



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Gerenciamento Inteligente de Microrredes: Impacto da Modelagem Matemática na Eficiência Computacional de Algoritmos de Otimização

Vitor dos Santos Batista

TD 05/2025

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Vitor dos Santos Batista

**Gerenciamento Inteligente de Microrredes: Impacto da
Modelagem Matemática na Eficiência Computacional de
Algoritmos de Otimização**

Tese submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para obtenção do Grau de Doutor em Engenharia Elétrica na Área de Sistemas de Energia.

Orientador: Prof. Dr. Ubiratan Holanda Bezerra
Coorientadora: Prof^a. Dr^a. Maria Emília de Lima Tostes

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

B333g Batista, Vitor dos Santos.
Gerenciamento Inteligente de Microrredes : Impacto da
Modelagem Matemática na Eficiência Computacional de
Algoritmos de Otimização / Vitor dos Santos Batista, . — 2025.
101 f. : il. color.

Orientador(a): Prof. Dr. Ubiratan Holanda Bezerra
Coorientação: Prof^a. Dra. Maria Emília de Lima Tostes
Tese (Doutorado) - Universidade Federal do Pará, Instituto de
Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica,
Belém, 2025.

1. Microrredes isoladas. 2. Otimização multi-objetivo. 3.
Formulação matemática. 4. Custo operacional. 5. Emissões de
poluentes. I. Título.

CDD 621.3191



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“GERENCIAMENTO INTELIGENTE DE MICRORREDES: IMPACTO DA
MODELAGEM MATEMÁTICA NA EFICIÊNCIA COMPUTACIONAL DE
ALGORITMOS DE OTIMIZAÇÃO”**

AUTOR: VITOR DOS SANTOS BATISTA

TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA ELÉTRICA.

APROVADA EM: 16/05/2025

BANCA EXAMINADORA:

Prof. Dr. Ubiratan Holanda Bezerra
(Orientador - PPGEE/ITEC/UFPA)

Prof.ª Dr.ª Maria Emília de Lima Tostes
(Coorientadora - PPGEE/ITEC/UFPA)

Prof. Dr. Thiago Mota Soares
(Avaliador Interno - PPGEE/ITEC/UFPA)

Prof. Dr. Wellington da Silva Fonseca
(Avaliador Interno - PPGEE/ITEC/UFPA)

Prof. Dr. Filipe de Oliveira Saraiva
(Avaliador Externo ao Programa - ICEN/UFPA)

Prof.ª Dr.ª Luciane Silva Neves
(Avaliadora Externa - UFSM)

VISTO:

Prof. Dr. Diego Lisboa Cardoso

(Coordenador do PPGEE/ITEC/UFPA)

Dedico esta tese à Deus, que me colocou nesta jornada.

À minha esposa, Eduarda Batista, a quem amo muito.

Aos meus pais, Jonas e Sonia, que sempre me incentivaram ao estudo desde a infância.

Agradecimentos

Agradeço a Deus por ter me colocado nesta jornada e por me sustentar durante toda a trajetória.

À minha esposa, Eduarda Batista, por me apoiar em tudo.

Aos meus pais, Jonas e Sonia, que sempre me incentivaram a estudar desde pequeno. Eles foram os grandes investidores neste trabalho.

À minha família, em especial ao meu irmão, Thiago; meus tios, Pinduca e Gabriela; minhas avós, vovó Elisa e vovó Helena; a todos os meus familiares em Belém e à família dos Santos no Rio de Janeiro.

Ao Prof. Andrey Vieira, por sua imensa contribuição nesta jornada. Ao Prof. Otávio Noura, por ter aberto as portas do mundo acadêmico para mim. Aos meus colegas de trabalho, que sempre me ajudaram e tiraram minhas dúvidas.

Aos professores da UFPA que tanto me ajudaram, em especial ao Prof. Bira e à Prof^a. Maria Emília, pelo grande incentivo e apoio durante minha pesquisa.

Ao Ceamazon, por ser uma grande instituição de ensino e uma referência em pesquisa sobre eficiência energética no Norte e em todo o Brasil. Agradeço também pelo acolhimento e pelo carinho de todos que fazem parte dessa comunidade.

Ao CNPq, à Norte Energia e ao Grupo Equatorial pelo apoio financeiro ao longo desses anos.

*“Deus não é homem para mentir,
nem ser humano para mudar de ideia.
Alguma vez ele falou e não agiu?
Alguma vez prometeu e não cumpriu?”
(Números 23.19)*

Resumo

Uma microrrede pode ser considerada um grupo localizado de cargas e fontes de energia elétrica, geralmente utilizando energias renováveis como principais fontes geradoras, além de possuir um sistema de armazenamento de energia. As microrredes podem operar de forma isolada da rede elétrica tradicional devido a fatores como a necessidade de fornecer eletricidade a áreas remotas, aumentar a resiliência do sistema elétrico e reduzir a dependência de infraestruturas centralizadas. O gerenciamento de microrredes consiste em definir o despacho ótimo de energia de cada elemento da microrrede, garantindo o atendimento da demanda e buscando minimizar os custos operacionais e a emissão de gases poluentes. Esse processo de gerenciamento geralmente ocorre por meio de sistemas de gerenciamento inteligentes, que utilizam algoritmos baseados em inteligência artificial para otimizar a alocação dos recursos energéticos. Uma metodologia bastante utilizada nesse contexto é o *Model Predictive Control* (MPC), que integra algoritmos de previsão e otimização para o gerenciamento energético. Um dos pontos principais dos algoritmos de otimização está na formulação matemática. Uma formulação inadequada pode levar a um maior custo computacional e a soluções ineficientes. Esta tese investiga e propõe aprimoramentos na formulação matemática de algoritmos de otimização para o gerenciamento inteligente de microrredes isoladas, com ênfase na relação entre custos operacionais, emissões de poluentes e custos de operação e manutenção (O&M) de geradores não despacháveis. Foram analisadas abordagens mono-objetivo e multi-objetivo, comparando metodologias existentes com propostas inovadoras que visam reduzir a complexidade computacional e melhorar a qualidade das soluções obtidas. Os testes realizados em diferentes cenários e configurações – incluindo casos com uma única fonte geradora poluente e com múltiplas fontes – demonstraram que a formulação aprimorada é mais eficiente e oferece um equilíbrio mais robusto entre eficiência e diversidade de soluções, contribuindo para a viabilidade econômica e ambiental do gerenciamento de microrredes isoladas.

Palavras-chave: microrredes isoladas. otimização multi-objetivo. formulação matemática. custo operacional. emissões de poluentes. operação e manutenção. algoritmos de otimização. pareto.

Abstract

A microgrid can be defined as a localized group of loads and energy sources, typically relying on renewable energy as its primary generation source, along with an energy storage system. Microgrids can operate independently from the traditional power grid due to factors such as the need to supply electricity to remote areas, enhancing system resilience, and reducing dependency on centralized infrastructures. Microgrid management involves determining the optimal energy dispatch for each microgrid element, ensuring demand fulfillment while minimizing operational costs and pollutant emissions. This management process is often carried out using intelligent management systems that employ artificial intelligence-based algorithms to optimize energy resource allocation. A widely used methodology in this context is *Model Predictive Control* (MPC), which integrates forecasting and optimization algorithms for energy management. One of the key aspects of optimization algorithms lies in their mathematical formulation. An inadequate formulation can lead to higher computational costs and inefficient solutions. This thesis investigates and proposes improvements in the mathematical formulation of optimization algorithms for intelligent management of isolated microgrids, focusing on the relationship between operational costs, pollutant emissions, and Operation and Maintenance (O&M) costs of non-dispatchable generators. Mono-objective and multi-objective approaches were analyzed, comparing existing methodologies with innovative proposals aimed at reducing computational complexity and improving the quality of obtained solutions. The tests conducted under different scenarios and configurations—including cases with a single pollutant-based generator and multiple sources—demonstrated that the improved formulation is more efficient and provides a more robust balance between efficiency and solution diversity, contributing to the economic viability and environmental sustainability of isolated microgrid management.

Keywords: isolated microgrids. multi-objective optimization. mathematical formulation. operational cost. pollutant emissions. operation and maintenance. evolutionary algorithms. pareto.

Lista de Figuras

Figura 1.	Exemplo de MG	16
Figura 2.	MG com Gerenciamento Centralizado	35
Figura 3.	MG com Gerenciamento Distribuído	39
Figura 4.	MPC Aplicado numa MG	43
Figura 5.	MPC Sendo Executado às 12:00 horas	44
Figura 6.	MPC Sendo Executado às 14:00 horas	45
Figura 7.	Espaço de decisão e o espaço de objetivo	47
Figura 8.	Dominância de Pareto	48
Figura 9.	Fluxograma do AG	51
Figura 10.	Funcionamento do NSGA-II	53
Figura 11.	MGs utilizadas nos testes	61
Figura 12.	Geração Fotovoltaica Nos Dias Seleccionados	61
Figura 13.	Geração Eólica Nos Dias Seleccionados	62
Figura 14.	Cargas nos Dias Seleccionados	62
Figura 15.	Relação de dominância entre as soluções mono-objetivo e a fronteira de Pareto das execuções multi-objetivo, classificadas como 'Domina', 'É dominado' e 'Fronteira'	66
Figura 16.	Comparação da evolução dos cenários de custo operacional médio (destacando os desvios padrão em verde):	72
Figura 17.	Tempo de Execução das abordagens com e sem os custos de O&M dos DNDs.	73
Figura 18.	Dispersão da metodologia da literatura (Equação 4.7) para uma única fonte geradora poluente.	74
Figura 19.	Dispersão da metodologia proposta (Equação 4.8) para uma única fonte geradora poluente.	75
Figura 20.	Dispersão da metodologia da literatura e proposta para uma única fonte geradoras poluentes.	76
Figura 21.	Dispersão da metodologia da literatura (Equação 4.7) para múltiplas fontes geradoras poluentes.	77
Figura 22.	Dispersão da metodologia proposta (Equação 4.8) para múltiplas fontes geradoras poluentes.	78
Figura 23.	Dispersão da metodologia da literatura e proposta para múltiplas fontes geradoras poluentes.	79
Figura 24.	Relação entre as soluções mono-objetivo e a fronteira de Pareto na abordagem com um único gerador poluente.	80

Figura 25. Relação entre as soluções mono-objetivo e a fronteira de Pareto na abordagem com múltiplos geradores poluentes.	81
Figura 26. Fluxograma do Funcionamento da Carga e Descarga das Baterias . . .	101

Lista de tabelas

Tabela 1.	Configuração das MGs Testadas	60
Tabela 2.	Custos de O&M e fatores de emissão.	63
Tabela 3.	Parâmetros dos Algoritmos de Otimização.	64
Tabela 4.	Resultados do <i>p-value</i> para o Teste <i>t-student</i>	70
Tabela 5.	Estatísticas <i>t</i> calculadas para cada teste com $df = 49$	71

Lista de abreviaturas e siglas

DD	Dispositivo Despachável
DND	Dispositivo Não Despachável
GA	Genetic Algorithm
IA	Inteligência Artificial
NSGA-II	Non-dominated Sorting Genetic Algorithm II
O&M	Operation and Maintenance
PSO	Particle Swarm Optimization
SGI	Sistema de Gerenciamento Inteligente
MG	Microgrid
MPC	Model Predictive Control
C_{total}	Custo total da operação da MG
$C_{fuel}(P)$	Custo de combustível
$C_{O\&M}(P)$	Custo de operação e manutenção
E_{total}	Emissões totais de CO ₂ da MG
$E_{fuel}(P)$	Emissões de CO ₂
t	Instante de tempo dentro do horizonte de planejamento
W	Janela de tempo analisada (período total de planejamento)
P	Potência fornecida por um dispositivo
P_{load}	Potência total demandada pela MG.
V_{MG}	Nível de tensão da MG
SoC	Estado de carga dos dispositivos de armazenamento da MG
α	Coefficiente de custo
β	Coefficiente de emissões

Sumário

1	INTRODUÇÃO	16
1.1	Motivação	18
1.2	Objetivos	18
1.3	Contribuições	19
1.4	Estrutura da Tese	20
2	REVISÃO DA LITERATURA	21
2.1	Revisões da Literatura	21
2.2	Função Objetivo Somente com Custos	21
2.2.1	Microrredes Isoladas	21
2.2.2	Microrredes Conectadas	23
2.3	Outros Objetivos na Função Objetivo	26
2.4	Funções Objetivo com Custo e Emissões	28
2.4.1	Microrrede Conectada	28
2.4.2	Microrrede com Múltiplas Fontes Geradoras Poluente	28
2.4.3	Microrrede com uma Única Fonte Geradora Poluente	30
2.5	Avaliação das Pesquisas Existentes	30
2.6	Considerações Finais	32
3	REFERENCIAL TEÓRICO	33
3.1	Microrredes	33
3.1.1	Características Gerais das Microrredes	33
3.1.2	Gerenciamento de Microrredes e o Uso de Inteligência Artificial	36
3.1.3	Tipos de Microrredes	37
3.1.3.1	Modo de Operação: Isolado e Conectado	37
3.1.3.2	Gerenciamento Distribuído e Centralizado	38
3.2	Model Predictive Control	40
3.2.1	Funcionamento do MPC	41
3.2.2	Desvantagens do MPC	43
3.3	Otimização Matemática	44
3.3.1	Dominância de Pareto	47
3.4	Algoritmos de Otimização e Microrredes	47
3.5	Algoritmos de Otimização	50
3.5.1	Algoritmos Genéticos	50
3.5.2	<i>Non-dominated Sorting Genetic Algorithm-II</i>	52
3.6	Considerações Finais	52

4	METODOLOGIA	55
4.1	Formulação Matemática	55
4.2	Formulação Matemática Proposta	57
4.2.1	Analisando a Influência da Inclusão dos Custos de O&M	57
4.2.2	Analisando a Relação Entre os Custos e Emissões	58
4.3	Metodologia de Testes e Validações	59
4.3.1	Microrredes de Teste	59
4.3.2	Algoritmos de Otimização	63
4.3.3	Análise dos Resultados	64
4.3.4	Análise entre as Metodologias Mono-objetivo e Multi-objetivos	66
4.4	Considerações Finais	67
5	RESULTADO E DISCUSSÃO	69
5.1	Análise do Número de Operações das Formulações	69
5.2	Avaliação do Impacto dos Custos de O&M dos Dispositivos Não- Despacháveis na Otimização	70
5.3	Análise Comparativa das Metodologias Proposta e da Literatura	74
5.3.1	Microrrede com uma única fonte geradora poluente	74
5.3.2	Microrrede com múltiplas fontes geradoras poluentes	76
5.4	Análise relação Mono-objetivo e Multi-objetivo	79
5.5	Discussão dos resultados	81
5.5.1	Custos de O&M dos Dispositivos Não-Despacháveis	81
5.5.2	Comparação das Modelagem Multi-objetivos	82
5.5.3	Comparação Entre as Abordagens Mono-objetivo e Multi-objetivo	83
6	CONCLUSÃO	85
6.1	Proposta de Trabalhos Futuros	85
6.2	Artigo Publicado	86
	REFERÊNCIAS	87
	APÊNDICES	95
	APÊNDICE A – PARALELIZAÇÃO DOS ALGORITMOS DE OTI- MIZAÇÃO E DE FLUXO DE CARGA	96
A.1	Algoritmos de Otimização e Fluxo de Carga	96
A.2	Relação Entre as Bibliotecas Utilizadas	97

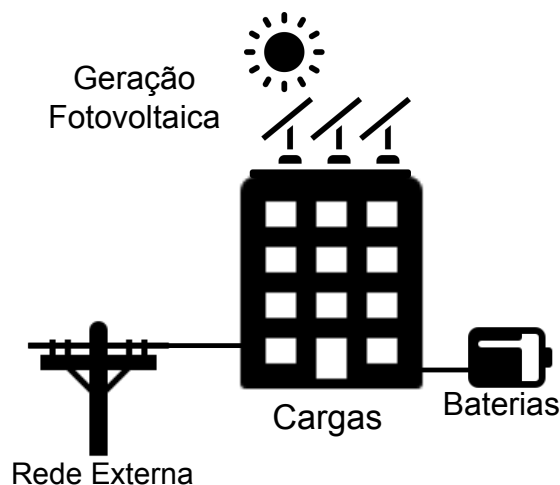
APÊNDICE B – PROCEESO DE CARGA E DESCARGA DAS BA- TERIAS	100
---	------------

1 Introdução

A energia constitui um elemento fundamental para o desenvolvimento econômico de uma nação, tornando a otimização de seus recursos uma prioridade crescente. Estudos recentes investigam o potencial das microrredes (MG do inglês *MicroGrid*) como soluções descentralizadas e sustentáveis, capazes de integrar fontes renováveis de energia, como solar e eólica, associadas a sistemas de armazenamento, para atender a uma ampla gama de aplicações, desde residências individuais até comunidades inteiras (AGüERA-PÉREZ et al., 2018; VERA; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2019).

Uma MG é um sistema elétrico local composto por um grupo de cargas e fontes de geração, geralmente baseado em fontes renováveis, que operam de forma integrada em uma rede separada e podem funcionar conectadas ou isoladas da rede principal, oferecendo uma infraestrutura flexível, confiável e resiliente. (AGüERA-PÉREZ et al., 2018; VERA; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2019; FARHANGI; JOÓS, 2019). Essas redes são empregadas para fornecer energia a um único edifício, a um complexo de edificações (como hospitais, bases militares ou universidades) ou, ainda, a bairros inteiros e pequenas cidades (ZHANG et al., 2021). Um exemplo de MG é apresentado na Figura 1, na qual se observa, em um mesmo local, a carga elétrica do sistema, representada por um edifício, um sistema de armazenamento de energia e um sistema de geração fotovoltaica instalado no topo da edificação (ZUBARAN, 2018).

Figura 1. Exemplo de MG



Fonte: Produzido Pelo Autor

As MGs possuem a capacidade de operar conectadas aos Sistemas Elétricos de

Potência convencionais, possibilitando a comercialização de energia com as concessionárias. Além disso, podem funcionar de forma autônoma ao se desconectarem desses sistemas, o que ocorre, por exemplo, em situações de interrupção no fornecimento de energia pelos sistemas tradicionais ou em locais remotos sem acesso à rede elétrica, como determinadas áreas rurais ou bases militares (AGÜERA-PÉREZ et al., 2018; CAO et al., 2021). A implementação de MGs é de fundamental importância em áreas isoladas. A integração de tecnologias inteligentes e fontes renováveis assegura o fornecimento de energia e aprimora a resiliência desses sistemas. Entre as principais vantagens das MGs destacam-se a redução de custos operacionais, a melhoria na qualidade da energia e a diminuição das emissões de gases poluentes (CO_2 , SO_2 , NO_x). Esses benefícios são fundamentais para o aprimoramento da eficiência e da sustentabilidade dos sistemas energéticos (KAVITHA et al., 2021).

O gerenciamento é um dos desafios centrais na implementação de uma MG, pois busca determinar quais geradores de energia devem ser ativados em cada intervalo de tempo. Este gerenciamento pode ser realizado por sistemas inteligentes que otimizam o uso da energia elétrica, maximizam a integração de fontes renováveis, minimizam a emissão de poluentes e reduzem os custos operacionais. Esse gerenciamento configura um problema de otimização conhecido como *Scheduling Problem*, cujo objetivo é definir o funcionamento e o fluxo de potência de cada componente da MG ao longo do tempo (RAGHAV et al., 2021).

Uma das abordagens empregadas nesse contexto é o uso de Sistemas Multiagentes, compostos por múltiplos agentes inteligentes que interagem para solucionar problemas complexos. Esses agentes podem operar de forma autônoma ou colaborativa, visando alcançar objetivos comuns (WOOLDRIDGE, 2009; KARAVAS et al., 2015; ANVARI-MOGHADDAM et al., 2017; BOUDOUDOUH; MAÂROUFI, 2018). Embora o uso de sistemas multiagentes para o gerenciamento de MGs tenha avançado nos últimos anos, essa abordagem ainda se encontra em estágio inicial, demandando pesquisas adicionais para a obtenção de resultados mais robustos e eficazes.

O gerenciamento eficiente das MGs é amplamente realizado por meio do *Model Predictive Control* (MPC), também denominado *Rolling Time Horizon* (RTH) ou *Receding Horizon Control* (RHC). Essa abordagem integra algoritmos de previsão e otimização para elaborar um cronograma operacional otimizado (LEONORI et al., 2020a). No contexto da previsão, modelos como SARIMA (*Seasonal AutoRegressive Integrated Moving Average*) e LSTM (*Long Short-Term Memory*) são comumente utilizados para estimar a demanda e a geração de energia em janelas temporais futuras. Com base nessas estimativas, algoritmos de otimização determinam a estratégia operacional mais eficiente, garantindo um desempenho otimizado da MG (HU et al., 2021).

A definição dos geradores que devem ser ativados em cada intervalo de tempo constitui um dos principais desafios do gerenciamento de MGs. Esse processo visa minimizar

os custos operacionais, reduzir as emissões de poluentes e garantir o atendimento da demanda (RAGHAV et al., 2021). Para esse fim, diversos algoritmos de otimização são empregados no MPC, incluindo GA (*Genetic Algorithm*), NSGA-II (*Nondominated Sorting Genetic Algorithm - II*) e DE (*Differential Evolution*), entre outros. Esses algoritmos desempenham um papel fundamental no equilíbrio entre múltiplos objetivos, assegurando a eficiência e a confiabilidade do sistema energético (ZUBARAN, 2018; LEONORI et al., 2020a). No entanto, a eficácia dos algoritmos de otimização empregados no MPC depende diretamente da formulação adequada da função objetivo, tornando essencial o desenvolvimento contínuo de novos modelos para aprimorar o processo de tomada de decisão (TALBI, 2009; KAVITHA et al., 2021).

1.1 Motivação

O desempenho de algoritmos de otimização aplicados ao gerenciamento de Microrredes (MGs) depende fortemente da qualidade da formulação matemática utilizada, em especial da definição da função objetivo. Uma formulação inadequada pode comprometer significativamente os resultados, levando a soluções subótimas que não refletem o real potencial do sistema. Além disso, pode resultar em desperdício de recursos computacionais — um aspecto particularmente crítico em aplicações embarcadas, onde os sistemas de gerenciamento frequentemente operam com capacidade de processamento e memória limitadas (LEONORI et al., 2020a).

Para garantir que as soluções obtidas sejam tecnicamente viáveis, economicamente vantajosas e ambientalmente sustentáveis, é fundamental que a função objetivo seja formulada de maneira rigorosa e precisa. Isso inclui representar adequadamente as interações complexas entre os diversos componentes das MGs isoladas, como geradores, cargas e dispositivos de armazenamento.

A busca por uma modelagem eficiente não se limita à obtenção de melhores soluções, mas também visa maximizar o uso dos recursos computacionais disponíveis. Essa abordagem é crucial para viabilizar a implementação de estratégias avançadas de otimização em sistemas reais, promovendo um gerenciamento de energia mais eficaz, robusto e adaptado às necessidades específicas das MGs isoladas.

1.2 Objetivos

- **Objetivo Geral:** Investigar a relação entre custos operacionais e emissões de gases poluentes na formulação matemática dos algoritmos de otimização em MGs isoladas.
- **Objetivos Específicos:**

- Realizar uma revisão bibliográfica abrangente para identificar as principais metodologias e abordagens empregadas no gerenciamento ótimo de MGs isoladas;
- Simplificar os modelos matemáticos existentes, com o intuito de aprimorar a precisão e a eficácia dos resultados obtidos e garantir soluções mais precisas e computacionalmente eficientes;
- Analisar e comparar a formulação matemática da literatura com a formulação matemática proposta, destacando suas vantagens e limitações;
- Implementar e avaliar a metodologia proposta em quatro MGs distintas, considerando suas particularidades operacionais;
- Realizar testes da metodologia proposta em cenários anuais, a fim de verificar sua robustez e adaptabilidade a diferentes condições de operação;

1.3 Contribuições

Esta tese investiga a relação entre custos operacionais e emissões de gases poluentes em MGs isoladas, analisando a adequação das metodologias de otimização multiobjetivo nesse contexto. O estudo propõe ajustes na formulação matemática dos algoritmos de otimização, visando garantir soluções mais precisas e computacionalmente eficientes, sem comprometer a qualidade dos resultados.

Em particular, a pesquisa avalia a necessidade da abordagem multiobjetivo para esses sistemas, considerando a hipótese de que, em MGs com um único gerador poluente, a relação entre custo e emissões pode ser diretamente proporcional. Assim, investiga-se se a formulação tradicional baseada em Pareto permanece válida ou se ajustes são necessários para evitar redundâncias ou ineficiências no processo de otimização.

Além disso, a tese analisa a inclusão dos custos de O&M dos DNDs na função objetivo, considerando que esses custos permanecem amplamente invariáveis ao longo do processo de otimização. A hipótese avaliada é que tais custos podem ser tratados separadamente após a otimização, sem comprometer a qualidade da solução obtida, reduzindo assim a complexidade computacional do problema.

Por fim, os resultados obtidos poderão aprimorar as formulações matemáticas existentes e contribuir para a definição de estratégias de otimização mais realistas e eficientes para MGs isoladas. Além disso, a abordagem proposta pode servir como base para futuras pesquisas que explorem a relação entre custos, emissões e custos de O&M em diferentes configurações de MGs, bem como a inclusão de outros objetivos, como a confiabilidade do sistema e eficiência energética. Dessa forma, este estudo busca não apenas fornecer um modelo matemático mais adequado para o problema em questão, mas também abrir caminho para novas investigações no campo da otimização de MGs.

1.4 Estrutura da Tese

Esta tese está organizada da seguinte forma:

- **Capítulo 2:** Sintetiza os principais trabalhos da literatura sobre otimização e MGs;
- **Capítulo 3:** Apresenta uma descrição do funcionamento das MGs, da abordagem de gerenciamento centralizada baseada no MPC e uma visão sobre os algoritmos de otimização empregados no MPC, incluindo a análise dos algoritmos que serão adotados nesta pesquisa;
- **Capítulo 4:** Expõe a metodologia utilizada, abordando a modelagem matemática disponível na literatura e a formulação matemática proposta, desenvolvida para MGs isoladas com dois objetivos. Além disso, descreve os procedimentos adotados para a condução dos testes e validação da nova formulação;
- **Capítulo 5:** Apresenta os resultados obtidos e a respectiva análise crítica;
- **Capítulo 6:** Sintetiza as conclusões do estudo e discute possíveis direções para trabalhos futuros;
- **Apêndice:** Detalhes sobre o desenvolvimento da metodologia proposta, como a implementação dos algoritmos de fluxo de carga e a paralelização dos algoritmos de otimização.

2 Revisão da Literatura

Diversos estudos na literatura têm-se dedicado ao problema de gerenciamento de MGs, propondo algoritmos de otimização com diferentes formulações matemáticas, adaptadas às características e desafios específicos de cada aplicação. Os principais objetivos dessas pesquisas incluem a redução dos custos operacionais, a minimização das emissões de gases poluentes e a garantia da confiabilidade e eficiência no fornecimento de energia.

Nesta revisão, foram selecionados artigos publicados entre 2015 e 2025 que abordam o gerenciamento inteligente de MGs, com ênfase na metodologia empregada e na formulação matemática adotada.

2.1 Revisões da Literatura

Algumas revisões destacam o papel predominante da otimização multiobjetivo no gerenciamento de MGs. O estudo de Thirunavukkarasu et al. (2022) identifica o *Particle Swarm Optimization* (PSO) e o GA como as técnicas mais amplamente adotadas nessa área. Expandindo essa análise, Arunkumar et al. (2022) observa que os custos e emissões são os objetivos de otimização mais comuns nos estudos sobre MGs. Além disso, Akter et al. (2024) sugere que pesquisas futuras devem aprimorar as abordagens de otimização, incorporando um foco mais abrangente nos benefícios econômicos, sociais e ambientais, aumentando assim a aplicabilidade e o impacto das soluções propostas.

2.2 Função Objetivo Somente com Custos

2.2.1 Microrredes Isoladas

Alguns estudos focam exclusivamente na minimização dos custos operacionais de MGs isoladas.

Em Fossati et al. (2015) foi proposta uma abordagem que utiliza um sistema *fuzzy* para realizar o gerenciamento da MG, empregando dois GAs para definir os parâmetros do sistema. Um GA foi utilizado para gerar as regras *fuzzy*, enquanto o outro foi empregado para definir as funções de pertinência. O objetivo da abordagem foi minimizar o custo operacional da MG, tanto para um sistema isolado quanto para um conectado à rede, considerando exclusivamente os custos de Operação e Manutenção (O&M) dos Dispositivos Despacháveis (DD) da MG. Para validar o método, os autores o compararam com duas abordagens distintas. A primeira, denominada caso base, adota uma estratégia simples de carga e descarga das baterias. No segundo método, as baterias são controladas por

um sistema *fuzzy* com regras e funções de pertinência previamente definidas por um especialista. Os testes foram realizados em ambos os modos de operação — conectado à rede e isolado — com o objetivo de reduzir o custo operacional. Em ambas as configurações, o algoritmo proposto apresentou um desempenho superior às demais abordagens, com melhorias de aproximadamente 3,34% no modo isolado e 1,43% no modo conectado à rede.

Em Zhao et al. (2018), os autores utilizaram uma metodologia de gerenciamento em duas etapas para uma MG AC/DC operando no modo ilhado, com o objetivo de minimizar o custo operacional diário no pior cenário, considerando os custos de O&M das fontes de energia renovável. O gerenciamento foi modelado como um problema *min-max-min*, utilizando o método *Column-and-Constraint Generation* (C&CG). Esse método consiste em dividir o problema em dois *Mixed Integer Linear Program* (MILP), sendo um principal e outro secundário. Para resolver o MILP, os autores utilizaram o algoritmo *Simplex*. Um aspecto importante deste trabalho foi a comparação entre o C&CG e a decomposição de Benders, na qual verificaram que o C&CG apresentou um desempenho superior em termos de velocidade. Em seguida, foi realizada uma análise de sensibilidade com o C&CG em uma MG real, localizada no distrito de Shangyu, na província de Zhejiang, China. Os testes apresentaram bons resultados; no entanto, segundo os próprios autores, as variações na geração das energias renováveis e nas cargas podem afetar diretamente os resultados obtidos.

No trabalho de Li et al. (2018), foram comparadas duas abordagens do MPC para o gerenciamento de múltiplas MGs. Na primeira abordagem, a gestão foi realizada por meio de um GA para otimizar o gerenciamento, visando minimizar o custo operacional, incluindo os custos de O&M dos geradores renováveis, ao longo de um dia inteiro. Na segunda abordagem, a janela de previsão manteve-se em 24 horas; entretanto, a janela de controle — que determina a frequência de execução do algoritmo de gerenciamento — foi definida em 5 minutos, resultando em um total de 288 execuções do algoritmo de otimização ao longo do dia. Os resultados mostraram que essa segunda abordagem proporcionou uma redução de custos de 21,46% em comparação com a primeira.

No trabalho de Garcia-Torres, Bordons e Ridao (2019), os autores desenvolveram uma metodologia de gerenciamento para uma rede de MGs, utilizando uma versão distribuída do MPC. Nesse modelo, diversas MGs enviam informações para uma central, onde os dados são processados, e o planejamento para um período de 24 horas é retornado para cada MG, com o objetivo de minimizar o custo operacional. Os resultados demonstraram que a cooperação entre as MGs proporcionou desempenhos similares e, em alguns casos, até superiores em comparação com as MGs operando com gerenciamento local, conforme apresentado em Garcia-Torres e Bordons (2015).

Em Xing, Xie e Meng (2019), foi desenvolvido um MPC distribuído para o gerenciamento de um conjunto de MGs conectadas à rede, utilizando uma soma ponderada

dos objetivos. Cada MG possui seu próprio MPC, que realiza o processo de otimização localmente, empregando o DLBM (*Distributed Logarithmic-Barrier Method*) como algoritmo de otimização distribuído. Nesse modelo, as MGs compartilham informações entre si, permitindo um ajuste dinâmico das decisões de operação. O objetivo de cada MPC local é minimizar o custo operacional com base nos dados extraídos localmente e nas informações das demais MGs interconectadas. Os resultados indicaram que a abordagem distribuída apresentou um desempenho ligeiramente inferior ao da abordagem centralizada, na qual todas as informações das MGs são enviadas para um único local para processamento e tomada de decisão.

Em Kavitha et al. (2021), foi proposto um algoritmo baseado no comportamento da planta *Mimosa pudica* para o gerenciamento de MG. Os testes foram realizados em uma MG operando tanto no modo ilhado quanto no modo conectado à rede externa, utilizando uma janela de previsão de 24 horas e visando minimizar o custo. O algoritmo foi comparado com o RCGA (*Real Coded Genetic Algorithm*) e com uma abordagem híbrida entre GA e PSO. Os resultados demonstraram que o algoritmo proposto obteve o melhor desempenho. Além disso, os autores compararam o tempo de execução e o custo obtido com outros dois algoritmos presentes na literatura (SHI et al., 2015; VELUCHAMY; VELUCHAMY, 2021), evidenciando que a abordagem proposta reduziu o custo operacional em relação às demais.

A referência (SHEZAN et al., 2023) explora diversas técnicas de otimização, como GA, PSO e ACO (Ant Colony Optimization) para determinar o número ideal de módulos geradores de energia em um sistema híbrido de energia renovável em Pulau Perhentian, Malásia. A função objetivo busca minimizar o custo, incorporando o NPC (*Net Present Cost*) e o LCOE (*Levelized Cost of Energy*), garantindo a estabilidade e a eficiência do sistema.

Já Ibrahim et al. (2023) apresenta uma abordagem estocástica, baseada no algoritmo de otimização por busca transitória para o gerenciamento energético de MGs híbridas isoladas. A função objetivo é formulada para minimizar os custos operacionais, incorporando diversos componentes, como unidades geradoras a diesel, sistemas fotovoltaicos e armazenamento de energia em baterias. Nesses estudos, os custos operacionais incluem os custos de O&M dos DNDs.

2.2.2 Microrredes Conectadas

Outros trabalhos minimizam o custo operacional em MGs conectadas.

Em Choobineh e Mohagheghi (2016), os autores utilizam o ELGP (*Extended Lexicographic Goal Programming*) para encontrar o melhor plano de gerenciamento para uma MG industrial conectada à rede, mais precisamente uma planta de fabricação para

a linha de montagem de cabines de veículos de luxo. O objetivo foi minimizar o custo operacional, sem considerar custos de O&M, reduzir a emissão de gases poluentes e maximizar a vida útil do transformador. Foi utilizado um horizonte de 1 hora. O algoritmo proposto no artigo apresentou melhorias significativas para o caso de estudo industrial analisado.

No artigo de Leonori et al. (2020b), foi implementado um GA-FIS (*Genetic Algorithm-Fuzzy Inference System*) para resolver o problema do gerenciamento ótimo de MGs, com o objetivo de minimizar os custos operacionais. Além de apresentar detalhes da implementação, a metodologia proposta foi comparada com os resultados ótimos e com a abordagem baseada em RTH, na qual um GA foi empregado como algoritmo de otimização. É importante destacar que a metodologia proposta não se baseia no RTH, mas sim em um sistema *fuzzy*, no qual as regras são otimizadas por meio de um GA. Os resultados indicaram que o GA-FIS obteve um desempenho satisfatório, correspondendo a 90% do desempenho do método ótimo. Quando comparado com o RTH, apresentou resultados ligeiramente inferiores, porém foi mais rápido, uma vez que não exige o uso de algoritmos de previsão no processo de gerenciamento.

Em Cao et al. (2021), foi proposto um algoritmo de gerenciamento em três níveis para MGs comunitárias conectadas à rede externa. No primeiro nível (inferior), cada MG minimiza seu custo operacional usando o Simplex. No segundo (superior), o Simplex é aplicado para otimizar o custo de todas as MGs conectadas. No terceiro (intermediário), o EMOHT (*Evolutionary Many-objective Optimization based on Hyperplane Transformation*) é empregado para otimizar a alocação de recursos, tratando cada MG como uma função objetivo. Os testes, realizados com seis MGs para 20 cenários distintos, usaram uma janela de previsão de 24 horas e uma de controle de 1 hora. A metodologia foi comparada com as estratégias de gerenciamento de MGs de Wang et al. (2018) e Bui, Hussain e Kim (2016), além da operação individual das MGs, mostrando-se superior. O EMOHT também foi avaliado contra o MOEA/D (*Multi-objective Evolutionary Algorithm based on Decomposition*), NSGA-II e NSGA-III, demonstrando melhor desempenho e maior rapidez. Os resultados comparativos consideraram os melhores valores obtidos nas 20 execuções, e não a média.

Em Logeswaran et al. (2021) foi utilizado o algoritmo CGO (*Chaos Game Optimization*) como algoritmo de otimização e o SBLA (*Side-Blotched Lizard Algorithm*) foi responsável por fazer as previsões da geração e da demanda energética para uma MG conectada. Utilizando uma janela de previsão de 24 horas, os testes foram realizados visando minimizar o custo operacional (incluindo o O&M e o custo de reposição de sistemas renováveis) e o custo do ciclo de vida anual de todo o sistema. O algoritmo proposto foi comparado com outros 3 algoritmos de otimização. O CGO se saiu melhor em todos os resultados apresentados. Além disso, observou-se que, no artigo, houve uma diminuição

das emissões de CO_2 ao minimizar os custos de energia.

Em Raghav et al. (2021) foi utilizado o QTLBO (*Quantum Teaching Learning-based Optimization*) no gerenciamento de uma MG conectada, comparando-o com outros três algoritmos, visando minimizar os custos da MG. Os testes foram realizados em quatro dias diferentes, um para cada estação do ano. Para cada cenário, foram realizadas 30 execuções, extraindo-se as médias e os desvios padrão. Os resultados mostraram que o algoritmo proposto obteve melhor desempenho em comparação com os demais testados, além de convergir mais rapidamente.

Em Ferahtia et al. (2022), foi utilizado o BES (*Bald Eagle Search*) no gerenciamento de uma MG conectada. O algoritmo foi comparado com cinco métodos de otimização. O objetivo foi exclusivamente minimizar o custo operacional. Para cada algoritmo, foram realizadas 10 execuções, sendo extraídas as médias e os desvios padrão dos resultados. Os testes demonstraram que o BES apresentou desempenho superior aos demais algoritmos avaliados. Um aspecto relevante do estudo foi a aplicação da ANOVA (*Analysis of Variance*), uma análise estatística utilizada para comparar a variância dos resultados dos algoritmos testados. Os resultados indicaram que nenhuma das abordagens apresentou grandes variações nos desempenhos obtidos, evidenciando a robustez das metodologias propostas.

O artigo de Fathy et al. (2022) apresentou uma abordagem similar à de Ferahtia et al. (2022), porém aplicada a uma MG DC. Neste trabalho, foi utilizado um sistema de inferência *Fuzzy* do tipo Mamdani para o gerenciamento, no qual as funções de pertinência foram aprimoradas por meio de algoritmos de otimização. No total, oito algoritmos foram comparados, e os resultados indicaram que o algoritmo PO obteve o melhor desempenho em todos os cenários.

Em Guo et al. (2022), foi utilizado um algoritmo baseado em aprendizado por reforço para o gerenciamento de uma MG conectada, o PPO (*Proximal Policy Optimization*). O método opera em duas etapas: primeiro, o algoritmo é treinado com uma base de dados (no artigo, foram utilizados 100 dias); em seguida, é realizada a fase de teste, na qual o desempenho do PPO foi comparado com três outros algoritmos de gerenciamento. Os dois primeiros são baseados em aprendizado por reforço, enquanto o último utiliza MPC. Os testes indicaram que o PPO apresentou o menor custo operacional. Além disso, foi realizada uma análise de sensibilidade comparando o PPO com uma abordagem baseada em MPC diante de erros no algoritmo de previsão. Os resultados foram avaliados para erros de 10%, 15% e 20%, e a metodologia proposta demonstrou melhor desempenho em relação ao MPC.

Suresh et al. (2023) apresenta um *framework* de otimização utilizando diversos algoritmos meta-heurísticos, incluindo GA, PSO e MIDACO (*Mixed Integer Distributed Ant Colony Optimization*), para um gerenciamento eficiente da energia em uma MG conectada. Foram realizados testes em 3 cenários, com 100 execuções cada. Os principais

objetivos são minimizar os custos operacionais (utilizando o LCOE), melhorar a alocação de recursos e garantir um fornecimento de energia confiável, integrando fontes renováveis.

O trabalho de (MAJEED et al., 2023) introduz um sistema de gerenciamento energético para MGs conectadas à rede, empregando o IAGA (*Improved Adaptive Genetic Algorithm*) para otimização. A MG integra diversas fontes renováveis, especificamente sistemas eólicos e fotovoltaicos, juntamente com um gerador a diesel como única fonte poluente de backup. Os principais objetivos incluem otimizar a alocação de recursos, reduzir custos operacionais e aumentar a eficiência energética diante da variação da demanda. O IAGA melhora a adaptabilidade e eficiência em relação aos métodos tradicionais, demonstrando aplicabilidade prática para o gerenciamento sustentável de energia. Esses estudos consideram os custos e as emissões das fontes geradoras poluentes como objetivos conflitantes em MGs com múltiplos geradores poluentes, enfatizando a importância do equilíbrio entre viabilidade econômica e sustentabilidade ambiental.

Wu et al. (2024) propõe o IGOA (Improved Gazelle Optimization Algorithm) para a otimização operacional de um sistema de MG, incorporando tanto equipamentos *Power-to-Gas* quanto sistemas híbridos de armazenamento de energia. A MG opera no modo conectado, visando minimizar custos operacionais (considerando o custo de O&M de geradores renováveis) e emissões de carbono, mantendo um equilíbrio entre eletricidade e hidrogênio e reduzindo o custo e as emissões da MG em 6,54% e 33,56%, respectivamente.

Além disso, a referência (WANG et al., 2024) propõe um algoritmo de otimização avançado para o gerenciamento energético de MGs, integrando uma rede neural difusa híbrida ao MPSO (Modified Particle Swarm Optimization). A MG busca minimizar os custos de geração e maximizar a eficiência do consumo de energia. O sistema utiliza múltiplas fontes renováveis e um sistema de armazenamento de energia, juntamente com uma microturbina, para garantir confiabilidade e equilíbrio durante períodos de alta demanda. A abordagem proposta demonstra desempenho superior em termos de custo-benefício e economia de energia em comparação com métodos tradicionais.

2.3 Outros Objetivos na Função Objetivo

Alguns artigos abordaram a otimização com foco em objetivos menos explorados na literatura.

Venayagamoorthy et al. (2016) desenvolveram o I-DEMS (*Intelligent Dynamic Energy Management System*), um algoritmo híbrido entre programação dinâmica e aprendizado por reforço, que utiliza duas redes neurais para o gerenciamento ótimo de MGs conectadas. Os objetivos da otimização são minimizar o consumo de energia vinda da rede externa e maximizar a vida útil das baterias. Os testes foram conduzidos com uma janela de controle de 1 minuto, utilizando o período de 24 horas para o treinamento do algoritmo

e as 24 horas consecutivas para a avaliação do modelo implementado. O algoritmo proposto foi comparado com uma versão anterior da metodologia utilizada, que empregava árvores de decisão. Os testes foram realizados variando o estado inicial das baterias para 35%, 60% e 90%. Os resultados mostraram uma melhoria do I-DEMS em comparação com sua versão baseada em árvores de decisão.

Em Li et al. (2019), foi proposta uma melhoria no GSOMP (*Group Search Optimizer with Multiple Producers*), adicionando sequências caóticas ao algoritmo, criando assim o CGSOMP (*Chaotic Group Search Optimizer with Multiple Producers*). Após a obtenção da fronteira de Pareto, um Sistema *Fuzzy* foi utilizado para realizar a tomada de decisão. Os objetivos do gerenciamento incluem: minimizar os custos de compra e de geração de energia elétrica; minimizar o desvio de tensão; e minimizar os índices de estabilidade de tensão na MG. As simulações foram realizadas na rede IEEE de 112 barras modificada. Os testes foram conduzidos em 4 cenários distintos, com 50 execuções para cada cenário. A comparação foi realizada apenas com o GSOMP, e os resultados mostraram que as modificações realizadas geraram um desempenho superior em relação à versão original do algoritmo.

No trabalho de Leonori et al. (2020a), foram comparados seis algoritmos de otimização para o gerenciamento inteligente de MGs, sendo que cinco deles não foram baseados no MPC. O objetivo do estudo foi comparar os resultados de abordagens baseadas em aprendizado de máquina, destacando sua menor complexidade computacional em relação ao MPC tradicional. Os testes foram realizados em três cenários distintos: no primeiro, os algoritmos buscavam maximizar os lucros; no segundo, o foco era minimizar o estresse da rede; e no terceiro, a otimização combinava os objetivos dos dois cenários anteriores. Para essas análises, foi utilizada uma janela de previsão de 10 dias. Os resultados demonstraram que a metodologia baseada no RTH obteve o melhor desempenho em todos os cenários, seguida pelo ANFIS.

A referência (ELKHOLY et al., 2024) apresenta um Sistema de Gestão de Energia Residencial baseado em IA adaptativa, utilizando o AVOA (*African Vultures Optimization Algorithm*). O estudo foca em sistemas isolados, buscando minimizar custos, excedentes de energia e a Probabilidade de Perda no Suprimento de Energia, além de incorporar os custos de O&M dos DNDs. A MG integra fontes de energia renovável juntamente com fontes de backup, e o estudo formula um problema de otimização multiobjetivo para coordenar a operação desses geradores de reserva.

2.4 Funções Objetivo com Custo e Emissões

2.4.1 Microrrede Conectada

Poucos estudos se propuseram a investigar a minimização de custos e emissões em sistemas conectados à rede externa.

No trabalho de Roslan et al. (2021), foi utilizado o LSA (*Lightning Search Algorithm*) para otimizar o gerenciamento de um conjunto de MGs conectadas a uma central, minimizando o custo operacional. O algoritmo foi comparado com o BSA (*Back-tracking Search Algorithm*) no sistema IEEE de 14 barras modificado, utilizando uma janela de previsão de 24 horas. Os resultados mostraram que o LSA foi melhor que o BSA em todos os cenários, apresentando uma melhora de 62,5% com relação ao custo e de 61,98% com relação à emissão de CO_2 . Além disso, os autores também mostraram que a redução dos custos também implica na redução da emissão de CO_2 .

A referência (TAABODI et al., 2025) apresenta o IMOCSA (*Improved Multi-Objective Crow Search Algorithm*), projetado para otimizar o desempenho de MGs rurais, que podem operar tanto de forma isolada quanto interconectada. A otimização visa três objetivos principais: minimizar os custos operacionais, reduzir a variação de tensão para garantir a qualidade da energia e diminuir as emissões poluentes provenientes de múltiplas fontes de geração, incluindo microturbinas e células a combustível. O IMOCSA aprimora o Algoritmo Padrão de Busca dos Corvos ao incorporar um mecanismo adaptativo de probabilidade caótica, um operador de mutação para evitar a convergência prematura e um método de agrupamento K-means para aumentar a eficiência da busca.

2.4.2 Microrrede com Múltiplas Fontes Geradoras Poluente

Outros estudos abordaram a otimização de MGs com o objetivo de minimizar simultaneamente os custos e as emissões em sistemas com múltiplas fontes geradoras poluentes.

Aghajani, Shayanfar e Shayeghi (2015) utiliza o MOPSO (Multi-Objective Particle Swarm Optimization) como algoritmo de otimização, em conjunto com um sistema *fuzzy* para a tomada de decisão da solução com a melhor estratégia de gerenciamento. O estudo avaliou a metodologia proposta com e sem programas de demanda responsiva. Os testes foram realizados tanto em modo isolado quanto conectado à rede, utilizando a mesma modelagem matemática para ambos os casos. O objetivo foi minimizar a emissão de gases poluentes (CO_2 , SO_2 e NO_x) e o custo operacional, sem considerar custos associados à operação e manutenção (O&M). O trabalho considerou dois geradores poluentes, além das taxas de emissões relacionadas ao uso de baterias e à compra de energia da rede externa. Para validar a proposta, os autores compararam o desempenho do MOPSO+Fuzzy com o

NSGA-II, demonstrando que a abordagem apresentada obteve resultados superiores.

Em Nazari-Heris, Abapour e Mohammadi-Ivatloo (2017), foi utilizado o método ε -*constraint*, juntamente com um sistema *fuzzy*, para realizar o processo de otimização multiobjetivo, minimizando o custo operacional e a emissão de gases poluentes (CO_2 , NO_x e SO_2). Os autores realizaram três estudos de caso, considerando uma janela de 24 horas para uma MG operando no modo ilhado, utilizando *combined heat and power* (CHP) e células a combustível, no modo conectado à rede e, por fim, incluindo um programa de resposta à demanda. O terceiro caso apresentou os melhores resultados.

Em Maulik e Das (2018) foi examinada a operação de uma MG isolada com o objetivo de minimizar o custo operacional total e as emissões de carbono. Para isso, foi utilizado o *Fuzzy-PSO*, sendo comparado com o ϵ -MOGA (*Elitist Multi Objective Genetic Algorithm*). Os testes foram realizados numa rede de 33 barras em vários cenários. Neste artigo, vários fatores de emissões foram utilizados, o que cria um *trade-off* natural entre custo e emissões, preservando o conflito entre esses objetivos.

Em Maulik e Das (2019), foi proposta uma metodologia baseada no PSO juntamente com um sistema *fuzzy* para o gerenciamento das MGs, visando a diminuição dos custos operacionais e das emissões de CO_2 . Os testes foram executados em uma rede AC/DC de 6 barras. Para validar a proposta, foram realizadas comparações com o algoritmo genético multi-objetivo com elitismo controlado (DEB; GOEL, 2001). Os testes ocorreram em três cenários distintos: o primeiro focado em minimizar apenas os custos, o segundo em minimizar as emissões de CO_2 , e o terceiro com o objetivo de minimizar simultaneamente os custos e as emissões de CO_2 . Os resultados mostraram que a solução proposta se situaria dentro da fronteira de Pareto do método de otimização multiobjetivo.

Tan e Chen (2020) aborda o gerenciamento de multi-microrredes integradas a veículos elétricos, com o objetivo de minimizar custos, emissões e perdas elétricas. Inicialmente, a previsão das cargas dos veículos é realizada por meio de uma Rede Neural. Em seguida, um processo de otimização é aplicado para determinar as melhores soluções. Os resultados mostraram que o MOEA/D-AMM (*Multi-Objective Evolutionary Algorithm based on Decomposition-Adaptive Multi-Model*) obteve o melhor desempenho. Vale destacar que, embora o artigo associe coeficientes de emissão para turbinas a gás e células a combustível, os valores desses coeficientes não foram apresentados.

O trabalho de Elsakaan et al. (2020) investiga o gerenciamento de MGs, tanto isoladas quanto conectadas, utilizando o EMFO (*Enhanced Moth-Flame Optimization*) para a minimização dos custos operacionais, incluindo os custos de O&M de DNDs, além da consideração das emissões. Para lidar com múltiplos objetivos, o estudo adotou a abordagem de soma ponderada, na qual pesos específicos são atribuídos a cada objetivo dentro da formulação matemática. Os resultados mostraram que o EMFO apresentou um desempenho superior em comparação com outros três algoritmos testados.

A referência Aldosary (2024) apresenta o algoritmo FOFMO (Fractional Order Fish Migration Optimization), aplicado à minimização de custos e emissões em sistemas elétricos que integram fontes renováveis de energia e unidades a gás natural. O algoritmo é testado em um sistema IEEE 30-barras modificado. Foram considerados três cenários de teste: o primeiro inclui três unidades termelétricas, enquanto o segundo e o terceiro incorporam uma combinação de unidades termelétricas e a gás natural. As três unidades termelétricas e as três unidades a gás natural possuem fatores de emissão distintos, permitindo a aplicação de algoritmos de otimização multiobjetivo. Semelhante a Maulik e Das (2018), esse *trade-off* entre os objetivos permanece devido à variação dos fatores de emissão.

2.4.3 Microrrede com uma Única Fonte Geradora Poluente

Por fim, apenas dois estudos abordaram a otimização de custos e emissões em redes isoladas, considerando apenas uma fonte geradora poluente.

Sachs e Sawodny (2016) desenvolveram uma metodologia de otimização em dois estágios. No primeiro, o algoritmo de otimização baseado em *Dynamic Programming* discreta visa minimizar o custo operacional para um horizonte de 24 horas. No segundo estágio, o objetivo é minimizar o uso do gerador a diesel, com um horizonte de 10 minutos. A abordagem proposta pelos autores foi simulada em uma MG operando de forma isolada. Para a previsão da geração das energias renováveis e da carga, foi utilizado o SARIMA. Os resultados foram comparados com o estado da arte da época e com a solução ótima gerada considerando o conhecimento pleno do comportamento das cargas e da geração. Os testes demonstraram uma redução de 7% em relação ao estado da arte da época.

Labra-Cáceres et al. (2025) apresenta uma metodologia inovadora de otimização baseada no algoritmo JAYA para o gerenciamento energético de MGs CC, operando tanto em modo isolado quanto conectado à rede. Os principais objetivos incluem a minimização dos custos operacionais, das perdas de energia e das emissões de CO_2 , além da integração eficiente da geração fotovoltaica. O estudo demonstra o desempenho superior do algoritmo em comparação com métodos tradicionais, como PSO e GA. Destaca-se que este trabalho é único na literatura por abordar especificamente a otimização de MGs isoladas com uma única fonte geradora poluente e um único coeficiente de poluição, evidenciando sua contribuição para o avanço das soluções de gerenciamento energético sustentável.

2.5 Avaliação das Pesquisas Existentes

Os estudos analisados propuseram a otimização do gerenciamento de microrredes por meio de algoritmos de otimização. Esses trabalhos focaram na minimização dos custos operacionais e, em alguns casos, também na redução das emissões de gases de efeito estufa.

No entanto, a modelagem matemática apresentada contém imprecisões que comprometem a coerência da formulação.

Em todos os artigos abordados, os custos aparecem como o principal objetivo, tanto em sistemas isolados da rede elétrica (GARCIA-TORRES; BORDONS; RIDAO, 2019; SHEZAN et al., 2023; IBRAHIM et al., 2023) quanto em sistemas conectados (SURESH et al., 2023; MAJEED et al., 2023; WANG et al., 2015). Além disso, os custos também são otimizados indiretamente, como em (VENAYAGAMOORTHY et al., 2016).

Na maioria dos trabalhos, os custos de O&M dos DNDs são incluídos diretamente na formulação do problema. No entanto, essa inclusão não é justificável, pois tais custos permanecem amplamente invariáveis ao longo do tempo. Dispositivos como turbinas eólicas e painéis solares são considerados não despacháveis, uma vez que não há controle preciso sobre a quantidade de energia que fornecem.

Independentemente desse aspecto, é notório que a maioria dos artigos foca exclusivamente na minimização dos custos, sem considerar as emissões, mesmo quando há geradores poluentes no sistema, como em Ibrahim et al. (2023), Shezan et al. (2023) e Wang et al. (2024). Essa tendência também é observada em Akter et al. (2024), onde grande parte dos trabalhos revisados não aborda explicitamente as emissões.

Entre os poucos estudos que consideram simultaneamente custos e emissões em MGs isoladas, a maioria analisa sistemas com múltiplas fontes geradoras poluentes (TAN; CHEN, 2020; ELSAKAAN et al., 2020; ALDOSARY, 2024). No entanto, há uma escassez de trabalhos que tratam de redes isoladas operando com uma única fonte geradora poluente, apesar da predominância dessas configurações em MGs remotas. Isso provavelmente ocorre porque grande parte dos algoritmos utilizados baseia-se em métodos multiobjetivo baseados em Pareto que dependem da existência de um conflito entre os objetivos para gerar soluções equilibradas. Quando há apenas uma fonte poluente, a relação contraditória entre custo e emissões pode não se manifestar de forma clara, exigindo a introdução artificial de mais fontes poluentes para que os algoritmos funcionem adequadamente.

Não há, na literatura, estudos que analisem detalhadamente a relação entre custos e emissões em MGs isoladas. Abordar essa lacuna é essencial, pois a formulação de problemas de otimização multiobjetivo pode exigir ajustes nessas condições. A investigação dessa relação, tanto para um único gerador quanto para múltiplos geradores, é crucial, pois uma formulação inadequada dos objetivos pode levar a resultados imprecisos e ao uso desnecessário de recursos computacionais.

2.6 Considerações Finais

A revisão da literatura evidenciou importantes avanços na aplicação de algoritmos de otimização ao gerenciamento de MGs, com foco predominante na minimização dos custos operacionais. Embora alguns estudos também considerem a redução das emissões de gases de efeito estufa, essa preocupação ainda é marginal em muitos trabalhos, mesmo na presença de fontes poluentes no sistema.

Verificou-se que, apesar da ampla adoção de formulações multiobjetivo, há fragilidades conceituais recorrentes, especialmente no tratamento dos custos de operação e manutenção (O&M) de dispositivos não despacháveis. A inclusão direta desses custos nas funções objetivo, sem considerar sua invariabilidade temporal, pode comprometer a coerência das modelagens propostas.

Outro ponto crítico identificado foi a escassez de estudos que abordam a otimização simultânea de custo e emissões em MGs isoladas com uma única fonte poluente. Essa limitação revela uma lacuna importante na literatura, que tende a favorecer cenários mais complexos para satisfazer os requisitos de conflito entre objetivos nos métodos de Pareto. No entanto, essa escolha metodológica pode negligenciar situações mais realistas e comuns em regiões remotas.

Diante desse panorama, reforça-se a necessidade de investigações que explorem com mais rigor a relação entre custo e emissões em MGs isoladas, especialmente em configurações com uma única fonte geradora poluente. Esse esforço é fundamental para o desenvolvimento de modelos mais aderentes à realidade e para o aprimoramento das estratégias de otimização em contextos práticos.

3 Referencial Teórico

Este capítulo de fundamentação teórica apresenta os conceitos essenciais sobre o funcionamento das MGs, seus principais componentes e as estratégias de gerenciamento, incluindo os Sistemas de Gerenciamento Inteligente (SGI) e o Controle Preditivo Baseado em Modelo (MPC), bem como os principais objetivos do gerenciamento inteligente dessas redes. Além disso, são introduzidos os conceitos gerais de otimização, com destaque para a otimização multiobjetivo, cuja abordagem é especialmente relevante em problemas que envolvem múltiplos critérios conflitantes — como custo e emissões — no contexto das MGs. Por fim, são discutidos dois métodos amplamente utilizados: os GAs, baseados em princípios de seleção natural, e o NSGA-II, um algoritmo avançado para otimização multiobjetivo que permite identificar soluções equilibradas entre diferentes objetivos de forma eficiente.

3.1 Microrredes

3.1.1 Características Gerais das Microrredes

As MGs são sistemas elétricos locais compostos por fontes de geração de energia e cargas que operam de forma integrada em uma rede separada. Elas podem funcionar de maneira isolada ou conectadas à rede elétrica principal, sendo essa alternância determinada por fatores técnicos e econômicos. Essas redes incorporam múltiplos recursos energéticos distribuídos (DERs), incluindo fontes renováveis, como solar e eólica, além de sistemas de cogeração e células a combustível, garantindo uma infraestrutura elétrica flexível, confiável e resiliente, mesmo com a eventual indisponibilidade de algumas fontes. Para manter o equilíbrio entre geração e demanda, as MGs utilizam sistemas de armazenamento de energia (como baterias e hidrogênio) e, quando conectadas, podem injetar excedentes na rede externa. Com capacidades instaladas que variam de poucos quilowatts a megawatts, elas são especialmente relevantes em áreas remotas, instalações industriais críticas e aplicações militares (FARHANGI; JOÓS, 2019; FARHANGI; ASADOLAH, 2019; SACHS; SAWODNY, 2016)

As particularidades das MGs também se manifestam na diversidade de suas configurações operacionais, na flexibilidade de controle e na adaptabilidade a diferentes contextos geográficos e demandas energéticas. Por operarem em baixa tensão e geralmente em pequena escala, essas redes permitem o gerenciamento mais preciso dos fluxos de energia, facilitando a aplicação de técnicas avançadas de otimização e controle. Além disso, a capacidade de operar de forma autônoma, desconectando-se da rede principal em situações

de falha ou instabilidade, torna as MGs uma solução atrativa para comunidades remotas, zonas rurais e instalações críticas que exigem alta confiabilidade no fornecimento de energia. Essa autonomia operacional, aliada à possibilidade de integrar recursos renováveis, posiciona as MGs como elementos centrais na transição para sistemas elétricos mais sustentáveis, resilientes e descentralizados.

Atualmente, as MGs desempenham um papel fundamental na implementação das Smart Grids (Redes Elétricas Inteligentes). Segundo o Departamento de Energia dos Estados Unidos (DOE - *Department of Energy*), sua relevância está associada à melhoria na qualidade da energia fornecida, além da maior independência operacional das Smart Grids, possibilitada pela capacidade de operação no modo isolado (TON; SMITH, 2012).

As MGs também contribuem para a redução das emissões de gases de efeito estufa, uma vez que utilizam fontes de energia renováveis como principal suprimento energético, emitindo menos poluentes em comparação às fontes baseadas em combustíveis fósseis (ZHAO et al., 2018; CONTE et al., 2019). Além disso, atuam como uma interface entre a rede de distribuição e a geração distribuída, assumindo a responsabilidade pelo gerenciamento das incertezas inerentes às fontes renováveis de energia (ROSLAN et al., 2021; LI et al., 2018).

Outra vantagem significativa das MGs refere-se à redução dos custos associados ao consumo de energia elétrica. Esse benefício decorre tanto do uso predominante de fontes renováveis quanto da implementação de estratégias de gerenciamento inteligente, que possibilitam a otimização do uso de baterias para minimizar despesas operacionais. Além disso, o gerenciamento eficiente da MG pode aumentar a quantidade de energia comercializada com a rede externa, proporcionando maior rentabilidade ao sistema (FOSSATI et al., 2015; XING; XIE; MENG, 2019).

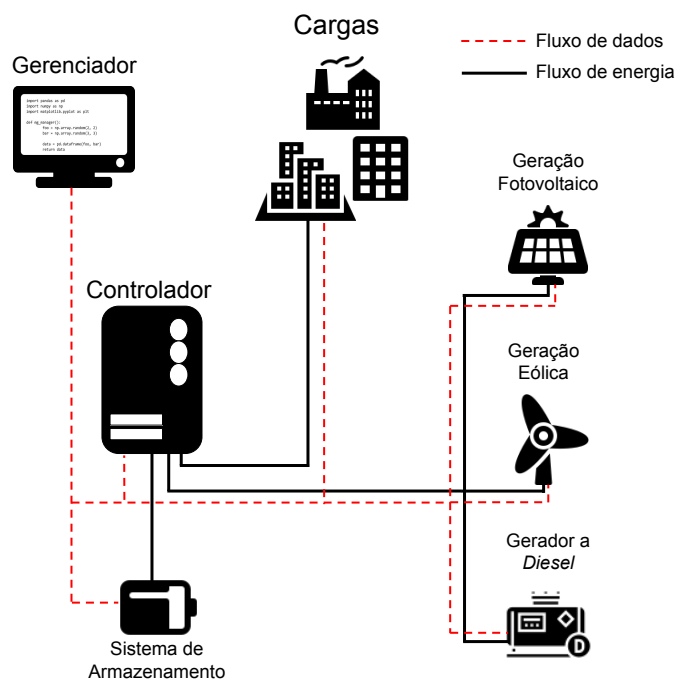
A Figura 2 apresenta um diagrama típico de uma MG. Os principais componentes de uma MG são:

- **Geração de energia renovável:** Representa a principal fonte de energia da MG, sendo geralmente composta por sistemas fotovoltaicos e eólicos;
- **Geração de energia não renovável:** Utilizada, em geral, como fonte de *backup*, fornecendo energia quando as fontes renováveis não estão disponíveis ou não conseguem suprir a demanda.
- **Sistema de armazenamento de energia:** São utilizados tanto como fonte de backup quanto para melhorar a qualidade da energia e reduzir os custos operacionais da MG por meio do gerenciamento inteligente;
- **Controladores de carga:** Equipamentos como inversores, responsáveis por gerenciar o fluxo de energia entre os dispositivos de armazenamento e as cargas elétricas. Este

dispositivo desempenha um papel essencial na estabilidade e no desempenho das MGs, atuando como parte integrante do sistema de controle que garante a operação coordenada e autônoma da MG.

- **Cargas elétricas:** Englobam diferentes tipos de consumo, incluindo cargas residenciais, comerciais e industriais;
- **Rede de dados:** Viabiliza a comunicação entre os dispositivos da MG, permitindo o monitoramento e controle do sistema;
- **Sistema de Gerenciamento Inteligente (SGI):** Responsável pela coordenação e operação eficiente da MG, otimizando o uso dos recursos energéticos.

Figura 2. MG com Gerenciamento Centralizado



Fonte: Produzido Pelo Autor

Apesar das diversas vantagens oferecidas, as MGs ainda enfrentam desafios significativos. Um dos principais obstáculos é o alto custo de implantação. Embora haja um retorno sobre o investimento e benefícios econômicos substanciais, o investimento inicial ainda é elevado, o que dificulta sua ampla adoção por empresas e comunidades.

Outro desafio relevante está relacionado às incertezas inerentes às fontes de energia renováveis e às cargas, ao mesmo tempo em que se busca manter a qualidade da energia fornecida. Isso ocorre porque as fontes renováveis são altamente voláteis e dependem diretamente das condições climáticas, tornando complexo o equilíbrio entre geração e

consumo de energia dentro da MG. De forma semelhante, as cargas elétricas apresentam um comportamento intermitente, variando conforme o número de usuários e o tipo de atividade desenvolvida no local (AGHAJANI; SHAYANFAR; SHAYEGHI, 2015; LI et al., 2019; SHAYEGHI et al., 2019).

3.1.2 Gerenciamento de Microrredes e o Uso de Inteligência Artificial

Lidar com as incertezas da geração e do consumo torna-se um grande desafio para qualquer estratégia de gerenciamento de MGs. À medida que a intermitência das fontes renováveis e das cargas aumenta, manter o equilíbrio entre geração e consumo torna-se mais complexo. Para mitigar esse problema, diversos pesquisadores utilizam técnicas de Inteligência Artificial (IA) para realizar o gerenciamento ótimo de MGs.

A IA tem sido aplicada em diversas áreas da Engenharia Elétrica, incluindo detecção de falhas na rede (VEERASAMY et al., 2021), reconfiguração e restauração de sistemas de distribuição (VIEIRA et al., 2021), alocação de dispositivos na rede elétrica (WANG et al., 2019) e no gerenciamento inteligente de MGs, conforme discutido na Seção 2.

As MGs podem ser gerenciadas por um SGI, cujo objetivo é otimizar o uso dos recursos energéticos. Esse sistema integra os elementos de geração, armazenamento e consumo em uma estrutura unificada, empregando algoritmos baseados em IA para coordenar sua operação de forma eficiente.

O SGI é responsável por definir o despacho ótimo de cada componente da MG, determinando a programação ideal de funcionamento dos dispositivos com o objetivo de melhorar a qualidade da energia e reduzir os custos operacionais (ZIA; ELBOUCHIKHI; BENBOUZID, 2018). Além disso, o SGI pode incorporar estratégias de aprendizado de máquina e otimização multiobjetivo, permitindo que a MG opere de forma autônoma e adaptável às variações nas condições de geração e demanda.

Para o funcionamento do SGI, todos os dispositivos de uma MG precisam estar conectados, trocando informações sobre a geração, demanda energética e sobre a disponibilidade dos dispositivos da MG. Com essas informações, o SGI consegue controlar o fluxo de energia dentro da MG, a fim de atender à demanda das cargas e manter a estabilidade da MG (ESPÍN-SARZOSA; PALMA-BEHNKE; NÚÑEZ-MATA, 2020).

As informações trocadas pelos dispositivos na MG são:

- Previsão da geração dos sistemas de energias renováveis;
- Previsão da demanda energética;
- Estado de carga do sistema de armazenamento;
- Disponibilidade da rede externa;

- Preço de compra e venda da energia elétrica;
- Preço do combustível utilizado por fontes de energias não-renováveis.

3.1.3 Tipos de Microrredes

As MGs podem ser classificadas de diversas formas, considerando fatores como modo de operação, fontes de energia utilizadas e finalidade. Elas podem operar de forma conectada ou isolada da rede elétrica, utilizar fontes renováveis, fósseis ou híbridas e atender a diferentes necessidades, como abastecimento comunitário, industrial ou emergencial. Além disso, o gerenciamento pode ocorrer de forma centralizada, onde um único controlador define a operação do sistema, podendo ser baseado em parâmetros predeterminados ou utilizar técnicas inteligentes para otimização, ou de maneira descentralizada, por meio de Sistemas Multi-Agentes (SMA), que aumentam a autonomia e a adaptabilidade da MG. Diante dessas classificações, este tópico se concentrará no modo de operação e no tipo de gerenciamento, explorando como a interação entre esses fatores influencia o desempenho e a flexibilidade das MGs.

3.1.3.1 Modo de Operação: Isolado e Conectado

Existem dois modos de operação das MGs: o modo conectado à rede externa e o modo isolado, também encontrado na literatura como ilhado. O modo conectado à rede significa que a MG está interligada a um sistema elétrico de potência de grande porte. Esse tipo de MG pode fornecer energia de backup à rede principal em caso de falha no fornecimento e também pode vender o excesso de energia gerada de volta à rede externa, quando necessário. As MGs conectadas à rede são normalmente utilizadas por empresas e instituições que demandam um fornecimento de energia confiável, como hospitais, data centers e complexos industriais (ZIA; ELBOUCHIKHI; BENBOUZID, 2018; BEKTAS; KAYAKUTLU, 2021).

Por outro lado, as MGs isoladas operam de forma autônoma, sem conexão com a rede elétrica principal, utilizando exclusivamente fontes locais de geração de energia. Esse tipo de MG é essencial em regiões remotas e rurais onde a infraestrutura elétrica convencional não está disponível ou seria economicamente inviável. Além disso, são amplamente empregadas em aplicações específicas que exigem independência energética, como sistemas de telecomunicações, estações meteorológicas, comunidades indígenas, instalações militares e operações de mineração (BEKTAS; KAYAKUTLU, 2021).

As MGs isoladas geralmente dependem de fontes renováveis, como energia solar e eólica, complementadas por sistemas de armazenamento de energia (baterias) para garantir o fornecimento contínuo. Em alguns casos, geradores a diesel são integrados ao sistema para oferecer suporte em períodos de baixa geração renovável. Entretanto, devido aos desafios

logísticos e ambientais associados ao transporte de combustível para locais remotos, há um crescente interesse na otimização do uso de baterias e outras soluções sustentáveis para aumentar a confiabilidade dessas redes.

Outro aspecto relevante das MGs isoladas é a complexidade no gerenciamento da geração e do consumo de energia. Como não há suporte da rede externa para suprir eventuais déficits de geração, estratégias avançadas de controle e otimização são fundamentais para equilibrar a demanda e a oferta de energia em tempo real. O uso de algoritmos de otimização para o despacho econômico e o controle preditivo de carga desempenha um papel crucial na maximização da eficiência e na minimização dos custos operacionais dessas redes.

Além disso, algumas MGs possuem a capacidade de transicionar entre os modos conectado e isolado, dependendo das condições operacionais. Essa transição ocorre, por exemplo, em situações de falha no fornecimento elétrico da rede externa, garantindo a continuidade da energia por meio dos próprios recursos de geração e armazenamento da MG. Esse tipo de configuração híbrida é especialmente vantajoso em áreas sujeitas a frequentes interrupções no fornecimento elétrico, oferecendo maior resiliência e confiabilidade ao sistema.

3.1.3.2 Gerenciamento Distribuído e Centralizado

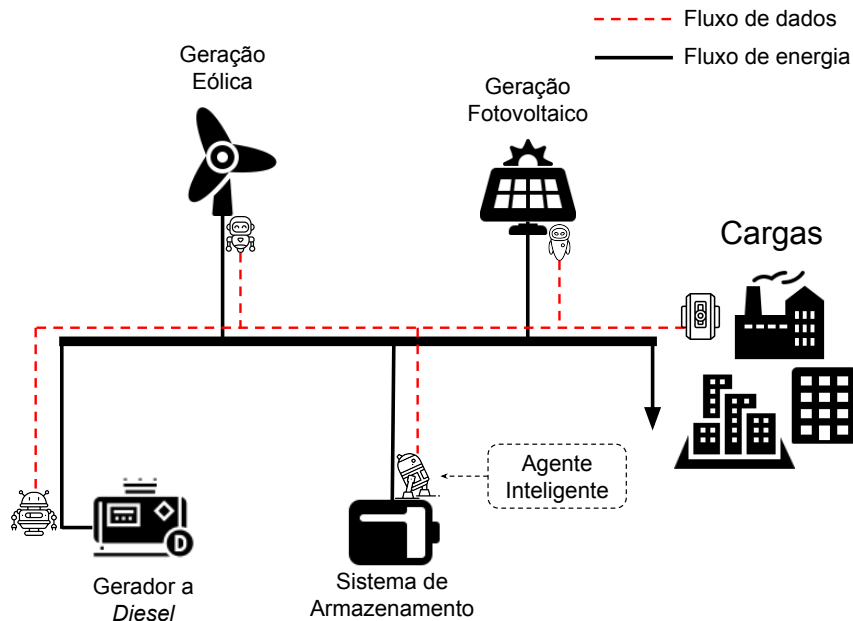
O Gerenciamento Distribuído envolve a descentralização das funções de controle e tomada de decisão dentro da MG, permitindo que diferentes componentes — como fontes de geração, cargas e sistemas de armazenamento — operem de forma autônoma, mas coordenada. Essa abordagem visa aumentar a flexibilidade operacional, melhorar a resiliência do sistema frente a falhas locais e facilitar a integração de múltiplos recursos energéticos distribuídos.

Os Sistemas Multiagentes (SMA) são uma abordagem amplamente utilizada para o gerenciamento distribuído de MGs, permitindo a coordenação eficiente entre diferentes dispositivos. Essa arquitetura distribui a inteligência e a capacidade de controle, reduzindo a dependência de um único ponto central e aumentando a resiliência da MG. Além disso, a topologia da rede de comunicação de dados da MG deve ser projetada para suportar essa estrutura descentralizada, garantindo a troca de informações entre os agentes e permitindo a tomada de decisão em tempo real.

Cada agente possui um sistema inteligente integrado, agindo de forma independente, e sendo capaz de se comunicar com outros agentes da MG, com o objetivo de elaborar as melhores estratégias de gerenciamento (ESPÍN-SARZOSA; PALMA-BEHNKE; NÚÑEZ-MATA, 2020). Também existe a possibilidade de implementação dos SMA para o gerenciamento de um conjunto de MGs, onde cada MG seria considerada um agente (ANVARI-MOGHADDAM et al., 2017).

Na Figura 3 é apresentado um esquema de funcionamento típico de um SMA aplicado a uma MG, as linhas pretas contínuas representam o fluxo de energia da MG e as linhas vermelhas tracejadas o fluxo de comunicação da MG. Pode-se observar a presença de um sistema inteligente em cada componente da MG.

Figura 3. MG com Gerenciamento Distribuído



Fonte: Produzido Pelo Autor

Mesmo que o SMA apresente diversas vantagens, como uma melhor escalabilidade, tolerância a falhas e a possibilidade da utilização da tecnologia *Plug-and-Play*, os resultados relacionados ao custo operacional e outros objetivos ainda não se mostraram satisfatórios, quando comparados ao gerenciamento centralizado, o que torna a segunda opção mais viável atualmente.

Em contrapartida, num sistema de Gerenciamento Centralizado, todas as informações relacionadas ao consumo e geração de energia da MG são enviadas para uma central de controle, onde ocorre o processamento das informações obtidas, sendo identificados os padrões de uso e geração energética. De posse dessas informações, o SGI centralizado irá elaborar um cronograma de despacho energético otimizado que será, posteriormente, aplicado em toda a MG (ESPÍN-SARZOSA; PALMA-BEHNKE; NÚÑEZ-MATA, 2020).

Um modelo de funcionamento de um SGI centralizado foi apresentado na Figura 2. As informações transmitidas para a central de controle são os dados em tempo real sobre o funcionamento da MG, sendo eles:

- Estado de carga dos sistemas de armazenamento;

- Potência gerada pelos sistemas de energias renováveis;
- Potência consumida pelas cargas do sistema;
- Níveis de tensão da MG;
- Preços de compra/venda de energia;
- Informações meteorológicas.

No gerenciamento centralizado, o SGI processa as informações recebidas da MG, analisando seu estado atual e realizando previsões sobre a geração de energia e a demanda futura. Com base nessa análise, o SGI define a estratégia ótima de despacho energético a ser implementada. Esse tipo de problema pode ser formulado computacionalmente como um *SchedulingProblem* (TALBI, 2009).

O *SchedulingProblem* é uma classe de problemas de otimização combinatória que envolve a alocação de tarefas ou recursos finitos dentro de uma determinada janela temporal. Trata-se de um problema *NP-hard*, o que implica a inexistência de algoritmos conhecidos que possam garantir uma solução ótima em tempo polinomial. No entanto, diversas abordagens heurísticas e metaheurísticas podem ser aplicadas para encontrar soluções satisfatórias na prática (TALBI, 2009; PREVIERO, 2016).

No contexto do gerenciamento ótimo de MGs, esse problema pode ser modelado como um *SchedulingProblem*, onde os recursos finitos correspondem aos sistemas de geração controláveis, como unidades de armazenamento e geradores a diesel. A otimização requer a alocação desses recursos ao longo do horizonte temporal, determinando não apenas sua ativação, mas também a potência injetada na MG pelos sistemas de armazenamento.

3.2 Model Predictive Control

O MPC é uma estratégia de controle de processos amplamente utilizada em diversas aplicações. O MPC realiza medições e previsões das variáveis do processo, utilizando essas informações para calcular as melhores configurações de controle, de modo a otimizar a saída do sistema (CAMACHO; ALBA, 2013).

De acordo com Bruni et al. (2015), o MPC baseia-se na previsão do comportamento do sistema no qual está inserido. A cada intervalo de tempo, as ações a serem implementadas são determinadas por meio da resolução de um modelo de otimização, que utiliza a previsão do comportamento do sistema dentro de um determinado horizonte temporal.

O MPC possui uma ampla gama de aplicações na engenharia, incluindo o gerenciamento de sistemas elétricos de potência e sistemas de AVAC (Aquecimento, Ventilação e Ar Condicionado). Além disso, essa abordagem tem sido empregada no controle de motores

industriais e até mesmo na mitigação de surtos de COVID-19 (VENKAT et al., 2008; SERALE et al., 2018; ELMORSHEDY et al., 2021; CARLI et al., 2020).

No contexto das MGs, o MPC é utilizado em SGI centralizados, sendo responsável por prever a geração das fontes renováveis e o comportamento da carga para um instante futuro. Com base nessas previsões, o MPC otimiza o despacho energético, garantindo um funcionamento eficiente de todos os componentes da MG (KONNEH et al., 2022).

3.2.1 Funcionamento do MPC

Antes de apresentar o funcionamento do MPC, é fundamental introduzir alguns conceitos essenciais para a compreensão do modelo.

A **granularidade** refere-se ao intervalo de tempo entre cada amostragem de dados do sistema. Esse parâmetro define a frequência com que as medições de variáveis, como carga e geração de energia, são realizadas. Uma granularidade menor implica em medições mais frequentes, proporcionando um maior detalhamento das dinâmicas do sistema e, conseqüentemente, gerando um volume maior de dados. Por outro lado, uma granularidade maior resulta em medições mais espaçadas, o que pode reduzir a complexidade computacional do modelo; porém, em contrapartida, também pode comprometer sua precisão.

A **janela de previsão** corresponde ao horizonte de tempo futuro no qual o modelo realiza estimativas das variáveis do sistema, como a demanda de carga e a geração elétrica. Essa previsão é essencial para que o MPC antecipe variações no comportamento do sistema e tome decisões mais informadas. A escolha do tamanho dessa janela influencia diretamente a qualidade do planejamento: janelas curtas podem resultar em decisões menos robustas, enquanto janelas longas podem aumentar a incerteza das previsões.

A **janela de controle** define o intervalo de tempo no qual o MPC executa suas ações de otimização e aplica as decisões calculadas. Em cada ciclo de controle, o algoritmo resolve um problema de otimização considerando a janela de previsão, mas apenas as primeiras decisões dessa sequência são aplicadas ao sistema. Em seguida, o processo é reiniciado, incorporando novas medições e atualizando as previsões, em uma abordagem denominada *receding horizon* (horizonte recuante). Esse mecanismo permite que o MPC adapte suas decisões continuamente, levando em conta as mudanças dinâmicas do sistema.

Destaca-se que a janela de previsão e a janela de controle podem apresentar valores distintos, desde que a janela de previsão seja maior que a janela de controle. De forma geral, define-se uma única janela de tempo para a previsão das cargas e da geração de energia, bem como para a definição do despacho energético. O desafio dessa abordagem reside na determinação do valor ótimo da janela de tempo: se a janela de previsão for muito grande, o algoritmo pode não se adaptar adequadamente às variações de geração

e consumo ao longo do dia; por outro lado, se a janela for excessivamente pequena, o MPC pode adotar um comportamento “egoísta”, maximizando o uso de recursos em um curto intervalo de tempo, prejudicando o planejamento das janelas subsequentes. Por esse motivo, são definidas duas janelas de tempo, permitindo que o MPC elabore um plano de gerenciamento ótimo para um horizonte temporal maior, distribuindo os recursos de forma equilibrada ao longo do tempo, ao mesmo tempo em que se adapta às mudanças que possam ocorrer durante o dia.

Na Figura 4, é possível observar o funcionamento do MPC. Inicialmente, são coletados os dados referentes às cargas do sistema e à geração das fontes de energia renováveis. Esses dados, juntamente com a série histórica correspondente, são enviados para o modelo de previsão. O modelo, então, realiza a previsão da geração e do consumo energético para uma janela de previsão específica.

Vale ressaltar que o modelo de previsão apresenta um certo nível de erro, o qual é fortemente influenciado pelo tamanho da janela de previsão. Quanto maior for a janela, maior será o erro associado às previsões. Por esse motivo, recomenda-se a escolha de uma janela de previsão de no máximo 24 horas.

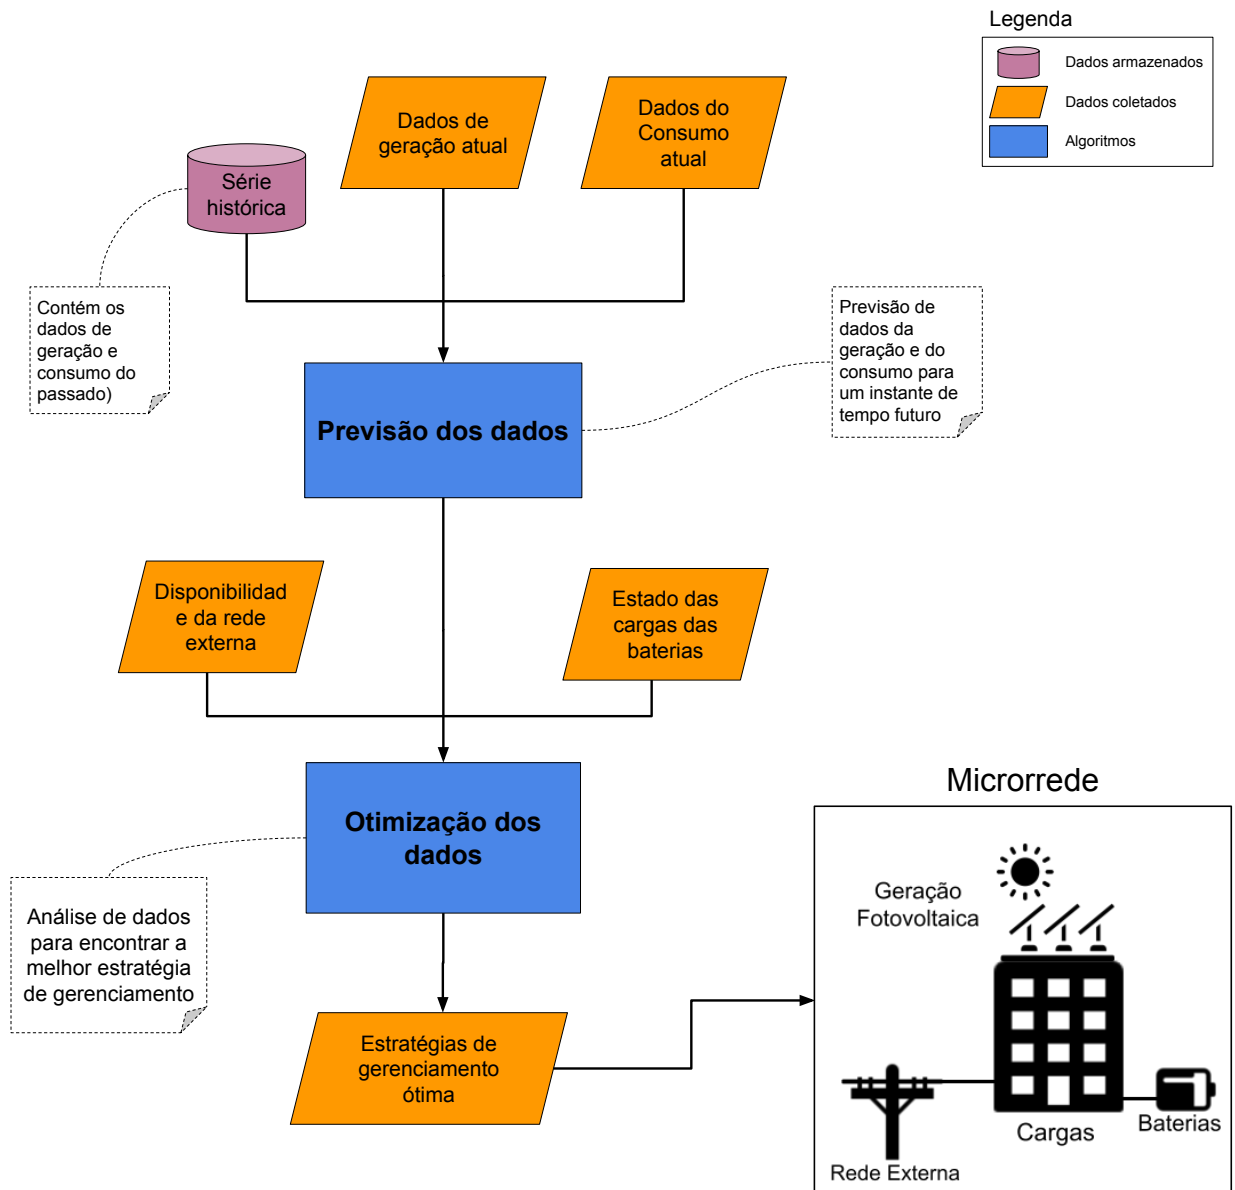
Os dados previstos, juntamente com outras informações relevantes da MG, como o nível de carga das baterias e a disponibilidade da rede externa, são então enviados para o modelo de otimização. Este modelo, por sua vez, elabora a melhor estratégia de gerenciamento energético para a MG. Por fim, a estratégia gerada é aplicada à MG para garantir um funcionamento eficiente e coordenado.

Como a estratégia do MPC é contínua, torna-se essencial visualizar seu funcionamento ao longo do tempo. A seguir, será apresentado o comportamento do SGI da MG no intervalo entre 12:00 e 14:00 horas. Para este exemplo, considera-se uma granularidade de 1 hora, uma janela de previsão de 6 horas e uma janela de controle de 2 horas.

Na Figura 5, observa-se o funcionamento do MPC às 12:00 horas. Nesse instante, os dados de geração e consumo de carga referentes ao período entre 10:00 e 12:00 são coletados (Figura 5, área em vermelho). Esses dados, juntamente com uma base histórica previamente armazenada, são utilizados para prever a geração e a demanda de energia na janela de previsão, compreendida entre 12:00 e 18:00 horas (área em azul).

Os valores previstos são então enviados a um algoritmo de otimização, que gera o plano ótimo de despacho energético da MG. Esse plano pode ser representado por uma matriz, na qual cada linha corresponde a um elemento controlável da MG e cada coluna representa um intervalo de tempo de acordo com a granularidade definida. A Figura 5 ilustra um exemplo desse planejamento, apresentando a matriz com os valores de potência de saída de duas baterias (*Bateria 1* e *Bateria 2*) e o status operacional de um gerador a diesel (*Diesel 1*).

Figura 4. MPC Aplicado numa MG



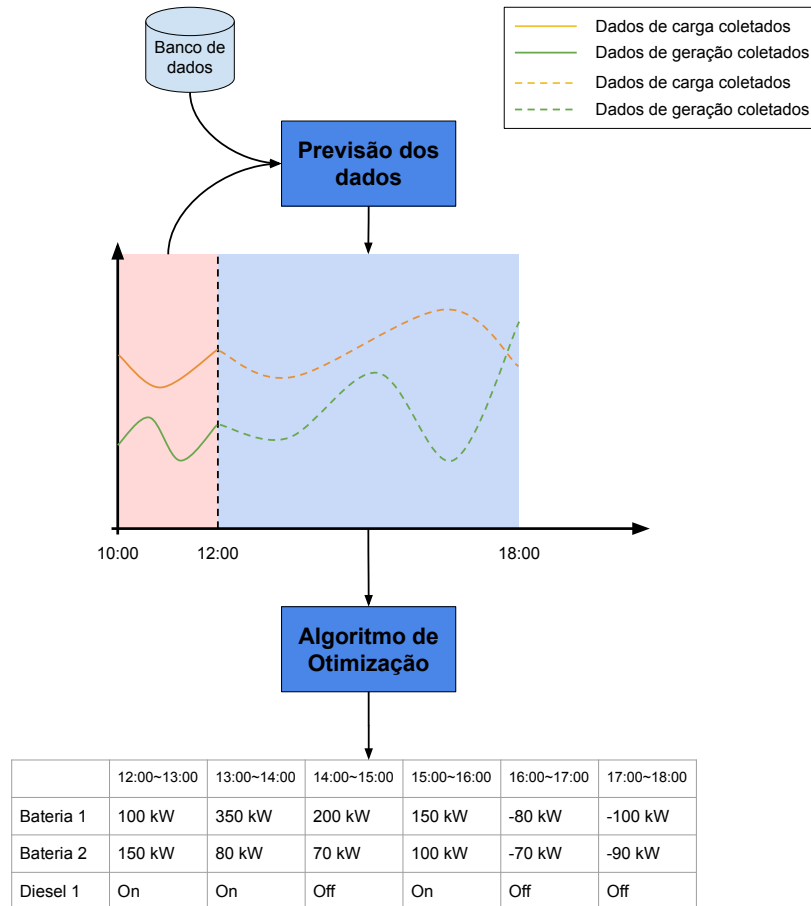
Fonte: Produzido Pelo Autor

A Figura 6 ilustra o funcionamento do MPC às 14:00 horas. O mesmo processo realizado às 12:00 horas se repete: os dados referentes ao período entre 12:00 e 14:00 horas são coletados e utilizados para prever o comportamento da carga e da geração de energia para a nova janela de previsão, compreendida entre 14:00 e 20:00 horas (Figura 6).

3.2.2 Desvantagens do MPC

Existem dois principais aspectos negativos associados ao MPC. O primeiro diz respeito ao seu alto custo computacional, uma vez que o MPC é uma abordagem que

Figura 5. MPC Sendo Executado às 12:00 horas



Fonte: Produzido Pelo Autor

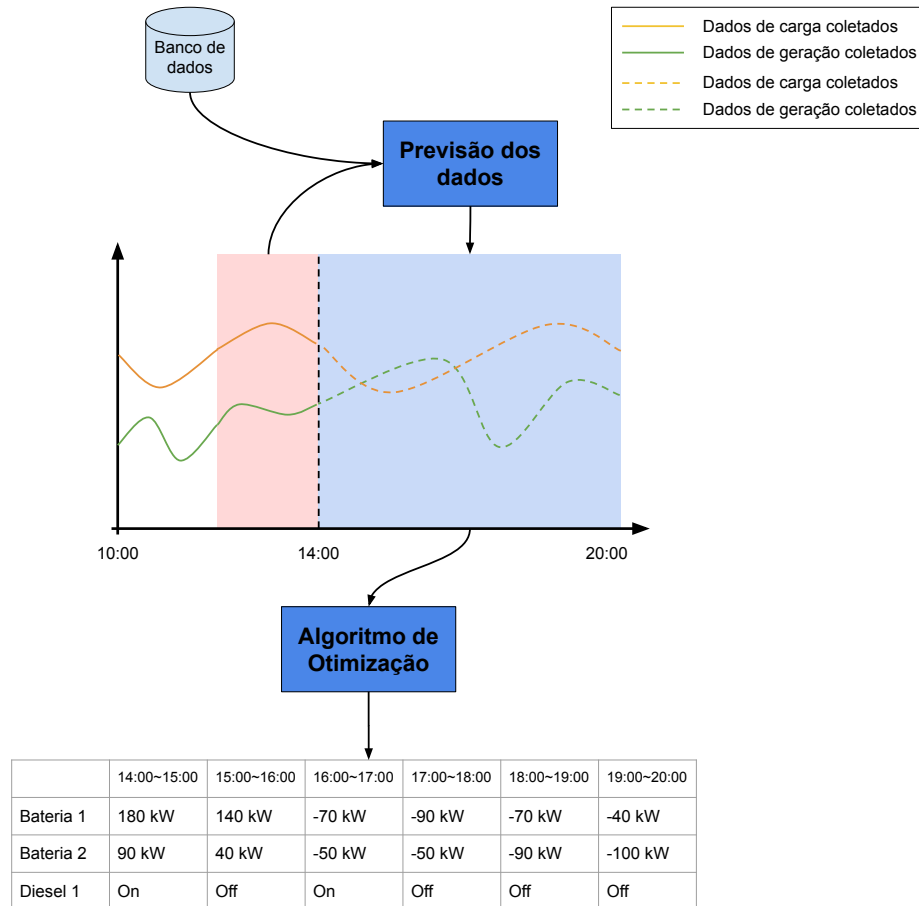
pode ser configurada para ser executada várias vezes ao longo do dia, com a execução também dos algoritmos de previsão e otimização. Alguns desses algoritmos, baseados em inteligência artificial, podem aumentar significativamente o tempo de execução, o que pode ultrapassar a janela de controle e tornar o método inviável.

O segundo aspecto negativo do MPC é a sua elevada dependência em relação aos modelos de previsão. Caso os modelos apresentem baixa precisão, todo o processo de otimização será comprometido, uma vez que o algoritmo encontrará as soluções de controle com base em dados imprecisos, prejudicando a qualidade das soluções obtidas (LEONORI et al., 2020a). Apesar dessas desvantagens, o MPC continua sendo o método mais utilizado, robusto e com os melhores resultados encontrados na literatura.

3.3 Otimização Matemática

O processo de otimização matemática consiste na seleção da melhor solução dentro de um conjunto de alternativas, com base em critérios previamente definidos. Problemas

Figura 6. MPC Sendo Executado às 14:00 horas



Fonte: Produzido Pelo Autor

como a maximização de uma função, a determinação da melhor rota para um destino ou a escolha de um produto com o melhor custo-benefício são exemplos de questões de otimização presentes tanto no cotidiano quanto em diversas áreas do conhecimento, como engenharia, economia, transportes, biologia e até mesmo no entretenimento.

No entanto, muitos problemas de otimização do mundo real apresentam alta complexidade, tornando inviável sua resolução manual. Questões como a definição do melhor calendário acadêmico para uma universidade ou a otimização de rotas logísticas para uma empresa de transportes podem exigir tempos computacionais extremamente elevados, chegando a centenas ou milhares de anos se solucionadas por métodos exaustivos com o poder computacional atual.

A escolha do método de solução depende da estrutura do problema, sendo que problemas de otimização podem ser classificados em diferentes categorias, como programação linear, programação inteira, programação não linear e otimização combinatória. Além disso, muitos desses problemas envolvem restrições que devem ser respeitadas na busca

pela solução ótima (ROBINSON, 2013).

Uma das etapas mais importantes do processo de otimização está na formulação da função objetivo do problema. A eficácia desses algoritmos está diretamente ligada à formulação precisa da função objetivo (TALBI, 2009). Uma formulação inadequada da função objetivo pode prejudicar significativamente o desempenho do algoritmo de otimização, levando a soluções subótimas e ao uso ineficiente de recursos computacionais, que frequentemente são limitados, especialmente em aplicações embarcadas, onde os sistemas de gerenciamento de MG são tipicamente implementados (LEONORI et al., 2020a).

Os problemas de otimização podem ser categorizados em dois grandes grupos: problemas mono-objetivo e problemas multi-objetivo, cada um com suas particularidades e algoritmos específicos para sua resolução. Na otimização mono-objetivo, busca-se otimizar uma única função objetivo, podendo haver restrições que limitam o espaço de soluções viáveis. A formulação matemática da otimização mono-objetivo é apresentada em (3.1).

$$\begin{aligned} & \textit{minimizar/maximizar } f(x) \\ & \textit{sujeito a : } g_1(x), g_2(x), \dots, g_m(x) \end{aligned} \tag{3.1}$$


Onde f é a função objetivo, x é a solução do problema, g representa as restrições do problema, e m é o número total de restrições que o problema pode apresentar.

Embora o processo de otimização mono-objetivo tenha gerado bons resultados nas últimas décadas, a grande maioria dos problemas do mundo real são caracterizados como problemas multi-objetivos. Nessa classe de problemas, dois ou mais objetivos são otimizados simultaneamente, sendo que esses objetivos são geralmente conflitantes. Ou seja, quando uma solução se aproxima de resolver um objetivo, ela acaba se afastando do outro, e vice-versa (DEB, 2011). A formulação matemática de um problema multi-objetivo é apresentada em (3.2), onde a diferença em relação à formulação (3.1) está na presença de mais de um objetivo, com $n \geq 2$.

$$\begin{aligned} & \textit{minimizar/maximizar } f_1(x), f_2(x), \dots, f_n(x) \\ & \textit{sujeito a : } g_1(x), g_2(x), \dots, g_m(x) \end{aligned} \tag{3.2}$$

Talbi (2009) e Deb e Goel (2001) mostram que existem dois espaços de busca nos quais o processo de otimização ocorre: o espaço de decisão e o espaço dos objetivos. Cada solução x do espaço de decisão possui um ponto correspondente no espaço dos objetivos (y), como ilustrado na Figura 7. O espaço dos objetivos é gerado a partir das soluções do espaço de decisão, sendo que essas soluções são passadas pelas funções objetivo (F).

Figura 7. Espaço de decisão e o espaço de objetivo



Fonte: Talbi (2009)

3.3.1 Dominância de Pareto


Um dos conceitos predominantes relacionados à otimização multi-objetivo é a dominância de Pareto, que serve de base para grande parte dos algoritmos multi-objetivos. Dadas duas soluções de um determinado problema (x_1 e x_2), podemos considerar que x_1 domina x_2 se x_1 não é pior que x_2 em todos os objetivos e x_1 é melhor em pelo menos um objetivo do que x_2 . A Figura 8 ilustra esse conceito, onde a área em vermelho é considerada o espaço dominado. A solução A , por exemplo, não é dominada por ninguém e domina as soluções B e C , mas ela não domina nem é dominada pela solução D .

Podemos considerar que as soluções $\{A, D\}$ fazem parte do conjunto de soluções não-dominadas, formando assim a fronteira de Pareto, que representa as soluções ótimas de um determinado problema, onde não é possível melhorar um objetivo sem piorar o outro. Os algoritmos de otimização multi-objetivos baseados em Pareto utilizam esse conceito para criar e selecionar, ao longo de gerações, as soluções não-dominadas, buscando progressivamente uma distribuição ideal de *trade-offs* entre os objetivos conflitantes.

3.4 Algoritmos de Otimização e Microrredes

A operação ótima de MGs depende diretamente da capacidade de formular e resolver problemas matemáticos complexos que representem com precisão o comportamento e as restrições dos dispositivos envolvidos. Como apresentado na Seção 3.2, os algoritmos de otimização são empregados para gerar soluções otimizadas para o planejamento do

Figura 8. Dominância de Pareto



Fonte: Produzido Pelo Autor

despacho energético da MG. Para avaliar essas soluções, utilizam-se as chamadas Funções de Aptidão, ou Funções Objetivo, que são expressões matemáticas responsáveis por mensurar o desempenho de cada solução candidata. Essas funções atribuem um valor numérico à qualidade da solução com base em critérios como custo operacional, eficiência energética, emissão de poluentes, entre outros. Assim, a função de aptidão permite comparar diferentes soluções e orientar a busca do algoritmo rumo à melhor alternativa.

A forma como essas funções de aptidão são formuladas é fundamental, pois determina todo o comportamento do algoritmo de otimização. Se o problema for modelado como mono-objetivo — ou seja, buscando otimizar apenas um critério, como o custo total —, podem ser utilizados algoritmos como o GA, PSO (*Particle Swarm Optimization*) ou *Simulated Annealing*, entre outros. Por outro lado, se a modelagem considerar múltiplos objetivos conflitantes, como minimizar simultaneamente o custo e as emissões de carbono, então será necessário utilizar algoritmos apropriados para problemas multiobjetivo, como o NSGA-II, MOEA/D (*Multi-Objective Evolutionary Algorithm based on Decomposition*) ou MOPSO (*Multi-Objective Particle Swarm Optimization*).

Como exemplo, considere uma formulação mono-objetivo baseada em soma ponderada, uma abordagem comum quando se deseja combinar múltiplos critérios de desempenho em uma única função de aptidão. Essa técnica consiste em atribuir pesos específicos a cada objetivo do problema (por exemplo, custo operacional e emissões de carbono), refletindo a importância relativa de cada um. A função de otimização assume a forma:

$$\min f = w_1 \cdot C_{total} + w_2 \cdot E_{total} \quad (3.3)$$

Onde w_1 e w_2 são coeficientes de ponderação definidos pelo planejador, C_{total} representa o custo total e E_{total} as emissões totais da MG. Ao ajustar os pesos, o tomador de decisão pode enfatizar, por exemplo, a minimização de custos em detrimento das emissões, ou vice-versa. Essa abordagem é especialmente útil quando se deseja uma solução única e direta, porém apresenta a limitação de exigir que o decisor defina a priori a importância de cada objetivo — o que pode não ser trivial ou pode não refletir adequadamente as condições reais do sistema.

A seguir, é apresentada a mesma função em sua formulação multiobjetivo, na qual os dois objetivos são tratados de forma independente. Isso permite explorar o conjunto de soluções de compromisso (conhecido como fronteira de Pareto), fornecendo um panorama mais amplo das alternativas possíveis para o planejamento energético da MG. Dessa forma, será possível observar como a escolha da modelagem influencia o comportamento e a aplicabilidade dos algoritmos de otimização utilizados.

$$\min f_1 = C_{total} \quad \min f_2 = E_{total} \quad (3.4)$$

A formulação mono-objetivo, como a baseada em soma ponderada, apresenta a vantagem de ser mais simples do ponto de vista computacional, exigindo menos tempo de processamento e permitindo a aplicação de algoritmos de otimização tradicionais, como o GA. No entanto, essa abordagem limita a análise a uma única solução, que depende fortemente da escolha dos pesos atribuídos a cada critério, o que pode introduzir viés ou resultar em decisões subótimas. Por outro lado, a formulação multiobjetivo trata cada critério de forma independente, permitindo identificar um conjunto de soluções de compromisso (a fronteira de Pareto) que oferecem ao tomador de decisão uma visão mais abrangente das alternativas possíveis. Isso possibilita uma tomada de decisão mais informada e alinhada aos objetivos reais da operação da MG. A principal desvantagem dessa abordagem está na sua complexidade computacional: algoritmos como NSGA-II ou SPEA2, que são projetados para lidar com múltiplos objetivos, exigem maior poder de processamento e mais iterações para convergir, especialmente em sistemas com muitas variáveis e restrições. Assim, embora a modelagem multiobjetivo forneça soluções

potencialmente mais equilibradas e robustas, ela demanda um esforço computacional significativamente maior.

3.5 Algoritmos de Otimização

Existem uma variedade de métodos de solução para problemas de otimização, incluindo abordagens determinísticas (como a programação linear) e heurísticas (como o arrefecimento simulado). Os métodos determinísticos são capazes de fornecer a solução ótima; contudo, em certos problemas, esses métodos podem levar um tempo considerável para encontrar a solução ideal, o que torna as heurísticas e meta-heurísticas uma excelente alternativa (TALBI, 2009).

As heurísticas e meta-heurísticas são eficazes na resolução de problemas complexos e desafiadores, apresentando soluções aceitáveis dentro de um tempo computacional viável. Essa classe de algoritmos não visa encontrar a melhor solução possível, mas sim identificar uma solução satisfatória que atenda às restrições do problema, tudo isso de forma eficiente em termos de tempo (RUSSELL, 2010).

A seguir, serão apresentados dois algoritmos de otimização, um mono-objetivos e o outro multi-objetivos, que podem ser aplicados à resolução do problema de gerenciamento de MGs. Ressalta-se que, embora o foco esteja em duas abordagens específicas, outras técnicas também podem ser incorporadas aos testes, desde que, no caso dos algoritmos multi-objetivos, estejam fundamentadas nos princípios de dominância de Pareto.

3.5.1 Algoritmos Genéticos

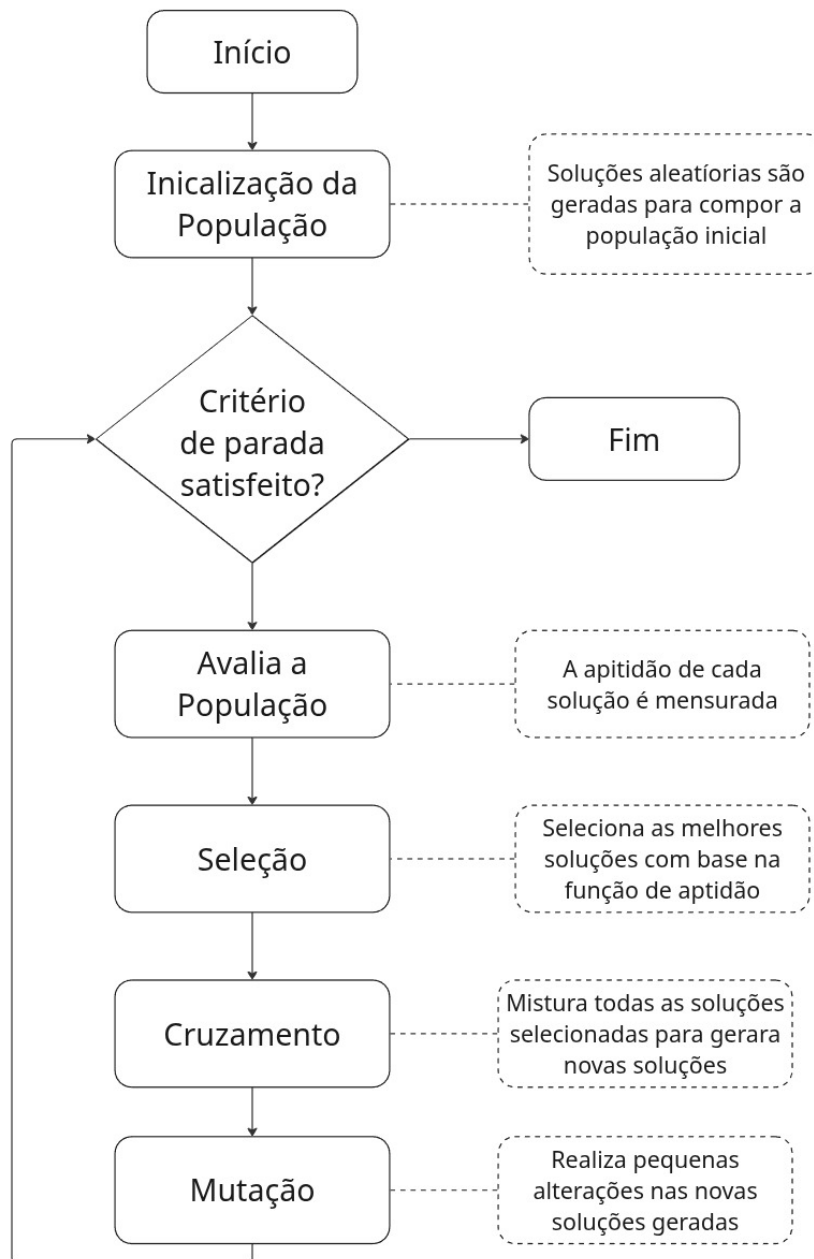
Um Algoritmo Genético (AG) é um algoritmo de otimização inspirado na teoria da seleção natural de Charles Darwin. Ele é frequentemente usado para encontrar boas soluções para problemas de busca e de otimização.

Na natureza, os organismos mais bem adaptados ao seu ambiente têm maiores chances de sobreviver e de se reproduzir. Da mesma forma, no AG, as soluções mais adequadas ao problema em questão são mais propensas a serem selecionadas para reprodução. Durante cada geração de um AG, as soluções são selecionadas para reprodução com base em sua aptidão. Em seguida, elas passam por um processo de cruzamento e mutação (NORVIG; INTELLIGENCE, 2002).

O Cruzamento é um processo onde duas soluções são combinadas para criar uma nova. Esta nova solução é então avaliada e pode ser selecionada para reprodução em gerações futuras. A Mutação é um processo em que uma solução é ligeiramente alterada. Esta alteração é então avaliada quanto à adequação e pode ser selecionada para reprodução em gerações futuras.

Este processo é repetido ao longo de várias gerações, até que uma solução satisfatória seja encontrada ou que uma outra condição de parada seja satisfeita. Na Figura 9 é apresentado o fluxograma do AG. Após a criação de uma população inicial aleatória, o programa entra num laço de repetição, selecionando novos indivíduos com base na função de aptidão, cruzando e realizando mutações nos indivíduos selecionados; por fim, avaliando a nova população de indivíduos gerados até que a condição de parada seja satisfeita.

Figura 9. Fluxograma do AG



Fonte: Produzido Pelo Autor

3.5.2 *Non-dominated Sorting Genetic Algorithm-II*

O NSGA-II é um algoritmo de otimização multi-objetivo que é usado para encontrar um conjunto de soluções não dominadas para um determinado problema com múltiplos objetivos. Ele é uma melhoria em relação ao algoritmo NSGA original, sendo mais eficaz no tratamento de problemas com um grande número de objetivos e mais rápido para encontrar as soluções não-dominadas.

O NSGA-II é um algoritmo elitista, o que significa que utiliza uma população de soluções e apenas as melhores soluções são mantidas de uma geração para a seguinte. O algoritmo funciona primeiro criando um conjunto de soluções aleatórias, depois avaliando-as de acordo com os objetivos (DEB et al., 2002). As soluções são então classificadas em *fronts* de acordo com seu nível de não-dominação, com os melhores *fronts* sendo mantidos para a próxima geração.

A Figura 10 ilustra o funcionamento deste processo, no qual os *fronts* F_1 , F_2 e F_3 foram selecionados para compor a próxima geração. Contudo, como a soma dos indivíduos pertencentes a esses três *fronts* excede o limite máximo permitido, o *front* F_3 é submetido a um critério adicional denominado *crowding distance sorting*. Esse processo avalia o grau de diversidade entre os indivíduos com base na métrica de *crowding distance*, que estima o quão espaçados estão os indivíduos dentro do *front*.

A *crowding distance* é calculada considerando, para cada indivíduo, a média das distâncias entre seus vizinhos mais próximos em cada um dos objetivos, formando um hiper-retângulo (no caso de dois objetivos, um retângulo) cujas extremidades são definidas pelos indivíduos adjacentes. Quanto maior essa distância, mais isolado — e, portanto, mais relevante para a diversidade — o indivíduo é considerado. Com base nesses valores, os indivíduos do *front* F_3 com maior *crowding distance* são priorizados para completar a população da próxima geração.

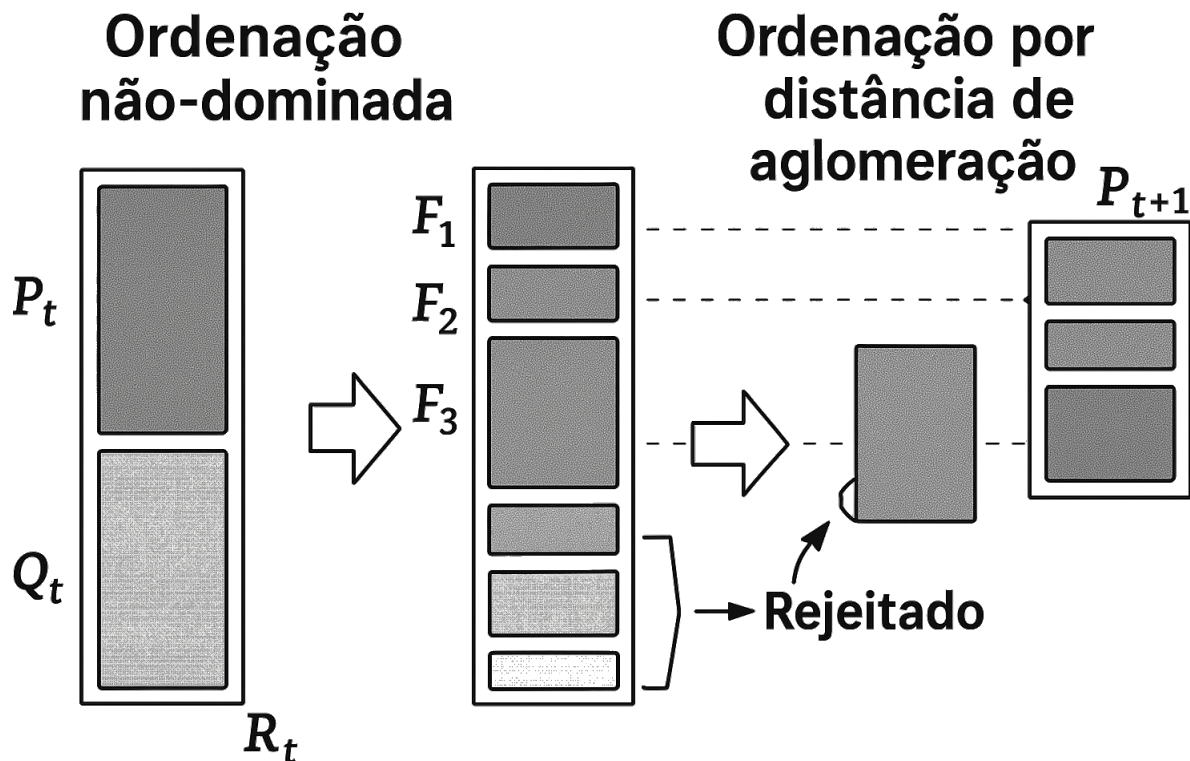
Após a seleção dos *fronts*, o algoritmo se comporta como um AG, aplicando operadores de reprodução, como cruzamento e mutação, para gerar novos indivíduos. Esse ciclo é repetido até que um conjunto satisfatório de soluções não-dominadas seja encontrado, representando a fronteira de Pareto final.

3.6 Considerações Finais

Este capítulo apresentou uma base teórica abrangente sobre o funcionamento das Microrredes (MGs) e os fundamentos da otimização aplicada ao seu gerenciamento. Inicialmente, foram discutidas as características gerais das MGs, incluindo sua estrutura, composição e os principais objetivos que orientam sua implementação.

Em seguida, foram exploradas as principais classificações dessas redes, com destaque

Figura 10. Funcionamento do NSGA-II



Fonte: Adaptado de Deb et al. (2002)

para a distinção entre MGs conectadas à rede elétrica convencional e aquelas que operam de forma isolada (*off-grid*). Essa diferenciação é fundamental para compreender os desafios específicos enfrentados em cada cenário, como a necessidade de resiliência e autonomia operacional no caso das MGs isoladas.

O capítulo também abordou os diferentes métodos de gerenciamento de MGs. Os Sistemas Multiagentes (SMAs) foram apresentados como uma abordagem descentralizada, ainda em desenvolvimento, que busca distribuir as decisões entre agentes autônomos. Já o Controle Preditivo Baseado em Modelo (MPC) foi descrito como uma estratégia centralizada, baseada em previsões e otimizações sucessivas ao longo do tempo. Um exemplo ilustrativo foi utilizado para demonstrar o funcionamento prático do MPC e sua aplicação no contexto das MGs.

Na segunda parte do capítulo, foi apresentada uma fundamentação teórica sobre o processo de otimização, com foco em sua aplicação em problemas complexos como o gerenciamento de MGs, destacando as diferenças entre algoritmos mono-objetivo e multi-objetivo, bem como as implicações práticas dessa distinção na busca por soluções. Apresentou-se a relação entre os algoritmos de otimização e as MGs, destacando-se

a influência direta da formulação matemática na eficácia do processo de otimização. Evidenciou-se que a forma como os objetivos, variáveis e restrições são modelados impacta significativamente o desempenho dos algoritmos e a qualidade das soluções obtidas para o planejamento e operação das MGs.

Foi introduzido o conceito de dominância de Pareto, essencial na otimização multi-objetivo, pois fundamenta a seleção de soluções eficientes e permite a construção das chamadas fronteiras de Pareto. A compreensão desse conceito será central para as análises realizadas nos capítulos seguintes, especialmente na avaliação comparativa de desempenho entre diferentes abordagens.

Por fim, foram apresentados dois algoritmos de otimização amplamente utilizados: o AG e o NSGA-II. O AG, inspirado na evolução natural, utiliza operadores como seleção, cruzamento e mutação para explorar o espaço de soluções. O NSGA-II, uma extensão voltada para problemas multi-objetivo, incorpora mecanismos adicionais, como a ordenação por dominância e o *crowding distance*, para manter a diversidade populacional. Ambos os algoritmos são fundamentais para o desenvolvimento metodológico dos capítulos seguintes.

Esse conjunto de discussões estabelece uma base sólida para a continuidade da Tese, na qual serão aprofundadas as formulações matemáticas aplicadas ao gerenciamento de MGs, com especial atenção aos impactos negativos que uma modelagem inadequada pode ter sobre o desempenho dos algoritmos de otimização aqui apresentados.

4 Metodologia

Neste capítulo, será apresentada a metodologia da tese. Inicialmente, são introduzidas as formulações matemáticas propostas para o gerenciamento inteligente de MGs isoladas. Em seguida, descreve-se a metodologia utilizada para testar essas formulações, por meio de análises estatísticas e experimentos com algoritmos de otimização. Por fim, são apresentadas as MGs de teste utilizadas nesta pesquisa.

4.1 Formulação Matemática

A literatura existente apresenta diversas formulações matemáticas para modelar o gerenciamento de energia em MGs isoladas, frequentemente formuladas como problemas de otimização multi-objetivo. O objetivo principal é minimizar simultaneamente os custos operacionais — englobando despesas com combustível e custos de O&M — enquanto se busca também a redução das emissões de gases poluentes.

Para consolidar essas abordagens, a Equação 4.1 fornece um resumo das fórmulas mais comumente usadas na literatura (FOSSATI et al., 2015; AGHAJANI; SHAYAN-FAR; SHAYEGHI, 2015; NAZARI-HERIS; ABAPOUR; MOHAMMADI-IVATLOO, 2017; MAULIK; DAS, 2018; ELSAKAAN et al., 2020), aplicadas em algoritmos de otimização projetados para esse contexto, juntamente com as restrições inerentes a tais problemas.

$$\begin{aligned}
 \min \left\{ \begin{aligned}
 f1 &= C_{total} = \sum_t^W [\sum_i^D (C_{fuel}(P_i^t) + C_{O\&M}(P_i^t)) + \sum_j^N C_{O\&M}(P_j^t) + \sum_k^M C_{O\&M}(P_k^t)] \\
 f2 &= E_{total} = \sum_t^W \sum_i^D E_{fuel}(P_i^t)
 \end{aligned} \right. \\
 s.t. \left\{ \begin{aligned}
 \sum_i^D P_i + \sum_j^N P_j - P_{load} &= 0 \\
 0.95 &< V_{MG} < 1.05 \\
 P_D^{min} &\leq P_D \leq P_D^{max} \\
 P_N^{min} &\leq P_N \leq P_N^{max} \\
 SoC_{stor}^{min} &\leq SoC_{stor} \leq SoC_{stor}^{max}
 \end{aligned} \right.
 \end{aligned} \tag{4.1}$$

Onde C_{total} e E_{total} representam, respectivamente, o custo total e as emissões da MG; t representa o instante de tempo considerado no horizonte de análise; W é o tamanho da janela de tempo analisada, correspondendo ao período total de planejamento; i , j e k são os índices de DDs, DNDs e outros dispositivos da MG (como baterias), respectivamente; D , N e M correspondem ao número total de DDs, DNDs e outros dispositivos da MG,

respectivamente; P é a potência de um dado dispositivo; C_{fuel} representa o custo do combustível consumido por um dispositivo; $C_{O\&M}$ é o custo de operação e manutenção (O&M) de um dispositivo; e E_{fuel} denota as emissões de CO_2 geradas pelo consumo de combustível de um dispositivo. P_{load} é a potência demandada pela MG; V_{MG} é o nível de tensão da MG (em p.u.), e SoC_{stor} é o estado de carga dos dispositivos de armazenamento da MG. As formulações do custo de combustível, custo de O&M e Emissões são apresentadas nas Equações 4.2, 4.3 e 4.4.

$$C_{fuel}(P) = \alpha * P \quad (4.2)$$

$$C_{O\&M}(P) = |\alpha * P| \quad (4.3)$$

$$E_{fuel}(P) = \beta * P \quad (4.4)$$

Onde, P é a potência de cada dispositivo da MG, α e β são os coeficientes de custo e de emissões, respectivamente.

Os objetivos da formulação matemática para o gerenciamento ótimo de MGs isoladas concentram-se na minimização dos custos operacionais e das emissões de carbono. O custo total da MG, C_{total} , inclui gastos com combustível dos geradores e custos de (O&M), enquanto as emissões totais, E_{total} , estão diretamente relacionadas ao consumo de combustível. Dessa forma, a otimização busca um equilíbrio entre esses objetivos aparentemente conflitantes, garantindo a operação econômica e sustentável da MG ao longo do horizonte de planejamento W .

Para assegurar a operação segura e eficiente da MG isolada, diversas restrições devem ser consideradas no modelo. A equação de balanço de potência garante que a geração total, somada ao armazenamento de energia, seja suficiente para suprir a demanda P_{load} da MG em todos os instantes de tempo. Além disso, restrições operacionais, como os limites de potência dos dispositivos geradores (P_D, P_N), a faixa admissível de tensão da MG (V_{MG}) e a manutenção do estado de carga (SoC_{stor}) dentro de valores seguros, são essenciais para garantir a estabilidade do sistema. Essas restrições impõem desafios adicionais à otimização, tornando necessária a aplicação de algoritmos eficientes para encontrar soluções viáveis e de alto desempenho.

4.2 Formulação Matemática Proposta

4.2.1 Analisando a Influência da Inclusão dos Custos de O&M

A equação 4.5 destaca o componente da equação 4.1 que está exclusivamente relacionado aos custos de O&M da MG.

$$C_{total} = \sum_t^W [\sum_i^D (C_{fuel}(P_i^t) + C_{O\&M}(P_i^t)) + \sum_j^N C_{O\&M}(P_j^t) + \sum_k^M C_{O\&M}(P_k^t)] \quad (4.5)$$

Nesta formulação, são considerados os custos associados tanto às DDs quanto às DNDs. No entanto, os algoritmos de otimização operam diretamente sobre as variáveis associadas às DDs, ajustando iterativamente suas potências para minimizar a função de custo. Dessa forma, a saída da função objetivo é determinada exclusivamente pelas variáveis desses componentes, uma vez que o processo de otimização não altera os parâmetros das DNDs. Assim, os custos de operação e manutenção (*O&M*) dessas últimas são considerados fixos no modelo, pois não participam da dinâmica evolutiva das soluções propostas.

A principal limitação dessa modelagem reside no fato de que o algoritmo de otimização, ao buscar soluções ótimas, executa um grande número de simulações iterativas, podendo alcançar centenas ou até milhares de execuções. Esse processo exige a recomputação frequente de todos os parâmetros definidos na função objetivo, incluindo os custos de *O&M* das DNDs. Entretanto, como esses custos não afetam diretamente as decisões de despacho de energia, sua reavaliação em cada iteração é desnecessária, resultando em um uso ineficiente dos recursos computacionais.

Essa redundância compromete a eficiência do algoritmo, especialmente em sistemas embarcados ou com recursos computacionais limitados, onde a otimização do tempo de processamento é essencial para garantir a viabilidade operacional. Dessa maneira, é metodologicamente mais apropriado considerar esses custos como fixos e apenas incorporá-los ao custo total após a execução do processo de otimização.

Ao excluir esses custos do cálculo iterativo inicial, o algoritmo pode concentrar seus recursos computacionais exclusivamente nas variáveis operacionais dinâmicas que impactam diretamente a eficiência da MG. Após a otimização, os custos de *O&M* dos DNDs podem ser adicionados ao custo total, garantindo que a solução final seja precisa sem comprometer a eficiência computacional.

Dessa forma, a simplificação da formulação matemática para o algoritmo de otimização é expressa na equação 4.6, na qual os cálculos referentes aos custos de *O&M* das DNDs são removidos do processo iterativo de otimização. Essa abordagem não apenas melhora o desempenho do algoritmo, mas também reforça a viabilidade prática de sua

aplicação em MGs isoladas, onde a otimização do uso de recursos computacionais é um fator determinante para a operação eficiente do sistema.

$$C_{total} = \sum_t^W [\sum_i^D (C_{fuel}(P_i^t) + C_{O\&M}(P_i^t)) + \sum_k^M C_{O\&M}(P_k^t)] \quad (4.6)$$

4.2.2 Analisando a Relação Entre os Custos e Emissões

Os algoritmos de otimização multi-objetivo são amplamente reconhecidos como a abordagem mais eficaz para resolver problemas que envolvem múltiplos critérios conflitantes. Esses algoritmos buscam soluções que compõem a chamada fronteira de Pareto, um conjunto de soluções não dominadas no qual a melhoria de um objetivo só pode ocorrer à custa da piora de outro. Essa característica é essencial para problemas complexos, como o gerenciamento de MGs, onde há uma relação intrínseca de compromisso entre objetivos distintos, como a minimização dos custos de *O&M* e a redução das emissões de poluentes. Portanto, a formulação matemática do problema deve refletir essa relação de conflito, garantindo que os algoritmos baseados em Pareto possam operar de maneira eficiente para encontrar soluções ótimas.

Ao examinar a Equação 4.7 (uma reformulação da Equação 4.1, incorporando a Equação 4.6), inicialmente, parece evidente que os objetivos definidos apresentam um conflito direto, o que é característico dos problemas de otimização multi-objetivo. A intuição sugere que uma redução nos custos de *O&M* pode resultar em um aumento nas emissões poluentes, enquanto a minimização das emissões pode elevar os custos operacionais. No entanto, uma análise mais aprofundada revela que essa relação pode não ocorrer da maneira tradicionalmente esperada.

$$\min \begin{cases} f1 = C_{total} = \sum_t^W [\sum_i^D (C_{fuel}(P_i^t) + C_{O\&M}(P_i^t)) + \sum_k^M C_{O\&M}(P_k^t)] \\ f2 = E_{total} = \sum_t^W [\sum_i^D E_{fuel}(P_i^t)] \end{cases} \quad (4.7)$$

Em particular, observa-se que as fontes de energia poluentes¹ despacháveis desempenham um papel semelhante em ambas as funções objetivo. Quando esses dispositivos são acionados, tanto os custos de operação quanto as emissões aumentam simultaneamente, indicando uma correlação direta entre essas métricas, em vez de um *trade-off* típico. Em outras palavras, a ativação dessas fontes impacta ambas as funções na mesma direção, o que pode comprometer a efetividade dos algoritmos de otimização baseados em Pareto, uma vez que a estrutura de conflito tradicional entre os objetivos não está bem definida.

¹ A partir desta seção, optou-se pelo termo fontes de energia poluentes em substituição a DD (dispositivos despacháveis), com o objetivo de reforçar a relação direta entre custo operacional, externalidades ambientais e objetivos de otimização. Essa escolha lexical visa destacar o *trade-off* inerente ao uso dessas fontes em sistemas energéticos sustentáveis.

Diante desse desafio, este estudo propõe duas soluções alternativas para reformular o problema de forma a melhorar a eficiência dos algoritmos de otimização multi-objetivo. A primeira abordagem consiste em remover explicitamente o termo relacionado aos custos dos geradores poluentes da função objetivo de custo, sendo eles o custo de $O\&M$ e o custo dos combustíveis. Dessa forma, a minimização dos custos desses geradores ocorre indiretamente, em conjunto com a minimização das emissões. Essa estratégia não apenas simplifica a formulação do problema, mas também reduz os custos computacionais, melhorando a qualidade das soluções obtidas. Após a conclusão do processo de otimização, os custos previamente excluídos podem ser reincorporados ao cálculo final, garantindo a integridade dos resultados. A formulação matemática correspondente a essa abordagem é apresentada na Equação 4.8.

$$\min \begin{cases} f1 = C_{total} = \sum_t^W \sum_k^M C_{O\&M}(P_k^t) \\ f2 = E_{total} = \sum_t^W \sum_i^D E_{fuel}(P_i^t) \end{cases} \quad (4.8)$$

A segunda solução proposta consiste em transformar o problema multi-objetivo em um problema mono-objetivo, eliminando a função de emissões da formulação. Nesse cenário, a minimização direta ocorre apenas sobre os custos operacionais, e a redução das emissões torna-se uma consequência natural da otimização de custo. Com essa abordagem, as emissões não são consideradas durante o processo de otimização, mas podem ser calculadas posteriormente para análise e verificação dos impactos ambientais da solução adotada. A formulação matemática correspondente a essa abordagem está representada na Equação 4.9.

$$\min \{ f1 = C_{total} = \sum_t^W [\sum_i^D (C_{fuel}(P_i^t) + C_{O\&M}(P_i^t)) + \sum_k^M C_{O\&M}(P_k^t)] \} \quad (4.9)$$

Ambas as estratégias visam tornar a formulação matemática do problema mais adequada para otimização, eliminando redundâncias e garantindo que o conflito entre os objetivos seja devidamente tratado. A escolha entre essas abordagens deve levar em consideração o contexto da aplicação e os requisitos específicos de cada MG, garantindo que a solução final atenda tanto a critérios técnicos quanto a restrições ambientais e operacionais.

4.3 Metodologia de Testes e Validações

4.3.1 Microrredes de Teste

Os testes foram realizados nas MGs fornecidas por Alam, Chakrabarti e Liang (2020), as quais foram desenvolvidas para servir como referência em *benchmarks*. Esse

estudo apresenta quatro MGs, todas com capacidade de operar em modo isolado. A Tabela 1 apresenta a configuração dessas MGs, destacando a quantidade de dispositivos presentes em cada uma. Dependendo do cenário de teste, as MGs podem ser simuladas com geradores a diesel, biomassa ou gás natural.

Tabela 1. Configuração das MGs Testadas

MG	Base	Nº de Barramentos	G. Poluentes	PV	WT	Baterias
MG 01	6-bus	6	3	3	0	3
MG 02	IEEE-33	9	3	3	2	3
MG 03	IEEE-69	18	3	6	2	6
MG 04	14-bus	7	2	3	0	3

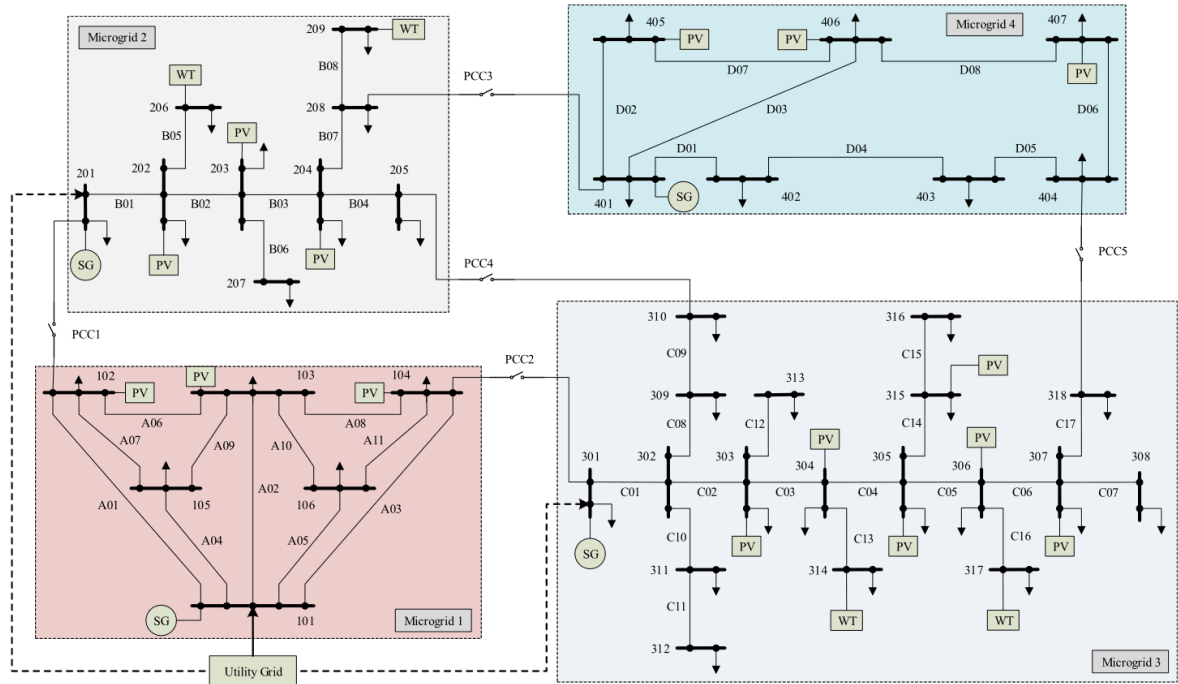
Fonte: Adaptado de Alam, Chakrabarti e Liang (2020)

As MGs operam num sistema trifásico de 11 kV e também incluem sistemas de armazenamento de energia localizados nos mesmos barramentos dos sistemas fotovoltaicos. Esses sistemas de armazenamento têm a capacidade de sustentar a operação das MGs de forma independente por até duas horas, fornecendo flexibilidade e suporte adicional à geração distribuída intermitente.

A Figura 11 apresenta o diagrama unifilar das MGs analisadas. Para a realização dos testes, foram selecionados quatro dias específicos, cujas características estão detalhadas nas Figuras 12, 13 e 14². A Figura 12 exibe as curvas de geração fotovoltaica de energia e a Figura 13 a geração eólica correspondentes aos dias escolhidos, enquanto a Figura 14 apresenta as respectivas curvas de carga. Além disso, foram realizados ajustes nas cargas para aumentar a variedade e a complexidade do sistema analisado.

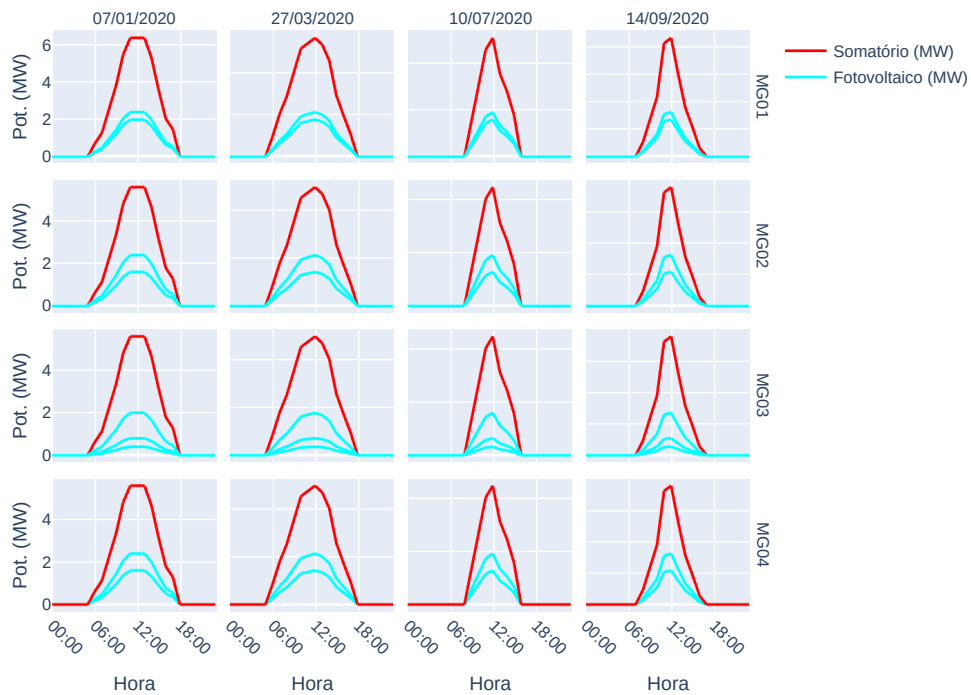
² Algumas curvas nessas figuras estão sobrepostas

Figura 11. MGs utilizadas nos testes




Fonte: Alam, Chakrabarti e Liang (2020)

Figura 12. Geração Fotovoltaica Nos Dias Selecionados



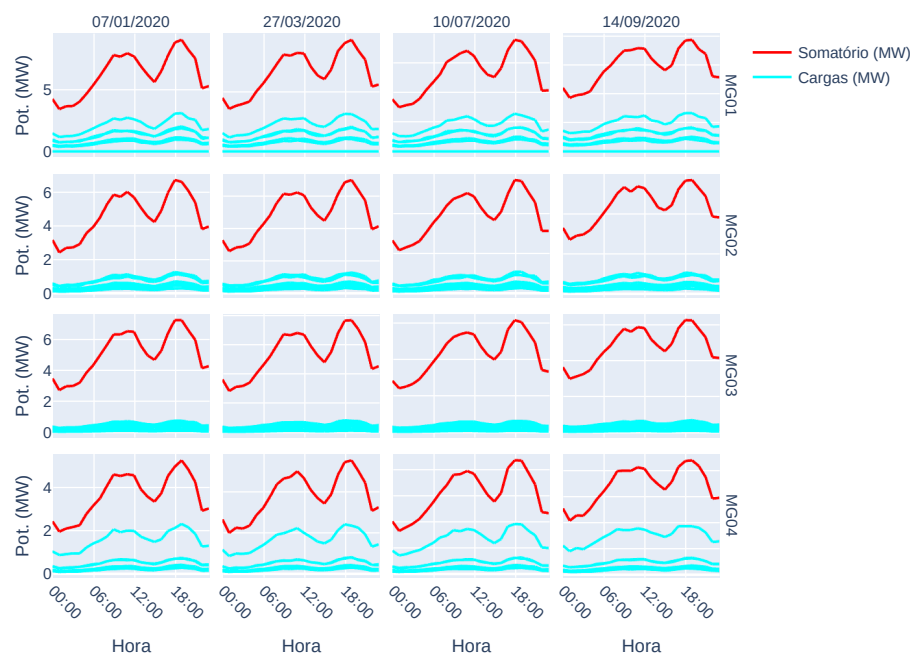
Fonte: Produzido pelo autor com os dados fornecidos por Alam, Chakrabarti e Liang (2020)

Figura 13. Geração Eólica Nos Dias Seleccionados



Fonte: Produzido Pelo Autor com os dados fornecidos por Alam, Chakrabarti e Liang (2020)

Figura 14. Cargas nos Dias Seleccionados



Fonte: Produzido Pelo Autor com os dados fornecidos por Alam, Chakrabarti e Liang (2020)

Os valores apresentados na Tabela 2 foram obtidos a partir de publicações técnicas recentes de fontes confiáveis. Os custos de operação e manutenção (O&M) foram extraídos de estudos do Annual Technology Baseline (ATB) do NREL, incluindo dados para sistemas de baterias (COLE; KARMAKAR, 2023), fotovoltaicos de larga escala (RAMASAMY et al., 2022) e eólicos terrestres com base em dados da Wood Mackenzie (LIU; FONSECA, 2021). Para fontes fósseis, considerou-se o relatório do BID sobre potencial de térmicas na América Latina (GOMELSKY, 2010). Já os fatores de emissão de CO₂ foram obtidos a partir da ferramenta metodológica da UNFCCC para geradores a diesel (UNFCCC, 2017) e dos fatores padrão publicados pela Comissão Europeia (COMMISSION, 2017). Fontes renováveis e sistemas de armazenamento foram considerados isentos de emissões diretas durante a operação.

Tabela 2. Custos de O&M e fatores de emissão.

Dispositivo	O&M [α] (\$/MW)	Emissões [β] (tCO₂/MW)
Baterias	5	N/A
Fotovoltaico	5	N/A
Gerador eólico	12	N/A
Gerador a diesel	20	0.8
Gerador a biomassa	20	0.072
Gás natural	4	0.5

Fonte: Produzido Pelo Autor

Foram realizados testes em dois cenários. No primeiro, considerou-se apenas um tipo de fonte geradora poluente, ou seja, todos os geradores poluentes eram do mesmo tipo, sendo adotada a geração a diesel. No segundo, foram utilizadas múltiplas fontes geradoras poluentes. Na MG04, empregaram-se geradores a diesel e biomassa; enquanto, nas demais, foram utilizados geradores a diesel, biomassa e gás natural.

A abordagem testada neste estudo, aplicada às quatro MGs simuladas, demonstra potencial de generalização para outras MGs, independentemente da sua topologia ou porte. Isso se deve ao fato de que a estrutura lógica do modelo de otimização não depende diretamente da quantidade de unidades geradoras ou do arranjo físico dos componentes. No entanto, a escalabilidade pode ser impactada quando se consideram explicitamente as perdas técnicas de energia, uma vez que essas perdas estão associadas às distâncias, à impedância das linhas e ao fluxo de potência na rede.

4.3.2 Algoritmos de Otimização

Os algoritmos de otimização utilizados nos testes foram o GA para a otimização mono-objetivo e o NSGA-II para a abordagem multi-objetivo. O foco principal desta tese é comparar a formulação matemática do gerenciamento de energia de MGs isoladas;

portanto, não foi realizada uma comparação entre os algoritmos de otimização. No entanto, o número de soluções avaliadas para ambos os algoritmos foi ajustado para 20.000 com o intuito de aproximar os resultados. Os parâmetros dos algoritmos de otimização são apresentados na Tabela 3.

Tabela 3. Parâmetros dos Algoritmos de Otimização.

Parâmetros	GA/NSGA-II
Número de gerações	200
Tamanho da população	100
Taxa de cruzamento (%)	0.1
Taxa de mutação (%)	0.7
Número de pais no cruzamento	2
Número de filhos no cruzamento	2

Fonte: Produzido Pelo Autor

O número de gerações define quantas iterações o processo evolutivo será repetido, enquanto o tamanho da população indica quantas soluções são avaliadas em cada uma dessas iterações, influenciando a diversidade e o custo computacional. A taxa de cruzamento representa a proporção de indivíduos submetidos ao cruzamento, operação que combina características de dois pais para formar novos filhos, cujo número também é definido como parâmetro. Já a taxa de mutação especifica a probabilidade de alterações aleatórias nos indivíduos, sendo essencial para manter a diversidade genética e evitar soluções subótimas. Por fim, o número de pais no cruzamento determina quantos indivíduos contribuem geneticamente para gerar descendentes, sendo normalmente dois. Esses parâmetros controlam a exploração e a intensificação do espaço de busca, afetando diretamente a qualidade das soluções obtidas.

A implementação foi realizada no Python 3.10.11, utilizando a biblioteca Pymoo na versão 0.6.0.1 (Blank; Deb, 2020) para executar os algoritmos de otimização. Além disso, a biblioteca PandaPower na versão 2.13.1 (THURNER et al., 2018) foi empregada para realizar os cálculos de fluxo de carga necessários para verificar as restrições operacionais da MG, garantindo a consistência dos resultados obtidos.

Os testes foram realizados em um sistema operacional Ubuntu 22.04.5 LTS, utilizando um computador com processador AMD Ryzen 9 7950X, com 32 *threads* rodando a 5,881 GHz e 32 GB de RAM.

4.3.3 Análise dos Resultados

Para a validação da metodologia proposta, foram realizados testes em quatro MGs isoladas (MGs), considerando quatro cenários distintos. A avaliação das formulações

matemáticas apresentadas na Seção 4.2 foi conduzida por meio da aplicação de algoritmos de otimização.

Inicialmente, foi realizada uma análise comparando o número de operações da metodologia com e sem a consideração dos custos de O&M. Em seguida, empregou-se o GA para investigar a influência dos custos de O&M no processo de otimização, analisando também o tempo médio de execução. Para isso, foram realizadas 50 execuções do GA, minimizando exclusivamente os custos operacionais, sem considerar as emissões de poluentes. Os experimentos foram conduzidos tanto para a formulação que inclui os custos de O&M quanto para a que os desconsidera.

Os resultados foram analisados por meio do cálculo da média e do desvio padrão das soluções obtidas ao longo das iterações. Além disso, foi aplicado o teste t de Student, um teste estatístico que verifica se há diferença significativa entre as médias de duas amostras independentes. Essa análise permitiu avaliar a relevância da inclusão dos custos de O&M na formulação matemática, determinando se a diferença entre as abordagens é estatisticamente significativa. Como medida de significância, foi adotado o valor de p de 5% (ou 0,05) que é um limiar comumente adotado na estatística para determinar a significância dos resultados de um teste de hipótese.

Para analisar a relação entre custos e emissões, foi conduzido um teste preliminar utilizando o algoritmo NSGA-II nas quatro MGs. Nesse teste, foram comparadas as Equações 4.7 e 4.8 em quatro dias distintos e sob duas condições específicas: uma considerando apenas um tipo de fonte geradora poluente e outra envolvendo múltiplas fontes geradoras poluentes. Durante essa bateria de testes, foi analisada a interação entre os objetivos, sendo realizada uma avaliação da correlação entre custo e emissões nesses cenários.

Para esse problema, dois tipos de testes estatísticos de correlação são possíveis: a correlação de Pearson e a correlação de Spearman. A escolha entre esses métodos depende da distribuição dos dados analisados. Para determinar se os dados seguem uma distribuição gaussiana, será empregado o teste de Kolmogorov-Smirnov. Caso os dados apresentem normalidade, será utilizada a correlação de Pearson; caso contrário, será adotada a correlação de Spearman.

Ambas as correlações fornecem dois resultados: o *p-value* e o coeficiente de correlação. O *p-value* indica a significância estatística da correlação; se for menor que 0,05, conclui-se que há uma relação estatisticamente significativa entre os objetivos analisados (custos e emissões).

O coeficiente de correlação, por sua vez, mede a força e a direção dessa relação. Seu valor varia entre -1 e 1: valores próximos de 1 indicam uma forte correlação positiva, próximos de -1 indicam uma forte correlação negativa, e valores próximos de 0 sugerem ausência de correlação linear entre as variáveis.

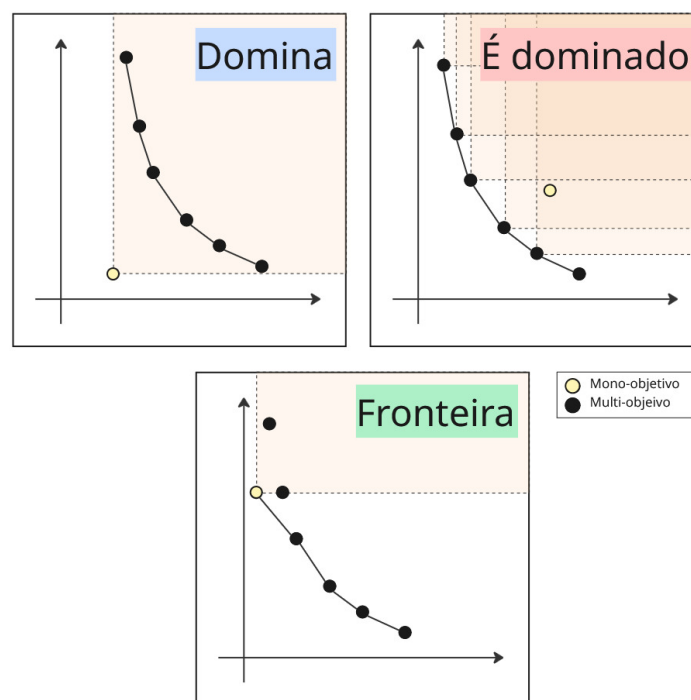
Por fim, com essas análises concluídas, será realizada a comparação entre as Equações 4.8 e 4.9, utilizando o algoritmo GA para uma e o NSGA-II para outra. Foram realizadas 50 execuções para cada algoritmo, em cada cenário e para cada MG, totalizando 800 execuções. O objetivo dessa etapa é avaliar o comportamento das formulações propostas e identificar qual delas apresenta melhor desempenho no contexto analisado.

4.3.4 Análise entre as Metodologias Mono-objetivo e Multi-objetivos

Para comparar as abordagens mono-objetivo e multi-objetivo, analisou-se a melhor solução obtida em cada execução do mono-objetivo em relação à fronteira de Pareto correspondente para os mesmos dias e MGs. Em seguida, avaliou-se a relação de dominância entre as soluções mono-objetivo e multi-objetivo.

Para isso, os dados foram categorizados em três grupos: 'Domina', 'É dominado' e 'Fronteira', conforme apresentado na Figura 15. Essas categorias representam a posição relativa das soluções mono-objetivo em relação ao conjunto de soluções ótimas na fronteira de Pareto.

Figura 15. Relação de dominância entre as soluções mono-objetivo e a fronteira de Pareto das execuções multi-objetivo, classificadas como 'Domina', 'É dominado' e 'Fronteira'



Fonte: Produzido Pelo Autor

A categoria 'Domina' corresponde aos casos em que a solução mono-objetivo

supera todas as soluções da fronteira de Pareto, evidenciando um desempenho superior à abordagem multi-objetivo nesses casos. Por sua vez, a categoria 'É dominado' refere-se às situações em que a solução mono-objetivo é superada por pelo menos uma das soluções pertencentes à fronteira multi-objetivo. Já a categoria 'Fronteira' representa os casos em que a solução mono-objetivo pertence à própria fronteira de Pareto, configurando-se como uma solução eficiente, embora sem dominar todas as demais.

Por fim, realiza-se a comparação entre todos os casos mono-objetivo e multi-objetivo, ou seja, todas as 50 execuções do mono-objetivo são comparadas com as 50 execuções do multi-objetivo, analisando-se a distribuição percentual das três categorias ao longo das simulações, o que permite uma avaliação mais abrangente dos desempenhos das abordagens mono-objetivo e multi-objetivo.

4.4 Considerações Finais

Este capítulo abordou a formulação matemática aplicada ao problema de gerenciamento de MGs, destacando os principais desafios e limitações encontrados na modelagem tradicional. Foi discutido o problema da consideração dos custos de operação e manutenção (O&M) dos dispositivos não despacháveis (DND), bem como a relação entre os custos financeiros e as emissões de CO_2 .

Nesses casos, pode ocorrer uma ausência de diversidade entre as soluções, o que pode levar a resultados enviesados, nos quais os custos e as emissões caminham na mesma direção. Essa característica dificulta a eficácia de algoritmos de otimização multi-objetivo, que dependem da existência de *trade-offs* claros entre os objetivos. Foram também discutidas possíveis soluções para mitigar esses problemas, como o balanceamento adequado dos termos da função objetivo e a adaptação da formulação matemática ao contexto analisado.

Na sequência, foi apresentado o procedimento adotado para os testes de avaliação do desempenho das formulações propostas. Esses testes foram realizados em quatro diferentes MGs, propostas por Alam, Chakrabarti e Liang (2020) operando de forma isolada, com o objetivo de verificar a robustez e a aplicabilidade dos modelos. Foram utilizados dois algoritmos de otimização: o AG, representando a abordagem mono-objetivo, e o NSGA-II, representando a abordagem multi-objetivo.

A análise dos resultados contemplará tanto a formulação matemática tradicional quanto a versão proposta neste trabalho, com o objetivo de identificar melhorias no desempenho e na representação do problema real. Inicialmente, será realizada uma análise de complexidade para avaliar os impactos da inclusão dos custos de O&M dos DND. Em seguida, serão examinados os resultados obtidos a partir do processo de otimização mono-objetivo, assim como o tempo de execução associado, visando compreender o custo computacional envolvido em cada abordagem.

Por fim, serão realizados testes preliminares com as formulações multiobjetivo, a fim de verificar a viabilidade e coerência das propostas. Por fim, será adotada uma metodologia comparativa entre as abordagens mono e multiobjetivo, utilizando métricas baseadas em dominância, como as categorias “Domina”, “É dominado” e “Fronteira”, já discutidas anteriormente. Essa comparação tem como objetivo avaliar o potencial de cada abordagem na representação de soluções eficientes para o gerenciamento energético de MGs, tanto em ambientes com uma única fonte geradora poluente quanto com múltiplas fontes geradoras poluentes.

5 Resultado e Discussão

5.1 Análise do Número de Operações das Formulações

Para avaliar a influência dos custos de O&M dos DNDs no gerenciamento de MGs, conforme descrito na Seção 4.2.1, foi comparado o Número de Operações de duas formulações matemáticas para o cálculo do custo total (C_{total}) no gerenciamento de MGs. A Equação 4.5 inclui três somatórios: um para os DD, um para os DNDs e outro para outros dispositivos da MG. Já a Equação (4.6) simplifica a expressão ao remover o somatório sobre os DNDs, reduzindo, assim, o número de operações necessárias.

Na Equação 4.5, para cada período de tempo t , o primeiro somatório sobre os geradores despacháveis (i) envolve duas operações por gerador (uma para os custos de combustível e outra para os custos de O&M). O segundo somatório, referente aos DNDs (j), envolve apenas uma operação por gerador (custos de O&M), enquanto o terceiro somatório, referente a outros dispositivos da MG (k), também envolve uma operação por dispositivo.

O número total de operações para essa formulação é proporcional a:

$$W * (2D + N + M) \quad (5.1)$$

onde W representa o número de períodos de tempo, D é o número de geradores despacháveis, N é o número de DNDs e M é o número de outros dispositivos da MG.

Na formulação simplificada (Equação 4.6), para cada período de tempo j , o somatório sobre os geradores despacháveis (i) envolve duas operações por gerador (custos de combustível e custos de O&M dos DGs) e uma operação para os outros dispositivos da MG.

O número total de operações para essa formulação simplificada é:

$$W * (2D + M) \quad (5.2)$$

A Equação 4.5 exige mais operações computacionais do que a Equação 4.6 devido ao somatório adicional sobre N , que introduz operações extras. Ao excluir os custos dos DNDs, a Equação 4.6 resulta em um menor número de operações e se torna computacionalmente mais eficiente. Essa simplificação leva à redução do tempo de execução, especialmente à medida que o número de DNDs aumenta.

5.2 Avaliação do Impacto dos Custos de O&M dos Dispositivos Não-Despacháveis na Otimização

Para avaliar essa questão, foram realizados testes comparativos em dois cenários distintos. No primeiro cenário, os custos de O&M dos DNDs foram incluídos (Equação 4.5), enquanto no segundo cenário, esses custos foram excluídos (Equação 4.6). Foram executadas cinquenta simulações para cada cenário e para cada MG.

Os resultados foram submetidos a uma análise estatística por meio do teste t de Student, utilizado para avaliar a significância das diferenças entre os cenários analisados. Esse teste determina se as diferenças observadas nas médias são estatisticamente relevantes. Ele retorna dois valores principais:

- Valor de p (p -value): Indica se há uma diferença significativa entre os dados observados. Caso o p -value seja maior que o nível de significância adotado (geralmente 5%), conclui-se que não há diferença estatisticamente significativa entre os grupos comparados;
- Estatística t : Representa a diferença entre as médias dos dois grupos, expressa em unidades do erro padrão. Necessário somente quando existe uma diferença significativa entre os grupos.

Os resultados dos p -values do teste t são apresentados na Tabela 4, comparando os valores obtidos nas formulações das Equações 4.5 e 4.6 com os custos de O&M dos DNDs somados após o processo de otimização.

Tabela 4. Resultados do p -value para o Teste t -student

	07/01	27/03	10/07	14/09
MG01	6,66%	55,05%	72,01%	58,21%
MG02	46,71%	20,93%	25,90%	74,04%
MG03	52,88%	89,25%	44,57%	15,14%
MG04	43,99%	62,59%	75,05%	90,50%

Fonte: Produzido Pelo Autor

Os resultados do teste t de Student indicam que não houve diferença estatisticamente significativa entre os valores em todos os cenários, uma vez que nenhum valor de p excedeu o limite de 5%. Dessa forma, o cálculo dos custos de O&M dos DNDs durante o processo de otimização revelou-se dispensável.

Ao analisar os graus de liberdade, que representam a quantidade de valores independentes que podem variar em um conjunto de dados após a imposição de restrições,

é possível compreender a flexibilidade estatística do modelo e a confiabilidade das inferências realizadas. Em cada um dos testes apresentados, foram realizadas 50 execuções independentes, resultando em graus de liberdade iguais a 49 ($df = N - 1 = 50 - 1$) para o teste *t-student*.

Com base nesse valor de $df = 49$, adota-se um intervalo crítico de $[-2,0096, 2,0096]$ para um teste bilateral com nível de significância de 5%. Isso significa que, para que se considere que não há diferença estatisticamente significativa entre as médias das duas formulações matemáticas comparadas, a estatística *t* deve se situar dentro desse intervalo. Conforme ilustrado na Tabela 5, todos os valores de *t* calculados para as diferentes datas e MGs permanecem dentro desse intervalo crítico. Esses resultados indicam que, em nenhuma das situações avaliadas, foi identificada diferença estatisticamente significativa entre as médias, o que evidencia a similaridade de desempenho entre as formulações testadas sob as condições analisadas.

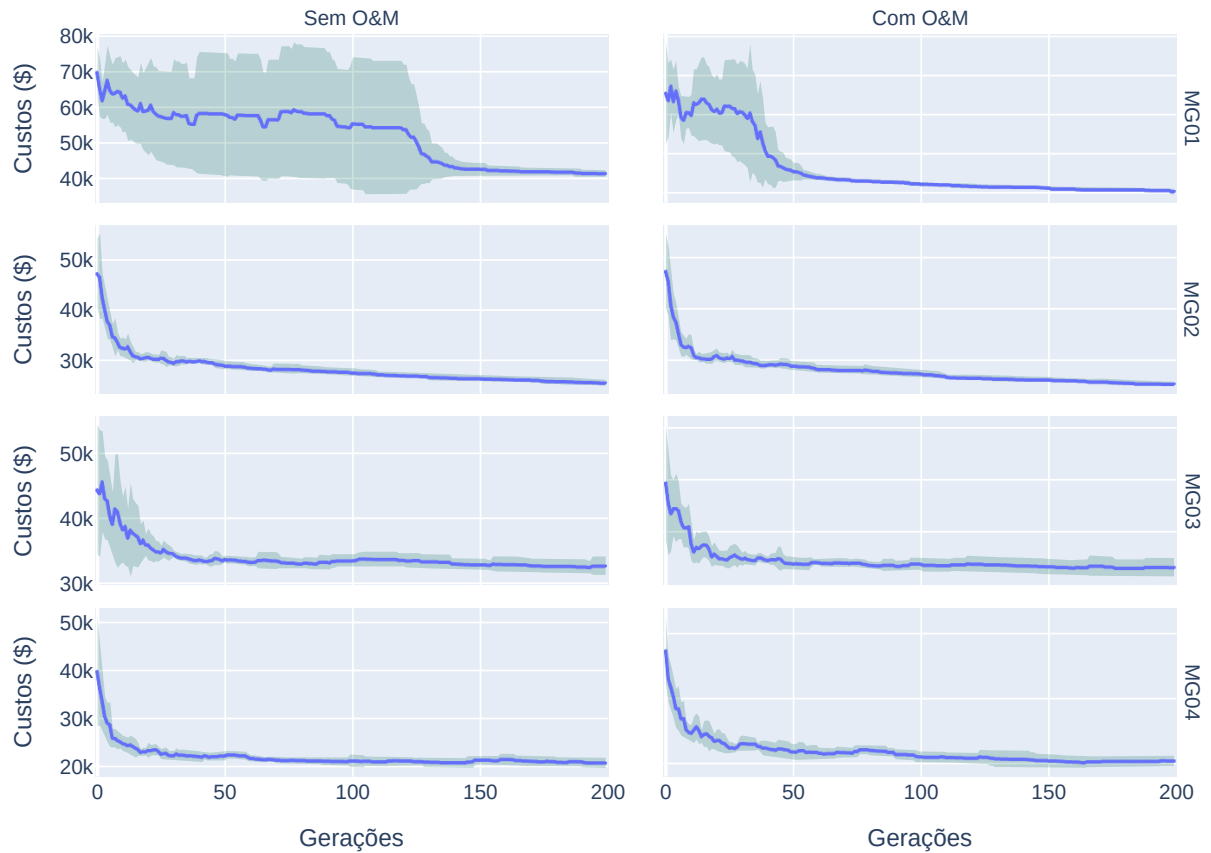
Tabela 5. Estatísticas *t* calculadas para cada teste com $df = 49$

	07/01	27/03	10/07	14/09
MG01	-1,996	0,627	0,394	-0,582
MG02	-0,743	1,302	-1,166	-0,336
MG03	0,642	0,137	0,780	1,498
MG04	-0,790	0,496	0,323	0,121

Fonte: Produzido pelo Autor

A Figura 16 ilustra a evolução média de todos os casos avaliados, destacando os desvios padrão de cada grupo, apresentando de forma visual que a diferença final entre eles não é significativa.


Figura 16. Comparação da evolução dos cenários de custo operacional médio (destacando os desvios padrão em verde):



Fonte: Produzido Pelo Autor

A comparação do tempo médio de execução entre as duas abordagens é apresentada na Figura 17, que exhibe o tempo médio ao longo das 50 simulações para ambos os métodos, juntamente com o erro médio representado em preto. A inclusão dos custos de O&M introduz um acréscimo computacional médio de aproximadamente 25 segundos no tempo de execução. Em ambientes com recursos computacionais limitados, essa diferença torna-se significativamente mais pronunciada, destacando os potenciais benefícios da simplificação proposta para aprimorar a eficiência computacional em condições restritas.

Figura 17. Tempo de Execução das abordagens com e sem os custos de O&M dos DNDs.



Fonte: Produzido Pelo Autor

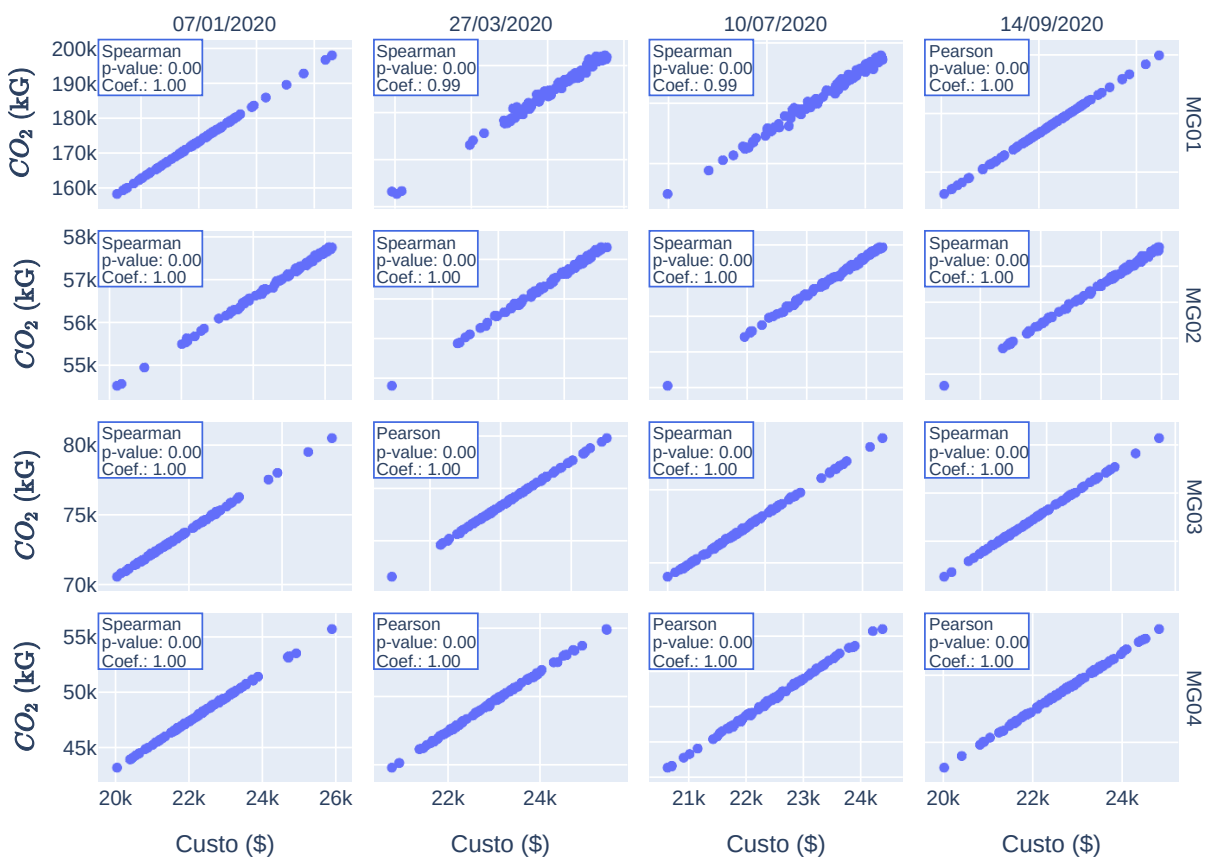
5.3 Análise Comparativa das Metodologias Proposta e da Literatura

Nesta seção, serão apresentados os gráficos de dispersão correspondentes à última geração de cada abordagem. Cada figura exibirá o tipo de correlação utilizado, previamente selecionado com base na distribuição dos dados. Se os dados apresentarem uma distribuição aproximadamente normal, será utilizado o coeficiente de correlação de Pearson; caso contrário, será empregado o coeficiente de Spearman. Além disso, serão fornecidos o *p-value* e o coeficiente de correlação correspondente em cada figura.

5.3.1 Microrrede com uma única fonte geradora poluente

Nas Figuras 18 e 19, é possível observar o comportamento da relação entre os objetivos na metodologia da literatura e na metodologia proposta, considerando uma única fonte geradora. No primeiro caso, nota-se uma forte correlação entre os objetivos, sem qualquer relação contraditória entre eles, o que inviabiliza essa formulação para algoritmos multi-objetivo baseados em Pareto.

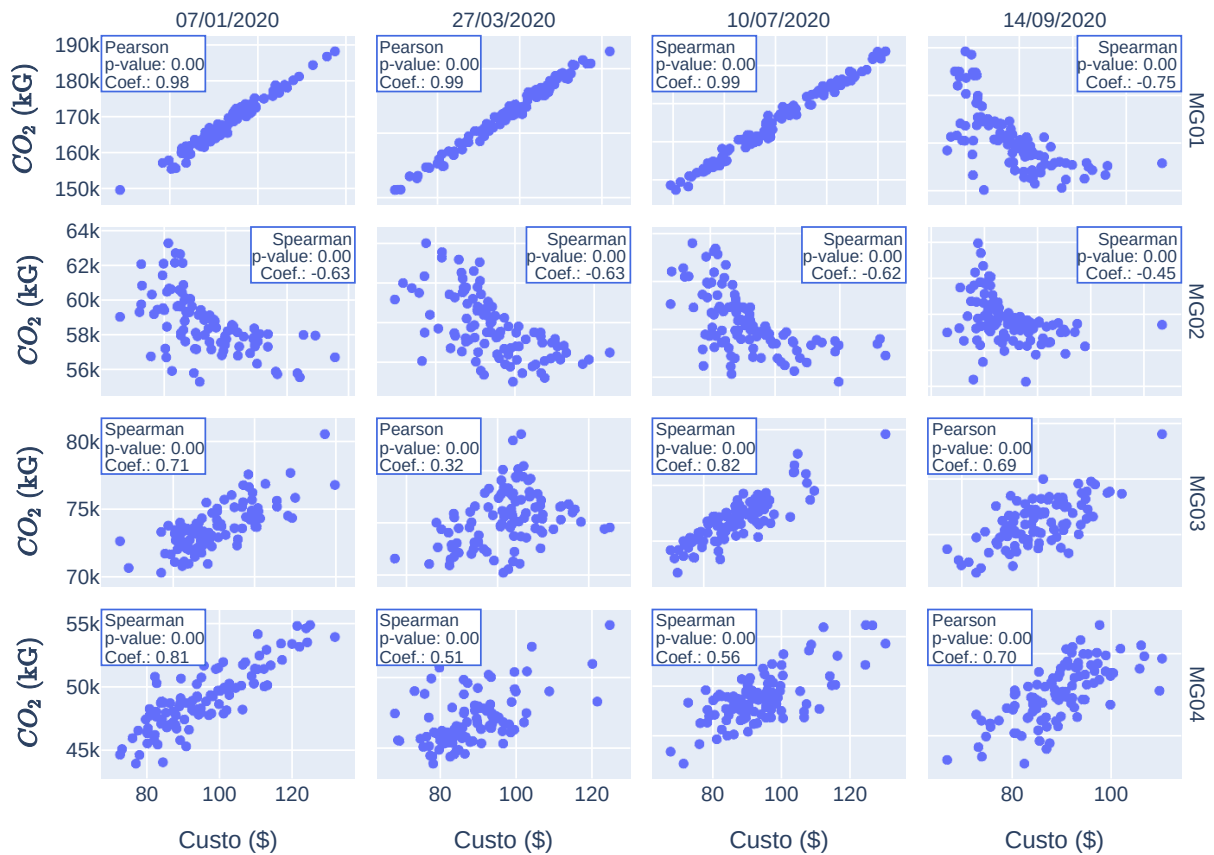
Figura 18. Dispersão da metodologia da literatura (Equação 4.7) para uma única fonte geradora poluente.



Fonte: Produzido Pelo Autor

Por outro lado, na metodologia proposta, essa característica não se mantém,

Figura 19. Dispersão da metodologia proposta (Equação 4.8) para uma única fonte geradora poluente.



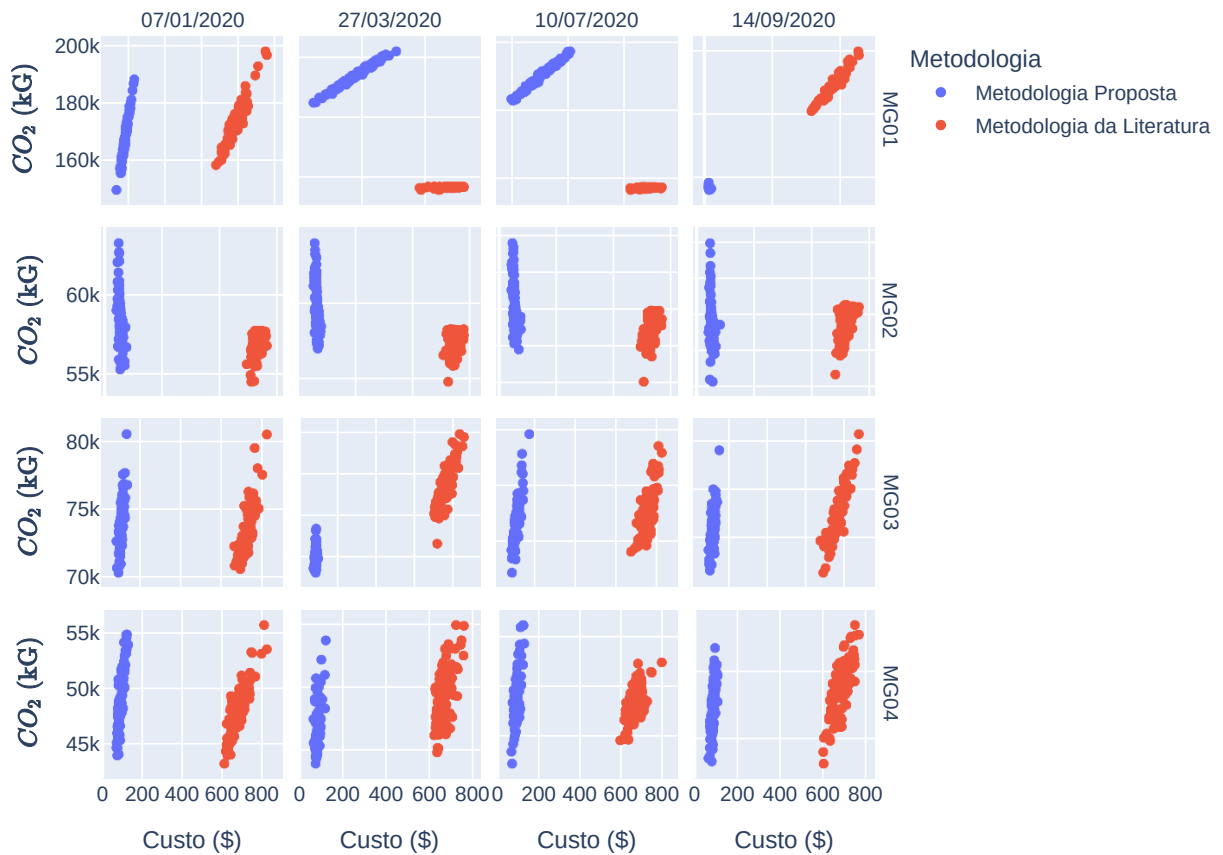
Fonte: Produzido Pelo Autor

resultando em soluções significativamente mais dispersas e melhor distribuídas no espaço de soluções. Embora algumas soluções ainda apresentem um comportamento linear (como ocorre em alguns dias na MG01), a comparação com a metodologia da literatura evidencia uma maior diversidade e dispersão nos resultados obtidos.

Os resultados apresentados na Figura 20 apresentam uma comparação lado a lado das duas metodologias apresentadas para uma única fonte geradora poluente, permitindo uma análise mais detalhada do desempenho de ambas as abordagens.

Como observado, a metodologia da literatura gera valores significativamente inferiores quando comparada com a metodologia proposta, especialmente no que diz respeito aos custos operacionais. Ainda que, em alguns cenários, a metodologia da literatura apresente uma leve vantagem em relação às emissões, essa melhoria não se traduz em uma otimização eficiente do problema de custo-emissões.

Figura 20. Dispersão da metodologia da literatura e proposta para uma única fonte geradoras poluentes.




Fonte: Produzido Pelo Autor

5.3.2 Microrrede com múltiplas fontes geradoras poluentes

Nas Figuras 21 e 22, são apresentados os mesmos resultados discutidos anteriormente, porém considerando cenários com múltiplos geradores poluentes, tanto para a metodologia da literatura quanto para a metodologia proposta. Observa-se que, em ambos os casos, há uma distribuição mais ampla das soluções no espaço de busca, indicando que a introdução de múltiplas fontes poluentes impacta a relação entre custo e emissões.

Figura 21. Dispersão da metodologia da literatura (Equação 4.7) para múltiplas fontes geradoras poluentes.



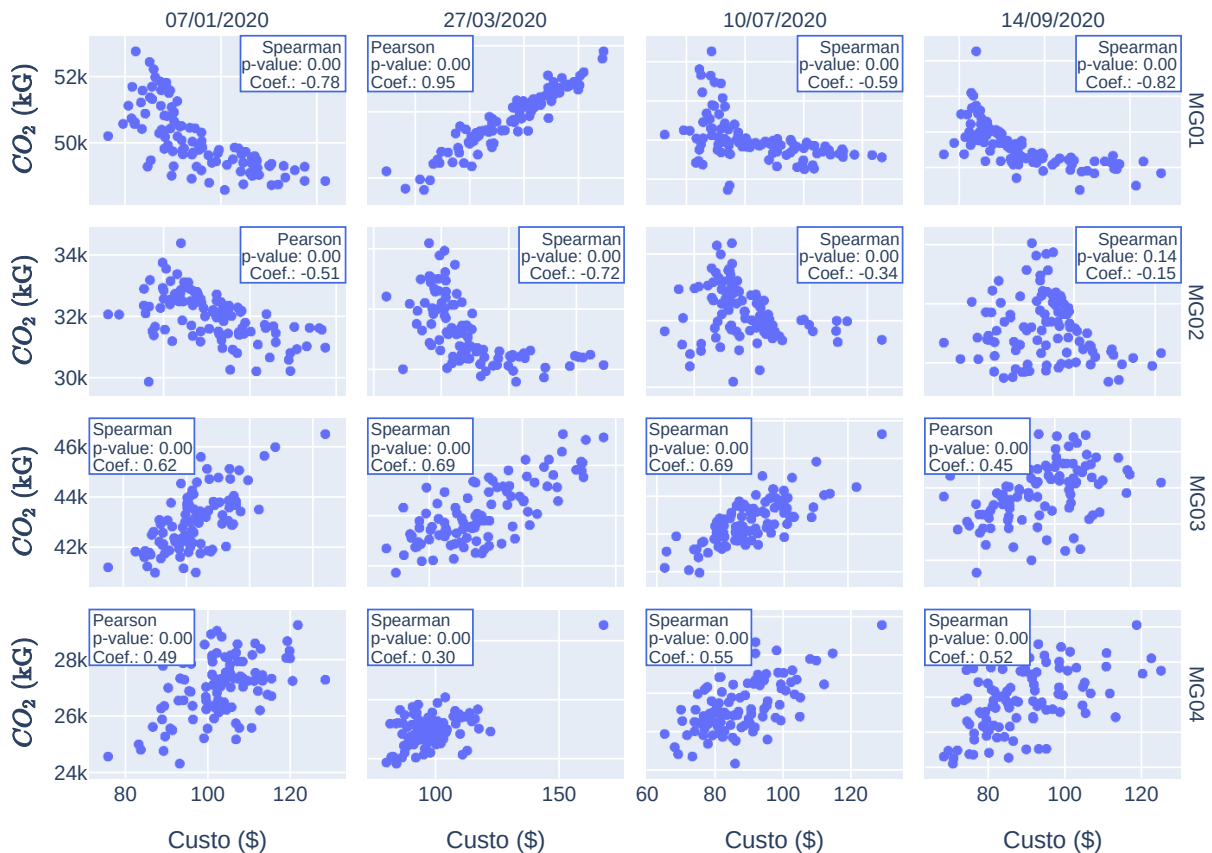
Fonte: Produzido Pelo Autor

No entanto, ao analisar a dispersão dos pontos gerados, percebe-se que a metodologia proposta apresenta uma distribuição significativamente mais abrangente em comparação à metodologia da literatura. Isso sugere que a formulação matemática revisada permite explorar uma gama mais ampla de soluções possíveis, tornando o problema mais adequado para otimização multiobjetivo baseada em Pareto.

Por outro lado, a metodologia da literatura, embora ainda viável para sistemas com múltiplos geradores poluentes, apresenta uma estrutura mais rígida, resultando em uma menor dispersão das soluções. Essa característica limita a eficácia de algoritmos de otimização multiobjetivo, especialmente em situações onde é desejável explorar um espaço de soluções mais diversificado.

Essas limitações tornam-se ainda mais evidentes ao comparar diretamente os resultados da metodologia da literatura com os da metodologia proposta. A Figura 23 apresenta essa comparação lado a lado. Assim como ocorre na análise com uma única fonte poluente, a metodologia da literatura continua gerando valores significativamente inferiores quando comparada com a metodologia proposta, especialmente no que diz respeito aos custos operacionais.

Figura 22. Dispersão da metodologia proposta (Equação 4.8) para múltiplas fontes geradoras poluentes.



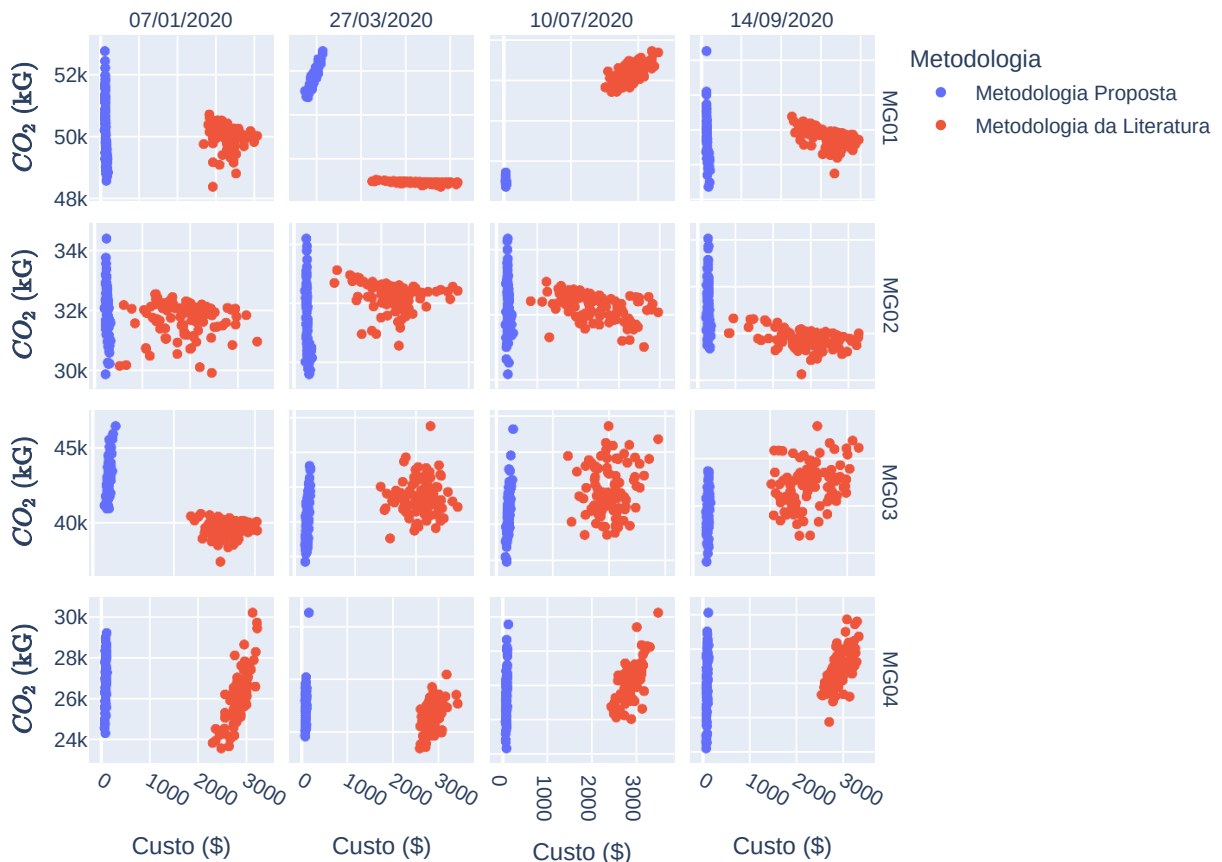
Fonte: Produzido Pelo Autor

Vale ressaltar que a principal finalidade dos algoritmos de otimização multiobjetivo é encontrar um conjunto de soluções que equilibrem adequadamente os custos e as emissões. No entanto, a metodologia da literatura demonstra uma incapacidade de gerar soluções competitivas nesse sentido, pois suas formulações limitam a diversidade dos pontos encontrados no espaço de soluções.

Mesmo em cenários com múltiplos geradores poluentes, onde teoricamente a metodologia da literatura poderia apresentar um desempenho mais adequado, os resultados indicam que a abordagem proposta ainda é superior. Isso evidencia que a formulação matemática da metodologia da literatura pode estar restringindo a exploração de soluções economicamente viáveis sem comprometer excessivamente as emissões.

Assim, os resultados reforçam a necessidade de aprimorar a modelagem do problema para garantir que as soluções obtidas representem melhor a realidade da operação de MGs isoladas, proporcionando um equilíbrio mais adequado entre custo e emissões. A metodologia proposta, ao ampliar a dispersão dos resultados e permitir uma melhor exploração do espaço de soluções, demonstra ser mais eficaz para problemas de otimização multiobjetivo nesse contexto.

Figura 23. Dispersão da metodologia da literatura e proposta para múltiplas fontes geradoras poluentes.



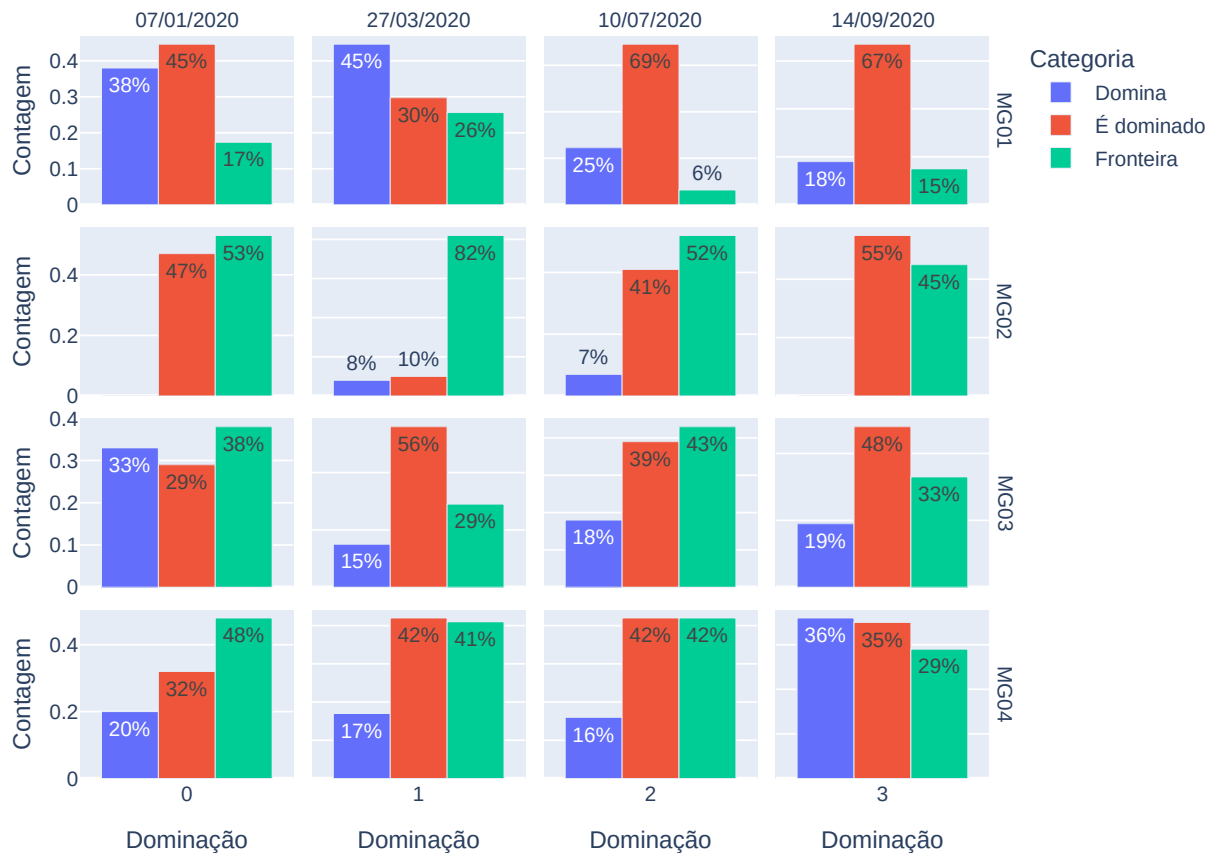
5.4 Análise relação Mono-objetivo e Multi-objetivo

Nesta seção, serão comparados os resultados entre as abordagens mono-objetivo e multi-objetivo. Para essa análise, como detalhado na Seção 4.3.4, cada solução mono-objetivo foi comparada com todas as fronteiras geradas, considerando cada dia e cada MG.

Os resultados para a abordagem com um único gerador poluente são apresentados na Figura 24. Nessa abordagem, a relação entre as soluções mono-objetivo e a fronteira de Pareto varia conforme as condições operacionais de cada MG. Por exemplo, na MG04, em 07/01/2020, observa-se que 20% das soluções mono-objetivo dominam a fronteira de Pareto, 32% são dominadas por ela e 48% pertencem diretamente à fronteira. Em contraste, na MG02, no mesmo período, nenhuma solução mono-objetivo domina a fronteira, enquanto 47% são dominadas e 53% pertencem à fronteira.

Além disso, os resultados indicam que, mesmo dentro da mesma MG, o desempenho relativo da abordagem mono-objetivo pode variar na mesma MG. Por exemplo, na MG01, em 07/01/2020, 38% das soluções mono-objetivo dominam a fronteira de Pareto, enquanto

Figura 24. Relação entre as soluções mono-objetivo e a fronteira de Pareto na abordagem com um único gerador poluente.




Fonte: Produzido Pelo Autor

em 10/07/2020 esse percentual reduz para cerca de 25%, sugerindo uma mudança na eficácia da abordagem ao longo dos períodos analisados.

Já para a abordagem com múltiplos geradores poluentes, os resultados são apresentados na Figura 25. Ao analisar os dados das diferentes MGs nos quatro dias selecionados, percebe-se que a relação entre a abordagem mono-objetivo e a fronteira de Pareto variam conforme as condições operacionais da MG. Por exemplo, na MG04, em 07/01/2020, observa-se que 22% das soluções mono-objetivo dominam a fronteira de Pareto, 38% são dominadas por ela e 40% pertencem diretamente à fronteira. Já na MG02, no mesmo período, o comportamento é distinto, com apenas 3% das soluções mono-objetivo dominando a fronteira, enquanto 39% são dominadas e 58% pertencem à fronteira.

Mesmo dentro de uma mesma MG, os resultados podem variar em função dos valores de geração e carga. Por exemplo, na MG01, observa-se que, em 07/01/2020, aproximadamente 31% das soluções mono-objetivo dominam a fronteira de Pareto, enquanto em 10/07/2020 esse valor cai para 9%, indicando uma mudança na eficiência relativa da abordagem mono-objetivo nesse intervalo.

Figura 25. Relação entre as soluções mono-objetivo e a fronteira de Pareto na abordagem com múltiplos geradores poluentes.



Fonte: Produzido Pelo Autor

5.5 Discussão dos resultados

As análises conduzidas foram baseadas em diversas formulações matemáticas e abordagens de otimização, utilizando ferramentas computacionais para calcular os despachos de energia e validar as restrições operacionais. O objetivo dos testes foi avaliar o impacto das propostas na redução de custos, emissões de poluentes e eficiência computacional, proporcionando uma visão crítica sobre o desempenho e a aplicabilidade das soluções propostas.

5.5.1 Custos de O&M dos Dispositivos Não-Despacháveis

Quanto à inclusão dos custos de operação e manutenção (O&M) para os DNDs, os resultados indicaram que a remoção desses custos da função objetivo durante o processo de otimização não impactou os resultados obtidos, conforme evidenciado pela análise do Número de Operações (Seção 5.1), análise estatística (Seção 4) e visualizações (Figura 16). Esse achado sugere que é viável excluir esses custos fixos da formulação inicial, simplificando o modelo matemático sem comprometer a qualidade das soluções geradas.

Além disso, a Figura 17 evidencia o impacto da inclusão desses custos no tempo de execução. Os testes foram conduzidos em um computador com altos recursos computacionais e, mesmo assim, observou-se uma diferença considerável no tempo de processamento (aproximadamente 25 segundos). Isso sugere que, em ambientes com recursos computacionais limitados, essa diferença se tornaria ainda mais relevante. Nesses cenários, além do processo de otimização, o sistema precisaria lidar com outras demandas de gerenciamento, como, por exemplo, previsão de cargas e geração, alocação dinâmica de cargas ou controle de resposta à demanda.

Dessa forma, a remoção dos custos de O&M dos DNDs se mostrou uma estratégia eficiente para a gestão de MGs isoladas, garantindo um equilíbrio entre desempenho e viabilidade computacional.

5.5.2 Comparação das Modelagem Multi-objetivos

No que diz respeito à interação entre custos e emissões, a utilização da Equação 4.7 mostrou-se ineficiente no processo de otimização multi-objetivo quando há apenas uma única fonte geradora poluente, exigindo modificações na formulação matemática para aprimorar os resultados. Isso pode ser observado na Figura 18, onde a alta linearidade entre os objetivos indica uma ausência significativa de conflito entre eles.

Nessas condições, o NSGA-II se comporta de forma semelhante a um algoritmo mono-objetivo. Embora ainda consiga realizar o processo de otimização, a utilização de um algoritmo multi-objetivo implica um consumo excessivo de recursos computacionais, uma vez que tais algoritmos são, em geral, mais complexos do que algoritmos mono-objetivo. Além disso, esse comportamento particular do NSGA-II decorre do fato de que, na ausência de uma relação clara de troca entre os objetivos, ele tende a atuar como um algoritmo mono-objetivo.

Entretanto, essa característica não se aplica a todas as abordagens de otimização baseadas em Pareto. Se forem utilizados outros métodos que dependem fortemente da relação de comprometimento entre os objetivos, é possível que a otimização não ocorra de maneira eficiente, ou até mesmo que o processo falhe em gerar soluções adequadas. Isso reforça a necessidade de ajustes na formulação matemática para lidar corretamente com cenários em que há apenas uma fonte geradora poluente.

Quando comparada à metodologia proposta (Figura 19), essa diferença se torna ainda mais evidente, pois a nova abordagem permitiu uma distribuição mais ampla das soluções no espaço de busca para esse cenário. Isso evidencia uma melhor exploração do conjunto de soluções possíveis, além de aprimorar a eficiência do processo de otimização.

Com relação aos testes conduzidos em ambientes com múltiplos geradores poluentes, a metodologia da literatura conseguiu gerar dados mais abrangentes (Figura 21); no entanto,

a metodologia proposta obteve uma abrangência ainda maior nos resultados (Figura 22).

Embora, nesse cenário, a metodologia da literatura gere soluções mais dispersas, a comparação dos resultados com a metodologia proposta evidencia uma vantagem significativa desta última em ambos os casos, como demonstrado nas Figuras 20 e 23. A metodologia proposta apresenta uma diferença expressiva em relação à abordagem da literatura, indicando que uma formulação matemática adequada não apenas reduz os custos computacionais — considerando que ambas foram executadas com os mesmos parâmetros do NSGA-II —, mas também proporciona resultados mais robustos e abrangentes.

5.5.3 Comparação Entre as Abordagens Mono-objetivo e Multi-objetivo

Tendo demonstrado que a formulação multiobjetivo proposta superou a metodologia da literatura, a próxima etapa consistiu na comparação entre as metodologias mono-objetivo (Equação 4.9) e multi-objetivo (Equação 4.8) propostas. Os resultados dessa análise foram apresentados nas Figuras 24 e 25. Em ambos os casos, pode-se observar o comportamento da melhor solução da otimização mono-objetivo em relação à fronteira de Pareto obtida pela abordagem multi-objetivo.

Em determinados cenários, há uma predominância da metodologia mono-objetivo, como no caso de um único tipo de gerador poluente na MG01, nos dias 07/01/2020 e 27/03/2020. Nesses casos, a solução gerada pela otimização mono-objetivo domina toda a fronteira de Pareto ou faz parte dela. Já em outras situações, observa-se a superioridade da abordagem multiobjetivo, como ocorre na mesma MG01 nos outros dois dias analisados.

Quando se introduzem múltiplas fontes geradoras poluentes, há uma tendência de maior predominância dos resultados da abordagem multi-objetivo. Isso pode estar relacionado à maior complexidade da relação entre custos e emissões nesses cenários. Assim, os resultados indicam que a abordagem multi-objetivo é a mais adequada para a otimização na maioria dos casos, apresentando um melhor desempenho geral.

Contudo, a otimização mono-objetivo não deve ser descartada. Devido à sua menor complexidade, essa abordagem pode ser vantajosa em ambientes com recursos computacionais mais limitados, pois, embora não apresente os melhores resultados, ainda é capaz de produzir soluções satisfatórias. Além disso, por reduzir o número de objetivos, essa abordagem pode ser implementada com algoritmos de otimização menos complexos, resultando em maior velocidade na execução. Caso novos objetivos sejam introduzidos, a abordagem mono-objetivo permite reduzir a complexidade global do problema, facilitando a otimização da gestão das MGs.

Portanto, a escolha entre as abordagens deve ser guiada pelas prioridades do projeto, como simplicidade e eficiência ou diversidade de soluções. Enquanto a abordagem mono-objetivo é mais adequada para soluções rápidas e de baixo custo computacional, a

abordagem multi-objetivo continua sendo essencial para lidar com múltiplos critérios e fontes geradoras heterogêneas. A decisão final sobre a abordagem mais apropriada deve levar em consideração as demandas específicas de cada projeto, alinhando-se aos critérios técnicos e operacionais previamente estabelecidos.

Dessa forma, esses achados ressaltam a importância da escolha criteriosa da estratégia de otimização com base nas restrições e objetivos específicos de cada implementação de MG.

6 Conclusão

Neste trabalho, foram analisadas e comparadas diferentes formulações matemáticas para a otimização da operação de MGs, considerando abordagens mono-objetivo e multi-objetivo. A partir dos resultados obtidos, verificou-se que a formulação multi-objetivo proposta supera a metodologia da literatura, permitindo uma distribuição mais abrangente das soluções no espaço de busca e melhorando a eficiência do processo de otimização.

Com relação à interação entre custos e emissões, a formulação multi-objetivo da literatura apresentou limitações quando aplicada a sistemas com um único tipo de gerador poluente, exigindo ajustes na modelagem para melhorar os resultados. As modificações propostas tornaram a abordagem mais eficiente, garantindo uma melhor exploração do conjunto de soluções possíveis e reduzindo a complexidade computacional.

A análise comparativa entre as metodologias mono-objetivo e multi-objetivo mostrou que, em alguns cenários, a abordagem mono-objetivo pode ser vantajosa, especialmente quando se busca rapidez e baixo custo computacional. No entanto, em contextos com múltiplos geradores poluentes, a formulação multi-objetivo demonstrou melhor desempenho, possibilitando uma maior diversidade de soluções e permitindo um melhor equilíbrio entre custo e emissão de poluentes.

Além disso, observou-se que a inclusão dos custos de operação e manutenção (O&M) dos DNDs não impactou significativamente os resultados finais, sugerindo que tais custos podem ser excluídos da formulação dos custos. Essa simplificação também reduziu o tempo de execução, tornando-o mais eficiente, especialmente em ambientes com recursos computacionais limitados.

Dessa forma, a escolha entre abordagens mono-objetivo e multi-objetivo deve ser guiada pelas necessidades específicas de cada projeto. A abordagem mono-objetivo é recomendada para cenários que exigem soluções rápidas e menos custosas computacionalmente, enquanto a abordagem multi-objetivo é essencial para sistemas que necessitam de uma maior diversidade de soluções e um melhor controle sobre as decisões de geração e emissão.

6.1 Proposta de Trabalhos Futuros

Como continuidade, planeja-se investigar o impacto dessas modificações em MGs conectadas à rede, onde a interação entre a geração local e a rede principal introduz restrições operacionais adicionais e desafios de otimização. Além disso, trabalhos futuros explorarão a modelagem de outros objetivos, como minimização de perdas, controle de tensão e ampliação da vida útil dos dispositivos da MG. Ao incorporar esses aspectos, a

metodologia proposta poderá ser ainda mais aprimorada para aumentar a confiabilidade do sistema, melhorar a qualidade da energia e otimizar a eficiência operacional no longo prazo.

Também poderão ser analisados outros aspectos relacionados aos custos e seus impactos no gerenciamento, como o custo de aquisição ou financiamento de equipamentos. Além disso, será importante avaliar se o transporte de combustíveis — como o diesel, a biomassa e o hidrogênio — introduz impactos significativos nos custos operacionais e logísticos das MGs, especialmente em regiões remotas ou com infraestrutura limitada. Esses avanços contribuirão para expandir a aplicabilidade e a robustez das soluções desenvolvidas, tornando-as mais adequadas a uma ampla gama de configurações reais de MGs.

Como perspectiva futura, os métodos e resultados apresentados neste trabalho poderão ser empregados como base para o dimensionamento de MGs, oferecendo subsídios técnicos na escolha de tecnologias, estratégias operacionais e avaliação de desempenho. Além disso, destaca-se o potencial de aplicação prática em MGs reais no Brasil, como em comunidades isoladas no interior da Amazônia ou em sistemas insulares como o de Fernando de Noronha, onde a gestão energética eficiente e sustentável é crucial. Essas extensões permitirão validar o modelo proposto em contextos reais e desafiadores.

6.2 Artigo Publicado

Batista, V. d. S., Soares, T. M., Tostes, M. E. d. L., Bezerra, U. H., & Lott, H. G. 2025. *Mathematical Formulation of Intelligent Management Algorithms for Isolated Microgrids: A Pareto-Based Critical Approach*. *Energies*, 18(6), 1487.
<https://doi.org/10.3390/en18061487>

Referências

- AGHAJANI, G. R.; SHAYANFAR, H. A.; SHAYEGHI, H. Presenting a multi-objective generation scheduling model for pricing demand response rate in micro-grid energy management. *Energy Conversion and Management*, Elsevier Ltd, v. 106, p. 308–321, 2015. ISSN 01968904. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0196890415008134>>. Citado 3 vezes nas páginas 28, 36 e 55.
- AGÜERA-PÉREZ, A.; PALOMARES-SALAS, J. C.; ROSA, J. J. G. de la; FLORENCIAS-OLIVEROS, O. Weather forecasts for microgrid energy management: Review, discussion and recommendations. *Applied Energy*, Elsevier, v. 228, p. 265–278, 2018. ISSN 03062619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2018.06.087>>. Citado 2 vezes nas páginas 16 e 17.
- AKTER, A.; ZAFIR, E. I.; DANA, N. H.; JOYSOYAL, R.; SARKER, S. K.; LI, L.; MUYEEN, S. M.; DAS, S. K.; KAMWA, I. *A review on microgrid optimization with meta-heuristic techniques: Scopes, trends and recommendation*. [S.l.]: Elsevier Ltd, 2024. Citado 2 vezes nas páginas 21 e 31.
- ALAM, M. N.; CHAKRABARTI, S.; LIANG, X. A benchmark test system for networked microgrids. *IEEE Transactions on Industrial Informatics*, IEEE, v. 16, p. 6217–6230, 2020. ISSN 19410050. Citado 5 vezes nas páginas 59, 60, 61, 62 e 67.
- ALDOSARY, A. Optimizing economic dispatch with renewable energy and natural gas using fractional-order fish migration algorithm. *Fractal and Fractional*, Multidisciplinary Digital Publishing Institute (MDPI), v. 8, 6 2024. ISSN 25043110. Citado 2 vezes nas páginas 30 e 31.
- ANVARI-MOGHADDAM, A.; RAHIMI-KIAN, A.; MIRIAN, M. S.; GUERRERO, J. M. A multi-agent based energy management solution for integrated buildings and microgrid system. *Applied Energy*, Elsevier Ltd, v. 203, p. 41–56, 2017. ISSN 03062619. Disponível em: <<http://dx.doi.org/10.1016/j.apenergy.2017.06.007>>. Citado 2 vezes nas páginas 17 e 38.
- ARUNKUMAR, A. P.; KUPPUSAMY, S.; MUTHUSAMY, S.; PANDIYAN, S.; PANCHAL, H.; NAGAIYAN, P. *An extensive review on energy management system for microgrids*. [S.l.]: Taylor and Francis Ltd., 2022. 4203-4228 p. Citado na página 21.
- BEKTAS, Z.; KAYAKUTLU, G. Review and clustering of optimal energy management problem studies for industrial microgrids. *International Journal of Energy Research*, v. 45, p. 103–117, 2021. ISSN 1099114X. Citado na página 37.
- Blank, J.; Deb, K. pymoo: Multi-objective optimization in python. *IEEE Access*, v. 8, p. 89497–89509, 2020. Citado na página 64.
- BOUDOUDOUH, S.; MAËROUFI, M. Multi agent system solution to microgrid implementation. *Sustainable Cities and Society*, v. 39, p. 252–261, 2018. ISSN 22106707. Citado na página 17.

BRUNI, G.; CORDINER, S.; MULONE, V.; ROCCO, V.; SPAGNOLO, F. A study on the energy management in domestic micro-grids based on model predictive control strategies q. *Energy Conversion and Management*, Elsevier Ltd, v. 102, p. 50–58, 2015. ISSN 01968904. Citado na página 40.

BUI, V.-H.; HUSSAIN, A.; KIM, H.-M. A multiagent-based hierarchical energy management strategy for multi-microgrids considering adjustable power and demand response. *IEEE Transactions on Smart Grid*, IEEE, v. 9, n. 2, p. 1323–1333, 2016. Citado na página 24.

CAMACHO, E. F.; ALBA, C. B. *Model predictive control*. [S.l.]: Springer science & business media, 2013. Citado na página 40.

CAO, Y.; ZHOU, B.; OR, S. W.; CHAN, K. W.; LIU, N.; ZHANG, K. An interactive tri-level multi-energy management strategy for heterogeneous multi-microgrids. *Journal of Cleaner Production*, Elsevier Ltd, v. 319, p. 128716, 2021. ISSN 09596526. Disponível em: <<https://doi.org/10.1016/j.jclepro.2021.128716>>. Citado 2 vezes nas páginas 17 e 24.

CARLI, R.; CAVONE, G.; EPICOCO, N.; SCARABAGGIO, P.; DOTOLI, M. Model predictive control to mitigate the covid-19 outbreak in a multi-region scenario. *Annual Reviews in Control*, Elsevier Ltd, v. 50, p. 373–393, 1 2020. ISSN 13675788. Citado na página 41.

CHOOBINEH, M.; MOHAGHEGHI, S. A multi-objective optimization framework for energy and asset management in an industrial microgrid. *Journal of Cleaner Production*, Elsevier Ltd, v. 139, p. 1326–1338, 2016. ISSN 09596526. Disponível em: <<http://dx.doi.org/10.1016/j.jclepro.2016.08.138>>. Citado na página 23.

COLE, W.; KARMAKAR, R. *Utility-Scale Battery Storage (2024 ATB)*. 2023. Disponível em: <<https://atb.nrel.gov/electricity/2024/index>>. Citado na página 63.

COMMISSION, J. R. C. E. *Definition and use of 2017 Covenant of Mayors default emission factors for EU countries*. 2017. Disponível em: <<https://publications.jrc.ec.europa.eu/repository/handle/JRC108655>>. Citado na página 63.

CONTE, F.; D'AGOSTINO, F.; PONGIGLIONE, P.; SAVIOZZI, M.; SILVESTRO, F. Mixed-integer algorithm for optimal dispatch of integrated pv-storage systems. *IEEE Transactions on Industry Applications*, IEEE, v. 55, p. 238–247, 2019. ISSN 19399367. Citado na página 34.

DEB, K. Multi-objective optimisation using evolutionary algorithms: an introduction. In: *Multi-objective evolutionary optimisation for product design and manufacturing*. [S.l.]: Springer, 2011. p. 3–34. Citado na página 46.

DEB, K.; GOEL, T. Controlled elitist non-dominated sorting genetic algorithms for better convergence. In: SPRINGER. *International conference on evolutionary multi-criterion optimization*. [S.l.], 2001. p. 67–81. Citado 2 vezes nas páginas 29 e 46.

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 6, p. 182–197, 2002. ISSN 1089778X. Citado 2 vezes nas páginas 52 e 53.

ELKHOLY, M. H.; SENJYU, T.; ELYMANY, M.; GAMIL, M. M.; TALAAT, M.; MASRUR, H.; UEDA, S.; LOTFY, M. E. Optimal resilient operation and sustainable power management within an autonomous residential microgrid using african vultures optimization algorithm. *Renewable Energy*, Elsevier Ltd, v. 224, 4 2024. ISSN 18790682. Citado na página 27.

ELMORSHEDY, M. F.; XU, W.; EL-SOUSY, F. F.; ISLAM, M. R.; AHMED, A. A. Recent achievements in model predictive control techniques for industrial motor: A comprehensive state-of-the-art. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 9, p. 58170–58191, 2021. ISSN 21693536. Citado na página 41.

ELSAKAAN, A. A.; EL-SEHIEMY, R. A.; KADDAH, S. S.; ELSAID, M. I. Optimal economic–emission power scheduling of rers in mgs with uncertainty. *IET Generation, Transmission and Distribution*, Institution of Engineering and Technology, v. 14, p. 37–52, 2020. ISSN 17518687. Citado 3 vezes nas páginas 29, 31 e 55.

ESPÍN-SARZOSA, D.; PALMA-BEHNKE, R.; NÚÑEZ-MATA, O. Energy management systems for microgrids: Main existing trends in centralized control architectures. *Energies*, v. 13, p. 1–32, 2020. ISSN 19961073. Citado 3 vezes nas páginas 36, 38 e 39.

FARHANGI, H.; ASADOLAHI, A. (Ed.). *Microgrid Architectures, Control and Protection Methods*. Springer, 2019. Disponível em: <<https://doi.org/10.1007/978-3-030-23723-3>>. Citado na página 33.

FARHANGI, H.; JOÓS, G. *Microgrid planning and design: a concise guide*. [S.l.]: John Wiley & Sons, 2019. Citado 2 vezes nas páginas 16 e 33.

FATHY, A.; FERAHTIA, S.; REZK, H.; YOUSRI, D.; ABDELKAREEM, M. A.; OLABI, A. G. Optimal adaptive fuzzy management strategy for fuel cell-based dc microgrid. *Energy*, Elsevier Ltd, v. 247, 5 2022. ISSN 03605442. Citado na página 25.

FERAHTIA, S.; REZK, H.; ABDELKAREEM, M. A.; OLABI, A. Optimal techno-economic energy management strategy for building’s microgrids based bald eagle search optimization algorithm. *Applied Energy*, Elsevier Ltd, v. 306, p. 118069, 2022. ISSN 03062619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2021.118069>>. Citado na página 25.

FOSSATI, J. P.; GALARZA, A.; MARTÍN-VILLATE, A.; ECHEVERRÍA, J. M.; FONTÁN, L. Optimal scheduling of a microgrid with a fuzzy logic controlled storage system. *International Journal of Electrical Power and Energy Systems*, v. 68, p. 61–70, 2015. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061514007595>>. Citado 3 vezes nas páginas 21, 34 e 55.

GARCIA-TORRES, F.; BORDONS, C. Optimal economical schedule of hydrogen-based microgrids with hybrid storage using model predictive control. *IEEE Transactions on Industrial Electronics*, IEEE, v. 62, n. 8, p. 5195–5207, 2015. Citado na página 22.

GARCIA-TORRES, F.; BORDONS, C.; RIDAO, M. A. Optimal economic schedule for a network of microgrids with hybrid energy storage system using distributed model predictive control. *IEEE Transactions on Industrial Electronics*, IEEE, v. 66, p. 1919–1929, 2019. ISSN 02780046. Citado 2 vezes nas páginas 22 e 31.

GOMELSKY, R. e. a. *Fossil Fuel Power Plants: Available Technologies and Thermal Plant Prospective Potential in Latin America*. 2010. Disponível em: <<https://publications.iadb.org/en/fossil-fuel-power-plants-available-technologies-and-thermal-plant-prospective-potential-latin>>. Citado na página 63.

GUO, C.; WANG, X.; ZHENG, Y.; ZHANG, F. Real-time optimal energy management of microgrid with uncertainties based on deep reinforcement learning. *Energy*, Elsevier Ltd, v. 238, 1 2022. ISSN 03605442. Citado na página 25.

HU, J.; SHAN, Y.; GUERRERO, J. M.; IOINOVICI, A.; CHAN, K. W.; RODRIGUEZ, J. Model predictive control of microgrids – an overview. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 136, 2 2021. ISSN 18790690. Citado na página 17.

IBRAHIM, M. M.; HASANIEN, H. M.; FARAG, H. E.; OMRAN, W. A. Energy management of multi-area islanded hybrid microgrids: A stochastic approach. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 11, p. 101409–101424, 2023. ISSN 21693536. Citado 2 vezes nas páginas 23 e 31.

KARAVAS, C. S.; KYRIAKARAKOS, G.; ARVANITIS, K. G.; PAPADAKIS, G. A multi-agent decentralized energy management system based on distributed intelligence for the design and control of autonomous polygeneration microgrids. *Energy Conversion and Management*, Elsevier Ltd, v. 103, p. 166–179, 2015. ISSN 01968904. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2015.06.021>>. Citado na página 17.

KAVITHA, V.; MALATHI, V.; GUERRERO, J. M.; BAZMOHAMMADI, N. Energy management system using mimosa pudica optimization technique for microgrid applications. *Energy*, Elsevier Ltd, p. 122605, 2021. ISSN 03605442. Disponível em: <<https://doi.org/10.1016/j.energy.2021.122605>>. Citado 3 vezes nas páginas 17, 18 e 23.

KONNEH, K. V.; ADEWUYI, O. B.; LOTFY, M. E.; SUN, Y.; SENJYU, T. Application strategies of model predictive control for the design and operations of renewable energy-based microgrid: A survey. *Electronics*, MDPI, v. 11, n. 4, p. 554, 2022. Citado na página 41.

LABRA-CÁCERES, N. I.; GRISALES-NOREÑA, L. F.; BOLAÑOS, R. I.; GUZMÁN-HENAO, J. A.; MONTOYA, O. D. Energy management system for pv-based distributed generators in ac microgrids using an adapted jaya optimizer to minimize operational costs, energy losses, and co2 emissions. *Results in Engineering*, Elsevier B.V., v. 25, 3 2025. ISSN 25901230. Citado na página 30.

LEONORI, S.; MARTINO, A.; MASCIOLI, F. M. F.; RIZZI, A. Microgrid energy management systems design by computational intelligence techniques. *Applied Energy*, Elsevier, v. 277, p. 115524, 2020. ISSN 03062619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2020.115524>>. Citado 5 vezes nas páginas 17, 18, 27, 44 e 46.

LEONORI, S.; PASCHERO, M.; MASCIOLI, F. M. F.; RIZZI, A. Optimization strategies for microgrid energy management systems by genetic algorithms. *Applied Soft Computing Journal*, Elsevier B.V., v. 86, p. 105903, 2020. ISSN 15684946. Disponível em: <<https://doi.org/10.1016/j.asoc.2019.105903>>. Citado na página 24.

- LI, Y.; FAN, X.; CAI, Z.; YU, B. Optimal active power dispatching of microgrid and distribution network based on model predictive control. *Tsinghua Science and Technology*, v. 23, p. 266–276, 2018. ISSN 18787606. Citado 2 vezes nas páginas 22 e 34.
- LI, Y.; WANG, P.; GOOI, H. B.; YE, J.; WU, L. Multi-objective optimal dispatch of microgrid under uncertainties via interval optimization. *IEEE Transactions on Smart Grid*, IEEE, v. 10, p. 2046–2058, 2019. ISSN 19493053. Citado 2 vezes nas páginas 27 e 36.
- LIU, D.; FONSECA, L. García da. *O&M Economics and Cost Data for Onshore Wind Power Markets*. 2021. Citado na página 63.
- LOGESWARAN, T.; RAJESH, P.; SHAJIN, F. H.; PRAKASH, A. Combination of side-blotched lizard and chaos game optimization based distributed energy management for microgrid system. *International Transactions on Electrical Energy Systems*, p. 1–23, 2021. ISSN 20507038. Citado na página 24.
- MAJEED, M. A.; PHICHISAWAT, S.; ASGHAR, F.; HUSSAN, U. Optimal energy management system for grid-tied microgrid: An improved adaptive genetic algorithm. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 11, p. 117351–117361, 2023. ISSN 21693536. Citado 2 vezes nas páginas 26 e 31.
- MAULIK, A.; DAS, D. Optimal operation of droop-controlled islanded microgrids. *IEEE Transactions on Sustainable Energy*, Institute of Electrical and Electronics Engineers Inc., v. 9, p. 1337–1348, 7 2018. ISSN 19493029. Citado 3 vezes nas páginas 29, 30 e 55.
- MAULIK, A.; DAS, D. Optimal power dispatch considering load and renewable generation uncertainties in an ac–dc hybrid microgrid. *IET Generation, Transmission and Distribution*, v. 13, p. 1164–1176, 2019. ISSN 17518687. Citado na página 29.
- NAZARI-HERIS, M.; ABAPOUR, S.; MOHAMMADI-IVATLOO, B. Optimal economic dispatch of fc-chp based heat and power micro-grids. *Applied Thermal Engineering*, Elsevier Ltd, v. 114, p. 756–769, 2017. ISSN 13594311. Disponível em: <<http://dx.doi.org/10.1016/j.applthermaleng.2016.12.016>>. Citado 2 vezes nas páginas 29 e 55.
- NORVIG, P. R.; INTELLIGENCE, S. A. A modern approach. *Prentice Hall Upper Saddle River, NJ, USA: Rani, M., Nayak, R., & Vyas, OP (2015). An ontology-based adaptive personalized e-learning system, assisted by software agents on cloud storage. Knowledge-Based Systems*, v. 90, p. 33–48, 2002. Citado na página 50.
- PREVIERO, W. D. *Estratégias de resolução para o problema de job-shop flexível*. Tese (Doutorado) — Universidade de São Paulo, 2016. Citado na página 40.
- RAGHAV, L. P.; KUMAR, R. S.; RAJU, D. K.; SINGH, A. R. Optimal energy management of microgrids using quantum teaching learning based algorithm. *IEEE Transactions on Smart Grid*, IEEE, v. 12, p. 4834–4842, 2021. ISSN 19493061. Citado 3 vezes nas páginas 17, 18 e 25.
- RAMASAMY, B.; JOHS, A.; MARSHALL, R.; KEELIN, T. *Utility-Scale Solar Photovoltaic (2024 ATB)*. 2022. Disponível em: <<https://atb.nrel.gov/electricity/2024/index>>. Citado na página 63.

ROBINSON, R. C. Introduction to mathematical optimization. *Department of Mathematics, Northwestern University, Illinois US*, 2013. Citado na página 46.

ROSLAN, M. F.; HANNAN, M. A.; KER, P. J.; BEGUM, R. A.; MAHLIA, T. M. I.; DONG, Z. Y. Scheduling controller for microgrids energy management system using optimization algorithm in achieving cost saving and emission reduction. *Applied Energy*, Elsevier Ltd, v. 292, p. 116883, 2021. ISSN 03062619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2021.116883>>. Citado 2 vezes nas páginas 28 e 34.

RUSSELL, S. J. *Artificial intelligence a modern approach*. [S.l.]: Pearson Education, Inc., 2010. Citado na página 50.

SACHS, J.; SAWODNY, O. A two-stage model predictive control strategy for economic diesel-pv-battery island microgrid operation in rural areas. *IEEE Transactions on Sustainable Energy*, v. 7, p. 903–913, 2016. ISSN 19493029. Citado 2 vezes nas páginas 30 e 33.

SERALE, G.; FIORENTINI, M.; CAPOZZOLI, A.; BERNARDINI, D.; BEMPORAD, A. Model predictive control (mpc) for enhancing building and hvac system energy efficiency: Problem formulation, applications and opportunities. *Energies*, MDPI AG, v. 11, 2 2018. ISSN 19961073. Citado na página 41.

SHAYEGHI, H.; SHAHRYARI, E.; MORADZADEH, M.; SIANO, P. A survey on microgrid energy management considering flexible energy sources. *Energies*, v. 12, p. 1–26, 2019. ISSN 19961073. Citado na página 36.

SHEZAN, S. A.; ISHRAQUE, M. F.; SHAFIULLAH, G. M.; KAMWA, I.; PAUL, L. C.; MUYEEN, S. M.; NSS, R.; SALEHEEN, M. Z.; KUMAR, P. P. Optimization and control of solar-wind islanded hybrid microgrid by using heuristic and deterministic optimization algorithms and fuzzy logic controller. *Energy Reports*, Elsevier Ltd, v. 10, p. 3272–3288, 11 2023. ISSN 23524847. Citado 2 vezes nas páginas 23 e 31.

SHI, W.; XIE, X.; CHU, C.-C.; GADH, R. Distributed optimal energy management in microgrids. *IEEE Transactions on Smart Grid*, v. 6, n. 3, p. 1137–1146, 2015. Citado na página 23.

SURESH, V.; JANIK, P.; JASINSKI, M.; GUERRERO, J. M.; LEONOWICZ, Z. Microgrid energy management using metaheuristic optimization algorithms. *Applied Soft Computing*, Elsevier Ltd, v. 134, 2 2023. ISSN 15684946. Citado 2 vezes nas páginas 25 e 31.

TAABODI, M. H.; NIKNAM, T.; SHARIFHOSSEINI, S. M.; AGHAJARI, H. A.; BORNAPOUR, S. M.; SHEYBANI, E.; JAVIDI, G. Optimizing rural mg's performance: A scenario-based approach using an improved multi-objective crow search algorithm considering uncertainty. *Energies*, Multidisciplinary Digital Publishing Institute (MDPI), v. 18, 1 2025. ISSN 19961073. Citado na página 28.

TALBI, E.-G. *METAHEURISTICS FROM DESIGN TO IMPLEMENTATION*. [S.l.: s.n.], 2009. 593 p. ISBN 9789004310087. Citado 5 vezes nas páginas 18, 40, 46, 47 e 50.

TAN, B.; CHEN, H. Multi-objective energy management of multiple microgrids under random electric vehicle charging. *Energy*, Elsevier Ltd, v. 208, 10 2020. ISSN 03605442. Citado 2 vezes nas páginas 29 e 31.

THIRUNAVUKKARASU, G. S.; SEYEDMAHMOUDIAN, M.; JAMEI, E.; HORAN, B.; MEKHILEF, S.; STOJCEVSKI, A. *Role of optimization techniques in microgrid energy management systems—A review*. [S.l.]: Elsevier Ltd, 2022. Citado na página 21.

THURNER, L.; SCHEIDLER, A.; SCHÄFER, F.; MENKE, J.; DOLLICHON, J.; MEIER, F.; MEINECKE, S.; BRAUN, M. pandapower — an open-source python tool for convenient modeling, analysis, and optimization of electric power systems. *IEEE Transactions on Power Systems*, v. 33, n. 6, p. 6510–6521, Nov 2018. ISSN 0885-8950. Citado na página 64.

TON, D. T.; SMITH, M. A. The u.s. department of energy’s microgrid initiative. *Electricity Journal*, v. 25, p. 84–94, 10 2012. ISSN 10406190. Citado na página 34.

UNFCCC. *Tool 33: Default values for common parameters (diesel generator emission factors)*. 2017. Methodological tool for CDM, versão 01.0. Disponível em: <<https://cdm.unfccc.int/methodologies/PAMethodologies/tools/am-tool-33-v1.pdf>>. Citado na página 63.

VEERASAMY, V.; WAHAB, N. I. A.; OTHMAN, M. L.; PADMANABAN, S.; SEKAR, K.; RAMACHANDRAN, R.; HIZAM, H.; VINAYAGAM, A.; ISLAM, M. Z. Lstm recurrent neural network classifier for high impedance fault detection in solar pv integrated power system. *IEEE Access*, v. 9, p. 32672–32687, 2021. Citado na página 36.

VELUCHAMY, K.; VELUCHAMY, M. A new energy management technique for microgrid system using muddy soil fish optimization algorithm. *International Journal of Energy Research*, v. 45, n. 10, p. 14824–14844, 2021. Citado na página 23.

VENAYAGAMOORTHY, G. K.; SHARMA, R. K.; GAUTAM, P. K.; AHMADI, A. Dynamic energy management system for a smart microgrid. *IEEE Transactions on Neural Networks and Learning Systems*, IEEE, v. 27, p. 1643–1656, 2016. ISSN 21622388. Citado 2 vezes nas páginas 26 e 31.

VENKAT, A. N.; HISKENS, I. A.; RAWLINGS, J. B.; WRIGHT, S. J. Distributed mpc strategies with application to power system automatic generation control. *IEEE Transactions on Control Systems Technology*, v. 16, p. 1192–1206, 2008. ISSN 10636536. Citado na página 41.

VERA, Y. E.; DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. Energy management in microgrids with renewable energy sources: A literature review. *Applied Sciences (Switzerland)*, v. 9, 2019. ISSN 20763417. Citado na página 16.

VIEIRA, A. R.; BATISTA, V. S.; JÚNIOR, G. C.; VIEIRA, J. P. A. Integrating protection constraints to a mean-based method for service restoration in radial distribution systems. *Electric Power Systems Research*, v. 191, p. 106851, 2021. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779620306507>>. Citado na página 36.

WANG, D.; QIU, J.; REEDMAN, L.; MENG, K.; LAI, L. L. Two-stage energy management for networked microgrids with high renewable penetration. *Applied Energy*, Elsevier, v. 226, p. 39–48, 2018. Citado na página 24.

- WANG, S.; TAN, Q.; DING, X.; LI, J. Efficient microgrid energy management with neural-fuzzy optimization. *International Journal of Hydrogen Energy*, Elsevier Ltd, v. 64, p. 269–281, 4 2024. ISSN 03603199. Citado 2 vezes nas páginas 26 e 31.
- WANG, X.; ATKIN, J.; HILL, C.; BOZHKO, S. Power allocation and generator sizing optimisation of more-electric aircraft on-board electrical power during different flight stages. In: IEEE. *2019 AIAA/IEEE Electric Aircraft Technologies Symposium (EATS)*. [S.l.], 2019. p. 1–10. Citado na página 36.
- WANG, Z.; CHEN, B.; WANG, J.; BEGOVIC, M. M.; CHEN, C. Coordinated energy management of networked microgrids in distribution systems. *IEEE Transactions on Smart Grid*, v. 6, n. 1, p. 45–53, 2015. Citado na página 31.
- WOOLDRIDGE, M. *An introduction to multiagent systems*. [S.l.]: John wiley & sons, 2009. Citado na página 17.
- WU, D.; WU, L.; WEN, T.; LI, L. Microgrid operation optimization method considering power-to-gas equipment: An improved gazelle optimization algorithm. *Symmetry*, Multidisciplinary Digital Publishing Institute (MDPI), v. 16, 1 2024. ISSN 20738994. Citado na página 26.
- XING, X.; XIE, L.; MENG, H. Cooperative energy management optimization based on distributed mpc in grid-connected microgrids community. *International Journal of Electrical Power and Energy Systems*, Elsevier, v. 107, p. 186–199, 2019. ISSN 01420615. Disponível em: <<https://doi.org/10.1016/j.ijepes.2018.11.027>>. Citado 2 vezes nas páginas 22 e 34.
- ZHANG, C.; KAZANCI, O. B.; LEVINSON, R.; HEISELBERG, P.; OLESEN, B. W.; CHIESA, G.; SODAGAR, B.; AI, Z.; SELKOWITZ, S.; ZINZI, M. et al. Resilient cooling strategies—a critical review and qualitative assessment. *Energy and Buildings*, Elsevier, v. 251, p. 111312, 2021. Citado na página 16.
- ZHAO, B.; QIU, H.; QIN, R.; ZHANG, X.; GU, W.; WANG, C. Robust optimal dispatch of ac/dc hybrid microgrids considering generation and load uncertainties and energy storage loss. *IEEE Transactions on Power Systems*, v. 33, p. 5945–5957, 2018. ISSN 08858950. Citado 2 vezes nas páginas 22 e 34.
- ZIA, M. F.; ELBOUCHIKHI, E.; BENBOUZID, M. Microgrids energy management systems: A critical review on methods, solutions, and prospects. *Applied Energy*, Elsevier, v. 222, p. 1033–1055, 2018. ISSN 03062619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2018.04.103>>. Citado 2 vezes nas páginas 36 e 37.
- ZUBARAN, T. K. *A Study on Shop Scheduling Problems*. Tese (Doutorado) — Federal University of Rio Grande do Sul, Porto Alegre, Brazil, April 2018. Ph.D. Thesis. Citado 2 vezes nas páginas 16 e 18.

Apêndices

APÊNDICE A . Paralelização dos Algoritmos de Otimização e de Fluxo de Carga

Um aspecto importante na programação de algoritmos de otimização é a execução eficiente dos cálculos, garantindo que os resultados sejam obtidos dentro de um tempo viável. Neste trabalho, foram utilizados algoritmos de otimização populacionais, que são meta-heurísticas baseadas na evolução de uma população de soluções ao longo de várias iterações. Esses algoritmos buscam explorar o espaço de soluções por meio de operadores como seleção, recombinação e mutação, permitindo uma busca eficiente por ótimos globais em problemas complexos e não lineares.

No entanto, um dos desafios dessa abordagem está na integração com algoritmos de fluxo de carga, pois os algoritmos de otimização populacionais podem exigir a execução do fluxo de carga centenas ou até milhares de vezes para avaliar e aprimorar as soluções. Esse alto número de chamadas pode tornar o processo computacionalmente custoso, impactando o tempo de execução da otimização.

Neste apêndice, será detalhada a estratégia adotada para a paralelização do processo, combinando os algoritmos de otimização e os algoritmos de fluxo de carga. A implementação paralela visa reduzir o tempo de processamento, distribuindo as operações entre múltiplos núcleos de processamento e otimizando a execução das simulações.

A.1 Algoritmos de Otimização e Fluxo de Carga

O processo de otimização com algoritmos populacionais, como o GA e o NSGA-II, baseia-se na evolução iterativa de uma população de soluções potenciais. Inicialmente, um conjunto de soluções candidatas é gerado aleatoriamente e, a cada iteração, operadores como seleção, cruzamento e mutação são aplicados para gerar novas soluções. A aptidão de cada solução é avaliada de acordo com uma função objetivo, e as melhores são selecionadas para compor a próxima geração. Esse ciclo se repete até que um critério de parada seja atingido, como um número máximo de iterações ou a convergência das soluções.

A integração com algoritmos de fluxo de carga ocorre na etapa de avaliação das soluções. Para cada indivíduo da população, o algoritmo de fluxo de carga é executado para verificar a viabilidade técnica da solução proposta, calculando tensões, correntes e perdas no sistema elétrico. Esses resultados são então utilizados para calcular a função objetivo, que pode incluir critérios como minimização de custos operacionais e emissões. Como os algoritmos populacionais podem exigir centenas ou milhares de avaliações, a

implementação paralela do fluxo de carga se torna essencial para reduzir o tempo de execução e tornar a otimização viável em termos computacionais.

A.2 Relação Entre as Bibliotecas Utilizadas

Neste trabalho, foram utilizadas duas bibliotecas no Python para realizar este processo: *Pymoo* e *PandaPower*. O *Pymoo* é uma biblioteca de otimização multiobjetivo que oferece suporte a diversos algoritmos evolutivos, permitindo a resolução eficiente de problemas complexos por meio de técnicas populacionais. O *PandaPower* é uma biblioteca voltada para a simulação e análise de sistemas elétricos de potência, fornecendo ferramentas para a execução de fluxos de carga e estudos de estabilidade de rede.

Ambas as bibliotecas oferecem formas de aceleração em suas execuções. No entanto, ao serem utilizadas em conjunto, esses processos não funcionam corretamente devido a conflitos na gestão dos recursos computacionais. Por esse motivo, a paralelização foi implementada manualmente, conforme descrito a seguir.

A biblioteca *PandaPower* é capaz de melhorar a execução através da biblioteca *Numba*, que é um compilador *Just-In-Time* (JIT) para Python. O *Numba* acelera a execução de código numérico compilando funções Python para código de máquina otimizado em tempo de execução.

Neste caso, o JIT é ativado para acelerar o processo de execução do fluxo de carga. Contudo, as MGs utilizadas possuem um tempo relativamente pequeno de execução no fluxo de carga, por volta de 1 a 2 segundos. Esse tempo não é suficiente para que o JIT do *Numba* proporcione ganhos significativos, pois a compilação JIT introduz uma sobrecarga inicial. Como o fluxo de carga é executado várias vezes, mas em pequenas instâncias, o tempo gasto na compilação supera os benefícios da execução otimizada, tornando o uso do *Numba* ineficaz nesse contexto.

Com relação ao *Pymoo*, ele oferece diversas formas de paralelização, como utilizando a biblioteca *Dask*, que permite o processamento distribuído e paralelo de grandes conjuntos de dados de forma eficiente. Além disso, o *Pymoo* também permite a paralelização com processos internos do Python, como o pacote *multiprocessing*, utilizando *threads*, *process* e a interface *starmap*.

Esses métodos são bastante eficientes ao lidar com funções objetivo puramente matemáticas, onde cada avaliação pode ser computada de forma independente e rápida. Contudo, quando se utiliza uma biblioteca de simulação, como o *PandaPower* para cálculos de fluxo de carga, esses métodos acabam não sendo eficazes. Isso ocorre porque bibliotecas de simulação frequentemente envolvem operações mais complexas, acesso a estruturas de dados compartilhadas e chamadas a códigos compilados, o que pode gerar gargalos e

inviabilizar o ganho esperado com a paralelização padrão.

Para contornar essa limitação, o processo de paralelização foi realizado manualmente, internamente, antes da execução do cálculo do fluxo de carga. No processo de otimização da biblioteca *Pymoo*, é necessário criar duas classes principais. A primeira contém as definições do algoritmo de otimização, enquanto a segunda define o problema que será otimizado. Dentro dessa segunda classe, é necessário implementar duas funções principais:

- `__init__`: Responsável por inicializar a classe, armazenando informações do problema, como parâmetros fixos, limites das variáveis de decisão e configurações gerais.
- `__evaluate`: Onde ocorre a chamada da função de avaliação, sendo esse o ponto crítico para a paralelização.

Para otimizar a execução do fluxo de carga dentro da função `__evaluate`, foi utilizada a função `partial`, do pacote *functools*, que permite fixar certos parâmetros da função objetiva, deixando como variável de entrada apenas os dados dos indivíduos gerados pelo algoritmo evolutivo. Dessa forma, informações fixas, como dados da MG, janela de previsão e potência dos geradores não despacháveis, são pré-configuradas, reduzindo a sobrecarga na chamada da função durante a otimização.

Com essa função objetiva devidamente ajustada, a paralelização foi implementada usando o pacote *multiprocessing* do Python, especificamente o método `pool.map`. Esse método permite distribuir a carga de trabalho entre múltiplos processos, executando as avaliações em paralelo. O `pool.map` recebe uma função e um conjunto de dados como entrada, aplicando a função iterativamente a cada elemento do conjunto de forma distribuída. Isso significa que, em vez de avaliar cada indivíduo da população sequencialmente, a avaliação ocorre simultaneamente em diferentes núcleos de processamento, reduzindo significativamente o tempo total de execução.

A seguir, apresenta-se um exemplo de código implementando esse processo de paralelização.

```
from pymoo.core.problem import Problem
from functools import partial

class ProblemaDeOtimizacao(Problem):
    def __init__():
        ...

    def _evaluate(self, X, out, *args, **kwargs):
        # Criacao da funcao parcial
        partial_eval_ind = partial(
            funcao_de_avaliacao,
            load=self.load,
            pv_power=self.pv_power,
            wt_power=self.wt_power,
            ...
        )
        # Execucao paralela
        pool = multiprocessing.Pool(processes=32)
        results = pool.map(partial_eval_ind, X)
        pool.close()
```

APÊNDICE B . Processo de Carga e Descarga das Baterias

Um dos pontos essenciais no processo de otimização se concentra nas baterias, que desempenham um papel fundamental na gestão da MG. Elas armazenam energia quando há excedente de geração e a liberam quando há déficit, auxiliando no balanceamento do sistema e na redução de custos operacionais.

Um dos aspectos críticos é o cálculo adequado do SoC das baterias. Mesmo utilizando o *pandapower*, até o momento da elaboração desta tese, essa biblioteca não atualiza o SoC das baterias, pois não é uma ferramenta de simulação dependente do tempo. Portanto, foi necessário realizar os cálculos do SoC externamente.

O cálculo do SoC das baterias é executado antes de cada etapa de fluxo de carga. Para isso, são utilizados dois parâmetros principais: o SoC anterior e a potência máxima de saída. O algoritmo de otimização solicita das baterias uma determinada quantidade de energia, seja para carga ou descarga. Em seguida, essa potência é limitada pelos valores máximos permitidos para carga e descarga.

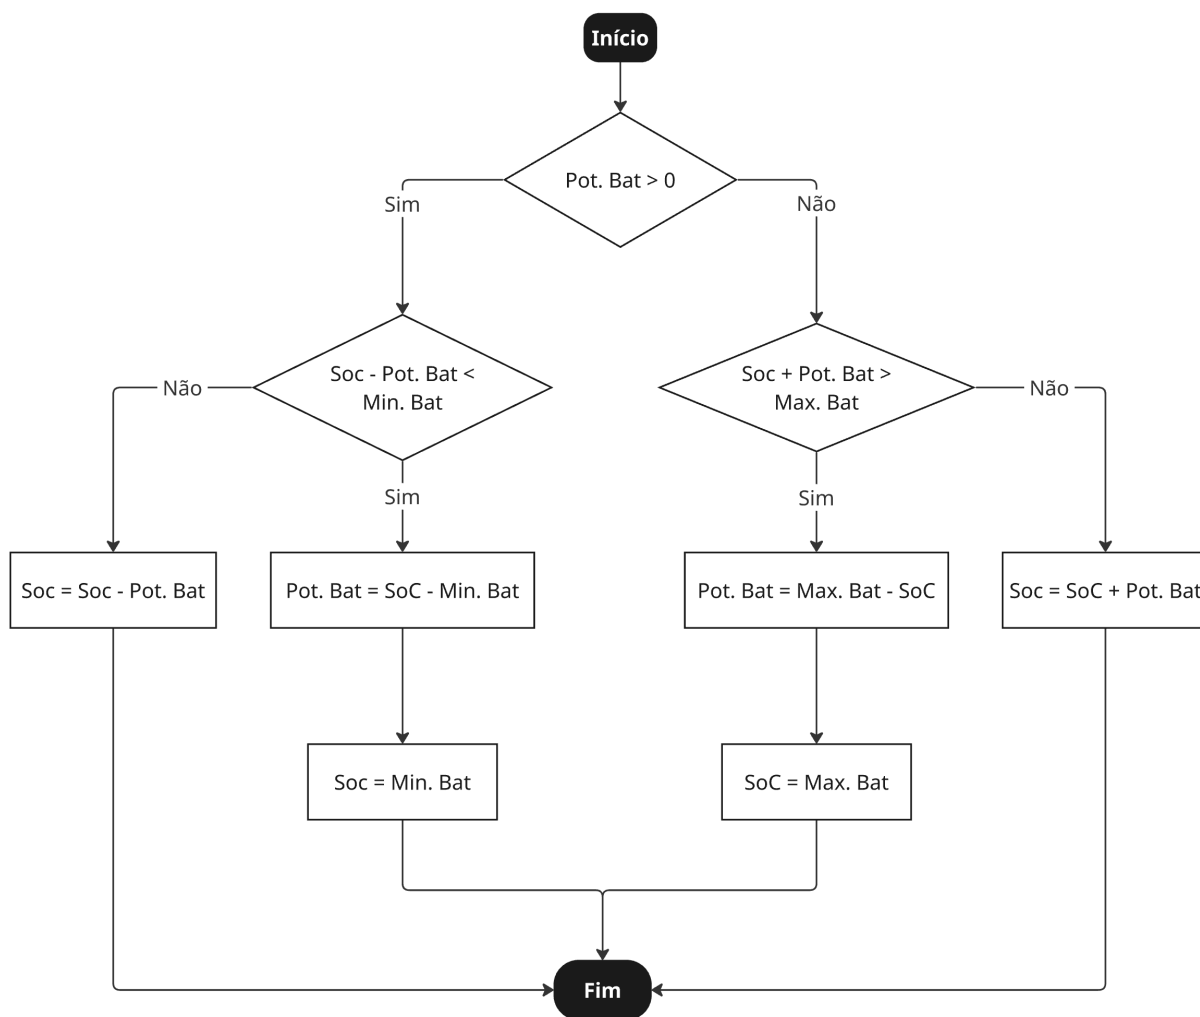
Por fim, o valor do SoC é atualizado, respeitando os limites máximos e mínimos de capacidade das baterias. Caso a bateria esteja totalmente carregada e seja solicitada uma carga adicional, a potência será zerada e o SoC permanecerá inalterado. Se for solicitada uma carga de uma quantidade X , mas a bateria só puder armazenar metade desse valor por estar próxima da carga máxima, a diferença entre os valores é calculada, e o valor de saída é ajustado de acordo.

De maneira análoga, quando a bateria estiver com níveis baixos de SoC, há um limite inferior definido em 20%. Se uma descarga for solicitada e essa ação fizer com que o SoC fique abaixo desse limite, apenas a energia correspondente à diferença entre o SoC atual e o limite inferior será disponibilizada.

Por fim, caso a bateria possa fornecer ou captar energia da MG sem atingir os limites de capacidade, o processo é apenas limitado pelas potências máximas de carga e descarga.

A Figura 26 ilustra, em um fluxograma, o funcionamento deste processo descrito.

Figura 26. Fluxograma do Funcionamento da Carga e Descarga das Baterias



Fonte: Produzido Pelo Autor