencionado ou até que a carga do SAE atinja o seu nível de reserva. De modo semelhante, quando o Loadshape cai abaixo do valor de disparo de carga, o SAE carrega a uma taxa específica e fixa até que atinja o seu limite máximo de carga ou que outra descarga seja necessária.
- **Modo Seguidor (Follow mode):** Neste modo, a injeção de potência ativa e reativa do SAE segue os multiplicadores indicados pelo Loadshape até que o SAE atinja seus limites de carga superior ou inferior. Assim, as operações de carga e descarga são proporcionais à potência nominal do sistema de armazenamento. Ressalta-se que o sistema carrega para valores negativos e descarrega para valores positivos.
- **Modo Valor Global (Loadlevel ou Price mode):** Neste modo de operação, o armazenador de energia orienta suas operações de carga e descarga a partir de um valor de preço ou de nível de carga definido, ao invés de seguir um Loadshape. Curvas de preço ou de carga são inseridas no OpenDSS, juntamente com o valor desejado como referência.
- **Modo Externo (External mode):** Neste modo, um elemento externo é responsável pelo controle das operações de carga e descarga do SAE. Este modo de controle é

adequado para ser utilizado em simulações em tempo real ou em simulações onde o padrão de carga e descarga do armazenador de energia não é previamente conhecido.

2.7.2.1 Sistema de Armazenamento com Baterias - Metodologia

Conforme apresentado na seção 2.7.2.1, para a modelagem do sistema de armazenamento de energia com baterias (SAEB) na aplicação da metodologia, ela foi realizada atribuindo as características pertinentes a tecnologia de íons de Lítio sobre as demais tecnologias aplicadas a armazenamento de energia via baterias da seguinte forma:

Tabela 2.1 – Parâmetros utilizados para modelagem do SAEB no OpenDSS.

Parâmetro	Valor
%effcharge	92,5%
%effdischarge	92,5%
%idlingkw	3% da potência nominal
%charge	90% da potência nominal
%discharge	90% da potência nominal
%reserve	20% da potência nominal (kWh)

Fonte: Adaptado de (ALEGRIA et al., 2013; DIVYA; ØSTERGAARD, 2009).

Tabela 2.2 – Descrição dos Parâmetros utilizados para modelagem do SAEB no OpenDSS.

Parâmetro	Descrição
%effcharge	Eficiência percentual do carregamento da bateria.
%effdischarge	Eficiência percentual da descarga da bateria.
%idlingkw	Percentual das perdas em inatividade da bateria.
%charge	Percentual de carregamento da bateria em relação à sua potência nominal.
%discharge	Percentual de descarga da bateria em relação à sua potência nominal.
%reserve	Percentual da capacidade da bateria reservado para evitar descarga completa.

Fonte: Elaborado pelo Autor.

O controle de carga e descarga do Sistema de Armazenamento de Energia por Baterias (SAEB) foi simulado utilizando o modo seguidor (*Follow Mode*). A curva de referência mais comumente adotada para esse tipo de controle está representada na Figura 2.6, onde os valores -1 e 1 indicam, respectivamente, as operações de carga e descarga. Com base nessa estratégia, o SAEB é carregado entre 6:00 e 14:00, período em que a geração distribuída fotovoltaica está em operação no sistema elétrico de distribuição, aproveitando o excedente de energia disponível na rede.

Por outro lado, a descarga do SAEB ocorre no horário de pico de consumo de energia elétrica, entre 19:00 e 22:00, após a interrupção da geração pelos sistemas fotovoltaicos. Essa abordagem é amplamente conhecida como peak shaving (FERREIRA, 2020; FERREIRA,

2019) e tem como objetivo reduzir as demandas de pico, promovendo maior eficiência no uso da energia armazenada.




Figura 2.6 – Indicador de Estado do SAEB.

Fonte: Elaborado pelo Autor

Dessa forma, para o estudo da aplicação da metodologia e das estratégias de otimização que serão discutidas nas seções posteriores, as seguintes variáveis de simulação da bateria serão utilizadas:

Tabela 2.3 – Variáveis do SAEB no OpenDSS utilizadas para aplicação da metodologia.

Variável	Definição
%kwrated	Potência nominal de saída [kW].
%kwhrated	Capacidade de armazenamento de energia nominal [kWh].

Fonte: Elaborado pelo Autor

2.8 Métodos de Otimização

Os problemas de otimização consistem na maximização ou minimização de uma função objetivo dentro de um domínio específico, geralmente sujeito a um conjunto de restrições aplicadas às variáveis envolvidas. Para solucionar tais problemas, dois tipos principais de algoritmos podem ser utilizados: determinísticos e probabilísticos.

Nesta seção, serão apresentadas as características fundamentais de cada abordagem, destacando suas respectivas vantagens e limitações. Em especial, será enfatizada a classe de algoritmos de computação evolucionária, uma subcategoria dos métodos probabilísticos

de otimização, amplamente reconhecida por sua capacidade de explorar extensos espaços de busca de maneira eficiente.

Este estudo concentra-se na Estratégia Evolutiva (EE) com os esquemas (μ, λ) e $(\mu + \lambda)$, bem como na aplicação de Algoritmos Genéticos com Elitismo, seguindo as mesmas configurações (μ, λ) e $(\mu + \lambda)$. Esses métodos pertencem à classe dos Algoritmos Genéticos e foram selecionados para o desenvolvimento deste trabalho devido ao seu potencial em lidar com problemas de alta complexidade e múltiplas variáveis. Sua aplicação destaca-se como uma solução robusta e eficaz no contexto de sistemas de otimização.

Para compreender os algoritmos de otimização de forma mais aprofundada, é fundamental conhecer alguns conceitos e definições amplamente utilizados na literatura especializada (BASTOS, 2004). A seguir, apresentam-se os principais termos associados a problemas de otimização:

- **Variáveis de Projeto:** Representam os elementos que podem ser modificados durante o processo de otimização, podendo assumir valores contínuos (reais), inteiros ou discretos.
- **Restrições:** São condições impostas sobre as variáveis de projeto, expressas na forma de funções de igualdade ou desigualdade, que delimitam situações consideradas inviáveis ou indesejáveis no projeto.
- **Espaço de Busca:** Refere-se ao conjunto, região ou domínio que engloba todas as soluções possíveis ou viáveis do problema de otimização, sendo delimitado pelas restrições estabelecidas.
- **Função Objetivo:** Define a relação matemática que se deseja otimizar, seja por meio de sua minimização ou maximização, envolvendo uma ou mais variáveis de projeto.
- **Ponto Ótimo:** Corresponde ao conjunto de valores das variáveis de projeto que maximizam ou minimizam a função objetivo, atendendo simultaneamente a todas as restrições impostas.
- **Valor Ótimo:** Representa o valor calculado da função objetivo no ponto ótimo, indicando o resultado extremo alcançado pelo processo de otimização.

2.8.1 Estratégias Evolutivas

A Computação Evolutiva, como antigamente eram conhecidos as Estratégias Evolutivas, surgiu no final da década de 1950 e permaneceu relativamente desconhecida da comunidade científica por cerca de três décadas. Esse desconhecimento se deveu principalmente à falta de computadores eficientes na época e à metodologia ainda pouco

desenvolvida durante as primeiras pesquisas. Na década de 1970, os trabalhos de Holland, Rechenberg, Schwefel e Fogel foram fundamentais para transformar a imagem da Computação Evolucionária, que a partir de então começou a ser amplamente desenvolvida e reconhecida.

As Estratégias Evolutivas ou Estratégias Evolucionárias (EE's) ou Algoritmos Evolutivos (AEs) formam uma classe de métodos de otimização probabilísticos que são inspirados por alguns princípios baseados em mecanismos evolutivos encontrados na natureza, como auto-organização e o comportamento adaptativo (BEYER; SCHWEFEL; WEGENER, 2002). De acordo com (BARBOSA, 1977), uma estratégia evolucionária se distingue dos métodos determinísticos mais comuns basicamente por:

- Empregar uma população de indivíduos, ou soluções;
- Trabalhar sobre uma codificação das possíveis soluções (genótipos) e não sobre as soluções (fenótipos) propriamente ditas;
- Empregar regras de transição probabilísticas;
- Não requerer informações adicionais (derivadas, por exemplo) sobre a função a otimizar e as restrições.

A busca de soluções em conjuntos não-convexos com funções objetivo não-convexas e não-diferenciáveis é uma característica distintiva das Estratégias Evolucionárias (EE's), que podem lidar simultaneamente com variáveis reais, lógicas e inteiras. EE's não ficam facilmente presos a mínimos locais, ao contrário dos métodos determinísticos convencionais. Essas características podem resultar na descoberta de soluções não convencionais e até mesmo contra-intuitivas. EE é um paradigma que não requer um conhecimento prévio específico sobre como encontrar a solução.

Para a aplicação de Algoritmos Evolutivos em problemas de otimização com restrições, uma abordagem comum é o método de penalização, conhecido como "pena de morte", onde um indivíduo é removido da população quando viola as restrições ou quando não é possível avaliar seu desempenho (função aptidão). No entanto, essa estratégia tem a desvantagem de potencialmente descartar um indivíduo que poderia ser útil ao processo evolutivo.

Para ilustrar o comportamento de uma EE, considera-se uma função objetivo unidimensional a ser maximizada. Na Figura 2.7, são mostradas três etapas da busca evolucionária: no início (a), no meio (b) e no fim (c) do processo de evolução. Na primeira fase, logo após a inicialização da população, os indivíduos são distribuídos aleatoriamente por todo o espaço de busca. Após várias gerações, a distribuição da população é modificada:

devido aos operadores de variação e seleção, os indivíduos abandonam áreas de baixa aptidão e passam a ocupar regiões de maior aptidão.

No final da busca, com uma condição de parada apropriada, toda a população tende a se concentrar em torno de poucos pontos, podendo alguns desses pontos serem sub-ótimos. Pode ocorrer uma convergência prematura onde todos os membros da população se concentram em torno de um ótimo local em vez do ótimo global. Esse fenômeno é conhecido como perda rápida de diversidade, que pode levar a população a ficar presa em ótimos locais (EIBEN; SMITH, 2003).




Figura 2.7 – Método de Evolução típica de uma EE, ilustrada de acordo com a distribuição da população.

Fonte: Adaptado de (EIBEN; SMITH, 2003).

Para a aplicação de uma EE, são essenciais definições específicas que são características desse tipo de algoritmo (BASTOS, 2004; EIBEN; SMITH, 2003). Como esses algoritmos são inspirados em mecanismos evolutivos da natureza, muitos termos adotados são baseados em conceitos genéticos, tais como:

- Cromossomo ou genótipo - representa um indivíduo no espaço do AE, ou seja, é a representação codificada de um indivíduo;
- Fenótipo - representa um indivíduo no espaço original de busca;
- Indivíduo - membro individual da população;
- Gene - unidade básica do cromossomo, sendo um elemento do vetor que representa o cromossomo;
- População - conjunto de indivíduos ou cromossomos;
- Geração - ordem evolutiva das diferentes populações ao longo do tempo;
- Operações genéticas - conjunto de operações que o AE realiza sobre cada cromossomo;

- Função aptidão - equivalente à função objetivo quando o AE é aplicado em problemas de otimização.

Qualquer variação de um Algoritmo Evolucionário baseia-se principalmente na ideia de que, dada uma população de indivíduos, a seleção natural induzida pelo ambiente leva à evolução dessa população (BACK; HAMMEL; SCHWEFEL, 1997; BEYER; SCHWEFEL; WEGENER, 2002). Conforme (BASTOS, 2004; EIBEN; SMITH, 2003), todo algoritmo evolucionário deve possuir os seguintes componentes básicos para resolver um problema:

1. CODIFICAÇÃO:

A codificação é uma representação genética das soluções do problema. Quando se utiliza uma Estratégia Evolutiva, a representação ou codificação de um indivíduo consiste em relacionar o espaço real do problema com o espaço adotado pelo EE. Isso significa representar ou codificar os elementos do espaço real no espaço do EE. Cada elemento no espaço de busca original é denominado fenótipo, enquanto sua representação no espaço do EE é chamada de genótipo. Essa relação é fundamental para que o EE possa operar eficazmente sobre os indivíduos e realizar as operações genéticas necessárias durante o processo evolutivo.

2. POPULAÇÃO:

O papel da população em uma Estratégia Evolutiva é manter as possíveis soluções do problema em questão. Enquanto os indivíduos são entidades estáticas, ou seja, não se modificam ao longo do processo evolutivo, a população como um todo é a unidade de evolução. Definir uma população significa decidir o número de indivíduos que a compõem. Em alguns EE's mais sofisticados, a população pode ter estruturas adicionais, como medidas de distância entre os indivíduos ou relações de vizinhança. Em quase todas as aplicações de EE, o tamanho da população é mantido constante ao longo da evolução e não é modificado durante o processo.

3. POPULAÇÃO INICIAL:

A inicialização da população geralmente é simples na maioria das aplicações de EE, sendo feita tipicamente gerando indivíduos aleatoriamente. No entanto, em algumas situações, heurísticas podem ser empregadas para gerar uma população inicial com maior aptidão. Por exemplo, é possível iniciar a população com soluções aproximadas conhecidas ou incorporar algum tipo de informação prévia. A decisão de utilizar tais heurísticas depende do benefício esperado em relação ao esforço computacional adicional necessário, o que varia significativamente de acordo com a aplicação específica.

4. FUNÇÃO DE APTIDÃO:

A função aptidão desempenha um papel crucial no processo de seleção dos indivíduos dentro de um algoritmo evolucionário. Ela é responsável por avaliar e indicar a qualidade de cada indivíduo na população, influenciando diretamente a evolução do algoritmo. Tecnicamente, a função aptidão atribui uma medida de qualidade ao genótipo, ou seja, à representação de um indivíduo no espaço do algoritmo evolucionário.

5. OPERADORES GENÉTICOS:

Os operadores genéticos desempenham um papel fundamental na evolução dos indivíduos dentro de um algoritmo evolucionário, modificando a composição genética dos filhos durante a reprodução. Eles operam diretamente sobre a codificação das possíveis soluções (genótipo), não sobre as soluções reais (fenótipos). Os principais operadores são a recombinação e a mutação.

A recombinação é um operador que combina informações de dois ou mais genótipos pais para gerar um ou dois descendentes. Este operador é estocástico, ou seja, a escolha das partes de cada pai que serão combinadas e o modo como serão combinadas são determinados de forma aleatória.

A mutação, por sua vez, é um operador que, aplicado a um genótipo, gera um filho modificando-o aleatoriamente. Assim como a recombinação, a mutação é estocástica: o resultado do operador depende das escolhas aleatórias realizadas durante o processo.

6. NOVA GERAÇÃO:

Nesse processo, distinguem-se os indivíduos com base em suas qualidades, especialmente permitindo que os melhores indivíduos se tornem pais da próxima geração.

7. CRITÉRIO DE PARADA:

Caso o problema tenha um valor ótimo da função aptidão conhecido, o critério de parada pode ser quando este valor for atingido, considerando uma certa precisão. Contudo, devido à natureza estocástica dos EE's e à falta de garantia de alcançar o ótimo global, essa condição pode nunca ser cumprida e o algoritmo pode não parar. Opções comuns de critérios de parada incluem:

- a) Tempo máximo transcorrido.
- b) Número total de avaliações da função aptidão atingindo um limite pré-determinado.
- c) Melhoria muito pequena na aptidão ao longo de um período de tempo específico (ou um número fixo de gerações ou avaliações da função aptidão).
- d) Diminuição da diversidade da população até um limite estabelecido. A diversidade pode ser medida pelo número de soluções diferentes na população,

que pode ser avaliada através das diferentes aptidões, fenótipos ou genótipos presentes.

A partir do exposto acima, observa-se que a combinação da aplicação de variação, através dos operadores genéticos, e seleção contribui para melhorar o valor da aptidão e, conseqüentemente, aprimorar a população. Essa evolução pode ser vista como um processo de otimização, onde os valores ótimos são gradualmente alcançados ao longo do processo. Alternativamente, essa evolução pode ser entendida como um processo de adaptação, onde a aptidão não é apenas uma função objetivo a ser maximizada, mas uma necessidade imposta pelo ambiente. O processo evolutivo permite que a população se adapte cada vez mais eficientemente ao meio ambiente. A Figura 2.8, é apresentado um pseudocódigo que exemplifica um algoritmo evolucionário.

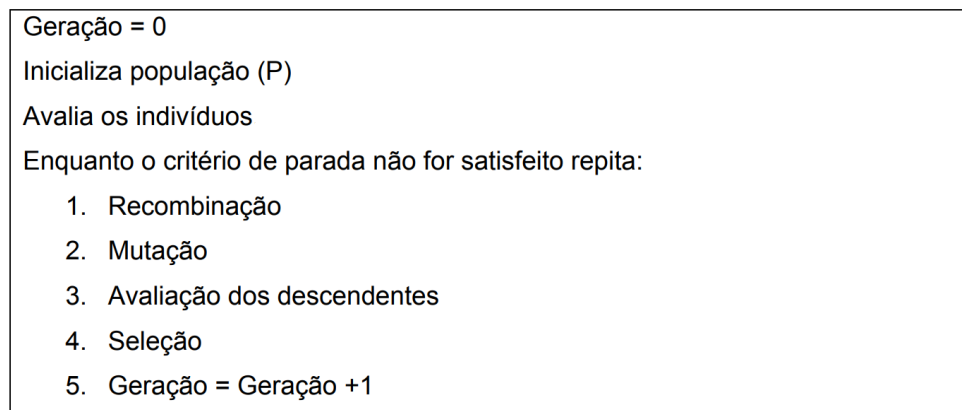


Figura 2.8 – Esquemático geral de um Algoritmo Evolutivo.

Fonte: Adaptado de (BACK; HAMMEL; SCHWEFEL, 1997; BEYER; SCHWEFEL; WEGENER, 2002).

2.8.2 Algoritmos Genéticos

Segundo (BARBOSA, 1977; BACK; HAMMEL; SCHWEFEL, 1997), o Algoritmo Genético (AG) foi inicialmente desenvolvido por John Holland no final da década de 1960, inspirado nos princípios do processo de evolução natural, conforme descrito na teoria da evolução de Darwin em sua obra seminal *A Origem das Espécies*. O objetivo do AG é reproduzir computacionalmente os mecanismos evolutivos, aplicando-os à resolução de problemas complexos de otimização.

Nas aplicações mais comuns que utilizam AGs, a representação binária de comprimento fixo é amplamente empregada como forma de codificação. Essa escolha está alinhada à base teórica do AG, que foi originalmente desenvolvida com essa representação. No entanto, (DAVIS, 1991) argumenta que a representação binária não é natural e, na maioria

dos casos, sua adoção pode ser desnecessária, sugerindo alternativas mais adequadas dependendo do contexto do problema.

O principal operador do AG é a recombinação, frequentemente denominada *crossover* na literatura inglesa, enquanto a mutação é considerada um operador secundário, mas não menos importante. No alfabeto binário, esses operadores funcionam da seguinte maneira:

- **Mutação:** Consiste na alteração do símbolo em uma posição específica do cromossomo. Se o gene é 1, ele é alterado para 0, e vice-versa. A probabilidade de mutação (p_m) de um gene é, geralmente, muito baixa, comumente da ordem de $\frac{1}{l}$, onde l é o número de bits do cromossomo.
- **Crossover:** No caso do *crossover* de um ponto (padrão no algoritmo genético), dois indivíduos são selecionados e, com uma probabilidade p_c , são submetidos à recombinação. Uma posição de *crossover* é escolhida aleatoriamente, e o material genético dos pais é trocado a partir desse ponto. Por exemplo:

$$\begin{array}{ll} p_1 : 1111111 & \longrightarrow f_1 : 1111000 \\ p_2 : 0000000 & \longrightarrow f_2 : 0000111 \end{array}$$

Outras variantes desse operador incluem *crossover* de dois pontos, *crossover* uniforme, entre outras, cada uma adaptável a diferentes problemas e configurações.

- **Seleção:** Geralmente implementada utilizando esquemas probabilísticos, onde a probabilidade (p_i) de seleção de um indivíduo i é proporcional à sua aptidão relativa, dada pela equação 2.1:

$$P_i = \frac{f(i)}{\sum_{i=1}^N f(i)} \quad (2.1)$$

onde:

- $f(i)$: Aptidão do i -ésimo indivíduo;
- N : Número total de indivíduos na população.

Essa abordagem garante que indivíduos com maior aptidão tenham uma probabilidade maior de serem selecionados, promovendo a evolução da população ao longo das gerações.

Um dos métodos amplamente utilizados para a seleção é o Método da Roleta (*Roulette Wheel Selection*), onde os indivíduos são representados proporcionalmente aos

seus valores de aptidão em uma roleta. Durante o processo, a roleta é girada tantas vezes quanto o tamanho da população, e os indivíduos selecionados correspondem às posições sorteadas, garantindo maior probabilidade de escolha para os mais aptos. Esse processo está ilustrado na Figura 2.9.




Figura 2.9 – Ilustração do Método da Roleta para seleção de indivíduos.

Fonte: Adaptado de (BARBOSA, 1977; BACK; HAMMEL; SCHWEFEL, 1997).

2.8.3 Estratégia Evolutiva e Algoritmo Genético

As Estratégias Evolutivas (EEs) e os Algoritmos Genéticos (AGs) são duas abordagens amplamente empregadas no campo da otimização evolutiva. Ambas compartilham uma base teórica nos princípios de seleção natural e reprodução, mas possuem características e métodos distintos que as tornam mais adequadas a diferentes tipos de problemas.

A primeira versão de Estratégias Evolutivas foi o modelo $(1 + 1)$ - EE, que utilizava um esquema simples no qual um único indivíduo gerava um único descendente por meio de mutação Gaussiana. Ambos eram submetidos ao processo de seleção, onde a solução menos apta era eliminada. Posteriormente, essa abordagem evoluiu para o modelo $(\mu + 1)$ - EE, no qual uma população de (μ) indivíduos era recombinada de maneira aleatória para formar um descendente. Esse descendente sofria mutação e passava pelo processo de seleção, de forma análoga ao que ocorre na evolução natural.

- **Semelhanças entre EEs e AGs:**

1. *População de Soluções:* Tanto as EEs quanto os AGs operam com uma população diversificada de soluções, o que possibilita a exploração e a exploração do espaço

de busca.

2. *Seleção Natural*: Ambas as abordagens utilizam mecanismos baseados na seleção natural para favorecer soluções com maior aptidão, aumentando a probabilidade de reprodução das melhores soluções.
3. *Operadores Genéticos*: Ambas empregam operadores genéticos, como recombinação (crossover) e mutação, para gerar novas soluções, promovendo a diversidade genética e a evolução da população.

- **Diferenças entre EEs e AGs:**

1. *Modelo de Evolução*:

- **EEs**: Adotam um modelo de evolução estacionário, onde apenas algumas soluções são modificadas em cada iteração. A Estratégia de Evolução (ES), por exemplo, foca na modificação contínua de soluções existentes.
- **AGs**: Operam em um modelo geracional, onde toda a população de soluções é atualizada a cada ciclo evolutivo. Isso caracteriza os AGs, que frequentemente utilizam operadores de recombinação e mutação aplicados de forma global.

2. *Estratégias de Seleção e Recombinação*:

- **EEs**: A seleção é baseada em uma amostra de indivíduos, aplicando mutações e recombinações de forma individualizada, com ênfase na variação contínua das soluções.
- **AGs**: Empregam uma seleção probabilística, na qual a probabilidade de um indivíduo ser selecionado é proporcional à sua aptidão. Os operadores de recombinação, como *crossover* de um ou dois pontos, combinam informações genéticas de dois indivíduos para formar descendentes.

- **Implicações na Aplicação:**

- **EEs**: São preferidas em problemas que demandam alta precisão e adaptação contínua, proporcionando uma abordagem mais controlada e frequentemente mais eficiente em termos de convergência.
- **AGs**: São mais indicados para problemas que exigem uma ampla exploração do espaço de busca e uma diversidade elevada de soluções, ainda que isso possa aumentar o custo computacional e o tempo de processamento.

Nas subseções a seguir, serão apresentadas em detalhe a Estratégia Evolutiva (μ, λ) , a Estratégia Evolutiva $(\mu + \lambda)$, o Algoritmo Genético com elitismo (μ, λ) e o Algoritmo Genético com elitismo $(\mu + \lambda)$, que compõem a metodologia adotada neste trabalho.

2.8.3.1 Metodologia Híbrida

A formulação de uma metodologia híbrida constitui uma estratégia promissora para integrar os atributos mais eficazes de diferentes algoritmos, combinando elementos de seleção e reprodução das Estratégias Evolutivas e dos Algoritmos Genéticos.

Essa configuração oferece um aprimoramento significativo no desempenho global do algoritmo, proporcionando maior flexibilidade para se adaptar às particularidades do problema em análise e aumentando a probabilidade de identificar soluções ótimas em espaços de busca altamente complexos.

A integração equilibrada entre exploração, que visa investigar novas regiões do espaço de busca, e intensificação, que se concentra no refinamento de soluções promissoras, é particularmente vantajosa em problemas de otimização. Nessas situações, a preservação da diversidade genética e a retenção de indivíduos de alto desempenho tornam-se fatores essenciais para evitar a estagnação prematura e assegurar a convergência para soluções globais ótimas.

2.8.4 Estratégia Evolutiva (μ, λ)

A Estratégia Evolutiva (μ, λ) é um método de otimização baseado em populações, pertencente à família dos algoritmos evolutivos. Essa abordagem é amplamente utilizada para resolver problemas de otimização em espaços de busca complexos, frequentemente caracterizados por alta dimensionalidade, onde se busca identificar a solução ideal.

Nesse método, μ representa o tamanho da população de pais, enquanto λ denota o número de descendentes gerados em cada iteração. Os principais elementos da Estratégia Evolutiva (μ, λ) podem ser descritos da seguinte forma:

1. **Inicialização da População:** Inicialmente, uma população de μ indivíduos (ou soluções candidatas) é gerada de maneira aleatória. Cada indivíduo é representado por um cromossomo, que codifica uma possível solução para o problema em questão.
2. **Geração de Descendentes:** A cada geração, λ indivíduos são selecionados a partir da população de pais (μ indivíduos) para atuar como progenitores. Esses pais são então utilizados para gerar uma nova população de λ descendentes por meio de operadores genéticos, como recombinação (*crossover*) e mutação.
3. **Seleção dos Pais:** A escolha dos pais geralmente é baseada na aptidão de cada indivíduo, de modo que soluções com maior aptidão têm maior probabilidade de serem selecionadas para reprodução.
4. **Recombinação e Mutação:** Os descendentes são criados utilizando operadores genéticos. A recombinação combina informações genéticas dos pais para produzir

novas soluções, enquanto a mutação introduz variações aleatórias nos descendentes, contribuindo para a diversidade genética.

5. **Seleção dos Sobreviventes:** Após a geração dos descendentes, uma nova população de μ indivíduos é selecionada para formar a próxima geração, garantindo a continuidade do processo evolutivo.
6. **Critério de Parada:** O algoritmo continua iterando até que seja alcançado um critério de parada predefinido, como o número máximo de gerações, a obtenção de um nível mínimo de aptidão, ou a ausência de melhorias significativas na aptidão ao longo de várias gerações.

Essa abordagem se destaca pela capacidade de lidar com problemas de alta complexidade e múltiplas variáveis, sendo amplamente aplicada em contextos que demandam soluções robustas e eficientes.

O pseudocódigo para a Estratégia Evolutiva (μ, λ), conforme descrito por (LUKE, 2013), é apresentado no Algoritmo 1.

Algorithm 1 Estratégia Evolutiva (μ, λ)

```

1:  $\mu \leftarrow$  número de pais selecionados
2:  $\lambda \leftarrow$  número de filhos gerados pelos pais
3:  $D \leftarrow \{\}$  ▷ Gera população inicial
4: for  $\lambda$  vezes do
5:    $D \leftarrow D \cup$  (novo indivíduo aleatório)
6: end for
7: Melhor  $\leftarrow$  Valor arbitrário ▷ Busca por uma solução enquanto o critério de parada não for atingido
8: while condição não satisfeita de parada do ▷ Avalia cada indivíduo de acordo com a aptidão calculada
9:   for cada indivíduo  $D_i \in D$  do
10:     Avaliar( $D_i$ )
11:     if Aptidão ( $D_i$ ) > Aptidão (Melhor) then
12:       Melhor  $\leftarrow D_i$ 
13:     end if
14:   end for
15:    $Q \leftarrow$  os  $\mu$  indivíduos em  $D$  cuja aptidão é melhor
16:    $D \leftarrow \{\}$ 
17:   for cada indivíduo  $Q_j \in Q$  do
18:     for  $\lambda/\mu$  vezes do
19:        $D \leftarrow D \cup$  Mutação(Cópia( $Q_j$ ))
20:     end for
21:   end for
22: end while
23: return Melhor

```

2.8.5 Estratégia Evolutiva ($\mu + \lambda$)

O algoritmo da Estratégia Evolutiva ($\mu + \lambda$), tem como principal distinção em relação ao modelo (μ, λ) na estratégia de seleção e composição da nova geração. Enquanto no modelo (μ, λ) a geração de pais é inteiramente substituída pelos descendentes, no modelo ($\mu + \lambda$) a nova população é formada pelos μ indivíduos da geração anterior (pais) somados aos λ novos indivíduos gerados (descendentes). Dessa forma, os pais e os descendentes competem diretamente para integrar a próxima geração, mantendo o tamanho populacional constante em ($\mu + \lambda$).

O modelo ($\mu + \lambda$) adota uma abordagem mais exploratória em comparação ao (μ, λ), pois indivíduos de elevada aptidão permanecem ativos no processo evolutivo por várias gerações, promovendo maior estabilidade em torno de soluções promissoras. Entretanto, essa característica pode também acarretar riscos: indivíduos de alta aptidão podem monopolizar a população, conduzindo à convergência prematura para soluções subótimas em torno desses indivíduos. Esse fenômeno, conhecido como estagnação em ótimos locais, reduz a capacidade do algoritmo de explorar regiões alternativas do espaço de busca.

O pseudocódigo para a Estratégia Evolutiva ($\mu + \lambda$), conforme descrito por (LUKE, 2013), é apresentado no Algoritmo 2.

Algorithm 2 Estratégia Evolutiva ($\mu + \lambda$)

```

1:  $\mu \leftarrow$  número de pais selecionados
2:  $\lambda \leftarrow$  número de filhos gerados pelos pais
3:  $D \leftarrow \{\}$  ▷ Gera população inicial
4: for  $\lambda$  vezes do
5:    $D \leftarrow D \cup$  (novo indivíduo aleatório)
6: end for
7: Melhor  $\leftarrow$  Valor arbitrário ▷ Busca por uma solução enquanto o critério de parada não for atingido
8: while condição não satisfeita de parada do ▷ Avalia cada indivíduo de acordo com a aptidão calculada
9:   for cada indivíduo  $D_i \in D$  do
10:     Avaliar( $D_i$ )
11:     if Aptidão ( $D_i$ ) > Aptidão (Melhor) then
12:       Melhor  $\leftarrow D_i$ 
13:     end if
14:   end for
15:    $Q \leftarrow$  os  $\mu$  indivíduos em  $D$  cuja aptidão é melhor
16:    $D \leftarrow Q$  ▷ Geração de novos indivíduos para complementar a população
17:   for cada indivíduo  $Q_j \in Q$  do
18:     for  $\lambda/\mu$  vezes do
19:        $D \leftarrow D \cup$  Mutação(Cópia( $Q_j$ ))
20:     end for
21:   end for
22: end while return Melhor

```

No modelo (μ, λ) , a população é renovada a cada iteração, promovendo uma rápida exploração do espaço de busca. No entanto, essa abordagem pode resultar na eliminação precoce de indivíduos com elevada aptidão, que poderiam contribuir significativamente para o avanço do processo evolutivo.

O algoritmo $(\mu + \lambda)$ caracteriza-se pela retenção dos indivíduos mais aptos da geração anterior (pais), permitindo que estes compitam diretamente com os novos indivíduos (descendentes) na composição da geração subsequente. Essa abordagem promove a estabilidade populacional ao preservar soluções promissoras, minimizando o risco de descarte prematuro de indivíduos de elevada qualidade. Como resultado, a manutenção contínua de pais aptos contribui para uma convergência mais consistente em direção à solução ótima global. Contudo, é crucial mitigar o risco de convergência prematura, que pode ocorrer quando um indivíduo altamente adaptado domina a população, levando à redução da variabilidade genética e comprometendo a exploração eficaz do espaço de busca.

Entre as vantagens do modelo $(\mu + \lambda)$, destacam-se:

1. **Exploração Ampliada e Sustentada:** A preservação de indivíduos de alta aptidão, em conjunto com a introdução de novos descendentes, promove uma exploração mais abrangente e profunda do espaço de busca. Enquanto a exploração se refere à avaliação de novas regiões no espaço de soluções, garantindo que diferentes áreas sejam investigadas, a introdução de diversidade evita a concentração em regiões específicas.
2. **Preservação de Soluções de Alta Qualidade:** Ao manter os pais na população, evita-se a perda prematura de indivíduos com potencial significativo para contribuir ao processo de otimização. A exploração, por sua vez, concentra-se no refinamento de soluções já identificadas, aproveitando ao máximo as características benéficas previamente encontradas.
3. **Estabilidade Populacional:** A integração de pais e descendentes confere maior estabilidade ao processo evolutivo, promovendo melhorias graduais e contínuas ao longo das gerações, reduzindo oscilações abruptas na qualidade das soluções.

2.8.6 Algoritmo Genético Híbrido: Elitismo com (μ, λ)

O elitismo é uma estratégia específica aplicada em algoritmos genéticos para preservar as melhores soluções encontradas ao longo das gerações. Em um AG com elitismo, uma ou mais das melhores soluções (indivíduos com maior fitness) da população são automaticamente selecionadas para passar para a próxima geração sem sofrer alterações

através dos operadores genéticos (cruzamento e mutação). A proposta do algoritmo genético híbrido pode ser detalhado como segue:

1. Inicialização da População: Uma população inicial de soluções (indivíduos) é gerada aleatoriamente ou através de algum método heurístico.
2. Avaliação Fitness: Cada indivíduo é avaliado com base em uma função de fitness que quantifica o quão boa é sua solução para o problema em questão.
3. Seleção: Indivíduos são selecionados para reprodução, geralmente com uma probabilidade proporcional ao seu fitness. Isso permite que indivíduos melhores (com maior fitness) tenham uma maior chance de serem escolhidos para reprodução.
4. Recombinação (Cruzamento): Pares de indivíduos selecionados são combinados através de um operador de cruzamento para gerar novos indivíduos (descendentes)
5. Mutação: Ocorre uma pequena probabilidade de mutação, onde alguns genes dos novos indivíduos podem ser alterados aleatoriamente.
6. Elitismo: Após a aplicação dos operadores genéticos, os indivíduos com os melhores resultados (maior fitness) na população atual são selecionados para passar diretamente para a próxima geração sem sofrer alterações. Isso garante que as melhores soluções encontradas não sejam perdidas ao longo das iterações do algoritmo.
7. Formação da Próxima Geração: Combinando os indivíduos selecionados através dos operadores genéticos com os indivíduos preservados pelo elitismo, forma-se a nova população para a próxima iteração.
8. Critério de Parada: O processo é repetido por um número fixo de iterações ou até que um critério de parada seja alcançado (por exemplo, convergência para uma solução satisfatória).

O algoritmo genético híbrido que insere o elitismo usando a estratégia (μ, λ) é uma variante dos algoritmos genéticos tradicionais que incorpora uma estratégia para preservar os melhores indivíduos de uma geração para a próxima. Essa abordagem visa combinar a exploração do espaço de busca com a preservação de soluções promissoras, melhorando assim a eficiência do processo de otimização.

O pseudocódigo para o AG híbrido (μ, λ) proposto é apresentado no Algoritmo 3.

Algorithm 3 Algoritmo Genético Híbrido - elitismo com (μ, λ)

```

1: tampop  $\leftarrow$  tamanho populacional de interesse
2:  $n \leftarrow$  número de indivíduos de elite
3:  $D \leftarrow \{\}$  ▷ Inicializa a população
4: for tampop vezes do
5:    $D \leftarrow D \cup$  (novo indivíduo aleatório)
6: end for
7: Melhor  $\leftarrow$  Valor arbitrário
8: while condição de parada não satisfeita do
9:   for cada indivíduo  $D_i \in D$  do
10:    Avaliar( $D_i$ )
11:    if Aptidão( $D_i$ ) > Aptidão(Melhor) then
12:      Melhor  $\leftarrow D_i$ 
13:    end if
14:  end for
15:   $Q \leftarrow$  os  $n$  indivíduos mais aptos em  $D$ 
16:  for (tampop -  $n$ )/2 vezes do
17:     $D_a \leftarrow$  Seleção( $D$ )
18:     $D_b \leftarrow$  Seleção( $D$ )
19:     $C_a, C_b \leftarrow$  Cruzamento(Cópia( $D_a$ ), Cópia( $D_b$ ))
20:     $Q \leftarrow Q \cup \{$ Mutação( $C_a$ ), Mutação( $C_b$ ) $\}$ 
21:  end for
22:   $D \leftarrow Q$ 
23:
24: end while
25: return Melhor

```

2.8.7 Algoritmo Genético Híbrido: Elitismo com $(\mu + \lambda)$

O Algoritmo Genético com Elitismo $(\mu + \lambda)$ representa uma abordagem evolutiva que incorpora elementos fundamentais do modelo (μ, λ) , distinguindo-se, contudo, pela estratégia empregada na formação das novas gerações. Enquanto no modelo (μ, λ) os indivíduos da geração corrente são integralmente substituídos por seus descendentes, no modelo $(\mu + \lambda)$ a geração subsequente resulta de uma combinação estratégica dos μ indivíduos mais aptos da geração anterior (os pais) com os λ descendentes gerados. Essa interação estabelece uma competição direta entre as gerações, permitindo que os melhores indivíduos da geração anterior sobrevivam e contribuam ativamente com suas características genéticas para as próximas iterações.

Essa dinâmica de seleção confere ao modelo $(\mu + \lambda)$ uma maior robustez no processo evolutivo, ao preservar soluções de alta qualidade e, simultaneamente, explorar novas áreas do espaço de busca. Tal equilíbrio entre exploração (descoberta de novas soluções) e exploração (refinamento das soluções existentes) é crucial para a eficácia do algoritmo. Essa característica destaca o modelo como uma ferramenta versátil em problemas de otimização que exigem tanto inovação quanto refinamento das soluções.

Contudo, o modelo $(\mu + \lambda)$ não está isento de desafios. A inclusão sistemática de indivíduos altamente aptos pode levar à convergência prematura, um fenômeno no qual a população tende a se concentrar em torno de uma solução subótima devido à perda de diversidade genética. Esse problema é particularmente crítico em cenários onde o espaço de busca é altamente complexo e multimodal, pois a diversidade é essencial para escapar de ótimos locais e explorar soluções mais promissoras.

Apesar dessas limitações, o elitismo desempenha um papel fundamental ao garantir que indivíduos com alta aptidão sejam preservados, evitando sua eliminação prematura. Essa preservação maximiza a eficiência do algoritmo em problemas de otimização que demandam um equilíbrio entre exploração e exploração. Quando calibrado adequadamente, o modelo $(\mu + \lambda)$ se torna altamente eficaz para uma ampla gama de aplicações, incluindo problemas de engenharia e otimização combinatória complexa.

Assim, o elitismo transcende sua função de mera preservação, transformando-se em uma estratégia essencial para promover um comportamento evolutivo equilibrado e eficiente. Esse mecanismo não apenas assegura a eficácia do algoritmo, mas também amplia sua adaptabilidade a diferentes contextos e demandas, consolidando-o como uma abordagem robusta e inovadora em otimização evolutiva.

O pseudocódigo para o AG híbrido $(\mu + \lambda)$ proposto é apresentado no Algoritmo 4.

Algorithm 4 Algoritmo Genético Híbrido - elitismo com $(\mu + \lambda)$

```

1:  $\mu \leftarrow$  número de pais selecionados
2:  $\lambda \leftarrow$  número de filhos gerados pelos pais
3:  $D \leftarrow \{\}$  ▷ Inicializa a população
4: for  $\mu + \lambda$  vezes do
5:    $D \leftarrow D \cup$  novo indivíduo aleatório
6: end for
7: Melhor  $\leftarrow$  Valor arbitrário
8: while condição não satisfeita de parada do
9:   for cada indivíduo  $D_i \in D$  do
10:    Avaliar( $D_i$ )
11:    if Qualidade( $D_i$ ) > Qualidade(Melhor) then
12:      Melhor  $\leftarrow D_i$ 
13:    end if
14:   end for
15:    $Q \leftarrow$  os  $\mu$  indivíduos mais aptos em  $D$ 
16:   for  $(\mu + \lambda - \mu)/2$  vezes do
17:      $D_a \leftarrow$  Seleção( $D$ )
18:      $D_b \leftarrow$  Seleção( $D$ )
19:      $C_a, C_b \leftarrow$  Cruzamento(Cópia( $D_a$ ), Cópia( $D_b$ ))
20:      $Q \leftarrow Q \cup \{$ Mutação( $C_a$ ), Mutação( $C_b$ ) $\}$ 
21:   end for
22:    $D \leftarrow Q$ 
23: end while return Melhor

```

Os modelos (μ, λ) e $(\mu + \lambda)$, no contexto de algoritmos genéticos, diferenciam-se por estratégias distintas de formação da nova geração, preservação da diversidade genética, dinâmica de convergência e impacto do elitismo. Esses aspectos desempenham papéis cruciais na eficiência e adaptabilidade do processo evolutivo, especialmente em problemas de otimização de alta complexidade.

- **Operação de União e Formação da Nova Geração:** No modelo (μ, λ) , a nova geração é formada exclusivamente pelos λ descendentes, substituindo integralmente os μ pais da geração anterior. Essa abordagem promove uma renovação total a cada iteração, o que pode acelerar a adaptação do algoritmo a novas soluções. Em contrapartida, no modelo $(\mu + \lambda)$, a nova população é composta pela combinação dos μ pais com os λ descendentes. Esse mecanismo competitivo, que preserva os pais nas iterações seguintes, confere maior estabilidade ao processo evolutivo, assegurando a retenção de informações genéticas relevantes ao longo das gerações.
- **Diversidade Genética e Exploração do Espaço de Busca:** O modelo $(\mu + \lambda)$ promove a manutenção de indivíduos de alta aptidão, favorecendo a diversidade genética e possibilitando a exploração eficiente de regiões inexploradas do espaço de busca. Esse equilíbrio reduz a probabilidade de estagnação em ótimos locais. Por outro lado, a estratégia de substituição completa do modelo (μ, λ) proporciona uma renovação populacional mais intensa, mas pode levar à perda precoce de soluções promissoras, comprometendo a exploração de trajetórias evolutivas potenciais.
- **Dinâmica de Convergência:** Quanto à convergência, o modelo (μ, λ) apresenta uma trajetória de otimização mais acelerada, devido à constante renovação da população. Essa característica é vantajosa em problemas que exigem alta adaptabilidade em curto prazo. No entanto, a substituição completa dos pais pode resultar na perda de indivíduos altamente aptos, comprometendo a qualidade da solução final. Por sua vez, o modelo $(\mu + \lambda)$ mitiga esse risco ao preservar pais aptos, favorecendo a convergência para soluções de melhor qualidade. Contudo, a retenção de progenitores dominantes pode limitar a variabilidade genética, levando à convergência prematura em soluções subótimas.
- **Elitismo e Influência Evolutiva:** O elitismo incorporado no modelo $(\mu + \lambda)$ garante que os indivíduos mais aptos permaneçam na população ao longo das gerações, aumentando a eficácia do processo evolutivo. Essa característica promove um equilíbrio essencial entre exploração de novas áreas do espaço de busca e exploração das melhores soluções já identificadas. No entanto, o elitismo deve ser aplicado com moderação, pois a redução excessiva da diversidade pode prejudicar a busca por soluções globais, especialmente em problemas que requerem ampla exploração.

A escolha entre os modelos (μ, λ) e $(\mu + \lambda)$ depende das características do problema e das prioridades do processo de otimização. O modelo (μ, λ) é mais adequado para situações que demandam alta taxa de renovação e adaptação rápida, enquanto o modelo $(\mu + \lambda)$ é preferido em cenários que exigem a preservação de soluções de alta qualidade e um equilíbrio sustentável entre exploração e exploração. Essa análise ressalta a importância de compreender os diferentes mecanismos evolutivos e suas implicações para maximizar o desempenho dos algoritmos em aplicações práticas e teóricas.

2.9 Revisão Bibliográfica

Nesta seção, apresenta-se uma análise bibliográfica detalhada e abrangente sobre os principais temas que fundamentam este estudo, com destaque para a aplicação de estratégias evolutivas e algoritmos genéticos na resolução de problemas de otimização, bem como na alocação de Recursos Energéticos Distribuídos (REDs).

Embora a técnica de otimização meta-heurística, que será abordada em profundidade na Seção 3, constitua o foco deste estudo, outras abordagens metodológicas relevantes também merecem consideração, como a busca exaustiva, os algoritmos exatos, os híbridos e os compostos, que oferecem alternativas robustas para problemas específicos.

A busca exaustiva, comumente conhecida como força bruta, caracteriza-se pela exploração completa do espaço de busca, avaliando todas as alternativas possíveis. Apesar de garantir a identificação da solução ótima, essa abordagem apresenta um custo computacional extremamente elevado, especialmente em problemas de alta complexidade e com um grande número de soluções potenciais. Essas características frequentemente tornam sua aplicação inviável em contextos práticos, particularmente em situações que exigem respostas em tempo hábil.

Os algoritmos exatos, por sua vez, têm como objetivo determinar a solução ideal de um problema mediante a exploração integral do espaço de soluções. Contudo, essa abordagem também demanda recursos computacionais substanciais e pode apresentar tempos de execução excessivamente longos, especialmente em problemas de larga escala. Os modelos matemáticos utilizados nesse contexto são estruturados com base em funções-objetivo e conjuntos de restrições que descrevem formalmente o problema a ser resolvido. Embora ofereçam precisão elevada, essas técnicas podem ser limitadas ao lidar com características ou restrições que nem sempre são facilmente representáveis em termos matemáticos.

A literatura aponta para o desenvolvimento de diversos modelos e abordagens voltados à integração de REDs nas redes elétricas, com o objetivo de aprimorar a estabilidade e o perfil de tensão, além de reduzir as perdas de energia. Cada modelo aborda diferentes restrições no problema de otimização, incluindo: i) limites de tensão nas barras,

ii) capacidade máxima da geração distribuída (GD), iii) restrições de corrente e iv) limites de potência reativa da GD. Além disso, múltiplos parâmetros de otimização são considerados para cada tipo de GD, tais como: i) potência injetada, ii) localização geográfica, iii) número de unidades de GD e iv) tipo de tecnologia de geração empregada (SULTANA et al., 2016).

Este trabalho adota algoritmos meta-heurísticos, que se destacam por sua eficiência em encontrar soluções próximas à ótima, reduzindo os custos computacionais e o tempo de execução. Assim, serão apresentados estudos que utilizam essa classe de algoritmos como forma de alcançar soluções eficazes, priorizando a otimização de recursos.

O trabalho desenvolvido por (PRADO; GARCES, 2013) propõe uma abordagem metodológica para a alocação otimizada de unidades de geração distribuída (GD), baseada no algoritmo genético de Chu-Beasley. Conforme apontado pelo autor, essa técnica apresenta elevado desempenho e alcança soluções precisas na resolução do problema de alocação de GD, especialmente em sistemas de distribuição de pequeno e médio porte. Os resultados demonstraram que, com o aumento da complexidade do sistema, o algoritmo proposto revela-se ainda mais eficiente em comparação com métodos como a busca exaustiva. A metodologia foi implementada em três sistemas distintos de distribuição, contendo 10, 34 e 70 barras, respectivamente. Para cada sistema, foram avaliados cenários contemplando a inserção de uma ou duas unidades de GD. Na realização dos fluxos de carga, foi utilizado o Método de Soma de Corrente (MSI), reconhecido por sua simplicidade e eficácia em análises de sistemas de distribuição. Os principais resultados obtidos consistem na determinação das localizações ideais para as unidades de GD, considerando a minimização das perdas de potência ativa e a consequente melhoria nos níveis de tensão nas barras do sistema. Esses achados evidenciam a eficácia do algoritmo genético de Chu-Beasley como uma ferramenta robusta e eficiente para problemas de otimização relacionados à alocação de recursos energéticos em redes elétricas.

A dissertação de mestrado de (NOGUEIRA, 2021) apresenta uma metodologia de otimização que integra a consideração de incertezas no problema de alocação e dimensionamento de geração distribuída (GD) em redes de distribuição de energia elétrica. A abordagem desenvolvida emprega o fluxo de potência intervalar (FPI), uma técnica que possibilita a inclusão das incertezas no contexto do problema de otimização combinatória. Esse problema é resolvido utilizando-se as meta-heurísticas Symbiotic Organism Search (SOS) e Particle Swarm Optimization (PSO), com o objetivo de realizar uma análise comparativa de desempenho entre os métodos. Os resultados obtidos indicam que a meta-heurística SOS demonstra maior robustez em relação ao PSO, que apresentou desempenho inferior na resolução do problema proposto. Essa superioridade do SOS destaca sua capacidade de lidar com incertezas e desafios computacionais elevados, evidenciando sua aplicabilidade em cenários complexos envolvendo a alocação e o dimensionamento de GD em redes

elétricas de distribuição.

O estudo conduzido por (THE; QUOC; NGOC, 2020) propõe a aplicação do algoritmo Symbiotic Organism Search (SOS) para determinar a configuração ideal da rede elétrica e o posicionamento estratégico de unidades de geração distribuída (GD), visando à minimização das perdas de potência em redes radiais de distribuição. O algoritmo simula interações simbióticas, incluindo mutualismo, comensalismo e parasitismo, como estratégias para resolver problemas complexos de otimização. Durante o processo de otimização, a reconfiguração da rede frequentemente gera um número elevado de configurações inviáveis. Para lidar com essas limitações e assegurar a preservação da topologia radial da rede, foi integrada a teoria dos grafos à metodologia, aplicada em conjunto com o fluxo de potência. Essa abordagem contribuiu significativamente para a obtenção de soluções viáveis e de alta qualidade. A metodologia desenvolvida foi implementada em sistemas de distribuição com 33, 69, 84 e 119 barras, abrangendo sete cenários distintos para avaliação. Os resultados das simulações, aliados à análise comparativa de desempenho em relação a outros métodos de otimização, demonstraram que o algoritmo SOS apresentou uma eficiência superior. Em particular, o método mostrou-se altamente eficaz na resolução de problemas de reconfiguração de redes e alocação de GD, destacando-se em aplicações envolvendo redes de distribuição complexas e de grande porte. Esses achados reafirmam a aplicabilidade do SOS como uma ferramenta robusta e eficiente em cenários desafiadores.

O trabalho apresentado por (PHAM; NGUYEN; DINH, 2021) introduz um algoritmo de otimização inovador denominado Enhanced Coyote Optimization Algorithm (ECO). Este método foi desenvolvido para otimizar a seleção da localização e capacidade de geradores distribuídos (DGs) em redes de distribuição radial. Trata-se de um problema de otimização multiobjetivo, no qual a instalação estratégica dos DGs deve, simultaneamente, minimizar as perdas de energia e os custos operacionais, além de melhorar a estabilidade da tensão na rede. Baseado no algoritmo original Coyote Optimization Algorithm (COA), o ECO foi aprimorado para ampliar o espaço de busca e manter um conjunto robusto de soluções a cada geração. Duas modificações principais foram incorporadas para melhorar a eficiência do método original. A primeira substituiu a solução central pela melhor solução atual durante a geração inicial de novas soluções. Já a segunda modificação concentra-se na redução da carga computacional e no tempo de processamento durante a etapa subsequente de geração de soluções. Para validar a eficácia do ECO, foram realizados experimentos em três redes de distribuição padrão IEEE, contendo 33, 69 e 85 barras. O método foi comparado com o COA, bem como com outros algoritmos meta-heurísticos, como Salp Swarm Algorithm (SSA) e Sunflower Optimization Algorithm (SOA). Adicionalmente, análises estatísticas detalhadas foram realizadas para avaliar os parâmetros de controle mais adequados e verificar o desempenho geral do ECO. Os resultados também foram comparados com outros métodos amplamente utilizados, como AG (Algoritmo Genético), PSO (Particle Swarm Optimization), SA (Simulated Annealing), algoritmos de otimização

de forrageamento bacteriano, de busca retroativa, HSA (Harmony Search Algorithm), e Whale Optimization Algorithm (WOA). As análises demonstraram que o ECOA foi capaz de identificar, de forma mais eficiente, as localizações e capacidades ideais dos DGs, superando outros métodos tanto em termos de precisão quanto de velocidade.

O estudo de (MACHAVA; KABERERE; VILANCULO, 2022) apresenta uma metodologia para a alocação otimizada de geradores distribuídos (GD) em redes de distribuição de energia elétrica, com o objetivo de minimizar as perdas totais do sistema. A abordagem proposta emprega algoritmos genéticos (AG), incorporando restrições operacionais baseadas nos limites de tensão máxima e mínima em cada barra. O fluxo de carga foi implementado utilizando o software OpenDSS, que foi integrado ao algoritmo genético para viabilizar o processo de otimização. Durante as simulações, curvas de carga representativas foram adotadas para modelar de maneira mais realista a operação do sistema de distribuição, proporcionando uma análise criteriosa e precisa. Essa estratégia permite a identificação das localizações ideais para a instalação de GDs, levando em consideração as condições operacionais reais da rede elétrica. A metodologia foi aplicada em sistemas de teste padronizados do IEEE, incluindo redes de 13, 34 e 126 barras. Os resultados obtidos demonstraram a eficácia da abordagem na determinação das localizações ótimas para os GDs, promovendo uma redução significativa nas perdas totais de potência ativa e assegurando o cumprimento das restrições operacionais previamente estabelecidas.

O artigo apresentado por (HASSAN; SUN; WANG, 2020) oferece significativas contribuições ao sistema elétrico, com ênfase na integração de unidades de geração distribuída (GD). O estudo avalia técnicas avançadas para o dimensionamento (sizing) e a localização (sitting) de GDs alimentadas por fontes renováveis de energia, baseando-se em estudos recentes já aplicados à otimização de sistemas de distribuição de energia elétrica. Além disso, o trabalho identifica os principais fatores motivadores, ou drivers, que impulsionam o crescente interesse pela GD renovável. Esses fatores incluem aspectos ambientais, econômicos, avanços tecnológicos e mudanças no âmbito regulatório, os quais têm sido determinantes para a rápida expansão da GD baseada em fontes sustentáveis. O artigo também apresenta uma análise consolidada das ferramentas de otimização meta-heurísticas mais populares, organizada em formato tabular, onde são discutidos os méritos e limitações de cada método. Entre os algoritmos analisados, destacam-se o Simulated Annealing (SA), Particle Swarm Optimization (PSO), Tabu Search (TS), Ant Colony Search Optimization (ACSO), Artificial Bee Colony (ABC), Firefly Search Algorithm e Cuckoo Search. Essa síntese fornece uma visão abrangente das principais abordagens de otimização, servindo como um recurso valioso para pesquisadores e profissionais que buscam soluções eficientes para problemas de otimização em redes de distribuição de energia.

O trabalho apresentado por (LOPEZ et al., 2019) realiza uma comparação detalhada de técnicas meta-heurísticas aplicadas à localização e ao dimensionamento de unidades de

geração distribuída (GD) em alimentadores de distribuição. A formulação do problema tem como objetivo a minimização das perdas de potência ativa em sistemas de distribuição radial com a inclusão de GD. As técnicas analisadas incluem Tabu Search (TS), Scatter Search e Ant Colony Optimization (ACO), que foram avaliadas quanto à sua eficácia na redução das perdas e na melhoria dos perfis de tensão em nós críticos do sistema. Para o dimensionamento e posicionamento das unidades de GD, foram considerados critérios como o respeito aos limites de tensão e a capacidade máxima de carregamento das linhas, garantindo a operação segura e eficiente do sistema. A análise comparativa avaliou o desempenho das técnicas tanto em termos de precisão das soluções obtidas quanto em relação aos tempos de execução, fornecendo uma perspectiva abrangente das vantagens e limitações de cada abordagem. Os resultados indicam que o Scatter Search apresentou um desempenho superior em comparação com as demais técnicas analisadas, destacando-se pela maior eficiência na redução das perdas de potência e na estabilização dos níveis de tensão em nós críticos. Essa conclusão reforça o potencial do Scatter Search como uma ferramenta robusta e eficaz para problemas de otimização em redes de distribuição de energia.

O estudo conduzido por (LEZAMA; GALEANO; DUQUE, 2020) apresenta uma abordagem fundamentada em algoritmos genéticos (AG) e na meta-heurística Particle Swarm Optimization (PSO) para a determinação da alocação ótima de geração distribuída (GD) em sistemas elétricos de potência, considerando múltiplos cenários operacionais. A metodologia proposta incorpora a definição de diversos índices, elaborados para avaliar o desempenho da rede em termos de limites de tensão e níveis de carregamento. Esses índices são utilizados para identificar violações em diferentes condições operacionais, orientando o funcionamento do algoritmo meta-heurístico. A formulação do problema é estruturada com o objetivo de minimizar os impactos das contingências no carregamento da rede e no perfil de tensão dos sistemas elétricos, por meio de uma função objetivo bem delineada. Para validar a eficácia da abordagem proposta, foram conduzidos testes em sistemas-padrão IEEE de 30 e 57 barras. Os resultados apresentados evidenciam que a metodologia é capaz de identificar a alocação ideal de GD, maximizando seus benefícios em termos de melhoria dos perfis de tensão e alívio dos carregamentos críticos na rede elétrica.

O estudo conduzido por (TRUONG et al., 2020) apresenta um esquema inovador baseado em um método meta-heurístico aprimorado para determinar o número ótimo de unidades de geração distribuída (GD) a serem instaladas em redes de distribuição, visando maximizar a penetração dessas unidades. O método proposto, denominado Quasi-Operational Chaotic Symbiotic Organisms Search (QOCSOS), constitui uma versão avançada do algoritmo SOS original. O QOCSOS combina duas estratégias de busca complementares: aprendizado baseado em quase-oposição e pesquisa local caótica, com o objetivo de melhorar a eficiência e o desempenho do SOS. A abordagem desenvolvida foi utilizada para determinar o número ideal, a localização, o dimensionamento e o fator de

potência das unidades de GD, considerando cenários com diferentes fatores de potência (unitário e não unitário). O objetivo principal foi minimizar as perdas de potência ativa na rede de distribuição. A eficácia da metodologia foi avaliada em redes radiais de distribuição padrão IEEE, incluindo sistemas de teste com 33, 69 e 118 barras. Os resultados obtidos pelo QOCSOS foram comparados com os de outros métodos consagrados na literatura, bem como com o algoritmo SOS em sua versão padrão. De acordo com os autores, a análise comparativa revelou que o QOCSOS produziu soluções de maior qualidade e apresentou desempenho superior em relação às técnicas avaliadas, destacando-se como uma ferramenta robusta e eficiente para a otimização de redes de distribuição.

De maneira geral, os estudos previamente abordados têm como objetivos principais a minimização das perdas ativas de energia, a melhoria do perfil de tensão, o incremento da confiabilidade do sistema e a promoção da eficiência econômica, entre outras metas associadas à otimização de redes de distribuição de energia elétrica. Dentro desse contexto, o presente trabalho propõe-se a contribuir com soluções inovadoras por meio da aplicação das metodologias de Estratégia Evolutiva Híbrida (EEH) e Algoritmo Genético Híbrido (AGH), nas formas (μ, λ) e $(\mu + \lambda)$. Essas técnicas são empregadas para realizar, de forma simultânea, a alocação e o dimensionamento da potência injetada pelos Recursos Energéticos Distribuídos (REDs), como a geração distribuída solar e sistemas de armazenamento de energia em baterias. Até o momento, essa aplicação específica, no contexto da alocação de REDs, não foi identificada em trabalhos previamente investigados na literatura científica e acadêmica, o que torna esta abordagem uma contribuição inédita para o campo da otimização de redes de distribuição de energia.

Adicionalmente, como parte desta contribuição inédita, o trabalho desenvolveu um algoritmo inovador para o desenho dos diagramas unifilares dos sistemas de distribuição de energia elétrica, utilizando a linguagem de programação Python. Essa metodologia, até então não aplicada na literatura, permite uma modelagem mais precisa e eficiente das redes de distribuição, representando um avanço significativo na forma de construir diagramas unifilares de maneira automatizada e integrada ao processo de otimização de sistemas de distribuição.

A implementação dessa abordagem foi realizada com o uso do software OpenDSS, permitindo uma análise integrada das soluções propostas. Dessa forma, a combinação das técnicas de otimização com a modelagem de redes contribui para o aprimoramento do planejamento e operação de redes de distribuição de energia elétrica, integrando de forma eficaz os recursos energéticos distribuídos.

3 Metodologia

Neste capítulo, apresenta-se a metodologia utilizada no estudo, organizada em três etapas principais. Na primeira etapa, definem-se os dados do sistema e as características operacionais do caso base, abrangendo o cenário inicial sem a presença de recursos energéticos distribuídos (REDs) e as variáveis que serão empregadas na análise. Na segunda etapa, determina-se o espaço de busca, especificando os possíveis locais para instalação e as capacidades máximas de geração distribuída e dos sistemas de armazenamento de energia. Por fim, na terceira etapa, aplicam-se as duas estratégias de otimização descritas na Seção 2.8, com o objetivo de identificar os melhores locais para a instalação dos REDs considerados, atendendo aos requisitos técnicos estabelecidos e alcançando os objetivos específicos definidos.

3.1 DADOS DO SISTEMA E DEFINIÇÃO DO CASO BASE

Nesta fase, o principal objetivo é avaliar as características do sistema de distribuição sem a presença dos recursos energéticos distribuídos, ou seja, a simulação do sistema sem a presença de geração solar fotovoltaica e baterias, modeladas como elementos de PVSystem (Seção 2.7.1) e SAEB (Seção 2.7.2.1).

O estudo do sistema é realizado por simulações em que o fluxo de potência é realizado no software OpenDSS, conforme apresentado na Seção 2.7.

Os parâmetros de entrada principais que necessários para o estudo são:

- **Topologia:** diagrama unifilar da rede, bem como as coordenadas de localização geográfica dos diferentes componentes do sistema.
- **Dados de barramentos:** são utilizados os dados de demanda de potência ativa e reativa das cargas existentes no barramentos, juntamente com seus perfis diários de consumo.
- **Dados de linhas:** correspondem aos parâmetros elétricos das linhas de distribuição do sistema em análise.
- **Barramentos candidatos para alocação:** definição dos locais onde os REDs podem ser alocados, incluindo dados adicionais como tensão nominal no barramento, capacidade de corrente, etc.

A partir desses parâmetros, serão obtidas informações de desempenho do sistema, incluindo:

- Perfil de Tensão por Linha: Valores de tensão registrados em cada linha do sistema, permitindo a avaliação do comportamento elétrico da rede.
- Perdas de Energia Ativa nas Linhas: Quantificação das perdas de potência ativa ao longo das linhas de distribuição, fornecendo uma métrica crucial para análise da eficiência do sistema.
- Perfil de Carregamento das Linhas: Representação do nível de utilização das linhas, identificando possíveis sobrecargas ou subutilizações na infraestrutura elétrica.

3.1.1 Estudo do sistema original

Definidos os parâmetros de entrada, é realizada a simulação do sistema original para obter os parâmetros de referência que serão utilizados ao longo da metodologia. Esses parâmetros correspondem aos níveis de tensão por linhas (V_j), perdas de energia ativa nas linhas ($P_{\text{perdas},j}^{\text{base}}$) e níveis de carregamento por linhas ($C_{\text{max},j}$).

Com base nesses parâmetros de estudo, obtidos por meio da simulação de fluxo de potência do sistema sem a presença dos REDs, são estabelecidos os parâmetros de desempenho do sistema, definidos da seguinte maneira:

- **Perdas totais** ($P_{\text{perdas}}^{\text{base}}$): As perdas totais do sistema são calculadas somando as perdas individuais de cada linha, conforme a equação 3.1, em que j corresponde ao número da linha e nl representa número total de linhas no sistema.

$$P_{\text{perdas}}^{\text{base}} = \sum_{j=1}^{nl} P_{\text{perdas},j}^{\text{base}} \quad (3.1)$$

- **Violações do nível máximo de tensão** ($NV_{\text{máx}}$): A avaliação dos níveis de tensão é feita por barramento, verificando se a tensão é superior a 105%. Esta variável armazena o número dos barramentos em que a tensão excede 105%, conforme definido em (ANEEL, 2021a).
- **Violações do nível mínimo de tensão** ($NV_{\text{mín}}$): A avaliação é feita por barramento para verificar se o nível de tensão é inferior a 95%. Esta variável corresponde ao número de barramentos em que a tensão for inferior a 95%, conforme definido em (ANEEL, 2021a).

3.1.1.1 Elaboração dos Diagramas Unifiliares

A principal contribuição deste trabalho está na aplicação das estratégias de otimização por meio das metodologias de Estratégia Evolutiva Híbrida (EEH) e Algoritmo

Genético Híbrido (AGH), que visam otimizar a alocação de Recursos Energéticos Distribuídos (REDs) em redes de distribuição de energia elétrica. No entanto, uma outra contribuição significativa e inédita foi o desenvolvimento de uma metodologia para a construção de diagramas unifilares que representam, de forma integrada, tanto o perfil de carregamento quanto o perfil de tensão do sistema.

Essa metodologia foi implementada com o uso da linguagem de programação Python, em conjunto com o software OpenDSS, permitindo a automação e a visualização detalhada dos perfis de carregamento e de tensão ao longo da rede de distribuição. Até o momento, não se identificou na literatura acadêmica uma aplicação similar que utilize essas ferramentas de forma combinada para representar os perfis de carregamento e de tensão, especialmente considerando a alocação de REDs.

Embora a principal contribuição esteja voltada para as estratégias de otimização, a modelagem dos diagramas unifilares representa um avanço adicional, proporcionando uma ferramenta eficiente para o planejamento e a análise dos efeitos da inserção de REDs no comportamento operacional das redes. Essa abordagem oferece uma visualização precisa dos impactos dos REDs, contribuindo para uma compreensão mais profunda dos desafios e das soluções para a otimização de sistemas de distribuição de energia elétrica.

3.1.1.2 Elaboração do Diagrama Unifilar do Perfil de Carregamento do Sistema

A construção do Diagrama Unifilar do Perfil de Carregamento, tanto para cenários sem a presença dos REDs quanto para aqueles está alocado ao longo da rede de distribuição, em relação ao carregamento total do sistema. O carregamento total é definido como a soma dos valores individuais de carregamento de todos os barramentos do sistema, representando a demanda agregada da rede.

No diagrama, a espessura das linhas é diretamente proporcional à porcentagem do carregamento de cada barramento em relação ao carregamento total. Essa abordagem gráfica oferece uma representação visual clara e objetiva, destacando os barramentos com maiores níveis de carregamento na rede. Essa ferramenta facilita a análise da distribuição de cargas no sistema, permitindo a identificação intuitiva de áreas críticas, como barramentos sujeitos a sobrecargas ou subutilização.

A Figura 3.1 apresenta um exemplo prático dessa representação gráfica, ilustrando a aplicação do método para análise do perfil de carregamento em redes de distribuição. Esse tipo de representação contribui significativamente para a identificação de gargalos e o planejamento de melhorias na infraestrutura elétrica.




Figura 3.1 – Exemplo de Diagrama Unifilar do Perfil de Carregamento.

Fonte: Elaborado pelo Autor.

3.1.1.3 Elaboração do Diagrama Unifilar do Perfil de Tensão do Sistema

A elaboração do Diagrama Unifilar que representa o perfil de tensão em um sistema de distribuição, considerando cenários com ou sem a alocação de Geração Distribuída (GD), baseia-se nos valores de tensão de cada barramento. Esses valores são expressos em unidades por unidade (pu), assegurando a padronização e a comparabilidade entre diferentes condições operacionais do sistema.

Para aprimorar a clareza e a eficácia visual do diagrama, foram definidos critérios básicos de codificação por cores aplicados às linhas que interligam os barramentos, conforme é utilizado pelo Operanador Nacional do Sistema Elétrico (ONS, 2023). Cada faixa de tensão foi associada a uma cor específica, proporcionando uma interpretação imediata e intuitiva das condições de tensão ao longo da rede.

- $V_i < 95\%$: Azul.
- $95\% \leq V_i < 100\%$: Amarelo.
- $100\% \leq V_i \leq 105\%$: Verde.
- $V_i > 105\%$: Vermelho.

Um exemplo de plotagem é apresentado na figura 3.2.




Figura 3.2 – Exemplo de Diagrama Unifilar do Perfil de Tensão.

Fonte: Elaborado pelo Autor.

Essa abordagem gráfica permite a identificação rápida de eventuais desvios em relação aos limites operacionais regulamentares, facilitando a análise do impacto da GD na estabilidade e no perfil de tensão da rede.

O diagrama resultante não apenas sintetiza as condições operacionais do sistema de forma clara e acessível, mas também oferece informações relevantes para subsidiar decisões relacionadas ao planejamento, operação e melhoria da rede de distribuição.

3.2 DETERMINAÇÃO DO ESPAÇO DE BUSCA

Realizada a definição do sistema de distribuição para teste da metodologia e obtidos os principais parâmetros de desempenho do sistema (perdas totais do sistema original e violações nos limites de tensão), continua-se com a determinação da capacidade máxima do empreendimento de GD e dos sistemas de armazenamento de energia.

O objetivo primordial desta etapa é estabelecer os valores de potência máxima que pode ser injetada nos barramentos candidatos, visando as mínimas perdas de energia totais do sistema obtidas ao alocar uma usina solar e/ou sistema de armazenamento de

energia com baterias nesses barramentos específicos, conforme o fluxograma apresentado na Figura 3.3.

Inicia-se com os barramentos disponíveis para a alocação dos REDs. Para cada um deles, é definido o mesmo valor de potência incremental, P_{Δ}^{RED} . Em que, para a geração solar fotovoltaica, a potência é em kVA_{Δ} e para o sistema de armazenamento, o incremento é kW_{Δ} .

Primeiro, inicializa-se a potência injetada pelo RED para cada barramento (P_j^{RED}), conforme 3.2. O valor das perdas do sistema atual ($P_{\text{perdas},j}^{\text{base}}$) deve ser armazenado e considerado como referência, sem a influência da alocação do RED.

$$\begin{aligned} 1) \quad & P_j^{\text{RED}} = 0 \\ 2) \quad & P_{\text{perdas},j} = P_{\text{perdas},j}^{\text{base}} \end{aligned} \quad (3.2)$$

Após a inicialização das variáveis, começa-se um ciclo iterativo de busca exaustiva. Nesse processo, enquanto o valor de $P_{\text{perdas},j}$ não exceda o valor de $P_{\text{perdas}^{\text{base}}}$, são adicionados incrementos na injeção de potência dos REDs. Esses valores de potência incrementais são armazenados para identificar o ponto máximo da injeção que resulta nas menores perdas de energia. Em outras palavras:

$$\begin{aligned} \text{Enquanto:} \quad & P_{\text{perdas},j} \leq P_{\text{perdas}^{\text{base}}}, \\ \text{faça:} \quad & P_j^{\text{RED}} = P_j^{\text{RED}} + P_{\Delta}^{\text{RED}} \\ \text{em que:} \quad & P_{\Delta}^{\text{RED}} = \text{kVA}_{\Delta}, \quad \text{se RED é GD} \\ & P_{\Delta}^{\text{RED}} = \text{kW}_{\Delta}, \quad \text{se RED é SAEB} \end{aligned} \quad (3.3)$$

Ao atingir um valor superior às perdas do caso base, o processo iterativo é interrompido.

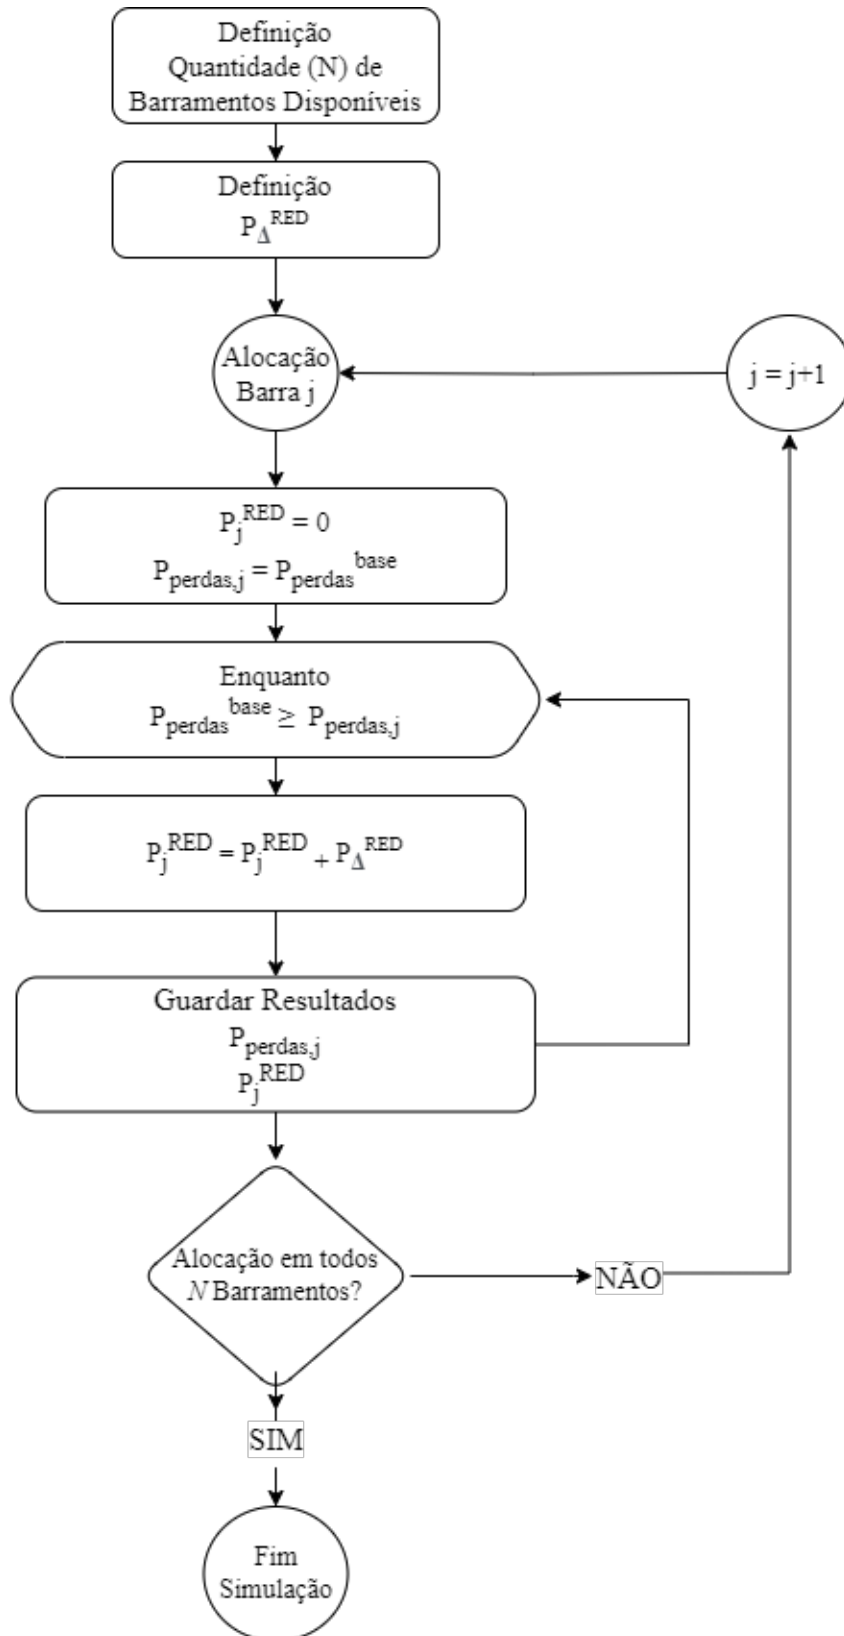


Figura 3.3 – Fluxograma para determinar a capacidade máxima dos REDs.

Fonte: Elaborado pelo Autor.

Por meio desse procedimento, é possível identificar, para os barramentos candidatos à alocação de Recursos Energéticos Distribuídos, a potência máxima desses recursos que pode ser injetada, visando à minimização das perdas de energia no sistema. Esse processo geralmente resulta na determinação dos pontos de mínimo em uma superfície parabólica tridimensional, que representa a combinação ideal entre o tipo de RED (Geração Distribuída e Sistema de Armazenamento em Baterias), a localização do barramento e a potência injetada, conforme ilustrado na 3.4.

Essa representação gráfica permite identificar a potência injetada ótima, que corresponde à maior redução de perdas no sistema quando o RED é alocado em um barramento específico. A potência ótima injetada torna-se um parâmetro essencial, servindo como referência para a definição da capacidade máxima dos REDs, expressa em kW e kVA. Essa informação é indispensável para subsidiar a aplicação das estratégias de otimização voltadas para a alocação conjunta e eficiente dos REDs no sistema.




Figura 3.4 – Percentual de redução de perdas em função da potência incremental injetada pelos Recursos Energéticos Distribuídos.

Fonte: Elaborado pelo Autor.

3.3 APLICAÇÃO DAS ESTRATÉGIAS DE OTIMIZAÇÃO

A identificação da configuração ideal dos Recursos Energéticos Distribuídos em sistemas de distribuição demanda o uso de algoritmos de otimização avançados. Entre as abordagens exploradas nesta pesquisa, destacam-se a Estratégia Evolutiva (Seção 2.8.1 e o Algoritmo Genético 2.8.2). O AG incorpora mecanismos sofisticados, como o elitismo, que assegura a preservação dos indivíduos mais aptos ao longo das gerações, promovendo uma evolução consistente e eficiente. A implementação dessas estratégias exige

a definição de procedimentos robustos, que abrangem desde a geração inicial de indivíduos representativos de soluções viáveis até a aplicação rigorosa de operadores genéticos, como seleção, cruzamento e mutação – elementos fundamentais para o sucesso dos algoritmos evolutivos e genéticos.

Após a definição do sistema de distribuição e a determinação dos parâmetros de desempenho relevantes, as análises avançam para a identificação dos barramentos aptos a receber geração distribuída, os sistemas de armazenamento de energia e a definição dos valores de geração de referência. Este processo é essencial para garantir a alocação eficiente dos RED e está descrito em detalhe nas seções metodológicas. A aplicação das estratégias de otimização envolvem a modelagem de indivíduos e a utilização de operadores genéticos cuidadosamente parametrizados, com foco na maximização da qualidade das soluções e na convergência do processo de otimização.

Antes de abordar os algoritmos em profundidade, é fundamental compreender a construção dos indivíduos no contexto deste estudo. Cada indivíduo, representando uma solução potencial, é submetido a processos estruturados que incluem seleção baseada em critérios de aptidão, mutação para introdução de diversidade genética e cruzamento para a recombinação de características vantajosas. Essas etapas são meticulosamente ajustadas para otimizar o desempenho do sistema, garantindo que a modelagem evolutiva produza soluções robustas e eficientes.

3.3.1 Construção do Indivíduo e População Inicial

A partir da identificação dos barramentos do sistema que podem receber ou não a alocação de um Recurso Energético Distribuído (RED), define-se um indivíduo como uma matriz composta por dois vetores linha de extensão M , onde M corresponde ao número de barramentos candidatos à alocação de RED. Cada elemento da matriz é representado por um valor booleano (0 ou 1), sendo 1 indicativo da presença de um RED no barramento correspondente, e 0, da sua ausência. A primeira linha da matriz especifica os barramentos destinados à alocação de usinas solares fotovoltaicas, enquanto a segunda linha define os barramentos reservados para a instalação de sistemas de baterias. Dessa forma, no início do algoritmo, são gerados N indivíduos para compor a população inicial.

Para ilustrar, considere um sistema com cinco barramentos. Uma população inicial pode ser formada por três indivíduos, considerando a restrição de alocar, no máximo, dois REDs no sistema. Uma possível geração inicial pode ser representada pela configuração mostrada na Tabela 3.1. Por exemplo, o primeiro indivíduo sugere a alocação de uma usina de geração distribuída no barramento 4 e de um sistema de baterias no barramento 5. Já o terceiro indivíduo propõe a alocação de duas GDs, uma nos barramentos 2 e 4, sem a instalação de BESS.

Tabela 3.1 – Exemplo de Geração 1 com 3 indivíduos

Geração	Indivíduo	B1	B2	B3	B4	B5
1	1	0	0	0	1	0
		0	0	0	0	1
1	2	1	0	0	0	0
		0	0	1	0	0
1	3	0	1	0	1	0
		0	0	0	0	0

Fonte: Elaborado pelo Autor

3.3.2 Capacidade da Geração

Após a definição da população de indivíduos, estabelece-se a potência injetada pelos Recursos Energéticos Distribuídos (RED) como uma fração percentual de sua capacidade máxima. Essa capacidade foi previamente determinada seguindo o procedimento descrito na Seção 4.1.2. Assim, a potência fornecida pelo RED no barramento j é calculada por meio da seguinte expressão:

$$P_{inj,j}^{RED} = \alpha * P_j^{RED} \quad (3.4)$$

onde α é um valor real aleatório no intervalo $[0, 1]$, representando a proporção da capacidade máxima efetivamente injetada no barramento.

3.3.3 Seleção de Indivíduos

Nesta etapa, são analisados os parâmetros de desempenho de cada indivíduo, em um processo comumente denominado de avaliação da qualidade dos indivíduos. Para essa avaliação, são considerados os seguintes critérios:

- **Perdas de energia dos indivíduos (P_{perdas}^k):** calculam-se as perdas de potência associadas a cada indivíduo k , simulando a operação do sistema com a proposta de REDs .
- **Número de violações do limite superior da tensão (NV_{max}^k):** Esta variável armazena, para cada proposta de solução, o número de barramentos cuja tensão ultrapassou acima de 105% o valor nominal.
- **Número de violações do limite inferior da tensão (NV_{min}^k):** Esta variável armazena, para cada proposta de solução, o número de barramentos cuja tensão apresenta valores abaixo de 95% do valor nominal.

Os indivíduos da população corrente são avaliados conforme os seguintes critérios de seleção:

- **Critério 1:** Os novos indivíduos devem garantir que não ocorram mais violações de tensão do que no sistema original:

$$NV_{max}^k \leq NV_{max}, \quad (3.5)$$

$$NV_{min}^k \leq NV_{min}. \quad (3.6)$$

- **Critério 2:** Cada indivíduo da população atual deve exibir um desempenho superior ou igual à média da população da geração anterior. Para isso, verifica-se que:

$$P_{perdas}^k \leq P_{perdas}^{média}. \quad (3.7)$$

em que $P_{perdas}^{média}$ corresponde ao valor das perdas médias obtidas na geração anterior.

3.3.4 Cruzamento de Indivíduos

Dois indivíduos distintos são selecionados aleatoriamente dentro da população corrente, os quais serão chamados de *pais*.

Presumindo que μ seja o parâmetro que seleciona parte do trecho do primeiro *pai*, e que δ seja o trecho selecionado do segundo *pai*. Sorteia-se apenas o valor de μ , e o valor de δ é calculado como:

$$\delta = M - \mu \quad (3.8)$$

Lembrando que M é o número de barramentos candidatos para a alocação de REDs.

Com os dois segmentos definidos, gera-se um novo indivíduo, denominado **filho**, que surge da fusão dos dois segmentos dos *pais*. Note, que neste algoritmo é gerado apenas um filho, como mostrado no exemplo da tabela 3.2.

Cabe ressaltar, que na solução gerada do cruzamento (*filho*), verifica-se que a mesma não exceda o número pré-definido de REDs.

3.3.5 Mutação de Indivíduos

O processo de mutação consiste em selecionar um trecho que será perturbado, sendo que o novo indivíduo (após mutação) será formado pela combinação do trecho preservado com o trecho modificado. Algumas premissas importantes são:

Tabela 3.2 – Exemplo de Cruzamento entre dois indivíduos

Geração	Indivíduo	B1	B2	B3	B4	B5
1	1	0	0	0	1	0
1	2	1	0	0	0	0
		0	0	1	0	0
1	<i>filho</i>	0	0	0	0	0
		0	0	1	0	0

Fonte: Elaborado pelo Autor

- **Premissa 1:** O tamanho do vetor linha no indivíduo não pode ser alterado; isto é, não haverá aumento ou redução na quantidade de barramentos candidatos à alocação de REDs.
- **Premissa 2:** Após a mutação, a quantidade de REDs alocadas deve estar dentro dos limites estabelecidos de quantidade mínima e máxima de REDs.

3.3.6 Estratégia Evolutiva Híbrida

Este estudo apresenta a implementação de uma abordagem híbrida de Estratégias Evolutivas, integrando as variantes (μ, λ) e $(\mu + \lambda)$ com o objetivo de explorar as vantagens inerentes a cada método ao longo do processo evolutivo. Os fundamentos teóricos dessas estratégias são detalhados nas Seções 2.8.4 e 2.8.5. O fluxo metodológico adotado é ilustrado no fluxograma da Figura 3.5, que começa com a definição da população inicial, contemplando a construção dos indivíduos iniciais e a atribuição da capacidade de geração.

Na etapa subsequente, ocorre a Seleção dos Indivíduos, onde os mais aptos são escolhidos com base nos critérios de avaliação previamente estabelecidos (Seção 3.3.3). Os indivíduos não selecionados são armazenados para eventuais consultas futuras. Após a seleção, inicia-se a criação das gerações subsequentes, com a aplicação dos operadores evolutivos.

A definição da estratégia evolutiva a ser utilizada em cada geração é realizada por meio de um sorteio binário, gerando um valor booleano. Caso o resultado seja 0, aplica-se a estratégia (μ, λ) ; se o resultado for 1, adota-se a estratégia $(\mu + \lambda)$. A principal diferença entre essas abordagens reside na forma de aplicação do processo de mutação:

1. Mutação na Estratégia Evolutiva (μ, λ) : Após a seleção dos indivíduos mais aptos, todos os membros da geração subsequente são gerados por meio do processo de mutação. Partindo de uma população inicial com λ indivíduos, e após a etapa de seleção que reduz o grupo para μ indivíduos, são realizados λ sorteios aleatórios, um de cada vez, entre os μ remanescentes. Cada indivíduo escolhido passa por uma

operação de mutação, gerando novos indivíduos que constituirão integralmente a próxima geração.

2. Mutação na Estratégia Evolutiva ($\mu + \lambda$): Considerando uma população inicial de λ indivíduos, e após a etapa de seleção, restando μ indivíduos, serão escolhidos $\lambda - \mu$ indivíduos para passar pelo processo de mutação. Cada indivíduo a ser submetido à mutação será selecionado aleatoriamente dentre os μ indivíduos remanescentes. Os μ indivíduos selecionados inicialmente para permanecerem na próxima geração serão combinados aos $\lambda - \mu$ indivíduos resultantes da mutação. Essa abordagem garante que o tamanho da população se mantenha constante em λ indivíduos, ao mesmo tempo em que promove a diversidade genética e assegura que indivíduos de alta aptidão sejam preservados, contribuindo para a melhoria contínua da solução ao longo das gerações.

Após a etapa de mutação, realiza-se a avaliação do desempenho dos indivíduos, de acordo com os critérios estabelecidos na Seção 3.3.3. Uma nova rodada de seleção é então executada, armazenando-se os indivíduos não selecionados. Simultaneamente, identifica-se o melhor indivíduo da geração, caracterizado como aquele que apresenta o menor valor de P_{perdas}^k , respeitando os limites de tensão NV_{max}^k e NV_{min}^k , conforme especificado em comparação ao sistema original (Seção 3.1.1).

Após a conclusão de todas as gerações, realiza-se uma análise final entre os N melhores indivíduos de cada geração, visando identificar a solução mais eficiente para o problema em questão, culminando na seleção do indivíduo globalmente mais adequado.

A abordagem híbrida proposta combina de maneira sinérgica as estratégias evolutivas (μ, λ) e ($\mu + \lambda$), promovendo uma exploração eficiente do espaço de busca e assegurando uma convergência robusta para soluções de alta qualidade. A metodologia desenvolvida, fundamentada em processos rigorosos de seleção, mutação e avaliação, representa uma contribuição significativa para o avanço do estado da arte na aplicação de algoritmos evolutivos à otimização de sistemas complexos.

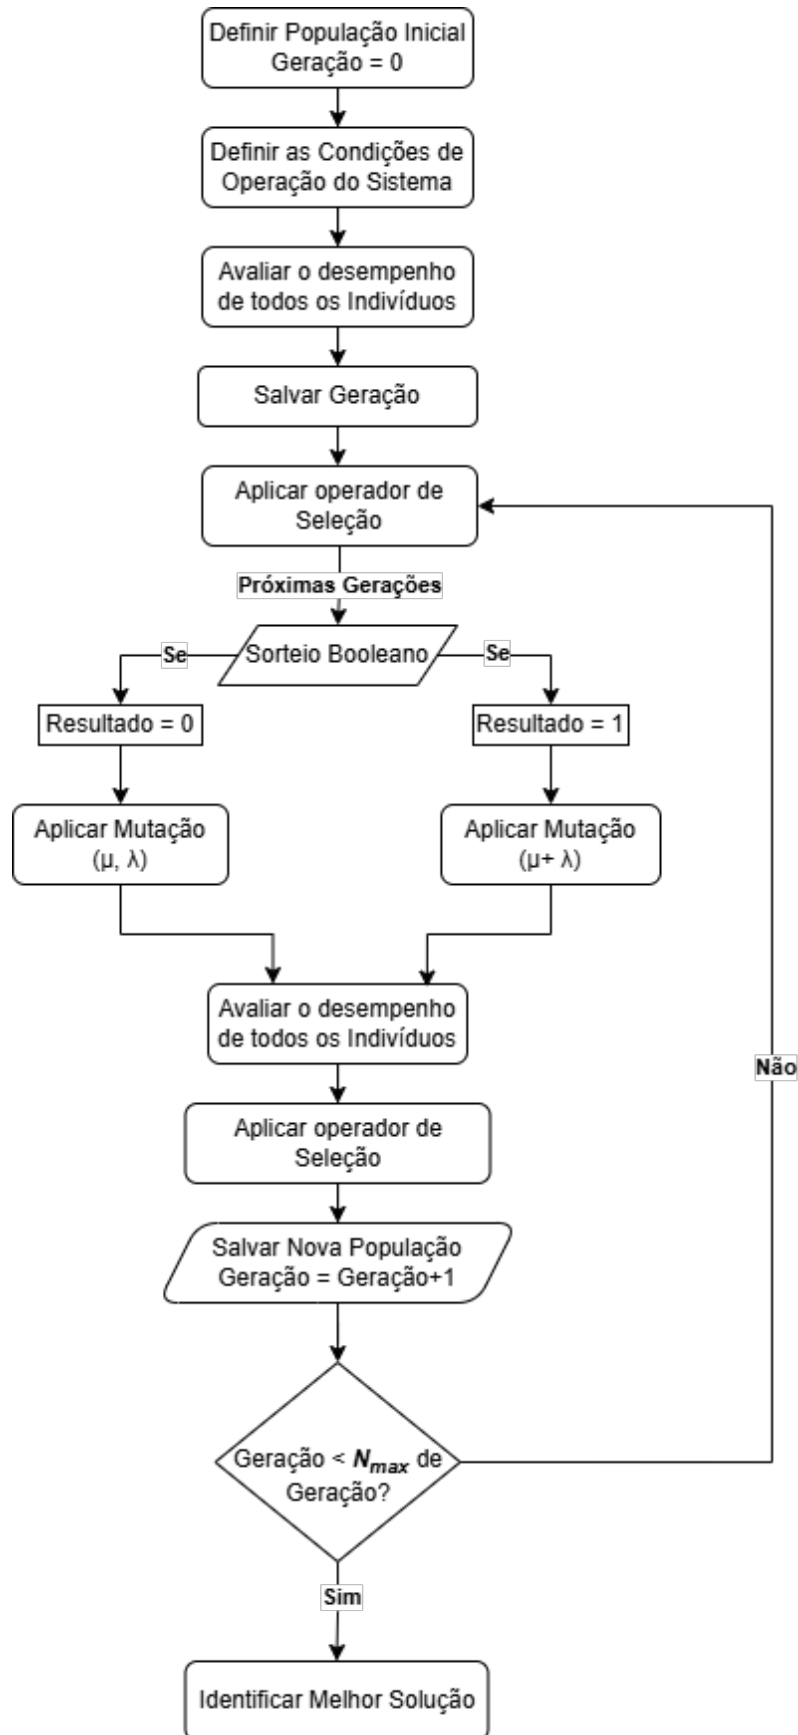


Figura 3.5 – Fluxograma da Estratégia Evolutiva Híbrida.

Fonte: Elaborado pelo Autor.

3.3.7 Algoritmo Genético Híbrido

A distinção entre o Algoritmo Genético Híbrido (AGH) e a Estratégia Evolutiva Híbrida (EEH) está na inclusão do processo de cruzamento no AGH, que ocorre antes da etapa de mutação, sendo representada graficamente no fluxograma da Figura 3.6. No AGH, o cruzamento é realizado entre dois indivíduos distintos da geração anterior, sendo aplicado tanto no caso do elitismo (μ, λ) quanto no elitismo $(\mu + \lambda)$, conforme definido pelo mecanismo de sorteio binário, gerando um valor booleano. Caso o resultado seja 0, aplica-se a estratégia (μ, λ) , se o resultado for 1, adota-se a estratégia $(\mu + \lambda)$.

1. **Cruzamento no AGH com Elitismo (μ, λ) :** Na abordagem de elitismo (μ, λ) , o cruzamento, consiste na escolha de dois indivíduos distintos dentre os mais aptos da geração anterior. Essa operação gera um novo indivíduo que herda características dos indivíduos selecionados. A quantidade total de novos indivíduos gerados é igual ao tamanho da população inicial (λ). Assim, λ indivíduos são criados a partir do cruzamento entre pares de indivíduos da geração precedente. Na sequência, os indivíduos gerados pelo cruzamento passam pela etapa de mutação. Durante essa fase, cada um dos λ indivíduos é submetido a uma mutação, realizada de maneira aleatória, promovendo variações dentro da população formada. Esse processo assegura a introdução de novos atributos genéticos, contribuindo para a diversificação e robustez da população. Ao final das etapas de cruzamento e mutação, a nova geração será composta por λ indivíduos, resultantes das operações realizadas. Esse ciclo de cruzamento e mutação desempenha um papel central na manutenção da diversidade genética e no aprimoramento contínuo das soluções, promovendo a evolução da população ao longo das gerações e aumentando a eficiência na busca por soluções ótimas.
2. **Cruzamento no AGH com Elitismo $(\mu + \lambda)$:** No modelo de elitismo $(\mu + \lambda)$, como também ocorre na Estratégia Evolutiva $(\mu + \lambda)$, os indivíduos mais aptos da geração anterior são mantidos para competir com os novos indivíduos gerados, compondo a população da próxima geração. A distinção central desse método está na inclusão de uma etapa de cruzamento antes do processo de mutação. Após o processo de seleção, considerando que restaram μ indivíduos dos λ da geração anterior, dois indivíduos distintos são selecionados aleatoriamente dentre esses μ remanescentes para a formação de $\lambda - \mu$ novos indivíduos, originados do cruzamento. Essa operação permite a recombinação de características genéticas dos indivíduos selecionados, criando uma nova base para a variabilidade genética. Os $\lambda - \mu$ indivíduos gerados pelo cruzamento são, então, submetidos ao processo de mutação, o qual introduz variações aleatórias para explorar o espaço de busca de forma mais ampla. O resultado desse processo são $\lambda - \mu$ novos indivíduos mutados. A população da geração seguinte é composta pelos μ indivíduos preservados da geração anterior,

combinados com os $\lambda - \mu$ indivíduos que passaram pelas etapas de cruzamento e mutação. Essa composição mantém o tamanho total da população em λ indivíduos, garantindo a retenção dos indivíduos mais adaptados enquanto promove a introdução de diversidade genética. Esse mecanismo é fundamental para assegurar a eficiência do processo evolutivo ao longo das gerações, equilibrando a exploração de novas soluções e a exploração incremental das melhores soluções já encontradas.

Após a definição dos λ indivíduos que compõem a nova geração, o processo prossegue conforme detalhado na seção anterior. Inicialmente, é estabelecida a capacidade de geração das usinas alocadas, seguida pela avaliação da qualidade dos indivíduos, realizada com base nos critérios previamente definidos.

Posteriormente, ocorre a seleção dos indivíduos mais aptos, que serão mantidos para a próxima etapa do processo evolutivo. Os indivíduos que não forem selecionados são armazenados para consultas futuras, caso necessário, permitindo a preservação de informações valiosas para análises posteriores. Concluída essa fase, dá-se início ao ciclo subsequente, com a geração de novos indivíduos, promovendo a continuidade do aprimoramento das soluções ao longo das gerações.

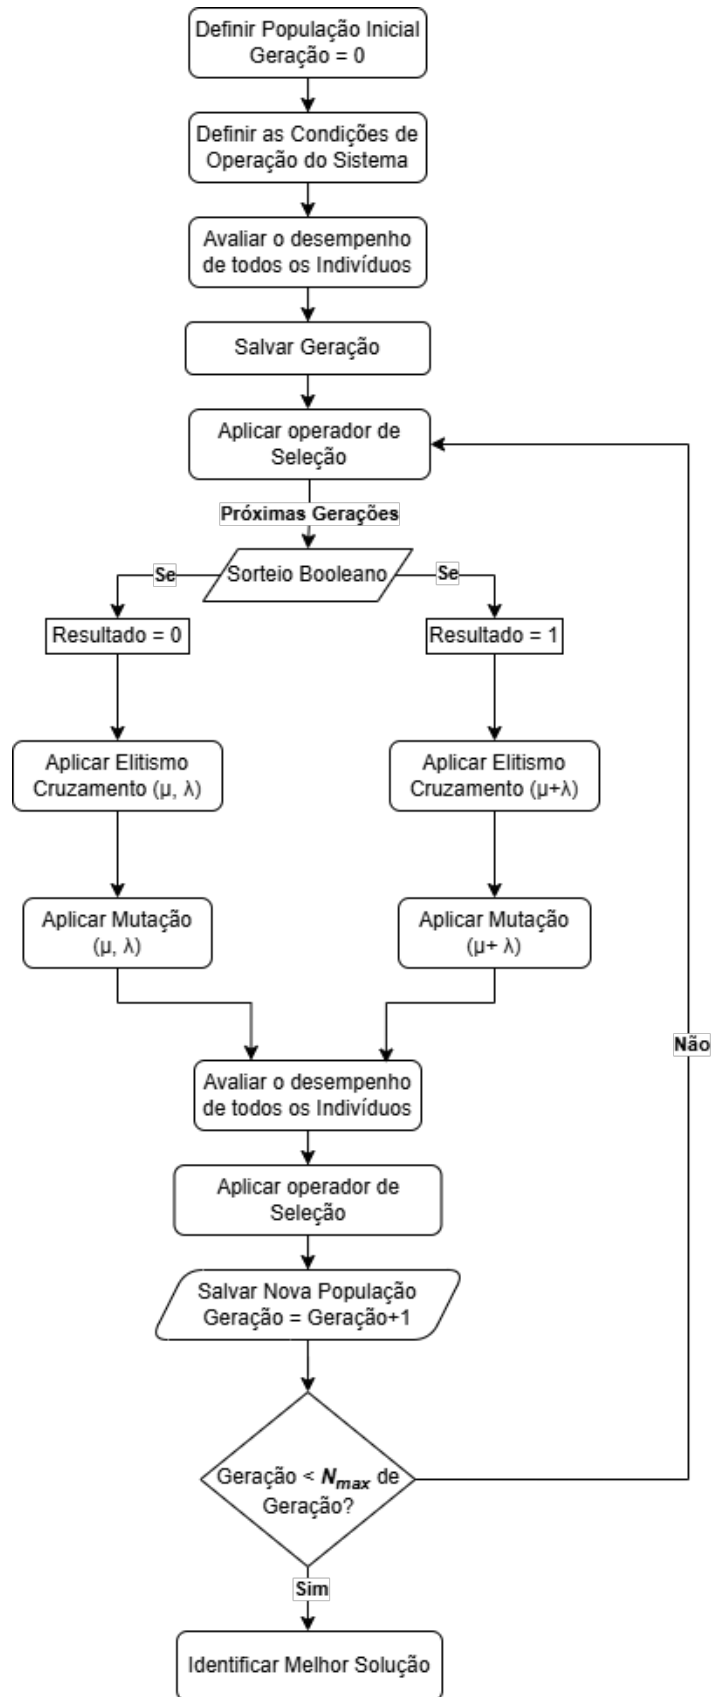


Figura 3.6 – Fluxograma do Algoritmo Elitismo Híbrido.

Fonte: Elaborado pelo Autor.

3.3.8 Identificação do Melhor Indivíduo nas Estratégias de Otimização

Concluída a implementação das estratégias de otimização, a etapa subsequente é a identificação do melhor indivíduo gerado por cada estratégia. O objetivo principal dessa análise é determinar qual estratégia apresentou o melhor desempenho técnico no contexto do sistema de distribuição, garantindo a eficácia das soluções propostas e a validação dos métodos aplicados. As etapas do processo de definição do melhor indivíduo são:

3.3.8.1 Análise de Desempenho

Os indivíduos gerados pelas estratégias de otimização são submetidos a uma análise rigorosa, fundamentada em parâmetros previamente definidos, tais como:

- **Perdas Totais do Sistema** ($P_{\text{perdas}}^{\text{base}}$): Indicador da eficiência energética da solução.
- **Limites de Tensão:** Avaliação da conformidade com as restrições de tensão máxima (NV_{max}) e mínima (NV_{min}) em cada barramento do sistema.

Essa análise permite avaliar o impacto de cada indivíduo no comportamento global do sistema, identificando suas influências na eficiência energética e na estabilidade operacional.

3.3.8.2 Comparação de Desempenho

Os indivíduos são comparados por meio de métricas específicas que contemplam:

- **Redução das Perdas Totais do Sistema:** Análise do potencial de economia de energia proporcionado por cada solução.
- **Conformidade com os Limites de Tensão:** Verificação de que a operação do sistema não resultará em condições de sobrecarga ou subcarga nos barramentos.

Essa comparação sistemática é essencial para distinguir as soluções mais eficazes e compatíveis com os requisitos operacionais.

3.3.8.3 Seleção do Melhor Indivíduo

O melhor indivíduo é aquele que apresenta:

- A maior redução nas perdas totais do sistema;
- Plena conformidade com os limites de tensão (NV_{max} e NV_{min}).

Esse indivíduo deve oferecer não apenas uma elevada eficiência energética, mas também estabilidade e confiabilidade na operação do sistema de distribuição. O processo de seleção baseia-se em uma análise comparativa detalhada, que avalia os resultados obtidos por cada estratégia de otimização, garantindo a escolha mais adequada para o problema em questão.

Essa abordagem estruturada possibilita uma avaliação objetiva e criteriosa das soluções propostas, destacando a estratégia que proporciona o melhor desempenho global. Além disso, a análise dos melhores indivíduos oferece insights relevantes sobre a eficácia das metodologias aplicadas, servindo como base para a tomada de decisão em implementações futuras. Esse processo é essencial para validar as estratégias desenvolvidas, assegurando a aplicação de soluções otimizadas e eficazes nos sistemas de distribuição de energia elétrica.

4 Testes e Resultados

A implementação da metodologia proposta será realizada no ambiente de programação Python, enquanto a análise do desempenho operacional da rede elétrica será conduzida por meio de simulações de fluxo de potência utilizando o software OpenDSS. Os sistemas de estudo selecionados serão apresentados e analisados nas seções subsequentes, com o objetivo de contextualizar sua relevância e justificar sua adequação à abordagem metodológica adotada.

4.1 Sistema IEEE 34 Barras

O Sistema IEEE de 34 Barras, conforme descrito por (FRACALOSSI L.G.V.; BATISTA, 2021) e representado na Figura 4.1, constitui um sistema de teste amplamente utilizado devido à sua capacidade de modelar uma extensa variedade de arranjos de linhas, cargas e componentes elétricos. Esse sistema destaca-se por sua habilidade em reproduzir, de forma precisa, cenários complexos frequentemente encontrados em redes elétricas de grande escala.




Figura 4.1 – Diagrama Unifilar do Sistema IEEE 34 Barras.

Fonte: (FRACALOSSI L.G.V.; BATISTA, 2021)

O sistema IEEE de 34 Barras abrange aproximadamente 94 km de linhas de distribuição, organizadas em cinco configurações distintas. O segmento mais longo, com 15 km de extensão, conecta os nós 818 e 820. A topologia do sistema incorpora tanto linhas monofásicas quanto trifásicas, refletindo sua diversidade estrutural.

A maior parte do sistema opera com uma tensão nominal de 24,9 kV, excetuando-se o trecho entre os nós 888 e 890, que utiliza uma tensão reduzida de 4,16 kV. O sistema também integra 19 cargas distribuídas ao longo de sua extensão, resultando em uma demanda total de 2.063,45 kVA.

O sistema também conta com dois reguladores de tensão, cada um composto por três transformadores monofásicos configurados em wye-wye. Cada transformador possui uma tensão nominal de operação de 14,376 kV e uma capacidade de 2.000 kVA, assegurando suporte adequado à regulação de tensão e contribuindo para a estabilidade e confiabilidade da rede elétrica.

A análise detalhada do perfil de tensão do sistema, inicialmente apresentado na Figura 4.1, é aprofundada na Figura 4.2. Os resultados demonstram que os limites de tensão estabelecidos e discutidos na Seção 2.4 são atendidos, garantindo a aderência aos critérios operacionais estipulados. Nesse cenário, as perdas totais do sistema foram calculadas em 5.958 kWh.

Complementarmente, a Figura 4.3 apresenta o perfil de carregamento do sistema, destacando a distribuição das cargas e sua influência direta no desempenho e na operação da rede elétrica.




Figura 4.2 – Análise do Perfil de Tensão no Sistema IEEE de 34 Barras.

Fonte: Elaborado pelo Autor




Figura 4.3 – Análise do Perfil de Carregamento no Sistema IEEE de 34 Barras.

Fonte: Elaborado pelo Autor

4.1.1 Modificações Implementadas

O planejamento do crescimento de carga em sistemas de distribuição de energia elétrica é uma etapa estratégica fundamental para as concessionárias do setor, (EPE, 2024). Essa prática não apenas orienta os investimentos de longo prazo, mas também assegura a conformidade com os padrões de qualidade regulamentados pela ANEEL (ANEEL, 2021b), promovendo uma operação confiável e eficiente da rede.

Nesse cenário, a integração de Redes Elétricas Distribuídas (REDs) destaca-se como um elemento essencial, pois não apenas atende às demandas energéticas atuais, mas também contribui para a preparação da infraestrutura visando a um crescimento sustentável, alinhado aos requisitos de confiabilidade e qualidade operacional.

No sistema em análise, que reflete a realidade de uma rede de distribuição, foi implementado um aumento de 30% na capacidade instalada com o objetivo de testar e validar a aplicação da metodologia proposta, elevando a capacidade de 2.063,45 kVA

para 2.682,48 kVA. Como consequência, houve um aumento significativo de 133,40% nas perdas totais, que subiram de 5.958 kWh para 13.906 kWh. Esse acréscimo na capacidade instalada também resultou em uma elevação de 30,91% no nível de carregamento em comparação com o cenário inicial.

Os impactos resultantes dessa expansão podem ser avaliados a partir do perfil de tensão apresentado na Figura 4.4. Nota-se que, em determinados barramentos, os níveis de tensão permaneceram abaixo do limite mínimo de 95%, conforme os critérios técnicos estabelecidos na Seções 2.4 e 3.1.1.3. Complementarmente, a Figura 4.5 ilustra o perfil de carregamento decorrente da ampliação da capacidade, evidenciando as repercussões dessas alterações no desempenho operacional e na estabilidade da rede elétrica.




Figura 4.4 – Análise do Perfil de Tensão do Sistema IEEE de 34 Barras após Crescimento de 30%.

Fonte: Elaborado pelo Autor




Figura 4.5 – Análise do Perfil de Carregamento do Sistema IEEE de 34 Barras após Crescimento de 30%

Fonte: Elaborado pelo Autor

4.1.2 Desempenho do Espaço de Busca

Nesta etapa, todos os barramentos foram considerados integralmente disponíveis para a alocação de Geração Distribuída e Sistemas de Armazenamento de Energia em Baterias, sem a imposição de quaisquer restrições. Essa abordagem garante total flexibilidade na exploração do espaço de busca, permitindo a identificação dos mínimos globais. Esses pontos são essenciais para maximizar a eficiência energética e alcançar um desempenho otimizado do sistema elétrico.

A Tabela 4.1 apresenta uma análise detalhada das cinco configurações mais eficientes, com destaque para aquelas que alcançaram uma redução significativa nas perdas totais do sistema. Todas as configurações analisadas demonstraram conformidade rigorosa com os

limites de tensão estabelecidos na Seção 2.4, evidenciando o compromisso com os critérios técnicos previamente definidos.

Tabela 4.1 – Sistema IEEE 34 Barras - Configurações de Barramentos com GD e SAEB: Mitigação das Perdas Totais e Conformidade com Limites de Tensão

Config	GD (kVA)	Barra GD	Bateria (kW)	Barra Bateria	Redução (%)
1	215,56	B09	148,15	B10	5,61
2	210,66	B11	143,01	B10	5,39
3	203,15	B20	139,44	B30	5,04
4	198,15	B23	136,09	B19	4,95
5	191,15	B21	129,09	B18	4,45

Fonte: Elaborado pelo Autor.

A análise detalhada dos dados apresentados na Tabela 4.1 evidencia que a Configuração 1 destaca-se como a mais eficiente, proporcionando uma redução de perdas totais de 5,61%. Esse desempenho foi alcançado por meio de uma combinação de Recursos de Energia Distribuída composta por uma Geração Distribuída de 215,56 kVA e um Sistema de Armazenamento de Energia em Bateria com capacidade de 148,15 kW. As demais configurações de REDs também apresentaram desempenhos significativos, com reduções de perdas de 5,39%, 5,04%, 4,95% e 4,45%, respectivamente. Os valores ideais de GD situaram-se no intervalo de 191,15 a 215,56 kVA, enquanto os valores de SAEB variaram entre 129,09 e 148,15 kW. O comportamento progressivo da Configuração 1 até atingir sua condição de otimização, ou ponto ótimo, está ilustrado de forma pormenorizada na Figura 4.6, reafirmando sua superioridade no escopo avaliado.

A análise apresentada na Tabela 4.2 destaca os benefícios decorrentes da incorporação de uma usina fotovoltaica, com capacidade instalada de 215,56 kVA, em conjunto com um Sistema de Armazenamento de Energia em Bateria de 148,15 kW, nos barramentos da linha L08. Os resultados indicam uma melhoria de 2,05% nos níveis de tensão, acompanhada por uma expressiva redução de 5,61% nas perdas totais do sistema. Adicionalmente, foi constatada uma redução de 3,09% no carregamento, evidenciando o impacto benéfico dessa integração tanto na eficiência energética quanto na estabilidade operacional da rede elétrica.

Tabela 4.2 – Sistema IEEE 34 Barras: Desempenho da Integração de Usina Fotovoltaica e SAEB nos Barramentos da Linha L08

Ganho - Tensão (%)	Redução - Perdas (%)	Redução - Carregamento (%)
2,05	5,61	3,09

Fonte: Elaborado pelo Autor.




Figura 4.6 – Sistema IEEE 34 Barras: Desempenho da Configuração 1.

Fonte: Elaborado pelo Autor.

As Figuras 4.7 e 4.8 ilustram, respectivamente, o perfil de tensão do sistema e o perfil de carregamento, após a alocação dos Recursos de Energia Distribuída associados à Configuração 1. Esses gráficos destacam as melhorias alcançadas na configuração elétrica, bem como o aprimoramento do desempenho global do sistema.

A metodologia proposta viabilizou a identificação dos barramentos com maior capacidade de otimização por meio da integração estratégica de Recursos Energéticos Distribuídos. Essa alocação eficiente não apenas reduziu de forma expressiva as perdas totais do sistema, mas também aprimorou significativamente os perfis de tensão e carregamento, desempenhando um papel fundamental na melhoria da estabilidade operacional e na maximização da eficiência energética da rede de distribuição.

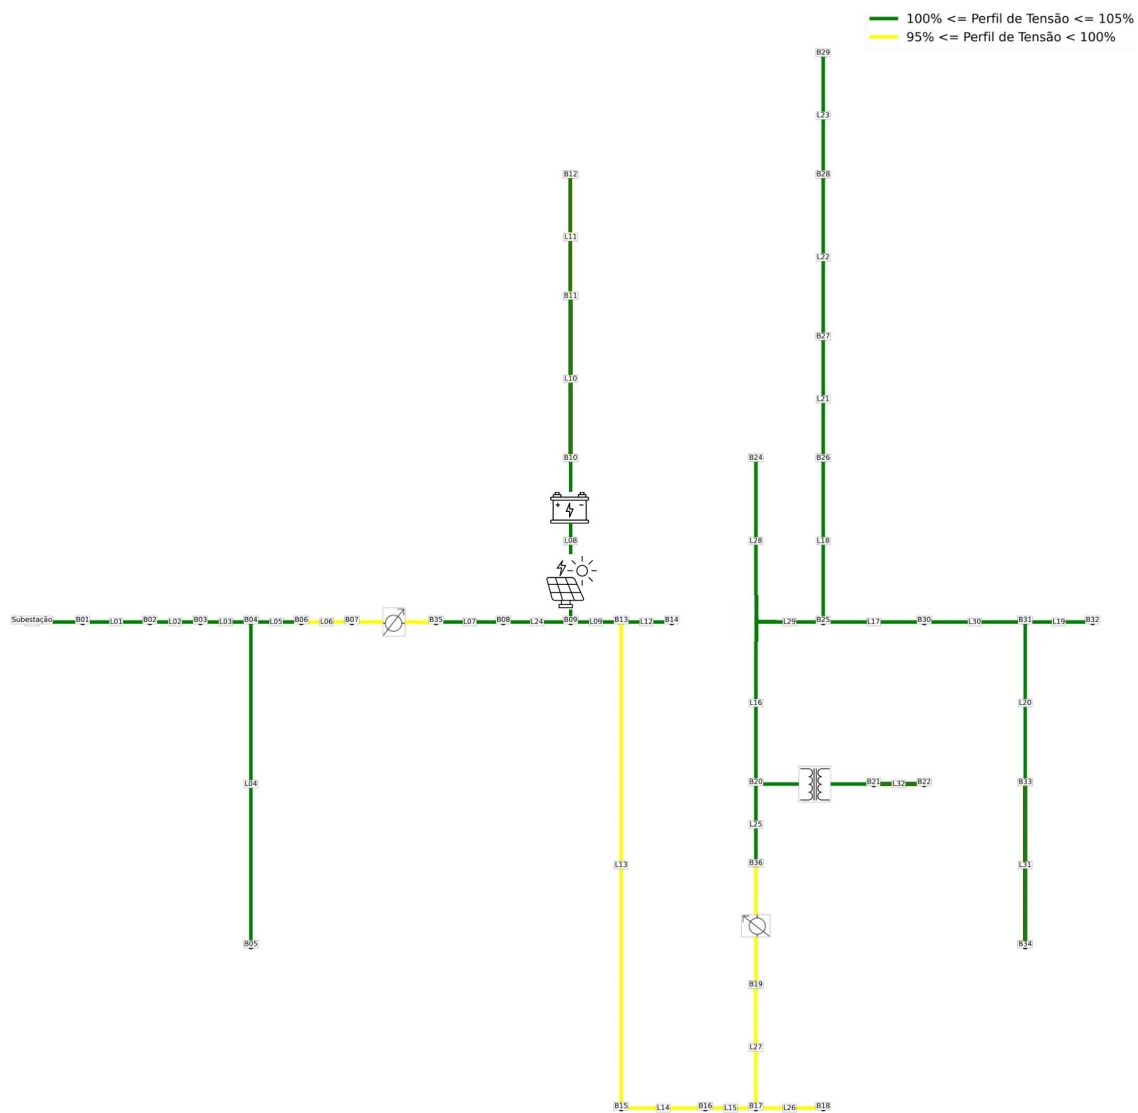


Figura 4.7 – Sistema IEEE 34 Barras: Perfil de Tensão do Sistema para a Configuração 1

Fonte: Elaborado pelo Autor.




Figura 4.8 – Sistema IEEE 34 Barras: Perfil de carregamento do Sistema para a configuração 1

Fonte: Elaborado pelo Autor.

4.1.3 Desempenho da Estratégia Evolutiva Híbrida

Dando prosseguimento à aplicação da metodologia proposta, a próxima etapa consiste em realizar uma análise de desempenho do sistema sob a aplicação da Estratégia Evolutiva Híbrida (EEH), visando avaliar sua eficácia nas melhorias operacionais e na mitigação de perdas do sistema de distribuição.

Os parâmetros limitantes a serem considerados são apresentados na Equação 4.1:

$$\begin{aligned}
 \min_{\text{SAEB}} &= 1 \\
 \max_{\text{SAEB}} &= 8 \\
 \min_{\text{GD}} &= 1 \\
 \max_{\text{GD}} &= 8
 \end{aligned}
 \tag{4.1}$$

Os valores definidos entre 1 e 8 delimitam os limites mínimo e máximo de Recursos Energéticos Distribuídos (REDs) a serem conectados na rede, estabelecendo um espaço de busca representativo para a otimização do sistema. Essa faixa foi escolhida para exemplificar a aplicação da metodologia, permitindo uma análise abrangente das configurações possíveis. Adicionalmente, o valor máximo pode ser ajustado pelo usuário, em conformidade com as restrições técnicas ou normativas estipuladas, como aquelas impostas pelas concessionárias. Essa abordagem possibilita identificar a quantidade ideal de REDs, bem como a combinação mais eficiente de recursos, com o objetivo de maximizar a eficiência energética, a estabilidade operacional e a confiabilidade do sistema de distribuição.

O comportamento evolutivo do melhor indivíduo ao longo das gerações está ilustrado na Figura 4.9. Nota-se que o indivíduo de melhor desempenho foi identificado na geração 48, alcançando uma redução significativa de 14,43% nas perdas totais do sistema.

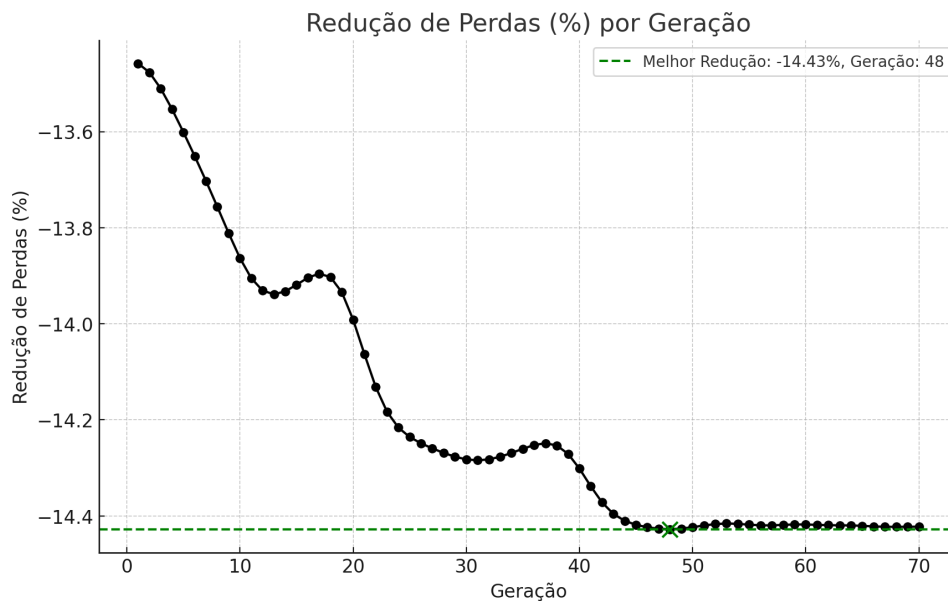


Figura 4.9 – Sistema IEEE 34 Barras: Comportamento do Melhor Indivíduo na EEH

Fonte: Elaborado pelo Autor.

As configurações ótimas que definem o sistema do melhor indivíduo estão apresentadas nas Tabelas 4.3 e 4.4. Para aprimorar a clareza e facilitar a compreensão, as composições foram organizadas separadamente, assegurando uma abordagem mais didática e objetiva.

Tabela 4.3 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de GD na Estratégia Evolutiva Híbrida

GD	Barramento	Fases	Potência Instalada (kVA)
A	B27	3	400,30
B	B11	3	128,36
C	B31	1	90,55
D	B05	3	105,87
E	B18	3	45,54

Fonte: Elaborado pelo Autor.

Tabela 4.4 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de SAEB na Estratégia Evolutiva Híbrida

SAEB	Barramento	Fases	Potência Instalada (kW)
A	B23	3	140,36
B	B10	3	123,66
C	B10	3	100,45
D	B04	3	80,54

Fonte: Elaborado pelo Autor.

A análise dos resultados apresentados na Tabela 4.5 demonstra que o melhor indivíduo não apenas operou dentro dos limites técnicos e operacionais estabelecidos, mas também alcançou avanços significativos em diversos parâmetros de desempenho do sistema. Especificamente, verificou-se um aumento de 15,21% nos níveis de tensão, uma redução de 14,43% nas perdas totais e uma diminuição de 17,56% no carregamento. Esses resultados reforçam a robustez e a eficácia da Estratégia Evolutiva Híbrida (EEH) na otimização do sistema, garantindo não apenas o aprimoramento do desempenho global, mas também a manutenção da integridade operacional e a confiabilidade da rede de distribuição.

Tabela 4.5 – Sistema IEEE 34 Barras: Avaliação do Desempenho do Melhor Indivíduo na Estratégia Evolutiva Híbrida

Ganho - Tensão (%)	Redução - Perdas (%)	Redução - Carregamento (%)
15,21	14,43	17,56

Fonte: Elaborado pelo Autor.

A Figura 4.10 apresenta o perfil de tensão do sistema após a alocação dos Recursos Energéticos Distribuídos, evidenciando as melhorias alcançadas na configuração elétrica. Complementarmente, a Figura 4.11 ilustra o perfil de carregamento do sistema, destacando os impactos positivos decorrentes da alocação dos REDs.

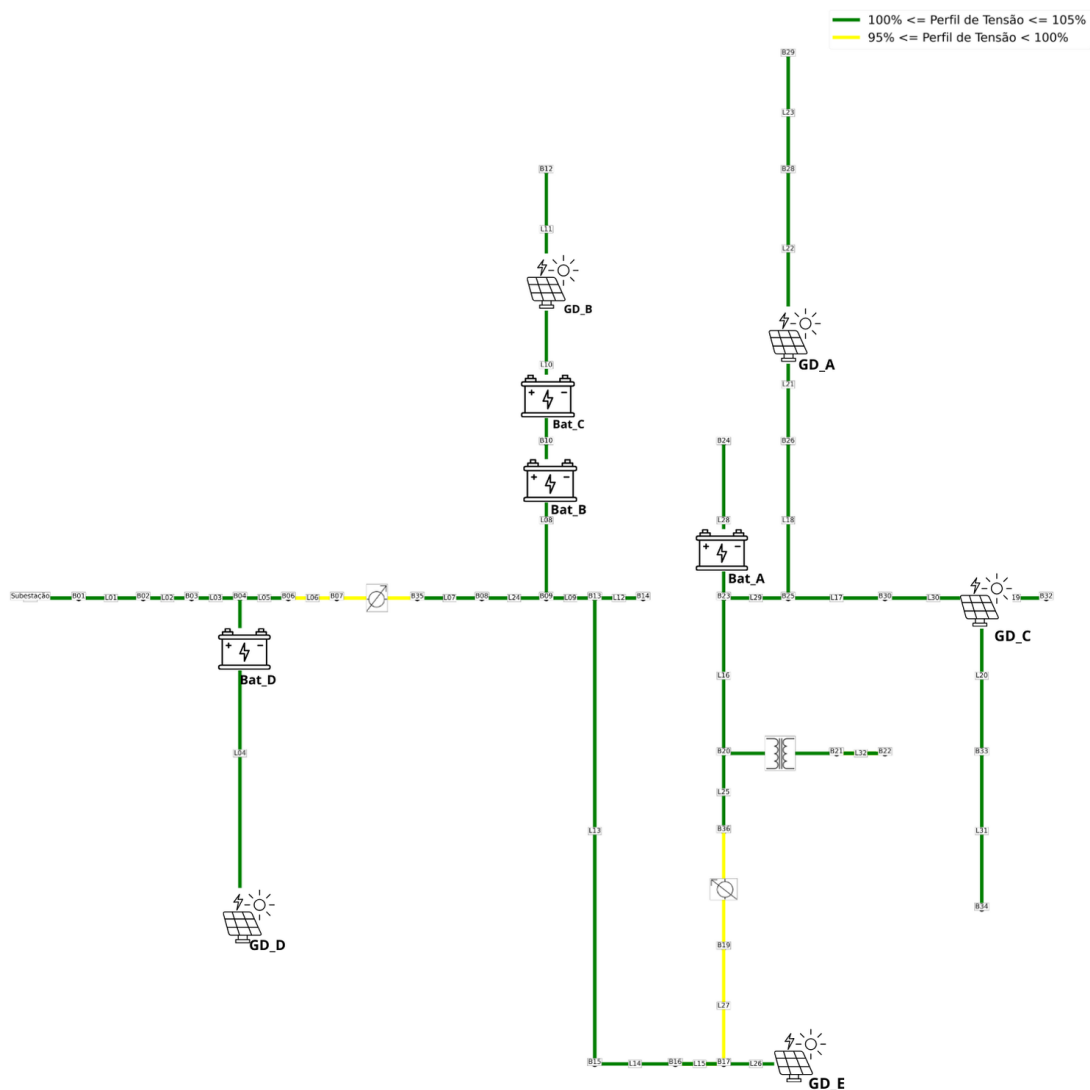


Figura 4.10 – Sistema IEEE de 34 Barras: Análise do Perfil de Tensão na Aplicação da Estratégia Evolutiva Híbrida

Fonte: Elaborado pelo Autor.

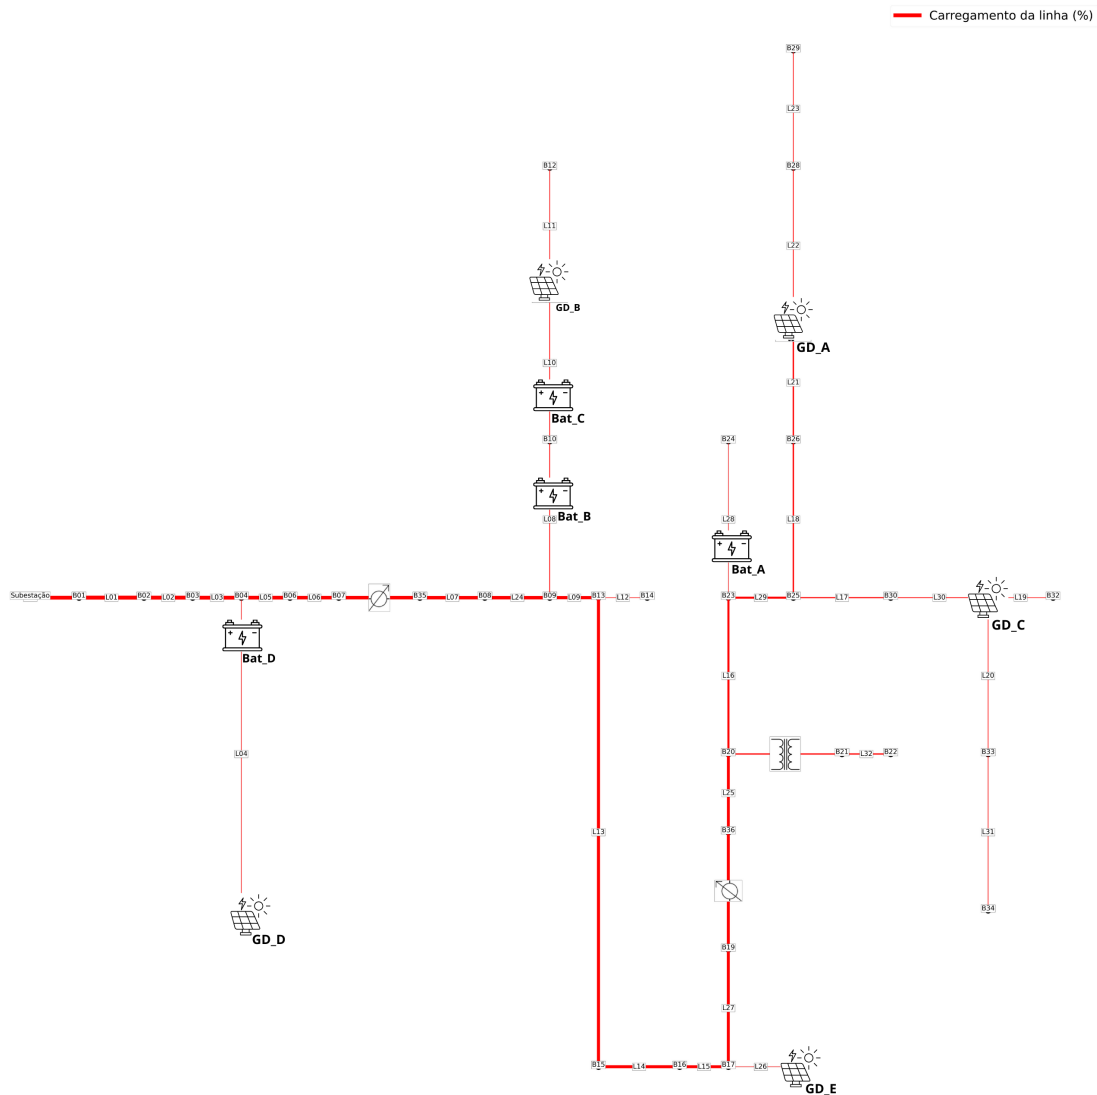


Figura 4.11 – Sistema IEEE de 34 Barras: Análise do Perfil de Carregamento na Aplicação da Estratégia Evolutiva Híbrida

Fonte: Elaborado pelo Autor.

A comparação entre os resultados da Estratégia Evolutiva Híbrida e a abordagem anterior baseada no Desempenho do Espaço de Busca revela uma melhoria substancial nos indicadores de desempenho do sistema. Enquanto a abordagem de Espaço de Busca obteve uma redução de 5,61% nas perdas totais e um ganho de tensão de 2,05%, a EEH demonstrou uma redução significativamente maior, alcançando 14,43% nas perdas e um ganho de 15,21% nos níveis de tensão. Adicionalmente, a Estratégia Evolutiva Híbrida apresentou uma redução de 17,56% no carregamento do sistema, superando amplamente os 3,09% obtidos pela estratégia anterior. Esses resultados reforçam a superioridade da EEH na otimização do desempenho global do sistema.

4.1.4 Desempenho do Algoritmo Genético Híbrido

Seguindo as mesmas restrições estabelecidas na Seção 4.1.3, as configurações que definem o sistema do Melhor Indivíduo são apresentadas nas Tabelas 4.6 e 4.7. O desempenho notável desse indivíduo é evidenciado por uma redução substancial de 16,10% nas perdas totais do sistema, conforme representado na Figura 4.12. Esses resultados reforçam a eficácia da configuração na otimização do desempenho da rede e na mitigação de perdas, comprovando sua superioridade técnica.

Tabela 4.6 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de GD no Algoritmo Genético Híbrido

GD	Barramento	Fases	Potência Instalada (kVA)
A	B12	3	315,55
B	B23	3	224,69
C	B31	1	87,66
D	B05	3	112,38
E	B28	3	93,31

Fonte: Elaborado pelo Autor.

Tabela 4.7 – Sistema IEEE 34 Barras: Configuração do Melhor Indivíduo com Composição de SAEB no Algoritmo Genético Híbrido

SAEB	Barramento	Fases	Potência Instalada (kW)
A	B11	3	201,53
B	B27	3	101,57
C	B33	3	84,02

Fonte: Elaborado pelo Autor.

A análise dos resultados apresentados na Tabela 4.8 evidencia que o Melhor Indivíduo não apenas atendeu plenamente aos limites operacionais estabelecidos, mas também proporcionou avanços expressivos nos principais indicadores de desempenho do sistema. Em particular, observou-se um aumento de 17,09% nos níveis de tensão, uma redução de 16,10% nas perdas totais do sistema e uma diminuição de 19,97% no carregamento. O perfil de tensão obtido é representado na Figura 4.13, enquanto a Figura 4.14 apresenta o perfil de carregamento, destacando os impactos benéficos e a eficácia dessa configuração na otimização do sistema.

Tabela 4.8 – Sistema IEEE 34 Barras: Avaliação do Desempenho do Melhor Indivíduo no Algoritmo Genético Híbrido

Ganho - Tensão (%)	Redução - Perdas (%)	Redução - Carregamento (%)
17,09	16,10	19,97

Fonte: Elaborado pelo Autor.



Figura 4.12 – Sistema IEEE 34 Barras: Comportamento do Melhor Indivíduo no AGH

Fonte: Elaborado pelo Autor.

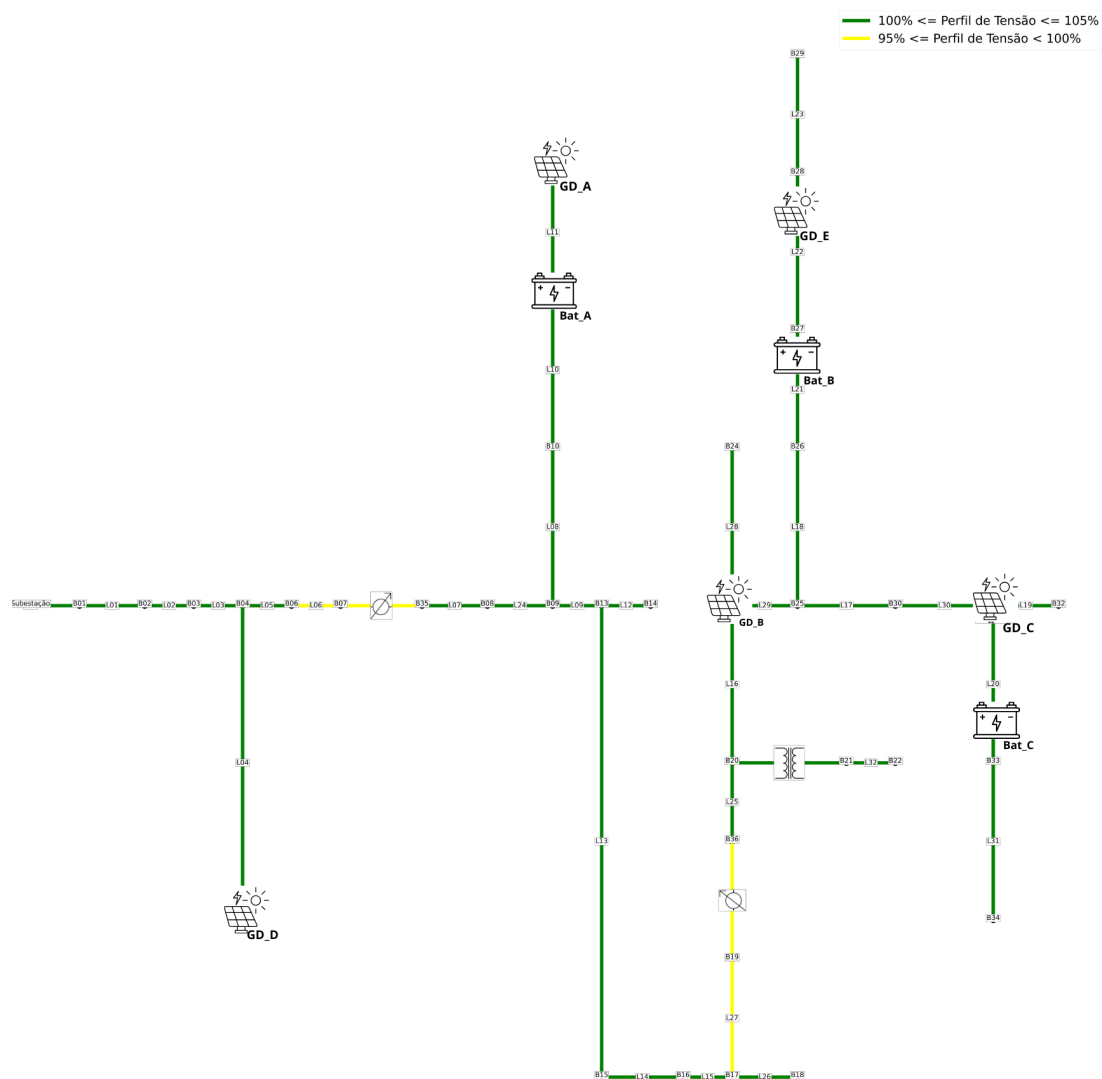


Figura 4.13 – Sistema IEEE de 34 Barras: Análise do Perfil de Tensão na Aplicação do Algoritmo Genético Híbrido

Fonte: Elaborado pelo Autor.




Figura 4.14 – Sistema IEEE de 34 Barras: Análise do Perfil de Carregamento na Aplicação do Algoritmo Genético Híbrido

Fonte: Elaborado pelo Autor.

4.1.5 Comparação dos Melhores Indivíduos

Com a aplicação das estratégias de otimização concluída, tanto a Estratégia Evolutiva Híbrida (EEH) quanto a Algoritmo Genético Híbrido (AGH) demonstraram indivíduos de desempenho excepcional, evidenciando sua eficácia na melhoria dos parâmetros do sistema. Para identificar o indivíduo mais eficiente, foi realizada uma análise comparativa detalhada entre os indicadores de desempenho dos melhores indivíduos produzidos por ambas as estratégias, além de uma avaliação dos resultados obtidos pela abordagem baseada no Espaço de Busca. Essa comparação, apresentada na Tabela 4.9, fornece uma base sólida para avaliar a superioridade relativa de cada metodologia na otimização do sistema analisado.

Tabela 4.9 – Análise Comparativa do Desempenho dos Melhores Indivíduos de cada Metodologia

Estratégia	Ganho - Tensão (%)	Red. - Perdas (%)	Red. - Carregamento (%)
Esp. de Busca	2,05	5,61	3,09
EE. Híbrida	15,21	14,43	17,56
AG. Híbrido	17,09	16,10	19,97

Fonte: Elaborado pelo Autor.

A análise dos resultados apresentados na Tabela 4.9 destaca que ambas as estratégias de otimização superaram de forma expressiva o desempenho da abordagem baseada no Espaço de Busca. Entre elas, o Algoritmo Genético Híbrido mostrou-se superior em todas as métricas avaliadas. O ganho de tensão alcançado foi de 17,09%, superando os 15,21% da Estratégia Evolutiva Híbrida e os 2,03% obtidos pelos Mínimos Globais. Em relação à redução das perdas totais, o AGH obteve uma diminuição de 17,09%, enquanto a EEH registrou 14,43% e os Mínimos Globais, apenas 5,64%. Adicionalmente, o AGH alcançou uma redução de 19,97% no carregamento do sistema, em comparação aos 17,56% da EEH e aos 3,09% da abordagem baseada no Espaço de Busca.

Os resultados evidenciam que, apesar de ambas as estratégias de otimização apresentarem desempenhos próximos, o Algoritmo Genético Híbrido destaca-se com um desempenho superior. Esse destaque pode ser atribuído à sua maior eficiência na exploração ampla e contínua do espaço de soluções, à retenção de indivíduos com elevado potencial de desempenho e à manutenção da estabilidade populacional ao longo das gerações. Essas características conferem ao AGH uma capacidade distinta de alcançar soluções otimizadas e robustas, consolidando sua superioridade no contexto avaliado.

Conclui-se, portanto, que o Algoritmo Genético Híbrido não apenas melhora de maneira mais eficiente o desempenho do sistema de distribuição de energia, como também promove maior estabilidade e confiabilidade operacional. Assim, consolida-se como a abordagem mais robusta e eficaz para a alocação de geração distribuída e sistemas de armazenamento de energia em sistemas de distribuição de energia elétrica.

4.2 Sistema Alimentador Real - PD04

Visando expandir a aplicabilidade da metodologia para além de sistemas experimentais limitados, este estudo concentra-se na análise do Alimentador de Média Tensão representado na Figura 4.15, com suporte no software QGIS, conforme detalhado na Seção 2.6. Este alimentador constitui parte de um sistema elétrico de 13,8 kV associado à Subestação PAD Jardim. As informações que fundamentam este estudo foram extraídas de um banco de dados público disponibilizado pela Neoenergia Brasília em 2023 para a

ANEEL, por intermédio da Base de Dados Geográfica da Distribuidora (BDGD), como descrito na Seção 2.5.

A modelagem georreferenciada do sistema foi desenvolvida utilizando o software QGIS, conforme ilustrado na Figura 4.15. Essa ferramenta permitiu tanto a visualização detalhada do sistema quanto sua adaptação aos padrões estabelecidos pelo OpenDSS. O modelo resultante é composto por 94 barras, com um perfil de tensão apresentado na Figura 4.16, o qual demonstra a conformidade do sistema com os limites de tensão regulamentados pela ANEEL, conforme discutido na Seção 2.4. Adicionalmente, o perfil de carregamento do sistema é exibido na Figura 4.17, complementando a análise com informações operacionais relevantes.

Neste sistema, considera-se que todas as cargas de Baixa Tensão estão centralizadas no transformador de Média Tensão, o qual possui uma potência instalada de aproximadamente 4.981 kVA, composta por cargas desbalanceadas. Essas cargas estão distribuídas ao longo de linhas de Média Tensão com uma extensão aproximada de 40 km. Adicionalmente, a análise revelou perdas totais de energia equivalentes a 2.181 kWh no sistema avaliado.

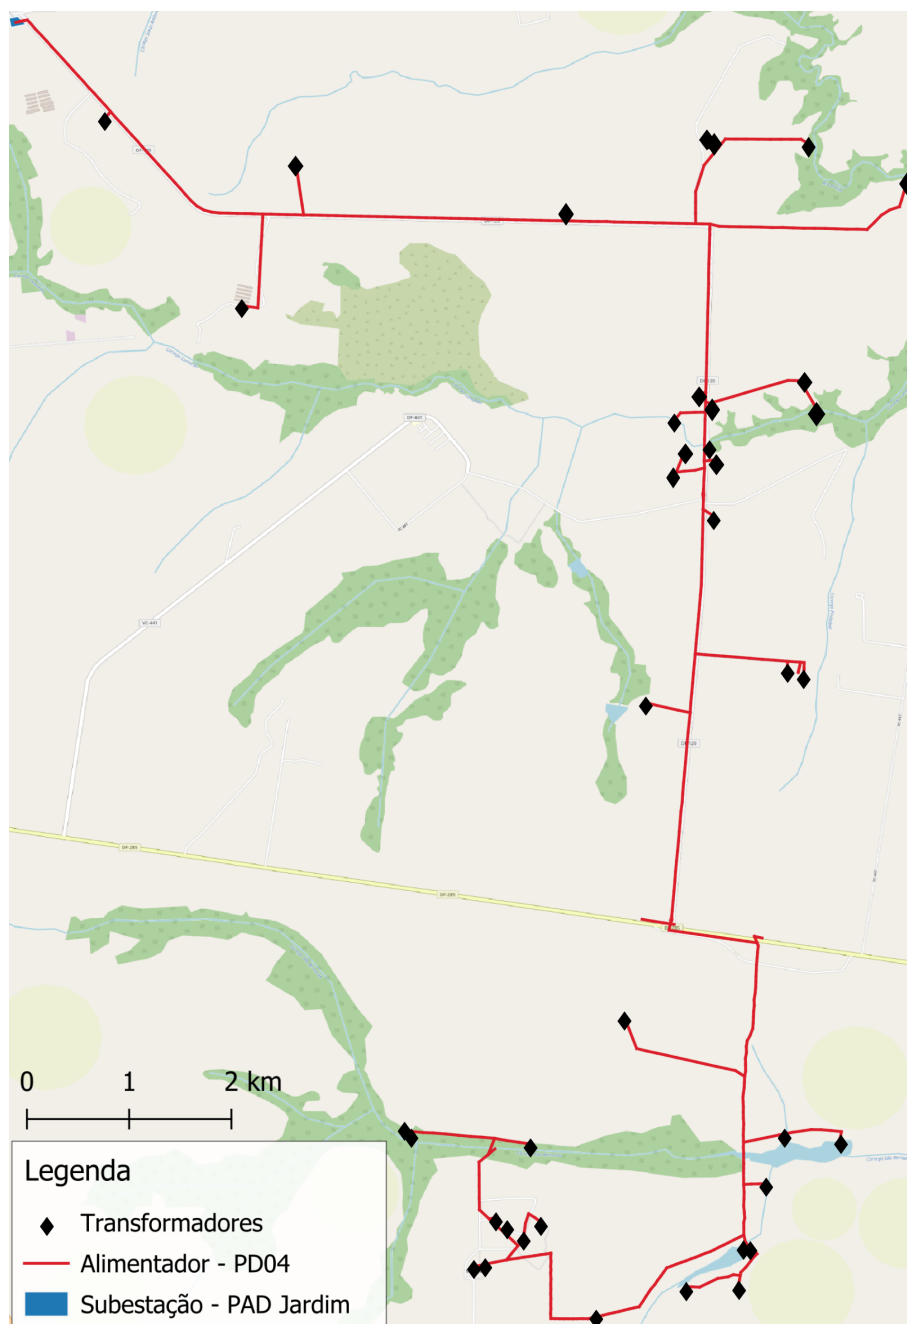


Figura 4.15 – Alimentador Real PD04: Representação Georreferenciada

Fonte: Elaborado pelo Autor.




Figura 4.16 – Alimentador Real PD04: Análise do Perfil de Tensão

Fonte: Elaborado pelo Autor.

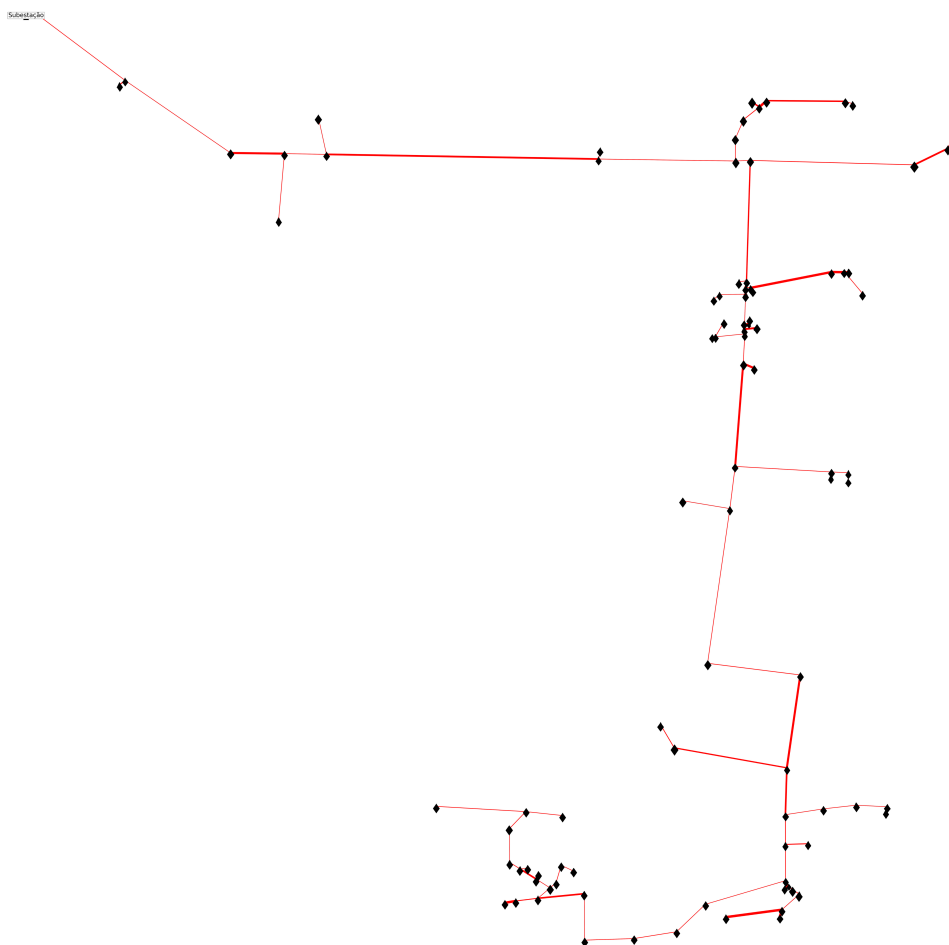


Figura 4.17 – Alimentador Real PD04: Análise do Perfil de Carregamento

Fonte: Elaborado pelo Autor.

4.2.1 Modificações Implementadas

A distribuidora prevê um aumento de 30% sobre o sistema ilustrado na Figura 4.15, conforme detalhado na Seção 4.1.1. Esse crescimento é esperado tanto na Carga Total Instalada quanto na extensão do sistema, sendo impulsionado pela aquisição de novos clientes e pelo incremento na capacidade de consumo dos clientes já existentes. Diante dessa expansão, a distribuidora antecipa que, caso o sistema permaneça inalterado, poderão surgir problemas relacionados ao aumento das perdas e à deterioração dos perfis de tensão.

Considerando o crescimento projetado, a Demanda Total Instalada do sistema será de 6.475 kVA, com uma extensão ampliada para 52 km. Assume-se que a expansão da extensão ocorrerá exclusivamente no lado de Baixa Tensão dos transformadores, mantendo inalterado o Diagrama Unifilar de Média Tensão do sistema. O perfil de tensão resultante, levando em conta esse aumento, é apresentado na Figura 4.18. Observa-se que diversos barramentos apresentam tensões abaixo do limite mínimo de 95%, conforme os parâmetros

estabelecidos pela ANEEL, conforme descrito na Seção 2.4.

Ademais, após o crescimento, o sistema apresenta 6.356 kWh de perdas totais, o que corresponde a um aumento de 2,91 vezes em comparação com o sistema original, além de um acréscimo de aproximadamente 40% no carregamento total do sistema..




Figura 4.18 – Alimentador Real PD04: Análise do Perfil de Tensão com 30% de Crescimento

Fonte: Elaborado pelo Autor.

Para mitigar os problemas projetados, a distribuidora optou por implementar medidas de investimento, incluindo a conexão de REDs, como usinas fotovoltaicas e sistemas de armazenamento de energia com baterias, com o intuito de contornar as dificuldades previstas no futuro.

Como diretriz, a distribuidora estabeleceu a necessidade de avaliar cenários com a alocação máxima de até 16 REDs, distribuídos entre 8 unidades de Geração Distribuída (GD) e 8 Sistemas de Armazenamento de Energia em Bateria (SAEB). Esses cenários serão analisados com o intuito de identificar a configuração que proporciona o melhor desempenho e otimiza o sistema, garantindo que esse quantitativo seja disponibilizado para alocação no máximo permitido.

4.2.2 Desempenho do Espaço de Busca

A modelagem do espaço de busca destaca o potencial da alocação de REDs como uma abordagem eficaz para atenuar os impactos decorrentes da expansão do sistema. A aplicação dessa metodologia não apenas facilita a identificação antecipada de problemas relacionados à qualidade da energia, mas também viabiliza a implementação de soluções que garantem a robustez e a continuidade operacional do sistema a longo prazo.

A estrutura da Tabela 4.10 foi organizada para apresentar, em ordem decrescente, as configurações dos REDs alocados que oferecem a maior capacidade de redução de perdas, destacando aquelas que proporcionam a melhor otimização do sistema em análise.

Tabela 4.10 – Alimentador Real PD04 - Configurações de Barramentos com GD e SAEB: Mitigação das Perdas Totais e Conformidade com Limites de Tensão

Config	GD (kVA)	Barra GD	Bateria (kW)	Barra Bateria	Redução (%)
1	1.024,63	B61	978,03	B61	9,112
2	956,65	B15	902,88	B13	9,085
3	1.540,11	B52	904,52	B59	9,079
4	1.203,05	B41	826,35	B38	9,058
5	963,30	B38	815,69	B34	9,057
6	832,69	B66	798,41	B58	9,055
7	931,27	B61	825,17	B60	9,052
8	1.005,39	B59	934,06	B56	9,023
9	1.025,85	B75	891,62	B72	9,001
10	986,36	B92	705,13	B94	8,992
11	900,13	B08	781,34	B10	8,954
12	815,51	B10	775,12	B07	8,846
13	702,23	B24	701,82	B22	8,792
14	781,27	B67	689,45	B65	8,721
15	994,02	B82	912,32	B81	8,695

Fonte: Elaborado pelo Autor.

A análise da Tabela 4.10 indica que a Configuração 1 é a mais eficiente na redução de perdas, alcançando uma diminuição de 9,11%, com uma potência instalada de Geração Distribuída (GD) de 1.024,63 kVA e uma potência de Sistemas de Armazenamento de Energia em Bateria (SAEB) de 978,03 kW. Outras configurações notáveis incluem a Configuração 2, que proporciona uma redução de perdas de 9,085%, com potência GD de 956,65 kVA e potência SAEB de 902,88 kW, e a Configuração 3, com uma redução de perdas de 9,079%, potência GD de 1.540,11 kVA e potência SAEB de 904,52 kW.

4.2.3 Otimização da Configuração de Recursos Energéticos Distribuídos e Identificação do Melhor Indivíduo

A estratégia empregada para a otimização da configuração do alimentador foi o Algoritmo Genético Híbrido, selecionado por sua capacidade de integrar eficientemente a exploração e a intensificação de soluções, conforme exposto na Seção 4.1.5. Este algoritmo mantém a diversidade genética ao longo das gerações, ao mesmo tempo que assegura a preservação dos melhores indivíduos para as gerações subsequentes. Essa abordagem facilita uma convergência mais eficiente e eficaz em direção às soluções ótimas. O desempenho do sistema ao longo das gerações é apresentado na Figura 4.19. Constatou-se que o melhor indivíduo foi identificado na geração 64, alcançando uma redução de perdas de 16,01%, evidenciando sua superioridade em relação ao desempenho do espaço de busca, que obteve uma redução de 9,11%, conforme esperado. A configuração do sistema do Melhor Indivíduo é detalhada nas Tabelas 4.11 e 4.12.

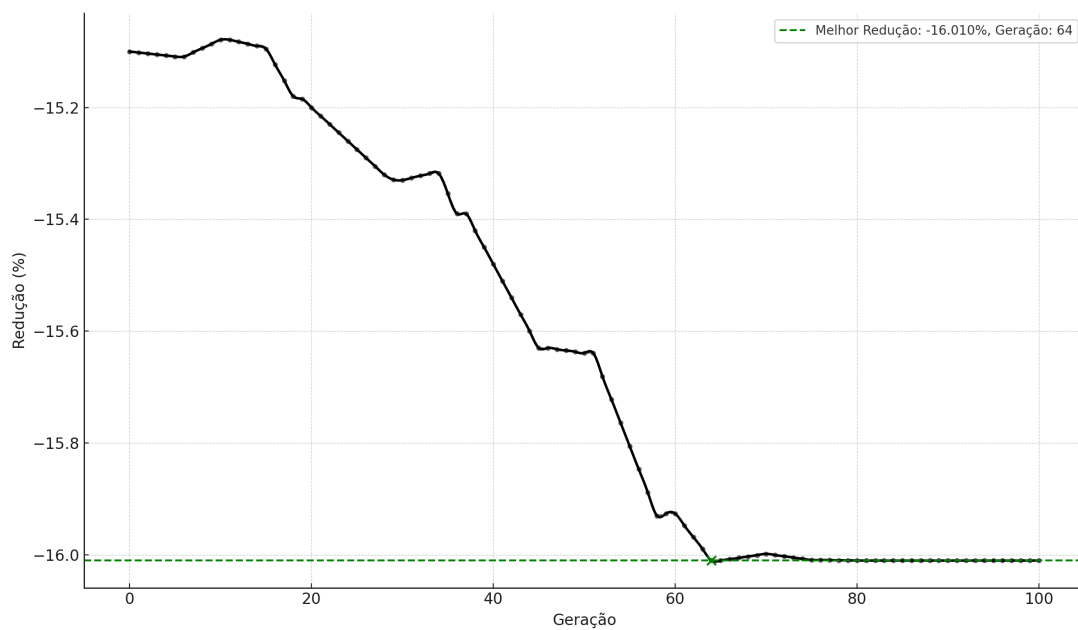


Figura 4.19 – Alimentador PD04: Comportamento do Melhor Indivíduo no AGH

Fonte: Elaborado pelo Autor.

Tabela 4.11 – Alimentador PD04: Configuração do Melhor Indivíduo com Composição de GD no Algoritmo Genético Híbrido

GD	Barramento	Fases	Potência Instalada (kVA)
A	B61	3	954,12
B	B52	3	702,53
C	B38	3	819,33
D	B24	3	998,10
E	B15	3	756,62
F	B03	3	1.002,53

Fonte: Elaborado pelo Autor.

Tabela 4.12 – Alimentador PD04: Configuração do Melhor Indivíduo com Composição de SAEB no Algoritmo Genético Híbrido

SAEB	Barramento	Fases	Potência Instalada (kW)
A	B61	3	901,04
B	B54	3	693,66
C	B42	3	802,51
D	B22	3	701,73
E	B07	3	655,27

Fonte: Elaborado pelo Autor.

O desempenho do sistema após a alocação dos REDs é apresentado na Tabela 4.13. Constatou-se que o Melhor Indivíduo não apenas manteve-se dentro dos limites operacionais, mas também obteve um aumento de 14,67% na tensão, uma redução de perdas de 16,01% e uma diminuição de 15,77% no carregamento. O perfil de tensão do sistema é ilustrado na Figura 4.20, enquanto o perfil de carregamento é mostrado na Figura 4.21.

Tabela 4.13 – Alimentador PD04: Avaliação do Desempenho do Melhor Indivíduo no Algoritmo Genético Híbrido

Ganho - Tensão (%)	Redução - Perdas (%)	Redução - Carregamento (%)
14,67	16,01	15,77

Fonte: Elaborado pelo Autor.

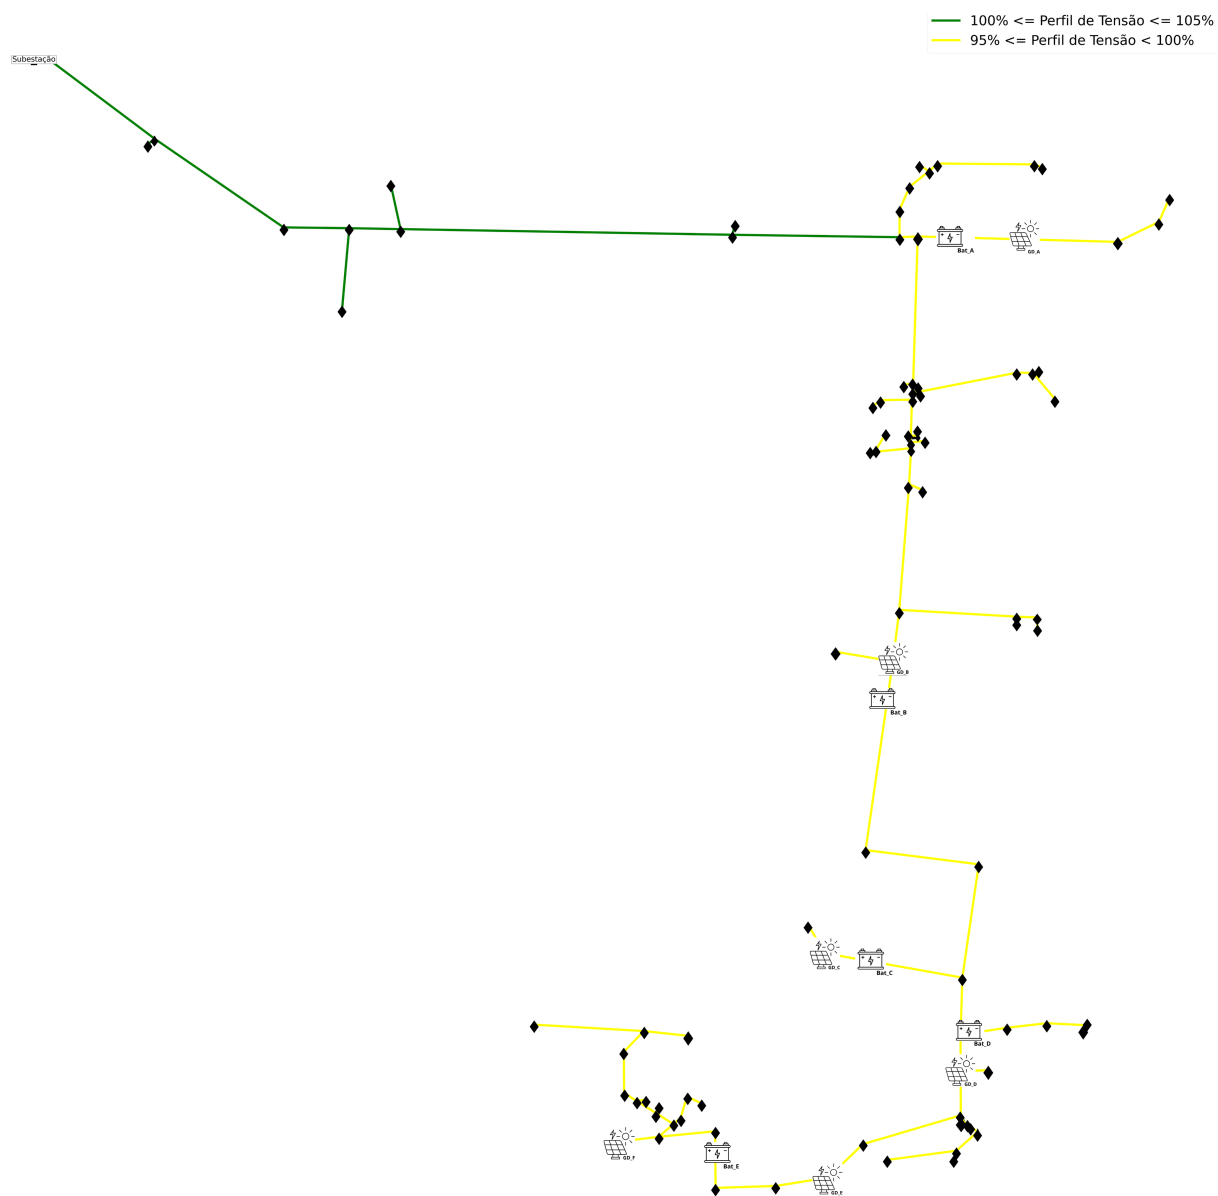


Figura 4.20 – Perfil de Tensão Alimentador PD04 - AGH Elitismo

Fonte: Elaborado pelo Autor.




Figura 4.21 – Perfil de Carregamento Alimentador PD04 - AGH Elitismo

Fonte: Elaborado pelo Autor.

5 Conclusão

Neste estudo, foram apresentados resultados significativos no contexto da alocação de recursos energéticos distribuídos (REDs), por meio da aplicação de estratégias evolutivas e algoritmos genéticos híbridos. As simulações, conduzidas utilizando o software OpenDSS, tiveram como objetivo principal a redução das perdas técnicas e a melhoria do perfil de tensão no sistema de distribuição.

Duas propostas de otimização baseadas em algoritmos evolutivos foram formuladas e testadas neste trabalho: a Estratégia Evolutiva Híbrida (EEH) e o Algoritmo Genético Híbrido (AGH). Essas abordagens foram projetadas para solucionar o problema de alocação e dimensionamento ótimos de Recursos Energéticos Distribuídos (REDs) em sistemas de distribuição operando em média tensão.

A primeira proposta, Estratégia Evolutiva Híbrida (EEH) utiliza princípios das estratégias evolutivas clássicas, baseando-se em operadores de mutação e seleção para explorar o espaço de busca. Seu foco na diversidade populacional evita estagnação em ótimos locais, permitindo a geração de soluções robustas e adequadas às restrições operacionais do sistema. Enquanto a segunda proposta, o Algoritmo Genético Híbrido (AGH) incorpora elitismo em sua formulação, garantindo a preservação das melhores soluções ao longo das iterações. Combinando operadores de cruzamento e mutação, o AGH promove uma exploração eficiente do espaço de busca, destacando-se pela rapidez na convergência e pela precisão na obtenção de soluções. Ambas as propostas demonstraram excelente desempenho, adaptando-se bem ao problema de alocação de REDs, com resultados consistentes e promissores nos sistemas analisados.

Um ponto crucial destacado neste estudo é a diferença de complexidade entre as propostas. A Estratégia Evolutiva Híbrida (EEH) apresentou maior simplicidade de implementação, devido à menor necessidade de parametrização e ao uso de operadores básicos, o que resulta em um menor consumo de memória e em tempos de processamento mais baixos. Em contrapartida, o Algoritmo Genético Híbrido (AGH), embora mais robusto, requer a implementação de múltiplas funções e verificações, principalmente durante os processos de cruzamento e mutação. Adicionalmente, o AGH demanda um maior espaço de memória, uma vez que armazena listas de gerações e trabalha com matrizes de dimensões consideráveis, frequentemente superiores a milhares de linhas. Essa diferença é essencial para avaliar a viabilidade das estratégias, especialmente em cenários com restrições computacionais.

A análise de eficiência dos algoritmos foi realizada nos sistemas IEEE 34 barras e Alimentador Real PD004, ambos com características radiais. Para simplificação, os sistemas

foram avaliados sem considerar variação horária de carga. No entanto, a incorporação da sazonalidade em futuros estudos poderia oferecer insights adicionais relevantes, ampliando a precisão e a aplicabilidade das soluções.

Os resultados evidenciaram os benefícios dos REDs, como a redução significativa das perdas de potência ativa, a melhoria nos níveis de tensão da rede e a diminuição do carregamento do alimentador da concessionária. Esses efeitos foram particularmente notáveis quando a alocação dos recursos foi planejada de forma otimizada, evitando impactos negativos associados à distribuição inadequada.

Os experimentos demonstraram que ambas as abordagens — a Estratégia Evolutiva Híbrida (EEH) e o Algoritmo Genético Híbrido (AGH) — foram eficazes na resolução do problema. A EEH destacou-se por sua eficiência em explorar cenários complexos, enquanto o AGH apresentou maior rapidez na convergência e maior precisão nas soluções finais. Em ambos os casos, as estratégias garantiram reduções significativas nas perdas de potência ativa, respeitando os limites de operação do sistema, como restrições de tensão e capacidade de carregamento. Essas características reforçam o potencial das propostas para aplicações práticas no planejamento energético, com benefícios diretos para concessionárias e operadores do setor elétrico.

Em conclusão, tanto a Estratégia Evolutiva quanto o Algoritmo Genético Híbrido demonstraram eficácia na alocação otimizada de REDs em redes de distribuição, com implicações diretas na melhoria da eficiência do sistema, na redução das perdas técnicas e no aprimoramento da qualidade do fornecimento de energia. O AGH se destacou por sua capacidade de identificar soluções de alta qualidade e promover uma operação mais estável e eficiente do sistema de distribuição.

Como proposta para trabalhos futuros, recomenda-se a aplicação do AGH, por sua superioridade nos testes realizados, com a inclusão de variáveis como sazonalidade da carga, otimização do estado das baterias e análise de custos associados. Essas extensões permitirão a modelagem de cenários mais realistas e a proposição de soluções que maximizem os benefícios técnicos e econômicos dos REDs, contribuindo assim para a melhoria contínua do serviço prestado à população e para a modernização do sistema elétrico.

Referências

ACHARYA, N.; MAHAT, P.; MITHULANANTHAN, N. An analytical approach for dg allocation in primary distribution network. *International Journal of Electrical Power & Energy Systems*, v. 28, n. 10, p. 669–678, 2006. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061506000652>>. Citado 2 vezes nas páginas 24 e 27.

ALEGRIA, E. et al. *CERTS Microgrid Demonstration with Large-scale Energy Storage and Renewables at Santa Rita Jail: Final Project Report*. California Energy Commission, Energy Research and Development Division, 2013. Disponível em: <<https://books.google.com.br/books?id=wDqE0AEACAAJ>>. Citado na página 55.

ANEEL. *Conexão em Geração Distribuída - Brasil*. [S.l.], 2022. Disponível em: <<https://app.powerbi.com/view?r=eyJrIjoiY2VmMmUwN2QtYWFiOS00ZDE3LWI3NDMtZDk0NGI4MGU2NTkxIiwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOiJ9>>. Acesso em: 06 nov. 2022. Citado na página 23.

ANEEL. *Perdas de Energia*. [S.l.], 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/distribuicao/perdas-de-energia/perdas-de-energia>>. Acesso em: 05 nov. 2022. Citado na página 27.

ANEEL, A. N. de E. E. *Base de Dados Geográfica da Distribuidora - BDGD*. <<https://dadosabertos.aneel.gov.br/dataset/base-de-dados-geografica-da-distribuidora-bdgd>>. Acessado em: 25 oct. 2024. Citado 2 vezes nas páginas 46 e 47.

ANEEL, A. N. de E. E. *Manual de Instruções da BDGD*. <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/manuais-modelos-e-instrucoes/distribuicao>>. Acessado em: 18 nov. 2024. Citado na página 47.

ANEEL, A. N. de E. E. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST*. <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>>. Acessado em: 10 nov. 2024. Citado na página 47.

ANEEL, A. N. de E. E. *Nota Técnica n° 0057/2014-SRD/ANEEL: Aprimoramento da metodologia de cálculo de perdas na distribuição regulamentada no Módulo 7 – Cálculo de Perdas na Distribuição do PRODIST*. Brasília: [s.n.], 2014. Nota Técnica. 27 p. Citado na página 48.

ANEEL, A. N. de E. E. *Chamada N° 021/2016. Projeto Estratégico: “Arranjos Técnicos e Comerciais para a Inserção de Sistemas de Armazenamento de Energia no Setor Elétrico Brasileiro”*. Brasília, DF: [s.n.], 2016. Citado na página 32.

ANEEL, A. N. de E. E. *Agência aprova 23 propostas da chamada de P&D sobre armazenamento de energia*. 2017. Acesso em: 07 nov. 2024. Disponível em: <<https://biblioteca.aneel.gov.br/acervo/detalhe/242638>>. Citado 2 vezes nas páginas 32 e 33.

ANEEL, A. N. de E. E. *Módulo 8 - Qualidade da Energia Elétrica do PRODIST*. Brasília: [s.n.], 2021. ANEEL - Agência Nacional de Energia Elétrica. Disponível em:

<https://www2.aneel.gov.br/cedoc/aren2020888_prodist_modulo_8_v11.pdf>. Citado 3 vezes nas páginas 44, 45 e 81.

ANEEL, A. N. de E. E. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) - Módulo 2: Planejamento da Expansão do Sistema de Distribuição*. 2021. Anexo II da Resolução Normativa ANEEL Nº 956, de 7 de dezembro de 2021. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/distribuicao/plano-d-e-desenvolvimento-da-distribuicao>>. Citado na página 101.

ANEEL, A. N. de E. E. *SOLUÇÃO NORMATIVA ANEEL Nº 1.000, DE 7 DE DEZEMBRO DE 2021*. [S.l.], 2023. Disponível em: <<https://www2.aneel.gov.br/cedoc/ren20211000.html>>. Acesso em: 20 fev. 2023. Citado na página 26.

BACK, T.; HAMMEL, U.; SCHWEFEL, H.-P. Evolutionary computation: comments on the history and current state. *IEEE Transactions on Evolutionary Computation*, v. 1, n. 1, p. 3–17, 1997. Citado 3 vezes nas páginas 60, 62 e 64.

BARBOSA, H. J. *Algoritmos Genéticos para Otimização em Engenharia: Uma introdução aos Algoritmos Genéticos*. Rio de Janeiro, Brasil: [s.n.], 1977. 2a Escola de Verão em Computação Científica, LNCC. Citado 3 vezes nas páginas 58, 62 e 64.

BASTOS, E. A. *Otimização de Seções Retangulares de Concreto Armado Submetidas à Flexo-Compressão Oblíqua Utilizando Algoritmos Genéticos*. Dissertação (Dissertação de Mestrado) — Programa de Pós-Graduação em Engenharia, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2004. Citado 3 vezes nas páginas 57, 59 e 60.

BEYER, H.-G.; SCHWEFEL, H.-P.; WEGENER, I. How to analyse evolutionary algorithms. *Theoretical Computer Science*, v. 287, n. 1, p. 101–130, 2002. ISSN 0304-3975. Natural Computing. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304397502001378>>. Citado 3 vezes nas páginas 58, 60 e 62.

BINACIONAL, I. *SALA DE IMPRENSA*. [S.l.], 2024. Disponível em: <<https://www.itaipu.gov.br/sala-de-imprensa/perguntas-frequentes>>. Acesso em: 23 de maio de 2024. Citado na página 23.

BOCANEGRA, S. Y.; MONTROYA, O. D. Heuristic approach for optimal location and sizing of distributed generators in ac distribution networks. *WSEAS Transactions on Power Systems*, v. 14, n. 3, p. 113–121, 2019. Citado na página 22.

BRASIL. Decreto-lei nº 5.163 de 30 de julho de 2004. *Diário Oficial [da] República Federativa do Brasil*, Brasília, DF, 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5163.HTM>. Citado na página 40.

BRASIL. Resolução normativa nº 482, de 17 de abril de 2012. *Agência Nacional [de] Energia Elétrica - ANEEL*, Brasília, DF, 2012. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2012482.pdf>>. Citado 2 vezes nas páginas 40 e 41.

COUNCIL, W. E. *World Energy Trilemma - 2017*. 2017. Acesso em: 05 out. 2024. Disponível em: <<https://www.worldenergy.org/publications/entry/world-energy-trilemma-index-2017-monitoring-the-sustainability-of-national-energy-systems>>. Citado na página 42.

- DAVIS, L. *Handbook of Genetic Algorithms*. Van Nostrand Reinhold, 1991. (VNR Computer Library VNR Computer Library). ISBN 9780442001735. Disponível em: <<https://books.google.com.br/books?id=Kl7vAAAAMAAJ>>. Citado na página 62.
- DIVYA, K.; ØSTERGAARD, J. Battery energy storage technology for power systems—an overview. *Electric Power Systems Research*, v. 79, n. 4, p. 511–520, 2009. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779608002642>>. Citado na página 55.
- DUGAN, R. C.; MONTENEGRO, D. *The Open Distribution System Simulator (OpenDSS) Reference Guide*. Washington, DC, 2020. Retrieved from <<https://sourceforge.net/p/electricdss/code/HEAD/tree/trunk/Distrib/Doc/OpenDSSManual.pdf>>. Citado 5 vezes nas páginas 49, 50, 51, 52 e 53.
- EIBEN, A. E.; SMITH, J. E. *Introduction to Evolutionary Computing*. Springer, 2003. ISBN 3-540-40184-9. Disponível em: <<http://www.cs.vu.nl/~gusz/ecbook/ecbook.html>>. Citado 2 vezes nas páginas 59 e 60.
- ENERGIA, N. *USINA HIDRÉLETRICA DE BELO MONTE*. [S.l.], 2024. Disponível em: <<https://www.norteenergiasa.com.br/uhe-belo-monte/>>. Acesso em: 23 de maio de 2024. Citado na página 23.
- EPBR. *Geração distribuída demanda uniformidade de regras tributárias*. [S.l.], 2022. Disponível em: <<https://epbr.com.br/geracao-distribuida-demanda-uniformidade-de-regras-tributarias/>>. Acesso em: 07 nov. 2022. Citado na página 44.
- EPE, E. D. P. E. Plano decenal de expansão de energia 2032. *Empresa de Pesquisas Energéticas - EPE*, Brasília, DF, 2022. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-689/topico-640/Caderno_MMGD_Baterias.pdf>. Citado na página 23.
- EPE, E. de P. E. *Planejamento Anual da Operação Energética 2024-2028*. 2024. Divulgado em parceria com ONS e CCEE. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/revisoes-quadrimestrais-da-carga#:~:text=Planejamento%20Anual%20da%20Opera%C3%A7%C3%A3o%20Energ%C3%A9tica%202021-2025&text=Para%20o%20per%C3%AAnodo%202021-2025,pelo%20carregamento%20estat%C3%ADstico%20de%202020.>> Citado na página 101.
- EPRI, E. *OpenDSS*. 2022. <<https://www.epri.com/pages/sa/opendss>>. Retrieved from EPRI. Citado 4 vezes nas páginas 49, 52, 53 e 54.
- FANG-ZONG, W.; JING, Y. Fast solution algorithm for optimal placement of distributed generations. In: *2011 IEEE Power Engineering and Automation Conference*. [S.l.: s.n.], 2011. v. 3, p. 1–4. Citado na página 27.
- FATHIMA, A. H.; PALANISAMY, K. *Energy Storage Systems for Energy Management of Renewables in Distributed Generation Systems*. India: [s.n.], 2016. Acesso em: 20 nov. 2024. Disponível em: <https://pdfs.semanticscholar.org/f410/939d82debd20e03de452b8167253d6d706ba.pdf?_ga=2.99995166.1222804676.1665855130-460168588.1665855130>. Citado 2 vezes nas páginas 37 e 38.

FERREIRA, K. *Otimização Da Capacidade Do Sistema De Acumulação De Energia Aplicados Em Peak Shaving E Avaliação Do Impacto Na Tensão Das Barras De Um Sistema De Distribuição*. Dissertação (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2020. Orientador: Prof. Dr. Walbermark Marques dos Santos. Citado 3 vezes nas páginas 31, 55 e 56.

FERREIRA, M. R. M. *Estudo de Estratégias e Análise Econômica de Sistemas Peak Shaving*. Dissertação (Dissertação de Mestrado) — Universidade Federal do Maranhão, São Luís, Brasil, 2019. Orientador: Prof. Luiz Antonio de Sousa Ribeiro; Coorientador: Prof. José Gomes de Matos. Citado 2 vezes nas páginas 55 e 56.

FGV, C. E. F. G. V. *Distributed Energy Resources*. 2016. Acesso em: 05 out. 2024. Disponível em: <https://fgvenergia.fgv.br/sites/fgvenergia.fgv.br/files/red_ingles.pdf>. Citado na página 42.

FRACALOSSO L.G.V., B. T. V. M.; BATISTA, O. Trip solidário no ieee 34-node test feeder: um estudo de caso. *Brazilian Journal of Development*, maio 2021. ISSN: 2525-8761. Citado na página 99.

FRANCO, A. K. S. *Estudo de caso dos impactos da inserção de fontes renováveis intermitentes na rede de transmissão e distribuição elétrica*. São Paulo: [s.n.], 2018. Monografia (Especialização em Energias Renováveis, Geração Distribuída e Eficiência Energética). Citado na página 32.

FRANÇA, L. *O que é o QGIS?* 2021. <<https://geoone.com.br/o-que-e-o-qgis/>>. Acessado em: 15 oct. 2024. Citado 2 vezes nas páginas 47 e 48.

FREITAS, P. R. R. *Modelos avançados de análise de redes elétricas inteligentes utilizando o software OpenDSS*. Trabalho de Conclusão de Curso — Universidade de São Paulo – USP, Escola Politécnica, São Paulo, 2015. 191f. Trabalho de Conclusão de Curso (Bacharel em Engenharia). Citado 2 vezes nas páginas 50 e 51.

FUCHS, S. G. et al. *Technology Overview on Electricity Storage*. 2012. Acesso em: 16 nov. 2024. Disponível em: <https://www.researchgate.net/profile/Dirk-Uwe-Sauer/publication/299425278_Technology_Overview_on_Electricity_Storage_-_Overview_on_the_potential_and_on_the_deployment_perspectives_of_electricity_storage_technologies/links/56f5bdca08ae81582bf21724/Technology-Overview-on-Electricity-Storage-Overview-on-the-potential-and-on-the-deployment-perspectives-of-electricity-storage-technologies.pdf>. Citado 5 vezes nas páginas 36, 37, 38, 39 e 40.

GALLO, A. B. et al. Energy storage in the energy transition context: A technology review. *Renewable and Sustainable Energy Reviews*, v. 65, p. 800–822, 2016. Citado na página 33.

GAUTAM, P. *Reliability studies of distribution systems integrated with energy storage*. Canada: [s.n.], 2018. Acesso em: 16 nov. 2024. Disponível em: <<https://core.ac.uk/download/pdf/226164517.pdf>>. Citado 3 vezes nas páginas 36, 37 e 39.

GONZALEZ-LONGATT, F.; FORTOUL, C. Review of distributed generation concept: Attempt of unification. *Renewable Energy and Power Quality Journal*, v. 1, 03 2005. Citado na página 41.

GRISALES-NOREÑA, L. F.; MONTOYA, D. G.; RAMOS-PAJA, C. A. Optimal sizing and location of distributed generators based on pbil and pso techniques. *Energies*, v. 11, n. 4, 2018. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/11/4/1018>>. Citado na página 22.

HASSAN, A. S.; SUN, Y.; WANG, Z. Optimization techniques applied for optimal planning and integration of renewable energy sources based on distributed generation: Recent trends. *Cogent Engineering*, Cogent OA, v. 7, n. 1, p. 1766394, 2020. Disponível em: <<https://doi.org/10.1080/23311916.2020.1766394>>. Citado na página 77.

IEA, I. E. A. *Grid-Scale Storage*. Paris: [s.n.], 2022. Acesso em: 16 nov. 2024. Disponível em: <<https://www.iea.org/reports/grid-scale-storage>>. Citado 2 vezes nas páginas 35 e 36.

IEC, I. E. C. *Electrical Energy Storage*. Genova: [s.n.], 2011. Acesso em: 16 nov. 2024. Disponível em: <https://storage-iecwebsite-prd-iec-ch.s3.eu-west-1.amazonaws.com/2019-09/content/media/files/iec_wp-electrical_energy_storage-en.pdf>. Citado 5 vezes nas páginas 36, 37, 38, 39 e 40.

IRENA, I. R. E. A. *Battery Storage for Renewables: Market Status and Technology Outlook*. 2015. Acesso em: 16 nov. 2024. Disponível em: <<https://www.irena.org/publications/2015/Jan/Battery-Storage-for-Renewables-Market-Status-and-Technology-Outlook>>. Citado na página 35.

IRENA, I. R. E. A. *Electricity Storage and Renewables: Costs and Markets to 2030*. [S.l.], 2017. Citado na página 31.

JÚNIOR, L. C. Z. *Fundamentos de Sistemas Elétricos de Potência*. 1. ed. São Paulo: Editora Livraria da Física, 2005. Citado na página 27.

JÚNIOR, B.; FERREIRA, M. Impacto da geração distribuída na proteção de sistema de distribuição. In: *Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá*. [S.l.: s.n.], 2017. Citado na página 44.

KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. *Introdução aos Sistemas de Distribuição de Energia Elétrica*. 1. ed. São Paulo: Editora Edgard Blücher, 2005. Citado na página 27.

LABORATORIES, S. N. *Energy Storage for the Electricity Grid: Benefits and Market Potential Assessment Guide*. EUA, 2010. Citado na página 31.

LEZAMA, J. M. L.; GALEANO, N. M.; DUQUE, F. V. Optimal allocation of distributed generation in power systems considering multiple operative scenarios. In: *International Journal of Engineering Research and Technology - IJERT*. [S.l.: s.n.], 2020. v. 13, n. 10, p. 2788–2791. Citado na página 78.

LOPEZ, L. et al. Distributed generation allocation and sizing: A comparison of metaheuristics techniques. In: *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / ICPS Europe)*. [S.l.: s.n.], 2019. p. 1–6. Citado na página 77.

LUKE, S. *Essentials of Metaheuristics*. second. [S.l.]: Lulu, 2013. Available for free at <https://cs.gmu.edu/~sean/book/metaheuristics/>. Citado 2 vezes nas páginas 67 e 68.

- LUO, X. et al. Overview of current development in electrical energy storage technologies and the application potential in power system operation. *Applied Energy*, Reino Unido, 2015. Acesso em: 18 nov. 2024. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261914010290>>. Citado 5 vezes nas páginas 36, 37, 38, 39 e 40.
- MACHAVA, A. S.; KABERERE, K. K.; VILANCULO, G. A. A method for optimal distributed generation allocation considering load demand uncertainties. In: *International Journal of Electrical and Electronic Engineering & Telecommunications - IJEETC 2022*. [S.l.: s.n.], 2022. v. 11, n. 3. Citado na página 77.
- MARQUES, L. *QGIS: O que é, o que faz e para que serve?* 2021. <<https://clubedogis.com.br/blog/qgis-o-que-e-o-que-faz-e-para-que-serve/>>. Acessado em: 15 oct. 2024. Citado na página 47.
- MITHULANANTHAN, N.; OO, T.; PHU, L. V. Distributed generator placement in power distribution system using genetic algorithm to reduce losses. *Science & Technology Asia*, v. 9, n. 3, p. 55–62, Nov. 2015. Disponível em: <<https://ph02.tci-thaijo.org/index.php/SciTechAsia/article/view/41639>>. Citado 2 vezes nas páginas 23 e 24.
- MONTOYA, O. D. et al. Distribution systems operation considering energy storage devices and distributed generation. *IEEE Latin America Transactions*, v. 15, n. 5, p. 890–900, 2017. Citado na página 22.
- MONTOYA, O. D. et al. Vortex search algorithm for optimal sizing of distributed generators in ac distribution networks with radial topology. In: FIGUEROA-GARCÍA, J. C. et al. (Ed.). *Applied Computer Sciences in Engineering*. Cham: Springer International Publishing, 2019. p. 235–249. ISBN 978-3-030-31019-6. Citado na página 22.
- NOGUEIRA, W. C. *Alocação e Dimensionamento Ótimo de Geração Distribuída Utilizando o Fluxo de Potência Intervalar*. 118 p. Dissertação (Mestrado em Engenharia Elétrica e Computação) — Universidade Federal Goiás, Goiânia, 2021. Citado na página 75.
- NYISO, N. Y. I. S. O. *Distributed Energy Resources Roadmap for New York's Wholesale Electricity Markets: A Report by the New York Independent System Operator*. 2017. Citado na página 43.
- OLABI, A. G. Renewable energy and energy storage systems. *Energy*, 2017. Acesso em: 13 nov. 2024. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0360544217312306?via%3Dihub>>. Citado na página 34.
- ONS, O. N. do S. E. *Diagramas Unifilares - Manual do Agente*. 2023. Acesso em: 06 de dez. de 2024. Disponível em: <<https://www.ons.org.br/AnexosMPO/Manual%20do%20Sistema%20Diagramas%20Unifilares.pdf>>. Citado na página 83.
- ONS, O. N. do S. E. *Qualidade do Suprimento*. 2024. Acesso em: 06 de dez. de 2024. Disponível em: <<https://www.ons.org.br/paginas/resultados-da-operacao/qualidade-do-suprimento>>. Citado 2 vezes nas páginas 22 e 26.
- PEREZ-ARRIAGA, I. et al. *Utility of the Future: An MIT Energy Initiative Response to an Industry in Transition*. [S.l.], 2016. Citado 2 vezes nas páginas 42 e 43.

PHAM, T. D.; NGUYEN, T. T.; DINH, B. H. Find optimal capacity and location of distributed generation units in radial distribution networks by using enhanced coyote optimization algorithm. *Neural Computing and Applications*, v. 33, n. 9, p. 4343–4371, May 2021. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-020-05239-1>>. Citado na página 76.

PRADO, I. F.; GARCES, L. P. Chu-beasley genetic algorithm applied to the allocation of distributed generation. In: *2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*. [S.l.: s.n.], 2013. p. 1–7. Citado na página 75.

PRODIST. *Módulo 7 - Cálculo de Perdas na Distribuição*. [S.l.], 2022. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2021956_2_6.pdf>. Acesso em: 05 nov. 2022. Citado na página 27.

QUIRIOGA, G. A. Impacto da geração distribuída sobre o sistema de proteção: considerações para o planejamento de redes de distribuição. In: *Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo*. [S.l.: s.n.], 2019. Citado na página 44.

SANTOS, J. D.; NEGRETE, L. P. G.; BRITO, L. D. C. Allocation of distributed generation in distribution networks using specialized genetic algorithms. In: *2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*. [S.l.: s.n.], 2021. p. 1–5. Citado na página 44.

SANTOS, J. R. d. et al. *Método de Extração de Atributos Técnicos e Geográficos de Distribuidoras de Energia Elétrica*. 2024. Universidade Federal de Santa Maria, Cachoeira do Sul, RS. Citado na página 46.

SEDIGHIZADEH, M.; REZAZADEH, A. Using genetic algorithm for distributed generation allocation to reduce losses and improve voltage profile. In: *World Academy of Science, Engineering and Technology*. [S.l.: s.n.], 2008. v. 37, p. 251–256. Citado na página 27.

SILVA, B. F. G. *Estudo de Soluções Alternativas de Armazenamento de Energia para Diferentes Horizontes Temporais*. Portugal: [s.n.], 2008. Acesso em: 16 nov. 2024. Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/58466/2/Texto%20integral.pdf>>. Citado na página 35.

SOLAR, C. *O que é geração distribuída de energia elétrica?* [S.l.], 2022. Disponível em: <<https://canalsolar.com.br/o-que-e-geracao-distribuida-de-energia-eletrica/>>. Acesso em: 07 nov. 2022. Citado na página 43.

SULTANA, U. et al. A review of optimum dg placement based on minimization of power losses and voltage stability enhancement of distribution system. *Renewable and Sustainable Energy Reviews*, v. 63, p. 363–378, 2016. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S136403211630168X>>. Citado na página 75.

THE, T. T.; QUOC, S. N.; NGOC, D. V. Symbiotic organism search algorithm for power loss minimization in radial distribution systems by network reconfiguration and distributed generation placement. In: *Mathematical Problems in Engineering*. [S.l.: s.n.], 2020. v. 2020. Citado na página 76.

TRUONG, K. H. et al. An improved meta-heuristic method to maximize the penetration of distributed generation in radial distribution networks. *Neural Computing and Applications*, v. 32, n. 14, p. 10159–10181, Jul 2020. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-019-04548-4>>. Citado na página 78.