



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
DOUTORADO EM ENGENHARIA ELÉTRICA

JANAÍNA BARBOSA ALMADA

**SISTEMA DE GERENCIAMENTO DE ENERGIA PARA MICRORREDES USANDO
MULTIAGENTES E OTIMIZAÇÃO META-HEURÍSTICA DISTRIBUÍDA EM
AMBIENTE DE CO-SIMULAÇÃO**

FORTALEZA

2025

JANAÍNA BARBOSA ALMADA

SISTEMA DE GERENCIAMENTO DE ENERGIA PARA MICRORREDES USANDO
MULTIAGENTES E OTIMIZAÇÃO META-HEURÍSTICA DISTRIBUÍDA EM AMBIENTE
DE CO-SIMULAÇÃO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Sistemas Elétricos de Potência.

Orientadora: Profa. PhD Ruth Pastôra
Saraiva Leão.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

A442s Almada, Janaína Barbosa.

Sistema de gerenciamento de energia para microrredes usando multiagentes e otimização meta-heurística distribuída em ambiente de co-simulação / Janaína Barbosa Almada. – 2025.
145 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2025.

Orientação: Prof. Dr. Ruth Pastôra Saraiva Leão.

1. co-simulação. 2. microrrede. 3. otimização distribuída. 4. paralelismo de meta-heurísticas. 5. sistema multiagente. I. Título.

CDD 621.3

JANAÍNA BARBOSA ALMADA

SISTEMA DE GERENCIAMENTO DE ENERGIA PARA MICRORREDES USANDO
MULTIAGENTES E OTIMIZAÇÃO META-HEURÍSTICA DISTRIBUÍDA EM AMBIENTE
DE CO-SIMULAÇÃO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Sistemas Elétricos de Potência.

Aprovada em: janeiro de 2025

BANCA EXAMINADORA

Profa. PhD Ruth Pastôra Saraiva Leão (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Guilherme de Alencar Barreto
Universidade Federal do Ceará (UFC)

Profa. Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo (UFES)

Prof. Dr. Lucas Silveira Melo
Universidade Federal do Ceará (UFC)

Profa. Dra. Raquel Cristina Filiargi Gregory
Universidade Federal do Ceará (UFC)

Aos meus pais, Antônio e Angela, por todos os sacrifícios e por cada oração que fizeram pela nossa família e por mim.

AGRADECIMENTOS

Agradeço à professora Ruth por me orientar não só na academia, mas também na vida. Obrigada por acreditar na capacidade que, por vezes, eu mesma esqueci que tinha.

Aos professores do Departamento de Engenharia Elétrica (DEE), especialmente aos professores do GREI (Grupo de Redes Elétricas Inteligentes), agradeço por todo o conhecimento compartilhado. Aos funcionários do DEE e da Universidade Federal do Ceará, agradeço pelo trabalho de vocês. Aos colegas da graduação e da pós-graduação, sou grata pelos exemplos de dedicação e pelo apoio.

Aos professores participantes da banca de qualificação: Raquel, Lucas e Guilherme, agradeço pelo tempo dedicado à avaliação e pelas contribuições para este trabalho.

Agradeço à plataforma de figuras vetorizadas freepik.com, que mantém gratuitamente diversos arquivos para *download*. Alguns elementos vetorizados dessa plataforma foram úteis na composição das figuras deste trabalho.

Gostaria de agradecer também aos meus colegas de trabalho da Unilab, especialmente às amigas Silvia e Karol, por suas orações e por não me deixarem desistir. Agradeço aos meus alunos pela compreensão durante todo esse processo, no qual não consegui estar plenamente com eles.

Agradeço também às profissionais fora da academia que me deram suporte físico e emocional na realização deste trabalho, principalmente à psicoterapeuta Annya, às fisioterapeutas do espaço Imagem Corporal e à médica Bruna Dourado.

Quero agradecer a todos que oraram para me dar força e discernimento para a entrega deste trabalho. Sem a força do nosso Deus, todo amoroso, não teria sido possível.

Por fim, gostaria de agradecer à minha família, aos meus amigos e às minhas amigas, que são minha base e, também, minha motivação para ser uma pessoa digna de tudo o que me foi confiado.

“Eis que faço novas todas as coisas.”
(Apocalipse, 21:5)

RESUMO

A diversidade de recursos energéticos nas redes de distribuição exige novas estratégias para planejamento e operação. As microrredes são soluções para integrar fontes renováveis, armazenamento de energia e resposta à demanda, descentralizando a operação e utilizando tecnologias digitais para mercados de energia mais granulares. A crescente complexidade demanda alternativas às técnicas centralizadas, especialmente para decisões rápidas como o despacho de carga de curtíssimo prazo. Este trabalho propõe uma estratégia de despacho ótimo distribuído para microrredes com múltiplos recursos energéticos, focando em escalabilidade. A simulação é realizada modelando agentes na plataforma PADE (*Python Agent DEvelopment*), considerando o uso de recursos computacionais distribuídos e comunicação entre agentes. Um ambiente de co-simulação coordenado pelo Mosaik sincroniza a troca de informações, enquanto um sistema *plug-and-play* permite a modificação dinâmica dos agentes. Os algoritmos PSO (*Particle Swarm Optimization*) e MAPSO (*Multi-Agent Particle Swarm Optimization*) foram escolhidos para a realização do estudo. A implementação proposta simula o paralelismo distribuído de meta-heurísticas, por meio de um sistema multiagente. Os estudos de caso mostram que o MAPSO distribuído tem melhor desempenho, com menores valores da função objetivo e menor desvio padrão relativo (15,6%), enquanto o PSO distribuído obteve maior desvio padrão (33,9%). Embora o tempo de resolução do MAPSO distribuído seja até 3 vezes maior (execução média de 9 segundos), esse intervalo é compatível com o despacho realizado a cada 5 minutos. A capacidade de processamento distribuído e tecnologias de comunicação tornam o método viável para aplicação prática. As principais contribuições incluem o desenvolvimento de um sistema *plug-and-play* para otimização de curtíssimo prazo e a distribuição das meta-heurísticas entre agentes, aumentando a tolerância a falhas.

Palavras-chave: co-simulação; microrrede; otimização distribuída; paralelismo de meta-heurísticas; sistema multiagente.

ABSTRACT

The diversity of energy resources in distribution networks requires new strategies for planning and operation. Microgrids are solutions to integrate renewable sources, energy storage, and demand response, decentralizing operation and using digital technologies for more granular energy markets. The increasing complexity demands alternatives to centralized techniques, especially for quick decisions such as very short-term load dispatch. This work proposes a distributed optimal dispatch strategy for microgrids with multiple energy resources, focusing on scalability and the use of distributed computational resources. The simulation is carried out by modeling agents on the PADE (Python Agent DEvelopment) platform, implementing the parallelism of metaheuristics, and considering distributed hardware with communication between agents. A co-simulation environment coordinated by Mosaik synchronizes information exchange, while a plug-and-play system allows for dynamic modification of the agents. The PSO (Particle Swarm Optimization) and MAPSO (Multi-Agent Particle Swarm Optimization) algorithms are the chosen metaheuristics. For comparison, the algorithms were implemented without parallelism, centralizing stages in a single agent, and simulating parallelism through a multi-agent system. Case studies show that the distributed MAPSO performs better, with lower objective function values and lower relative standard deviation (15.6%), while the centralized PSO had the highest standard deviation (106.9%). Although the resolution time of the distributed MAPSO is up to 3 times longer (average execution time of 9 seconds), this interval is compatible with dispatch performed every 5 minutes. The distributed processing capability and communication technologies make the method viable for practical application. The main contributions include the development of a plug-and-play system for very short-term optimization and the distribution of metaheuristics among agents, increasing fault tolerance.

Keywords: co-simulation; microgrid; distributed optimization; meta-heuristics parallelism; multi-agent system.

LISTA DE FIGURAS

Figura 1 – Capacidade instalada em operação até 22/11/2024	21
Figura 2 – Formas de integração de energia renovável	22
Figura 3 – Recursos e modos de operação de uma microrrede	29
Figura 4 – Previsão de geração de energia elétrica para fontes de natureza estocástica .	32
Figura 5 – Configuração para tornar o sistema mais controlável	35
Figura 6 – Capacidade e tempo de descarga	36
Figura 7 – Agentes, categorias e políticas para o gerenciamento de carga	37
Figura 8 – Subcategorias de programas de resposta à demanda	38
Figura 9 – Comportamento da frequência logo após um evento no sistema	40
Figura 10 – Controle hierárquico sistêmico	41
Figura 11 – Sistema interligado nacional dividido em áreas de controle	43
Figura 12 – Rede de distribuição dividida em microrredes	44
Figura 13 – Comparação do período mínimo de permanência para diferentes recursos após eventos transitórios de variação de frequência	45
Figura 14 – Controles de frequência para fontes de natureza estocástica	46
Figura 15 – Curva de eficiência por potência total entregue	47
Figura 16 – Modelos de otimização na operação de redes elétricas	49
Figura 17 – Programação e despacho das usinas por tipo	51
Figura 18 – Mercados de Energia	52
Figura 19 – Exemplo de granularidade temporal	55
Figura 20 – Etapas de uma aplicação de pesquisa operacional	58
Figura 21 – Classificação das características do problema	62
Figura 22 – Ambiente de co-simulação	66
Figura 23 – Camadas de interação do sistema multiagente	67
Figura 24 – Relação de tempo entre simuladores	69
Figura 25 – Tipos de mensagens e a troca entre os agentes durante a otimização	70
Figura 26 – Exemplo de atualização da lista de agentes ativos com a entrada de um novo agente equipamento	72
Figura 27 – Exemplo de atualização de agentes ativos com saída de um agente equipamento	73
Figura 28 – Classificação de meta-heurísticas	74
Figura 29 – Conflito de critérios em meta-heurísticas	75

Figura 30 – Possibilidades de ambientes para algoritmo MAPSO	78
Figura 31 – Exemplo da etapa de competição e cooperação do algoritmo MAPSO . . .	79
Figura 32 – Troca de informações na simulação do paralelismo distribuído de meta-heurísticas	83
Figura 33 – Etapas de atuação do agente <i>plug-and-play</i> durante a otimização	84
Figura 34 – Etapas de atuação do agente equipamento durante a otimização	85
Figura 35 – Fluxograma detalhado com as etapas dos algoritmos de otimização disponíveis	86
Figura 36 – Exemplo da etapa de competição e cooperação entre agentes do sistema SMA.	88
Figura 37 – Recursos energéticos da microrrede simulada	90
Figura 38 – Análise de sensibilidade da função custo das fontes despacháveis às variações nos coeficientes normalizados	92
Figura 39 – Função utilidade da carga transformada em função objetivo do problema . .	93
Figura 40 – Função custo da carga modelada por função exponencial	94
Figura 41 – Função custo do sistema de armazenamento de energia para diferentes valores de <i>SoC</i> e comparação entre dois rendimentos	96
Figura 42 – Função custo quadrática do sistema de armazenamento de energia para diferentes valores de <i>SoC</i> e valores de <i>n</i>	97
Figura 43 – Estimativas de previsão dos recursos variáveis.	102
Figura 44 – Convergência entre meta-heurísticas distribuídas com troca de mensagens a cada iteração.	104
Figura 45 – Convergência entre meta-heurísticas distribuídas com troca de mensagens a cada 100 iterações	106
Figura 46 – Corte de carga	109
Figura 47 – Valor inicial <i>SoC</i> de 20%	110
Figura 48 – Resposta após 500 iterações para os algoritmos centralizados	112
Figura 49 – Detalhe da convergência da função objetivo para os algoritmos centralizados	113
Figura 50 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 1	114
Figura 51 – Convergência da função objetivo para os algoritmos centralizados caso 2 . .	115
Figura 52 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 2	116
Figura 53 – Convergência da função objetivo para os algoritmos centralizados caso 3 . .	117

Figura 54 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 3	119
Figura 55 – Estatística das variáveis de saída e da função objetivo para as 50 execuções do caso 3	120
Figura 56 – Corte de carga durante a simulação do dia	123
Figura 57 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada iteração.	143
Figura 58 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada 10 iterações.	144
Figura 59 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada 100 iterações.	145

LISTA DE TABELAS

Tabela 1 – Agentes de operação de mercado e da rede elétrica	53
Tabela 2 – Exemplos de granularidade temporal	55
Tabela 3 – Diferença do paralelismo de meta-heurísticas por nível	82
Tabela 4 – Estabelecimentos dos parâmetros das funções objetivo de cada recurso da microrrede	101
Tabela 5 – Parâmetros das funções objetivo em unidades padrões	102
Tabela 6 – Meta-heurística executada por cada agente nos três simulações distribuídas implementadas.	103
Tabela 7 – Parâmetros do PSO e MAPSO	103
Tabela 8 – Variação máxima das variáveis de saída para simulação distribuída 1 com envio de mensagens a cada 5 iterações	107
Tabela 9 – Variação máxima das variáveis para simulação distribuída 2 com envio de mensagens a cada 5 iterações.	107
Tabela 10 – Variação máxima das variáveis para simulação distribuída 3 com envio de mensagens a cada 5 iterações.	107
Tabela 11 – Convergência das variáveis de saída e da função objetivo total para os 288 intervalos de otimização.	108
Tabela 12 – Parâmetros da próximas simulações	111
Tabela 13 – Parâmetros do modelo exponencial da carga nos próprios valores de base . .	112
Tabela 14 – Variáveis de saída da otimização	113
Tabela 15 – Variáveis de saída da otimização	117
Tabela 16 – Variáveis de saída da otimização caso 3	118
Tabela 17 – Tempo total de 50 execuções e a média considerando apenas 1 execução para cada um dos algoritmos	121
Tabela 18 – Convergência das variáveis de saída e da função objetivo total para os 288 intervalos de otimização	122

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
AEMO	<i>Australian Energy Market Operator</i>
Aneel	Agência Nacional de Energia Elétrica
API	<i>Application Programming Interface</i>
CAG	Controle Automático de Geração
CAISO	<i>California Independent System Operator</i>
CCEE	Câmara de Comercialização de Energia Elétrica
CVU	Custo Variável Unitário
DSO	Operador do Sistema de Distribuição (do inglês, DSO)
ED	Despacho Econômico (do inglês, ED)
EMS	Sistema de Gerenciamento de Energia (do inglês, EMS)
EPE	Empresa de Pesquisa Energética
ESS	Encargos de Serviços do Sistema
FIPA	<i>Foundation for Intelligent Physical Agents</i>
FMI	<i>Functional Mock-up Interface</i>
FMU	<i>Functional Mock-up Unit</i>
GLD	Gerenciamento pelo Lado da Demanda
INPE	Instituto Nacional de Pesquisas Espaciais
MAPSO	<i>Multiagent Particle Swarm Optimazation</i> - Otimização por enxame de partículas multiagentes
MGO	Operador da Microrrede (do inglês, MGO)
MH	Meta-heurística(s)
MIGDI	Microsistema Isolado de Geração e Distribuição de Energia Elétrica
MILP	Programação Linear Inteira Mista (do inglês, MILP)
MMGD	Micro e Minigeração Distribuída
MPP	Ponto de Máxima Potência (do inglês, MPP)
MRE	Mecanismo de Realocação de Energia
NEM	<i>National Electricity Market</i>
ONS	Operador Nacional do Sistema

Pade	<i>Python Agent Development Framework</i>
PD	Programação Dinâmica
PDO	Programação Diária de Operação
PLD	Preço de Liquidação das Diferenças
PMO	Programação Mensal de Operação
Prodist	Procedimentos de Distribuição
Prorede	Procedimentos de Rede
PSO	<i>Particle Swarm Optimazation</i> - Otimização por enxame de partículas
RED	Recurso(s) Energético(s) Distribuído(s)
REI	Rede(s) Elétrica(s) Inteligente(s)
RL	Relaxação Lagrangiana
RPO	Reserva de Potência Operativa
SAE	Sistema(s) de Armazenamento de Energia
SEP	Sistema(s) Elétrico(s) de Potência
SIGFI	Sistema Individual de Geração de Energia Elétrica com Fonte Intermitente
SIN	Sistema Interligado Nacional
SMA	Sistema(s) Multiagente(s)
SoC	<i>State of Charge</i>
UC	Compromisso da Unidade (do inglês, UC)
UHE	Usina(s) Hidrelétrica(s)
UHR	Usina(s) Hidrelétrica(s) Reversível(is)
UTE	Usina(s) Termelétrica(s)
VPP	<i>Virtual Power Plant</i>
VRE	Energia Renovável Variável (do inglês, VRE)
WEM	<i>Wholesale Electricity Market</i>

LISTA DE SÍMBOLOS

a_i	Coeficiente relacionado ao custo quadrático do recurso energético i
$AgPP$	Agente <i>Plug and Play</i>
$AgEQ$	Agente Equipamento
b_i	Coeficiente relacionado ao custo linear do recurso energético i
c_i	Coeficiente relacionado ao custo fixo do recurso energético i
cv	Coeficiente de velocidade do algoritmo PSO
C_i	Função custo do recurso energético i
CI_j	Potência da carga interna da área j
CL_j	Potência da carga líquida da área j
CT_j	Potência da carga total do sistema
C_i^V	Custo variável do recurso energético i
C_i^F	Custo fixo do recurso energético i
C_i^{SU}	Custo de rampa de subida do recurso energético i
C_i^{SD}	Custo de rampa de descida do recurso energético i
MM_j	Potência da máquina de maior capacidade da área de controle j
MM_p	Potência da máquina de maior probabilística
p_i	Potência do recurso energético i
p_{it}	Potência do recurso energético i no intervalo de tempo t
P_{jk}^{out}	Potência de intercâmbio de origem na área j com destino a área k
P_{kj}^{in}	Potência de intercâmbio de entrada na área j com origem na área k
P_i^{max}	Potência máxima de operação do recurso i
P_i^{min}	Potência mínima de operação do recurso i
P_t^D	Demanda total a ser atendida no intervalo de operação t
R_i^D	Inclinação mínima da rampa de descida
R_i^{SD}	Inclinação máxima da rampa de descida
R_i^U	Inclinação mínima da rampa de subida

R_i^{SU}	Inclinação máxima da rampa de subida
$R1_j$	Reserva de potência operativa primária na área de controle j
$R2e_j$	Reserva de potência operativa secundária de elevação na área de controle j
$R2r_j$	Reserva de potência operativa secundária de redução na área de controle j
$R3_j$	Reserva de potência operativa terciária na área de controle j
$R_{est,j}$	Reserva de potência operativa secundária relacionada a variabilidade da geração estocástica na área de controle j
RPO_j	Reserva de potência operativa na área de controle j
$RPO_{sistema}$	Reserva de potência operativa do sistema
RPO_t	Reserva de potência operativa do sistema no período t
u_{it}	Indica estado de operação do recurso i no intervalo de tempo t
y_{it}	Indica início da rampa de subida para o recurso i no intervalo de tempo t
z_{it}	Indica início da rampa de descida para o recurso i no intervalo de tempo t
λ_t	Previsão do preço da energia no intervalo de tempo t

SUMÁRIO

1	INTRODUÇÃO	19
1.1	Contexto e motivações	19
1.2	Hipótese do trabalho	23
1.3	Objetivos	23
<i>1.3.1</i>	<i>Objetivo geral</i>	<i>23</i>
<i>1.3.2</i>	<i>Objetivos específicos</i>	<i>23</i>
1.4	Contribuições	24
<i>1.4.1</i>	<i>Artigos publicados</i>	<i>24</i>
1.5	Estado da arte	25
1.6	Organização do documento	27
2	ABORDAGENS PARA GERENCIAMENTO ENERGÉTICO DE RE- CURSOS EM MICRORREDES	29
2.1	Recursos energéticos distribuídos	30
<i>2.1.1</i>	<i>Fontes renováveis de natureza estocástica</i>	<i>31</i>
<i>2.1.2</i>	<i>Fontes despacháveis</i>	<i>34</i>
<i>2.1.3</i>	<i>Armazenamento de energia</i>	<i>35</i>
<i>2.1.4</i>	<i>Resposta à demanda</i>	<i>37</i>
2.2	Controles operacionais	40
<i>2.2.1</i>	<i>Controle primário</i>	<i>44</i>
<i>2.2.2</i>	<i>Controle secundário</i>	<i>46</i>
<i>2.2.3</i>	<i>Controle terciário</i>	<i>48</i>
2.3	Programação do despacho de recursos	48
2.4	Mercado de energia e o despacho	51
2.5	Otimização na operação de sistemas elétricos de potência	57
<i>2.5.1</i>	<i>Modelos de otimização para a operação de recursos energéticos</i>	<i>59</i>
<i>2.5.2</i>	<i>Métodos de otimização</i>	<i>61</i>
2.6	Considerações finais	63
3	MÉTODOS E FERRAMENTA COMPUTACIONAL PARA GERENCI- AMENTO DE RECURSOS DE MICRORREDES	64
3.1	Co-simulação	64

3.1.1	<i>Sistemas multiagentes</i>	65
3.1.2	<i>Configurações de tempo na co-simulação</i>	68
3.1.3	<i>Protocolos de comunicação e a função plug-and-play</i>	69
3.1.3.1	<i>Função plug-and-play</i>	71
3.1.3.2	<i>Lista de vizinhos</i>	72
3.2	Meta-heurística para otimização em microrredes	74
3.2.1	<i>Otimização por enxame de partículas</i>	75
3.2.2	<i>Otimização por enxame de partículas multiagente</i>	77
3.3	Paralelismo distribuído de meta-heurísticas no ambiente de agentes inteligentes	80
3.3.1	<i>Níveis de paralelismo de meta-heurísticas</i>	81
3.3.2	<i>Implementação das meta-heurísticas por meio do sistema multiagente</i> . . .	82
3.3.2.1	<i>Meta-heurísticas sem paralelismo e centralizadas no agente plug-and-play</i> .	87
3.3.2.2	<i>Meta-heurísticas em paralelo distribuídas entre os agentes equipamentos</i> . .	87
3.4	Modelagem da função objetivo dos recursos distribuídos	89
3.4.1	<i>Fontes despacháveis</i>	90
3.4.2	<i>Cargas</i>	92
3.4.3	<i>Sistema de armazenamento de energia</i>	94
3.4.4	<i>Fontes não despacháveis</i>	97
3.4.5	<i>Reserva operativa</i>	98
3.5	Considerações finais	98
4	RESULTADOS E DISCUSSÃO	99
4.1	Implementação do sistema	99
4.2	Parametrização dos recursos	100
4.3	Convergência das variáveis em meta-heurísticas distribuídas	102
4.3.1	<i>Análise das respostas de saída</i>	109
4.4	Análise probabilística	110
4.4.1	<i>Caso 1 - Avaliação do modelo exponencial da carga</i>	111
4.4.2	<i>Caso 2 - Adequação da parametrização no modelo exponencial da carga</i> .	113
4.4.3	<i>Caso 3 - Alteração na parametrização do modelo da bateria e valor inicial do SoC</i>	117
4.4.4	<i>Avaliação do tempo de execução</i>	121

4.5	Análise de convergência com modelos ajustados	122
4.6	Considerações finais	123
5	CONCLUSÕES E TRABALHOS FUTUROS	125
	REFERÊNCIAS	127
	APÊNDICE A –ALGORITMOS IMPLEMENTADOS	136
	APÊNDICE B –RESULTADOS PARA A SIMULAÇÃO DE UM DIA	
	APÓS READEQUAÇÕES DOS MODELOS	143

1 INTRODUÇÃO

1.1 Contexto e motivações

A energia elétrica é um componente indispensável à sociedade e à economia. A sua produção de forma limpa é um dos grandes objetivos para mitigar as mudanças climáticas e promover um desenvolvimento sustentável neste século.

Mesmo com uma matriz elétrica historicamente renovável, o Brasil já percebe as consequências do aquecimento global com um regime de chuvas cada vez mais irregular. Segundo o Instituto Nacional de Pesquisas Espaciais (INPE), o número de dias consecutivos secos aumentou no Brasil nas últimas décadas. Em 60 anos, a média de dias seguidos sem chuva aumentou de 80 para 100 no Brasil, especialmente nas áreas que abrangem o norte do Nordeste e o centro do país. Os 20 dias consecutivos secos adicionais na última década são um indicador claro de que as mudanças climáticas já estão impactando significativamente o clima no Brasil (MCTI, 2024).

A atual estrutura dos Sistema(s) Elétrico(s) de Potência (SEP) em todo o mundo tem postulado a integração de fontes renováveis variáveis, geradores despacháveis distribuídos, dispositivos armazenadores de energia, bem como programas de resposta à demanda em redes de distribuição (FANG *et al.*, 2012). A enorme quantidade de unidades integradas de Recurso(s) Energético(s) Distribuído(s) (RED) e as mudanças na demanda energética, devido aos consumidores mais ativos, introduzem um padrão de produção-consumo de energia elétrica na estrutura tradicional dos sistemas elétricos, o que resulta em diversos desafios operacionais para garantir equilíbrio, estabilidade, previsibilidade e eficiência nas redes elétricas.

A fim de atender a essa realidade, o planejamento e a operação das redes de distribuição demandam a adoção de estruturas capazes de otimizar a gestão da energia e promover a integração de diversas fontes geradoras, como ocorre nas microrredes (SOSHINSKAYA *et al.*, 2014; BRAUN; STRAUSS, 2008). Além de sua capacidade de alternar entre modos de operação ligados à rede elétrica principal e ilhados para aumentar a confiabilidade do fornecimento, as microrredes também servem como uma solução para coordenar os interesses dos agentes envolvidos e melhorar o desempenho da rede elétrica (LIANG; ZHUANG, 2014), como alívio de congestionamento, controle de tensão e redução de perdas.

Além dos controles incorporados em nível de componente para facilitar a transição para o modo ilhado e manter a estabilidade, diversas outras funcionalidades específicas de uma


microrrede devem ser realizadas por um Sistema de Gerenciamento de Energia (do inglês, EMS) local (SOARES *et al.*, 2014). Esse sistema não apenas atua como um otimizador econômico, mas também monitora e ajusta os fluxos de energia na rede local (AMINI *et al.*, 2015). Em comparação com os EMS de nível de transmissão, as aplicações EMS para microrredes, com metas de otimização econômica, frequentemente enfrentam restrições mais rigorosas, tanto em relação à rede quanto às emissões de gases de efeito estufa (SOSHINSKAYA *et al.*, 2014), (EL-SEHIEMY *et al.*, 2013). Além disso, o despacho ótimo de recursos em microrredes deve ser tratado com atenção especial à inclusão de outros tipos de recursos (como dispositivos de armazenamento de energia (RIGO-MARIANI *et al.*, 2014) e cargas controláveis (SOARES *et al.*, 2014)), bem como à entrada e saída de recursos da rede e à adoção de novas considerações de modelagem.

A Agência Nacional de Energia Elétrica (Aneel), na perspectiva de utilizar esse tipo de solução, traz na resolução nº 1000 de 2021 os conceitos de Microssistema Isolado de Geração e Distribuição de Energia Elétrica (MIGDI) e de Sistema Individual de Geração de Energia Elétrica com Fonte Intermitente (SIGFI), que são sistemas semelhantes aos que a literatura chama de microrrede, sendo a primeira vez que a Aneel trata sobre o assunto em suas resoluções (ANEEL, 2021). O desafio regulatório para esse tipo de solução é extenso e denso, sendo necessários estudos para avaliações técnicas, contratuais e comerciais das relações dos agentes existentes entre si e dos novos, que surgirão a depender do modelo de negócio a ser regulado (ROSA *et al.*, 2022).

No Brasil, a geração de pequeno e médio porte com potência de até 5 MW tem crescido na última década, notadamente os sistemas fotovoltaicos, atingindo 13,9% da capacidade instalada do sistema, como apresentado na Figura 1. À medida que a participação dos recursos de Energia Renovável Variável (do inglês, VRE) cresce, os desafios para os operadores de rede são maiores, sendo necessário um aumento na capacidade de reserva do sistema para elevar a segurança operacional e, conseqüentemente, o custo global da energia.

Com objetivo semelhante, mas com uma pressão maior devido à maior dependência energética de fontes fósseis, a maioria dos membros da União Europeia já implementou, além da compensação na fatura, incentivos através de tarifas *feed-in* para promover o uso de recursos de energia renováveis. Além disso, o parlamento da União Europeia, com o intuito de aumentar ainda mais a participação de fontes renováveis na sua matriz, reformulou as diretivas relacionadas ao tema (TAJANI; BOGNER-STRAUSS, 2018; TAJANI; CIAMBA, 2019).

Figura 1 – Capacidade instalada em operação até 22/11/2024



Fonte: elaborada pela autora, dados de (ANEEL, 2024)

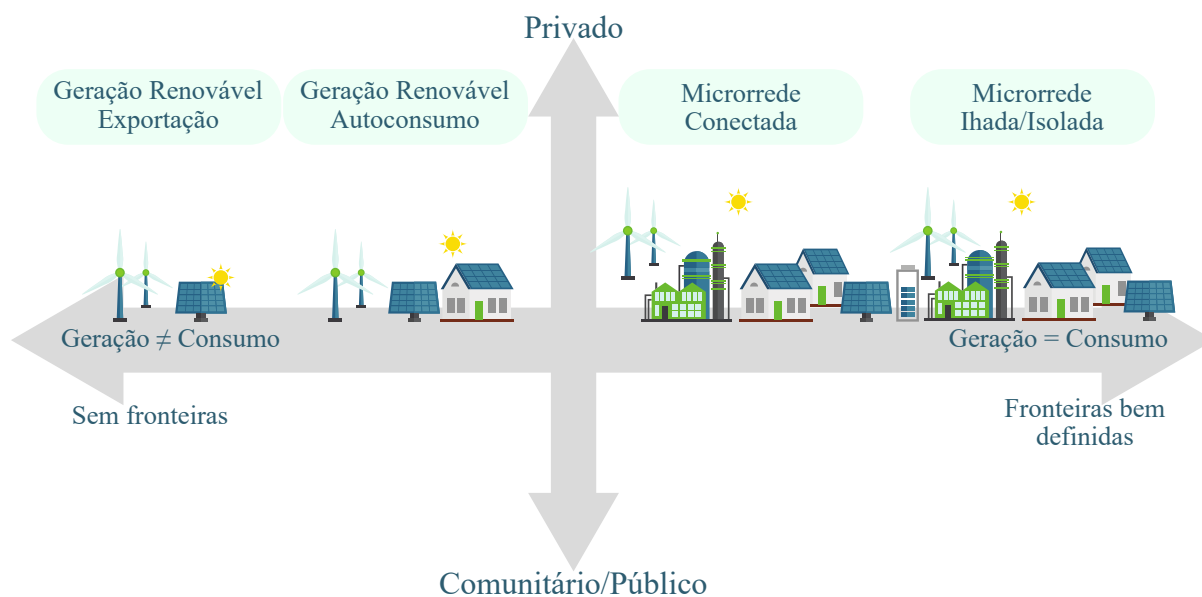
Em um primeiro momento, criou-se as “comunidades de energias renováveis”, cujo principal objetivo era tornar os cidadãos mais atuantes e conscientes sobre a utilização da energia, tornando-os, através de cooperativas, proprietários de RED. Além disso, as associações podem funcionar como agregador tanto na comercialização de energia no mercado de atacado quanto internamente entre seus membros (TAJANI; BOGNER-STRAUSS, 2018).

No segundo momento, o conceito foi ampliado e surgiram as “comunidades de cidadãos para energia”. Nesse caso, torna-se possível a diversificação dos serviços prestados pela Comunidade de Energia, como carregamento de veículos elétricos e distribuição de energia elétrica. Essas iniciativas tendem a facilitar a adoção de novas tecnologias e padrões de consumo, integrando a resposta à demanda, contribuindo para o desenvolvimento das Rede(s) Elétrica(s) Inteligente(s) (REI). Essas comunidades, como modelo de negócio, têm uma característica importante, que é sua finalidade de não lucro, mas de um atendimento menos oneroso e mais eficiente aos seus participantes, com benefícios econômicos, sociais e ambientais (TAJANI; CIAMBA, 2019).

A Figura 2 mostra uma perspectiva de como esses recursos têm se integrado à rede elétrica. Todas as formas podem coexistir no SEP, mas da esquerda para a direita, há aumento de complexidade, justamente porque é necessário um maior equilíbrio entre carga e geração. As comunidades de energias renováveis dentre os tipos apresentados poderiam ser entidades de autoconsumo ou microrredes conectadas à rede elétrica principal. Além das possibilidades já citadas, as comunidades de cidadãos para energias renováveis podem incluir também microrredes

isoladas, cujos modelos de negócio são regulamentados na perspectiva comunitária. O eixo vertical da figura mostra que os proprietários dos recursos podem variar de uma perspectiva privada, que visa o lucro, até uma perspectiva comunitária/pública, que busca o bem-estar do consumidor.

Figura 2 – Formas de integração de energia renovável



Fonte: adaptada de Harrison e Desmyter (2019)

No Brasil, as duas primeiras configurações estão consolidadas, quais sejam, a geração para exportação e o autoconsumo. A resolução nº 1000/2021 (ANEEL, 2021) aborda o caso de microrredes isoladas, no contexto de MIGDI e SIGFI, sendo de responsabilidade da distribuidora. Portanto, ainda não são um modelo de negócios de energia aberto para investidores ou cidadãos. Dessa forma, ainda não há perspectiva de criação de microrredes com um operador próprio e independente da concessionária de distribuição de energia como um novo modelo de negócio.

Outra forma de aumentar a participação das fontes renováveis variáveis é melhorar a interação entre operador de mercado e operador de rede. A redução dos intervalos de programação e despacho das fontes, do intervalo de tempo de liquidação financeira e do tempo entre os lances de mercado e a entrega de energia em tempo real são vantagens que agregam valor às fontes mais flexíveis, consequentemente, incentivando investimentos nesses recursos. Além de reduzir a capacidade de reserva necessária para operação segura do SEP (IRENA, 2019).

O intervalo de tempo de despacho dos recursos pode variar dependendo do operador

do sistema. Normalmente, sistemas com fontes de características mais variáveis tendem a ter intervalos menores. O despacho envolve a alteração dos pontos de referência de potência dos recursos, bem como das referências de tensão, direcionando o fluxo de energia para atender à carga de forma eficiente. À medida que a variabilidade dos recursos energéticos aumenta, a tendência do operador é reduzir o intervalo de despacho, aumentando sua granularidade temporal. Isso naturalmente leva os investidores a buscarem recursos mais flexíveis, como sistemas de armazenamento de energia e resposta à demanda. Para que o ganho sistêmico seja real, o período de liquidação financeira do mercado de energia deve acompanhar o despacho o mais próximo possível.

Esse trabalho, portanto, visa apresentar soluções para integração, operação e gerenciamento de forma econômica e segura dos recursos de pequeno e médio porte renováveis, que formam microrredes. Como a tendência do mercado de energia elétrica é o aumento da granularidade de seus produtos, entende-se que o primeiro passo é a possibilidade de o despacho também ter seu tempo reduzido; por isso, a proposição do trabalho é o despacho de recursos a cada 5 minutos.

1.2 Hipótese do trabalho

A implementação de otimização distribuída utilizando meta-heurísticas em paralelo, aproveitando a capacidade de processamento dos recursos energéticos distribuídos, pode melhorar a estabilidade, segurança e eficiência da operação de microrredes de energia elétrica, especialmente no gerenciamento de recursos energéticos em horizontes de curtíssimo prazo.

1.3 Objetivos

1.3.1 Objetivo geral

O objetivo geral deste trabalho é propor um modelo de gerenciamento de energia para microrredes para otimização dos recursos energéticos e redução do custo total, usando sistema multiagente e Meta-heurística(s) (MH) distribuídas, em um ambiente de co-simulação.

1.3.2 Objetivos específicos

Os objetivos específicos deste trabalho consistem em:

- a) modelar as funções custo dos RED por categorias, fontes despacháveis e variáveis, armazenadores de energia e resposta à demanda, bem como a função objetivo do problema;
- b) fazer uso de sistema multiagente e algoritmo de otimização meta-heurístico centralizado e distribuído em ambiente de co-simulação;
- c) realizar cálculo para o despacho de recursos em curtíssimo prazo para gerenciar incertezas relacionadas a fontes e cargas;
- d) incluir no sistema de despacho a funcionalidade *plug-and-play*, que permite a entrada e a saída, espontânea ou sob demanda, dos recursos energéticos nas próximas programações;
- e) apresentar a importância da granularidade do mercado de energia;
- f) desenvolver os estados de entrada para simulações, com característica quasi-dinâmica, em intervalos de cinco minutos;
- g) avaliar a funcionalidade de cada método de despacho, centralizado e distribuído;
- h) definir cenários de casos de teste para validação do modelo de gerenciamento de recursos energéticos.

1.4 Contribuições

Como contribuições científicas realizadas nesse trabalho, têm-se:

- a) elaboração de um sistema de *plug-and-play* para entrada de recursos energéticos em um ambiente de agentes para otimização de curtíssimo prazo;
- b) análise e parametrização das funções objetivo dos principais recursos energéticos em por unidade (pu);
- c) proposição da utilização de diferentes meta-heurísticas em paralelo no nível de algoritmo, adicionando etapas de competição e cooperação, visando a utilização de *hardware* distribuído por meio de Sistema(s) Multiagente(s) (SMA).

1.4.1 Artigos publicados

ALMADA, Janaína B.; LEÃO, Ruth P.S.; ALMEIDA, Rosana G.; SAMPAIO, Raimundo F. Microgrid distributed secondary control and energy management using multi-agent system. **International Transactions on Electrical Energy Systems**, v. 31, n. 10, p. e12886,

2021.

CES, Natalia P.L.; GADELHA, Nathanael D. Gadelha; ALMADA, Janaína B.; LEÃO, Ruth P.S.; SAMPAIO, Raimundo F. Economic dispatch of a microgrid using the distributed optimization methods of consensus and diffusion. In: 2021 **14th IEEE International Conference on Industry Applications (INDUSCON)**. IEEE, 2021. p. 648-654.

SOBRINHO, Dário M.; ALMADA, Janaína B.; TOFOLI, Fernando L.; LEÃO, Ruth P.S.; SAMPAIO, Raimundo F. Distributed control based on the consensus algorithm for the efficient charging of electric vehicles. **Electric Power Systems Research**, v. 218, p. 109231, 2023.

1.5 Estado da arte

As meta-heurísticas têm evoluído constantemente desde os primeiros algoritmos desenvolvidos na década de 1970 (RAJWAR *et al.*, 2023). Entre as inovações, o uso de múltiplos processadores para a solução dos problemas foi proposto em 1987, inspirado na biologia evolutiva e utilizando algoritmos genéticos (COHOON *et al.*, 1987). Esses estudos exploraram o uso de subpopulações com e sem comunicação entre os processadores, mostrando que, além da redução do tempo de execução, também era possível alcançar melhores resultados. Embora, desde Alba (2005), meta-heurísticas em paralelo tenham sido amplamente exploradas, Rajwar *et al.* (2023) aponta que essas implementações têm capacidades de otimização poderosas e ainda terão um grande impacto na computação futura.

Sun *et al.* (2022) listou mais de 70 proposições de paralelismo de meta-heurísticas, entre as quais três foram aplicadas em sistemas elétricos. Zhang *et al.* (2010) utilizou algoritmos de evolução diferencial com multigrupos que podem trocar informações dinamicamente a cada iteração para otimizar o fluxo de potência reativa na rede, reduzindo perdas elétricas. Shafik *et al.* (2019) aplicou o método *Adaptive Parallel Seeker Optimization Algorithm* para solucionar um fluxo de potência ótimo, com o objetivo de integrar compensadores série, reduzir custos e minimizar o fluxo de reativos no sistema. A troca de informações entre as subpopulações da meta-heurística é realizada a cada iteração, baseada no sorteio de números aleatórios; o pior elemento de uma subpopulação pode receber valores do melhor elemento de outra subpopulação. Zhang e Hui (2016) realizou o paralelismo do *Multiagent Coordination Optimization*, que utiliza a inteligência de enxame associada ao protocolo de consenso para resolver problemas de balanço de carga.

O gerenciamento de sistemas de armazenamento para microrredes em corrente contínua foi realizado com meta-heurísticas em paralelo, mas sem troca de informações no paralelismo (GRISALES-NOREÑA *et al.*, 2020; GRISALES-NOREÑA *et al.*, 2023). Em (GRISALES-NOREÑA *et al.*, 2020), o *Parallel Particle Swarm Optimization* foi utilizado com processamento em paralelo; já (GRISALES-NOREÑA *et al.*, 2023) acrescentou *Parallel Vortex Search Algorithm* e *Parallel Ant Lion Optimizer* para comparação. Todas as técnicas foram realizadas com a configuração de processadores do tipo mestre-escravo.

Fora dos sistemas elétricos de potência, diversas outras aplicações utilizam o paralelismo de meta-heurísticas para a solução de problemas como roteamento de veículos, projetos de equipamentos, problemas de larga escala, redes neurais, segmentação de imagens, entre outros (SUN *et al.*, 2022).

Durante o processo de utilização de meta-heurísticas em paralelo, alguns autores apresentaram resultados positivos, como Tsai *et al.* (2003), que utilizou clãs de formigas com comunicação unidirecional entre os clãs e troca de informações baseadas em pesos complementares entre os dados do próprio clã e do grupo vizinho. O autor encontrou resultados superiores ao sistema de uma única colônia de formigas no problema do caixeiro viajante. Já outros pesquisadores, ao realizar o paralelismo, encontraram problemas como a discrepância entre o tempo de execução real e o esperado. Gies e Rahmat-Samii (2003), que desenvolvia aplicações para antenas e radares, esperava que o tempo de execução fosse reduzido em 10 vezes ao utilizar 10 enxames de partículas. Entretanto, seus resultados apontaram para uma redução de apenas 8 vezes. Por isso, a utilização do paralelismo de meta-heurísticas deve estar associada à aplicação.

Neste trabalho, o objetivo da utilização de meta-heurísticas em paralelo é usar *hardware* comumente disponível em equipamentos para distribuir a otimização de forma a tornar o problema escalável. À medida que um novo equipamento é agregado, sua capacidade de processamento é utilizada para a solução do problema, sem a necessidade de aumentar a capacidade de processamento de uma unidade central.

Ao mesmo tempo, essa solução deve atender o despacho de curtíssimo prazo, que é a tendência para redes com alta penetração de fontes renováveis de natureza estocástica. O curtíssimo prazo, em alguns artigos, é tratado de dias a uma semana, o que anteriormente era comum, visto que os sistemas elétricos de potência tinham uma característica hidrotérmica (XIANGPING *et al.*, 2000). Para atender toda a capacidade dos recursos variáveis disponíveis hoje, a otimização da operação de curtíssimo prazo deve reduzir os tempos de atuação.

A otimização do despacho para o mercado de energia do dia seguinte tem bastante destaque na literatura, com a otimização sendo realizada em intervalos de uma hora para as próximas 24 horas (CHEN *et al.*, 2024). Entretanto, devido às inovações de grandes empresas de energia, como o *California Independent System Operator* (CAISO), que possuem produtos de rampas flexíveis de reserva de potência, novas publicações já buscam otimizar o despacho com base nessas regras, otimizando o despacho em intervalos de 5 a 15 minutos (NADERMAHMOUDI *et al.*, 2020). Mais de 470 artigos de pesquisa foram publicados em revistas científicas apenas na plataforma Elsevier nos anos de 2023 e 2024 e aceitos para publicação até março de 2025. Isso mostra que o tema é de interesse atual na comunidade científica, bem como o modelo proposto de meta-heurísticas em paralelo é aderente a essa abordagem, considerando a natureza dos recursos distribuídos.

1.6 Organização do documento

O trabalho está organizado em cinco capítulos. No primeiro capítulo, são apresentadas a contextualização do uso de microrredes nos sistemas de distribuição e a tendência de essas redes se tornarem cada vez mais digitais e abertas, abrangendo mercados de energia elétrica mais dinâmicos e acessíveis. A hipótese do trabalho surge da necessidade de otimizar, em curtíssimo prazo, os recursos energéticos nesses cenários. Também são destacados os principais objetivos, o estado da arte na área de pesquisa e as contribuições do trabalho.

O capítulo 2 aborda as definições e os principais desafios das microrredes. São apresentados os principais recursos energéticos utilizados em microrredes, assim como suas principais características e a influência que exercem no controle e gerenciamento das microrredes. Controle hierárquico, reserva de potência operativa, modelos e métodos de otimização são abordados nos sistemas de grande porte, especialmente o Sistema Interligado Nacional (SIN), que servem como parâmetros para decisões no gerenciamento de recursos de microrredes. Além disso, é realizado um levantamento de diversos países e regiões sobre o aumento da granularidade temporal. Ou seja, a redução dos intervalos de operação do sistema e de negociações nos mercados de energia decorrentes do aumento de fontes de energia renovável de natureza estocástica.

O capítulo 3 apresenta as ferramentas e os métodos para a aplicação da otimização distribuída por meio de meta-heurísticas. Destacam-se o ambiente de co-simulação, o sistema multiagente e as meta-heurísticas aplicadas. Por fim, são analisados os modelos utilizados para

cada um dos recursos, avaliando suas particularidades para a tomada de decisões.


O capítulo 4 apresenta os recursos escolhidos para a composição da microrrede teste, a parametrização de cada uma das variáveis do modelo. São apresentados cenários de simulação para avaliar, em um primeiro momento, a convergência das variáveis para o modelo de otimização distribuído baseado em meta-heurísticas. Em seguida, são realizados ajustes nos modelos das fontes e diversificação nos parâmetros dos métodos, para avaliar o desempenho das meta-heurísticas em paralelo em relação às aplicações centralizadas.

O capítulo 5 apresenta as conclusões obtidas nos estudos e simulações desenvolvidos, bem como as considerações para possíveis melhorias dos modelos e métodos para a aplicação na otimização de microrredes no curtíssimo prazo.

2 ABORDAGENS PARA GERENCIAMENTO ENERGÉTICO DE RECURSOS EM MICRORREDES

Microrrede é um sistema de energia que pode operar independentemente da rede elétrica principal (modo de operação ilhado ou isolado) ou como uma entidade controlável em relação à rede elétrica principal (modo de operação conectado), como apresentado na Figura 3. Uma microrrede inclui recursos energéticos distribuídos, como usinas solares fotovoltaicas, turbinas eólicas, células a combustível, sistemas de armazenamento, como baterias e hidrogênio, e geradores convencionais, cujas ferramentas avançadas de *hardware* e *software* permitem a integração de todos esses recursos. As microrredes podem atender a uma pequena comunidade energética, a um complexo de edifícios ou até mesmo a uma única casa. Muitas vezes, elas são projetadas para aumentar a resiliência daquela porção do sistema diante de desastres naturais, eventos climáticos extremos ou outras perturbações da rede, além de reduzir as emissões de carbono.

Figura 3 – Recursos e modos de operação de uma microrrede



Fonte: elaborada pela autora (2025).

Uma microrrede comunitária difere de uma microrrede residencial ou de um único edifício em termos de escala, cobertura, fontes de geração, complexidade e resiliência. Uma microrrede comunitária serve uma área maior com múltiplos edifícios, integra diversas fontes de geração e requer uma gestão e coordenação mais complexas. Relacionados a uma microrrede, encontram-se os consumidores que também atuam como produtores de energia, conhecidos como prosumidores, os produtores independentes, o Operador da Microrrede (do inglês, MGO),

que funciona como um agregador, e o Operador do Sistema de Distribuição (do inglês, DSO), responsável pela operação da rede de distribuição à qual a microrrede está conectada. Todos os produtores estabelecem comunicação com o MGO por meio de um canal de comunicação bidirecional. O papel do MGO é agregar e otimizar o despacho de energia da microrrede, garantindo a estabilidade sistêmica e assegurando a satisfação dos seus integrantes.

Dessa forma, neste capítulo são apresentados os recursos energéticos presentes nas microrredes, bem como as relações operacionais e comerciais entre representantes dos recursos energéticos, consumidores e operador do sistema. Utilizam-se as regras operativas das redes de grande porte como indicativo do que é necessário ser considerado para as microrredes.

2.1 Recursos energéticos distribuídos

Tradicionalmente, os sistemas elétricos de potência tinham como objetivo principal o atendimento à carga; assim, a expansão da geração era a estratégia adotada para alcançar esse propósito. Usinas hidrelétricas e termelétricas eram protagonistas neste objetivo. As térmicas, principalmente, de carvão mineral e derivados de petróleo ganharam grande parcela do mercado, visto à necessidade de rios perenes em terrenos com desníveis naturais para a geração através de fontes hidráulicas, bem como questões relacionadas aos outros usos da água e à dependência da precipitação para recuperação dos níveis dos reservatórios.

Essas usinas utilizam máquinas síncronas para a conversão da energia mecânica em energia elétrica e têm uma característica interessante do ponto de vista operacional. Devido à massa girante de seus rotores, é possível, de forma natural, reduzir os impactos de desvios de frequência.

Nos países com parques predominantemente de termelétricas, as crises políticas que elevaram o preço do petróleo e seus derivados comprometeram significativamente o abastecimento de energia elétrica (JANNUZZI *et al.*, 2018). Concomitantemente, pesquisas científicas mostravam que o planeta passa por um processo de aquecimento que traz diversos impactos ao meio ambiente, dificultando o uso das usinas térmicas de combustíveis fósseis, pois a queima de combustíveis lança na atmosfera produtos que agravavam a situação. Uma alternativa seria a utilização de termonucleares; contudo, a perspectiva de tratamento dos resíduos radioativos, os acidentes que já ocorreram e suas consequências (LUDOVICO *et al.*, 2023), bem como a restrição internacional a diversos países para o enriquecimento de combustíveis nucleares devido à preocupação com o desenvolvimento de armas de destruição em massa (ALVIM *et al.*, 2017),

torna esse tipo de fonte pouco atrativa.

Nesse contexto, nos países desenvolvidos, investiu-se em pesquisa e desenvolvimento, principalmente, de fontes de energia como a solar fotovoltaica e a eólica, tornando-as mais acessíveis e, por meio de incentivos econômicos iniciais, lucrativa a sua utilização. Consequentemente, essas fontes atingiram, nas redes elétricas de alguns países, uma participação expressiva. Entretanto, uma característica intrínseca, aleatoriedade dos recursos primários disponíveis, vento e irradiação solar, pode degradar a segurança dos SEP. Adequar a geração à carga apenas com essas fontes seria inviável. Além disso, a fonte fotovoltaica é totalmente indisponível durante o período noturno. Portanto, recursos que antes eram suplementares, como armazenamentos de energia e resposta à demanda, são cada vez mais essenciais para um funcionamento adequado do sistema (MELO, 2022).

No setor elétrico, o Brasil foi pouco afetado pelas primeiras crises do petróleo, já que mais de 80% de sua geração de energia provinha de fontes hidrelétricas. Somente em 2001, devido à baixa capacidade dos reservatórios na região Sudeste, o país começou a investir de forma significativa na diversificação de sua matriz elétrica. Nesse contexto, foram realizados aportes tanto na construção de usinas termelétricas quanto no desenvolvimento de fontes alternativas, com destaque para a energia eólica, que ganhava relevância nos países desenvolvidos.

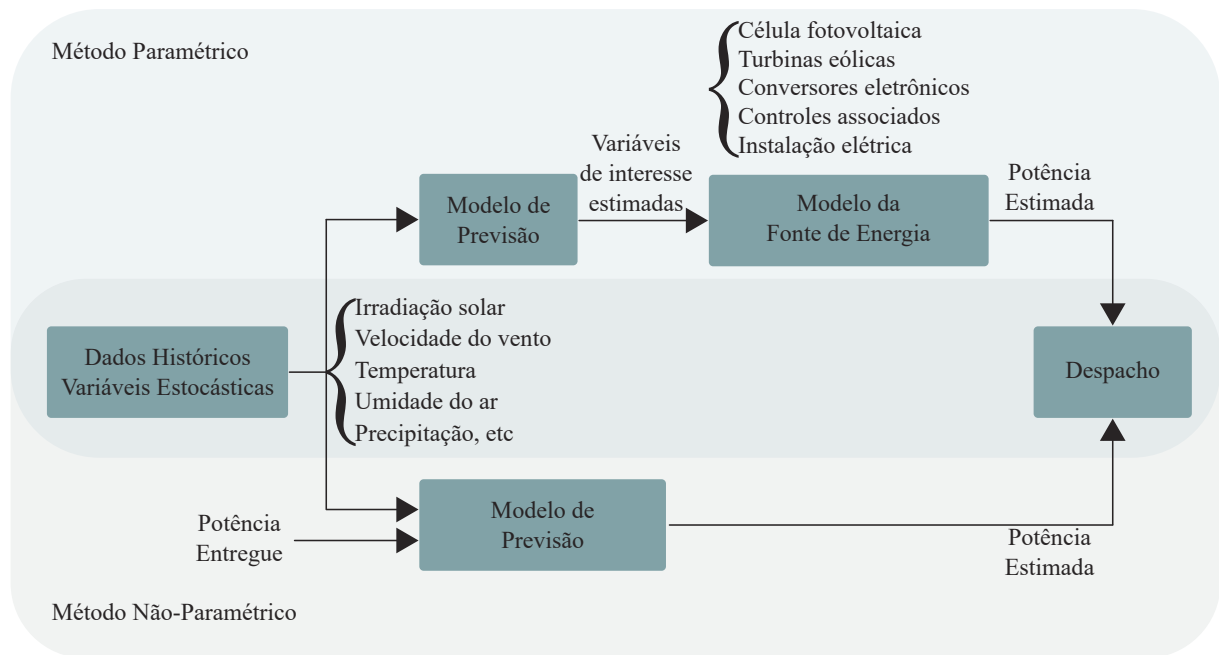
Nas microrredes, esses recursos são ainda mais importantes, visto que a geração fotovoltaica de pequeno porte é a mais difundida dos RED, por sua facilidade de instalação, modularidade e baixa necessidade de manutenção. Os armazenadores de energia são necessários para equilibrar oferta e consumo. E a resposta à demanda é responsável pelo seguimento da geração através de incentivos dados aos consumidores, ou seja, à medida que há um crescimento de geração, as cargas são incentivadas a consumir mais e, quando há restrição de geração por indisponibilidade do recurso ou restrição da rede, as cargas são incentivadas à redução ou deslocamento do consumo.

2.1.1 Fontes renováveis de natureza estocástica

Essas fontes têm sua geração variável ao longo do tempo, pois sua potência de saída está relacionada a condições climáticas, tais como temperatura, irradiação, velocidade do vento e precipitação. Por isso, são consideradas fontes não despacháveis, pois não conseguem aumentar sua capacidade de geração quando solicitadas, embora possam reduzir a geração em caso de diminuição da carga.

A forma de incluir esses recursos no despacho ótimo das fontes é baseando as decisões em previsões de geração. Portanto, qualquer metodologia de previsão, para a potência de saída dessas fontes, passa pela estimativa das variáveis meteorológicas, como apresentado na Figura 4. As abordagens não paramétricas utilizam a potência da própria unidade geradora para realizar a previsão nos próximos intervalos. O maior problema nesse caso é que a formação do banco de dados só acontece após a unidade geradora entrar em funcionamento. Além disso, se houver troca de equipamentos, poderá ser necessário um tempo de adaptação à nova configuração. A vantagem do modelo paramétrico é que variações de construção dos equipamentos em relação aos parâmetros nominais não são percebidas durante a previsão.

Figura 4 – Previsão de geração de energia elétrica para fontes de natureza estocástica



Fonte: elaborada pela autora (2025).

Já os modelos paramétricos podem prever a geração antes da usina estar em funcionamento, durante as etapas de projeto e de construção, uma vez que é necessária a modelagem da fonte junto com seus controles de forma separada. Essa modelagem fica sujeita à diferença entre os dados teóricos e reais dos equipamentos (ONS, 2018).

As previsões de geração das fontes podem ser realizadas em diferentes horizontes de tempo e espaço, cujos resultados têm objetivos diferentes. Enquanto intervalos de tempo longo (meses a anos) são usados para negociações de contratos de longo prazo e para o planejamento da expansão do sistema elétrico, a previsão em intervalos reduzidos (de minutos a semanas)

serve de apoio importante para a operação. Além disso, esses intervalos reduzidos permitem que os proprietários das unidades de geração realizem negociações nos mercados de curto prazo (ALMEIDA *et al.*, 2015).

Uma previsão de geração das fontes variáveis bem realizada contribui para a redução do custo global da energia, pois a reserva de capacidade, ou seja, recursos “em espera” ou “prontos para operar”, pode reduzir significativamente.

Os modelos de previsão para geração fotovoltaica e eólica podem ser divididos em modelos físicos, estocásticos tradicionais, e nos mais recentes que são baseados em inteligência artificial através de diversas técnicas, desde algoritmos meta-heurísticos (ex: *Particle Swarm Optimazation* - Otimização por enxame de partículas (PSO)) a aprendizado de máquina (ex: redes neurais artificiais) (ALMEIDA *et al.*, 2015; DAI *et al.*, 2023).

Cada agente gerador tem seu próprio sistema de previsão de geração para suas decisões de planejamento técnico e econômico. Entretanto, as previsões para a operação do sistema devem ter uma acurácia consistente, pois estão diretamente ligadas à segurança do sistema. No Brasil, desde 2018, o Operador Nacional do Sistema (ONS) utiliza a metodologia apresentada na Nota Técnica nº 151/2018 para a previsão de energia eólica (ONS, 2018). Já a previsão de energia solar fotovoltaica ainda está em desenvolvimento, com previsão de término no final de 2025 (ONS, 2023a). Até o final deste estudo, o método utilizado pelo ONS é um processo heurístico que combina a média de geração verificada de dias típicos (ONS, 2023d).

Todos os modelos dependem da qualidade e confiabilidade dos dados históricos dos principais parâmetros. O ONS utiliza uma composição de métodos para realizar a previsão utilizada tanto para o despacho em tempo real quanto para o planejamento de operação de curto prazo. Seu sistema de supervisão e controle atualiza a base de dados de geração, velocidade e direção do vento, temperatura, irradiância, com discretização de 4 em 4 segundos. Além disso, são usadas outras bases de dados, como as da Empresa de Pesquisa Energética (EPE) e da Câmara de Comercialização de Energia Elétrica (CCEE), para verificar a consistência e validar seus modelos (OLIVEIRA, 2020).

Diversas grandezas meteorológicas podem ser utilizadas, mas as que têm uma correlação forte com as gerações por fonte eólica e solar são a velocidade do vento e a irradiação solar, respectivamente, cujas previsões sempre terão um erro associado. Embora o objetivo deste trabalho não seja a previsão de geração, a previsão é considerada para a realização do despacho. Portanto, buscou-se na literatura erros típicos de previsão para um despacho cuja granularidade

temporal seja igual ou próxima ao intervalo de 5 minutos considerado neste trabalho. Esses valores serão descritos na implementação do modelo.

2.1.2 Fontes despacháveis

As fontes despacháveis são importantes para a operação adequada de uma microrrede, pois, sob ação de controles, podem aumentar ou diminuir a geração de acordo com a carga a ser atendida, mantendo níveis de tensão e frequência adequados ao sistema. Excluindo as restrições da rede elétrica, que são comuns a todos os recursos energéticos, o despacho dessas fontes é baseado em critérios econômicos e de segurança sistêmica, e também pela disponibilidade da fonte primária, como, por exemplo, combustível armazenado ou água em reservatório.

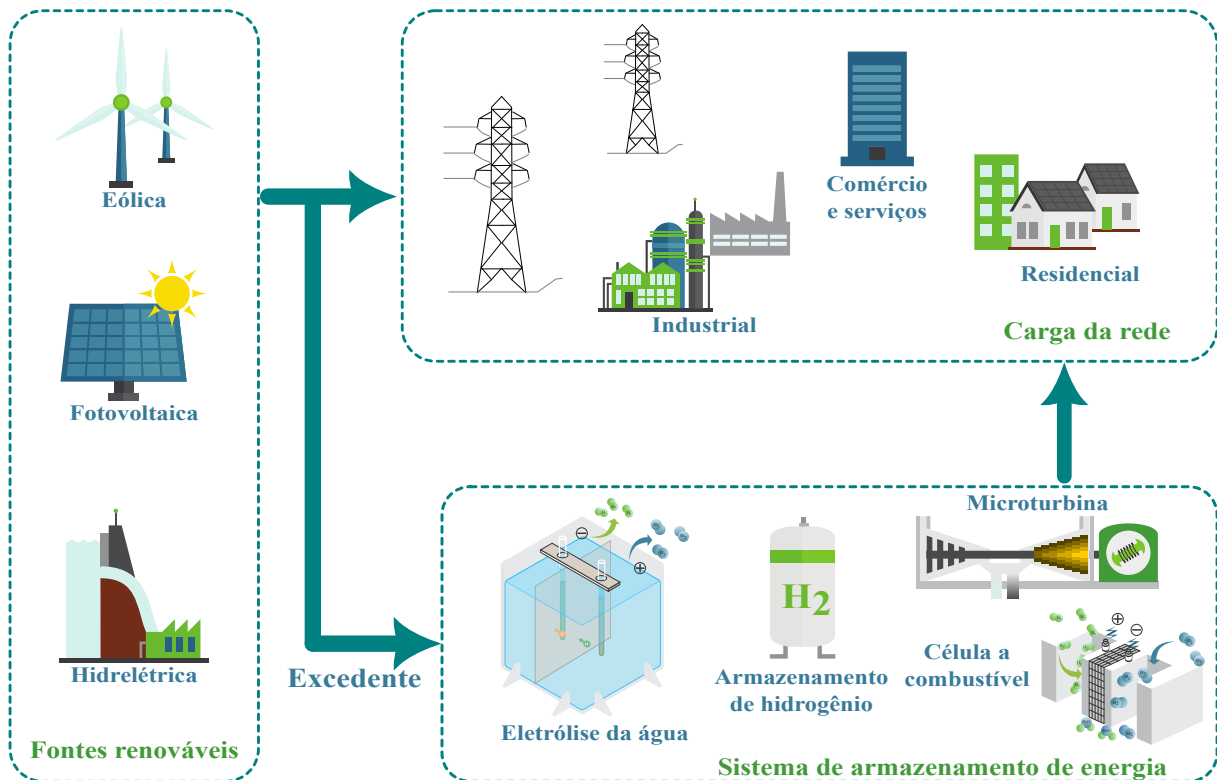
Em sistemas elétricos isolados de médio e pequeno porte, as fontes despacháveis mais comuns são os geradores síncronos acionados por máquinas de combustão interna. No Brasil, os sistemas isolados da região norte utilizam, em geral, combustíveis fósseis, principalmente, diesel e gasolina (ONS, 2022a). Para cargas conectadas à rede elétrica, essas máquinas ainda são amplamente utilizadas como sistemas de *backup*.

Entre as opções com menor impacto ambiental, existem as hidrelétricas de pequeno porte e as centrais geradoras térmicas que utilizam combustíveis como biogás, gás natural ou biomassa. Mesmo sendo fontes tradicionais, essas opções, quando reduzidas em potência, apresentam diferenças significativas na conexão e no funcionamento em relação às de grande porte.

Por exemplo, as térmicas a gás utilizam como máquina primária microturbinas que possuem frequências superiores a 1 kHz; portanto, para conexão em frequência industrial, utilizam conversores eletrônicos, reduzindo a inércia do sistema. Já as centrais hidrelétricas de pequeno e médio porte têm reservatório mínimo e, portanto, operam a fio d'água, ou seja, apenas com o fluxo natural do rio. Isso torna sua disponibilidade de despacho reduzida para apenas dias ou horas (BORKOWSKI; MAJDAK, 2020).

Uma forma de aumentar o número de recursos despacháveis é associar a produção de hidrogênio à utilização de fontes renováveis, como apresentado na Figura 5. Ao utilizar uma microturbina a gás ou uma célula a combustível bidirecional, é possível tornar o sistema elétrico mais controlável. A vantagem da microturbina é que existe, embora reduzida, uma inércia associada, semelhante à inércia das turbinas eólicas, enquanto na célula a combustível não há inércia, sendo equivalente aos sistemas fotovoltaicos.

Figura 5 – Configuração para tornar o sistema mais controlável



Fonte: adaptada de CGEC (2024).

2.1.3 Armazenamento de energia

Os sistemas de armazenamento de energia nos SEP são utilizados desde o início do século XIX com as Usina(s) Hidrelétrica(s) Reversível(is) (UHR). Atualmente, outros sistemas de armazenamento estão em operação, como baterias, volantes de inércia, ar comprimido e armazenamento térmico, embora de forma incipiente.

Segundo Association (2023), apenas China, Japão e Estados Unidos possuíam, aproximadamente, 56% da capacidade instalada dos 175GW de sistema de armazenamento baseado em UHR. Além disso, cerca de 27,1GW é a potência instalada para outros tipos de sistemas de armazenamento estacionários, sendo que 82,3% estão nos Estados Unidos, Reino Unido, Alemanha, China e Coreia do Sul (REI, 2023). Espera-se que em 2050 somente os sistemas de baterias atinjam a capacidade instalada de 3,8TW.

No Brasil, desde 2019, a EPE tem apresentado estudos, por meio de notas técnicas, sobre a introdução de Sistema(s) de Armazenamento de Energia (SAE), com baterias ou hidrelétricas reversíveis. A necessidade de SAE torna-se mais crítica à medida que a potência instalada de sistemas fotovoltaicos e eólicos aumenta na matriz elétrica.

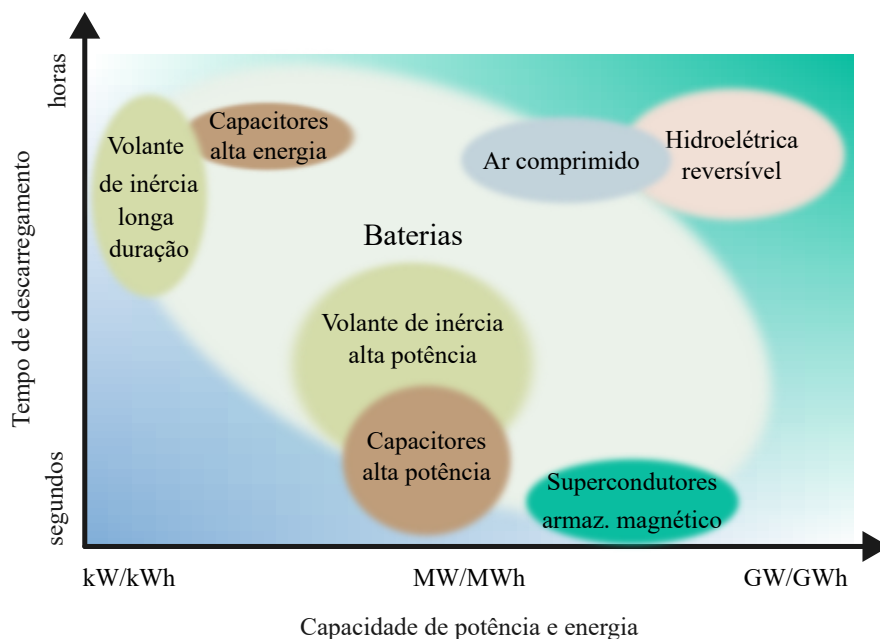
Desde o levantamento das causas do blecaute de 15 de agosto de 2023, o ONS resolveu limitar esse tipo de geração em algumas regiões por segurança. Isso ocorreu porque os modelos entregues pelos agentes não foram suficientes para prever a baixa regulação de tensão causada por fontes eólicas e fotovoltaicas. Essas fontes ampliaram a extensão da ocorrência inicial, que foi a abertura de uma linha de transmissão (ONS, 2023b).

Esse tipo de problema também pode ocorrer em microrredes, sendo necessário, portanto, algum recurso responsável por melhorar essa regulação. Dessa forma, espera-se que os sistemas de armazenamento de energia ganhem importante destaque tanto nos sistemas de transmissão quanto na distribuição. Estes sistemas, quando integrados a fontes de energia renováveis intermitentes, podem ampliar suas responsabilidades na regulação e na estabilização da rede elétrica, bem como tornar o sistema mais eficiente e dar suporte ao usuário final.

Atualmente, existem diversos sistemas considerados para armazenamento de energia. Essa diversidade é propícia, pois com isso tem-se tempos de resposta e capacidade de armazenamento diferentes. Um SAE eficaz deve ser capaz de fornecer uma alta potência para atender às demandas de pico, bem como armazenar uma quantidade suficiente de energia para garantir a continuidade do fornecimento quando as fontes primárias não estão disponíveis.

A tecnologia mais utilizada e bastante consolidada são as usinas hidrelétricas reversíveis, mas outras tecnologias são apresentadas na Figura 6 com suas respectivas capacidades e tempos de descarregamento.

Figura 6 – Capacidade e tempo de descarga



Fonte: adaptada de (EIA, 2023).

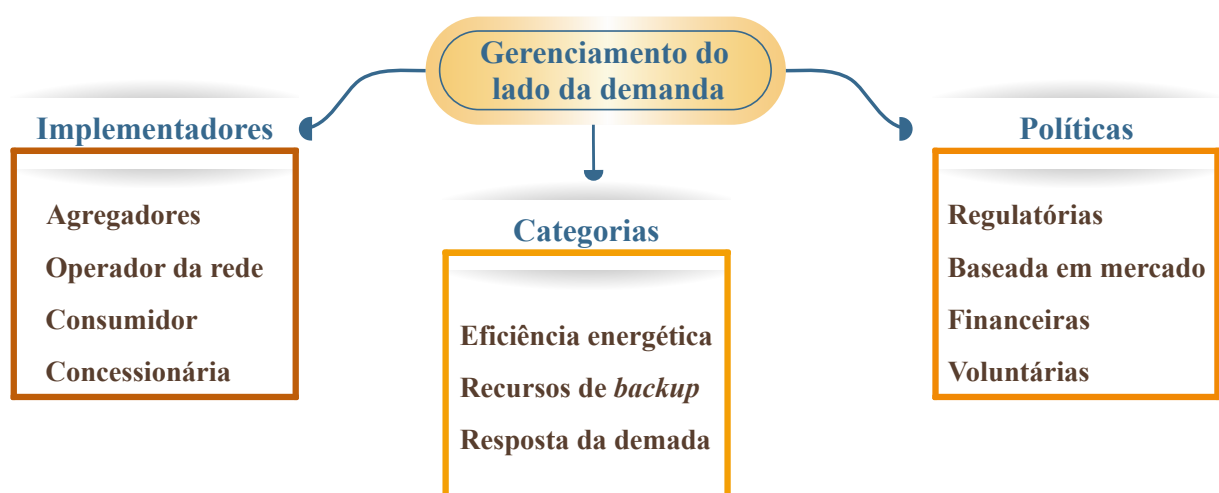
Características importantes para os sistemas de armazenamento incluem a densidade de potência, para lidar com eventos transitórios, e a densidade de energia, para o funcionamento em regime permanente. Dentre os sistemas que exibem ambas as características atrativas, destacam-se as hidrelétricas reversíveis e os sistemas de armazenamento de ar comprimido. No entanto, é importante notar que essas soluções tendem a ter projetos mais complexos e dependem do local de instalação.

Dessa forma, opções mais modulares, como as baterias, podem se tornar uma escolha, principalmente, em centros urbanos. Outra planta modular que vem crescendo em perspectiva de utilização é a produção de hidrogênio através da eletrólise da água, cuja fonte primária são recursos renováveis, como mostrado na Figura 5.

2.1.4 Resposta à demanda

A resposta à demanda é uma das formas de Gerenciamento pelo Lado da Demanda (GLD) cujo objetivo é reduzir e/ou deslocar o consumo para momentos que não coincidem com os períodos de sobrecarga da rede. Além disso, pode também incentivar o consumo quando há excesso de geração de fontes de natureza estocástica. A Figura 7 mostra, também, eficiência energética e recursos de *backup* como outras formas de GLD.

Figura 7 – Agentes, categorias e políticas para o gerenciamento de carga



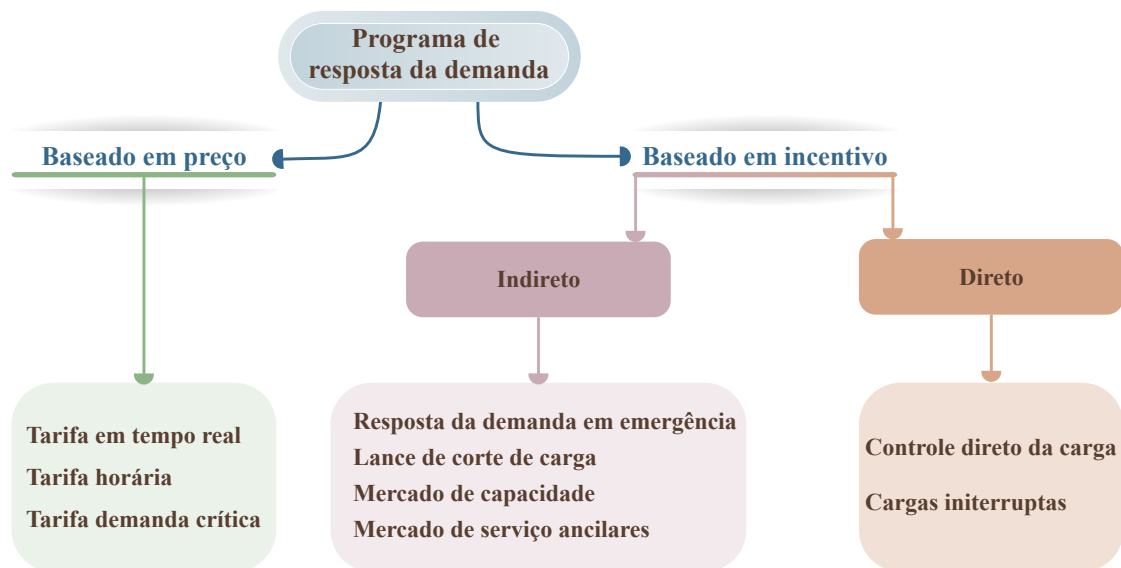
Fonte: adaptada de Stanelyte *et al.* (2022).

As ações de eficiência energética visam uma redução no consumo global de energia, já a resposta à demanda são decisões de curto prazo para ganho financeiro. A utilização de

recursos, tais como fontes de *backup* ou armazenadores de energia, pode facilitar a adesão dos consumidores aos programas de resposta à demanda, visto que a contabilização desses programas observa apenas a energia líquida no ponto de conexão.

A Figura 8 mostra que existe ainda uma divisão entre os programas de resposta à demanda, entre os baseados no preço da tarifa e aqueles baseados em incentivos. Nos programas baseados em preço, geralmente, são programas estabelecidos pelos agentes reguladores e operacionalizados pelas concessionárias. Nesses programas, os consumidores recebem informações sobre o preço da tarifa para diferentes horários, a partir dos custos da energia gerada. Espera-se que, mesmo sem incentivo, haja uma redução no consumo nas horas de maior demanda do sistema. A tarifa horária (em inglês, *Time of Use*) é utilizada no Brasil tanto para consumidores de pequeno porte, através da tarifa horária branca, como para consumidores de grande e médio porte, cujas tarifas são horária azul ou verde.

Figura 8 – Subcategorias de programas de resposta à demanda



Fonte: adaptada de Stanelyte *et al.* (2022).

Na tarifa em tempo real (em inglês, *Real Time Pricing*), o consumidor é informado diariamente, ou até uma hora antes, sobre o preço da energia e pode modificar seu padrão de consumo a partir dessa informação. Há ainda programas em que o consumidor pode aderir também à tarifa de demanda crítica (em inglês, *Critical Peak Pricing*) em que deve pagar mais em dias ou períodos críticos da rede, em função de um desconto na tarifa padrão no restante do período. Na Califórnia, esse é um dos programas disponíveis, no qual há limitação dos horários

em que os eventos críticos podem ocorrer, bem como é estabelecido que os descontos sejam aplicados durante o período de verão, quando a energia é mais cara (SCE, 2022).

Uma diferença significativa entre os programas baseados em preço e em incentivo é que o primeiro reage a um preço determinado para a energia, embora variável, e não existem metas ou aplicações de multas (VARDAKAS *et al.*, 2014). Já os programas que respondem a incentivos podem utilizar leilões para ofertar “corte de carga” nos ambientes de negociação, alterando o preço da energia. Além disso, quando são assinados contratos de redução de carga em emergência, caso o acordo não seja cumprido, os participantes podem sofrer penalidades.

Os programas de resposta à demanda que possuem controle direto são fáceis de serem atingidos, pois o consumidor libera ao operador da rede o controle remoto da carga. Exemplos de cargas que são bastante úteis para programas de resposta à demanda são sistemas que controlam temperatura e carregamento de veículos elétricos, cujo tempo de carregamento pode ser modificado.

Já os programas de controle indireto precisam de avaliação estatística dos dados de consumo do participante para a criação de curvas de base. Essas curvas são utilizadas na medição e verificação se houve ou não o atendimento à sinalização de redução na carga. Geralmente, os agentes que participam desses projetos são consumidores de grande porte. No Brasil, já foi criado um projeto-piloto operacionalizado pelo ONS e a CCEE em 2017. A adesão dos consumidores foi baixa e diversos pontos de melhoria foram identificados, principalmente relacionados à formação da curva de carga de base (CCEE, 2019). Em 2022, foi aberta novamente a possibilidade de adesão, mas com produtos disponibilizados pelo ONS em ambiente regulatório experimental (ANEEL, 2022).


Embora no Brasil esses projetos ainda estejam em desenvolvimento regulatório, a resposta à demanda já é um recurso amplamente utilizado em outros países para reduzir o custo da energia. Esse mecanismo é especialmente relevante em locais com alta penetração de fontes eólicas e fotovoltaicas. Embora os operadores do sistema busquem envolver consumidores de grande porte, também é possível obter bons resultados com a adesão de consumidores de médio e pequeno porte por meio de agregadores. A implantação desses programas pode ser bem-sucedida em mercados varejistas de energia consolidados.

2.2 Controles operacionais

Diversos sistemas têm de ser implementados para monitoramento, proteção, controle, manutenção e gerenciamento dos recursos que formam as microrredes. Entre os diversos assuntos de interesse para melhor operar microrredes, a questão do balanço de potência entre recursos de fornecimento e de consumo é fundamental. Sobretudo nos casos de funcionamento isolado da rede elétrica principal, pois o desbalanço de potência ativa causa desvios de frequência, enquanto os de potência reativa causam desvios na magnitude da tensão, que podem culminar em desligamentos indesejados. No caso de microrredes conectadas, o balanço também é importante, mas na perspectiva contratual de fluxo de potência com a concessionária, uma vez que a rede principal tem o papel de estabilizar a magnitude e a frequência da tensão, por ter capacidade superior à das microrredes.

A Figura 9 mostra como a frequência pode variar durante eventos na rede elétrica. A parte superior à operação normal representa um evento no qual a frequência atinge um valor máximo, ocorre em momentos de geração superior à carga. Nessa ocasião, os controles devem atuar reduzindo a geração. Já o evento representado na parte inferior do gráfico ocorre quando a potência da carga é superior à da geração. Nesse caso, a frequência atinge um valor mínimo (conhecido como frequência de nadir) devido à resposta inercial das máquinas.

Figura 9 – Comportamento da frequência logo após um evento no sistema



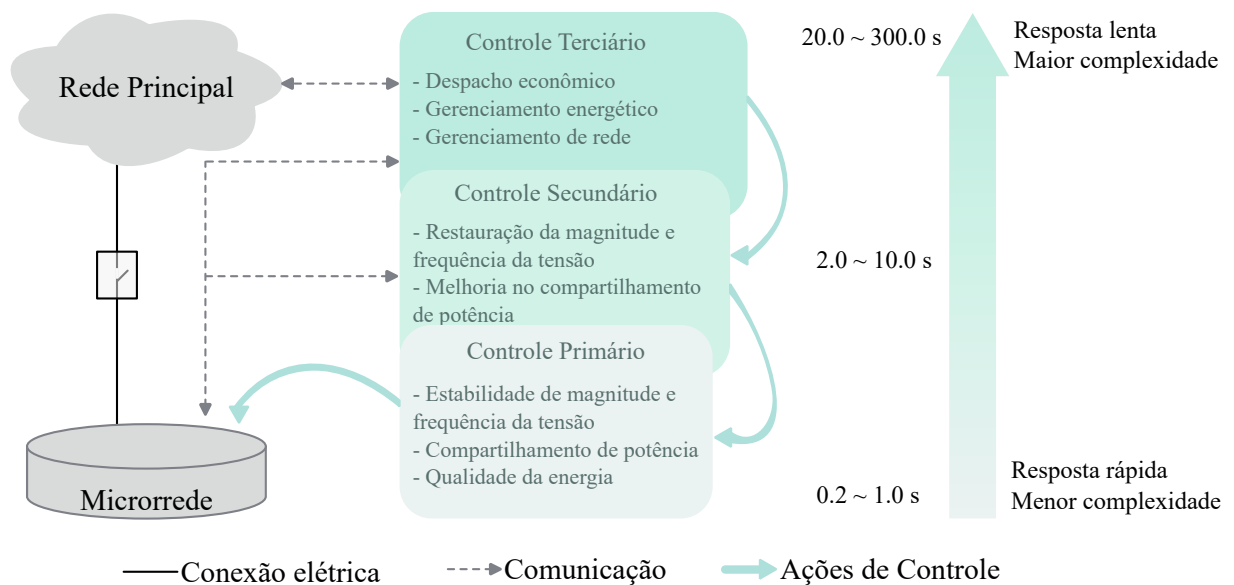
Fonte: adaptada de Nakiganda e Aristidou (2023).

Esses eventos ocorrem quando o balanço energético não é efetivo, ou seja, a potência

da carga difere da potência da geração. Dessa forma, uma concepção temporal de controles foi implementada nos SEP para reduzir os efeitos do desbalanço. Esse conjunto de ações é denominado controle hierárquico, dividido em três etapas: controles primário, secundário e terciário. A Figura 10 mostra os intervalos médios de atuação de cada um dos níveis hierárquicos de controle. É possível observar que, em todos os níveis, o balanço de potência é avaliado, com atuação de controle caso necessário.

Enquanto o controle primário busca a estabilização da magnitude e frequência da tensão, o controle secundário restaura possíveis desvios que ocorreram na atuação do controle primário. Essa ação já ocorre utilizando a reserva de potência operativa disponível cuja resposta esteja no limite temporal de atuação deste nível. O controle terciário visa melhorar os custos operacionais, atuando na redistribuição de potência entre os recursos e liberando as unidades utilizadas no controle secundário, de modo a estarem prontas caso um novo cenário ocorra. Para isso, utilizam-se técnicas de otimização.

Figura 10 – Controle hierárquico sistêmico



Fonte: adaptada de Espina *et al.* (2020).

Na Figura 10, observa-se a microrrede como um subsistema da rede elétrica principal. Dessa forma, para casos de ilhamento da rede principal, todos os níveis hierárquicos devem estar presentes na microrrede para um funcionamento satisfatório. Além disso, à medida que essas microrredes crescem em potência, também podem participar contribuindo com as regulações requeridas pela rede principal.

O despacho das fontes ocorre num cenário de normalidade, ou seja, sem eventos, e os controles atuam em situações de contingência. Entretanto, a Reserva de Potência Operativa (RPO) deve ser considerada no despacho ótimo das fontes. No cálculo da $RPO_{sistema}$, existem metodologias que consideram o máximo risco aceitável de não atendimento à carga no horário de ponta do sistema e a taxa de falha de cada unidade geradora. Será apresentada a metodologia de cálculo da RPO no SIN, com o objetivo de fornecer subsídios para sua aplicação no despacho das microrredes.

No Brasil, até 1985, o cálculo utilizava o método determinístico, e desde então utiliza-se o modelo probabilístico RESPROB desenvolvido pelo CEPEL (Eletrobras) que faz parte do *software* NH2 (ONS, 2022b; CEPEL, 2021). A RPO é dividida por nível de controle ($R1$ -reserva primária, $R2$ -reserva secundária e $R3$ -reserva terciária) e por área operativa. Para uma área de controle j , a reserva primária de potência operativa é dada por:

$$R1_j = 1\% \cdot CL_j$$

$$CL_j = CI_j + \sum_{k=1}^n (P_{jk}^{out} - P_{kj}^{in}) \quad (2.1)$$

em que CL_j é a carga líquida da área j , CI_j é a potência da carga interna da área j , P_{jk}^{out} é a potência de intercâmbio programado para fluir da área j para a área k , P_{kj}^{in} é a potência de intercâmbio programada que deve entrar na área j com origem na área k e n são todas as áreas que fazem fronteiras com a área j . Se considerarmos um sistema isolado, P_{jk}^{out} e P_{kj}^{in} são iguais a zero.

A reserva secundária de potência operativa é dividida em duas partes: elevação, $R2e_j$, e redução, $R2r_j$. Quando no subsistema há uma participação relevante de fontes variáveis, uma parcela relacionada a essa variabilidade deve ser acrescentada, R_{est} , como observado em:

$$R2r_j = 2,5\% \cdot CI_j + R_{est,j}$$

$$R2e_j = 4\% \cdot CI_j + R_{est,j}. \quad (2.2)$$

No Brasil, apenas as regiões de controle nordeste e sul têm essa parcela relacionada à variabilidade das fontes eólicas. Na região nordeste, $R_{est,NE}$ deve ser 6% da potência prevista para a energia eólica gerada, enquanto no sul, $R_{est,S}$ deve ser 15%.

Por fim, a reserva terciária de potência operativa deve ser diferente de zero quando a RPO global do sistema for maior que a 5% da carga total do sistema, $CT_{sistema}$, e será alocada

por área de controle da seguinte forma:

$$R3_j = \frac{MM_j \cdot CL_j}{\sum MM_j \cdot CL_j} \cdot MM_p \quad (2.3)$$

$$MM_p = RPO_{sistema} - 5\%CT_{sistema}$$

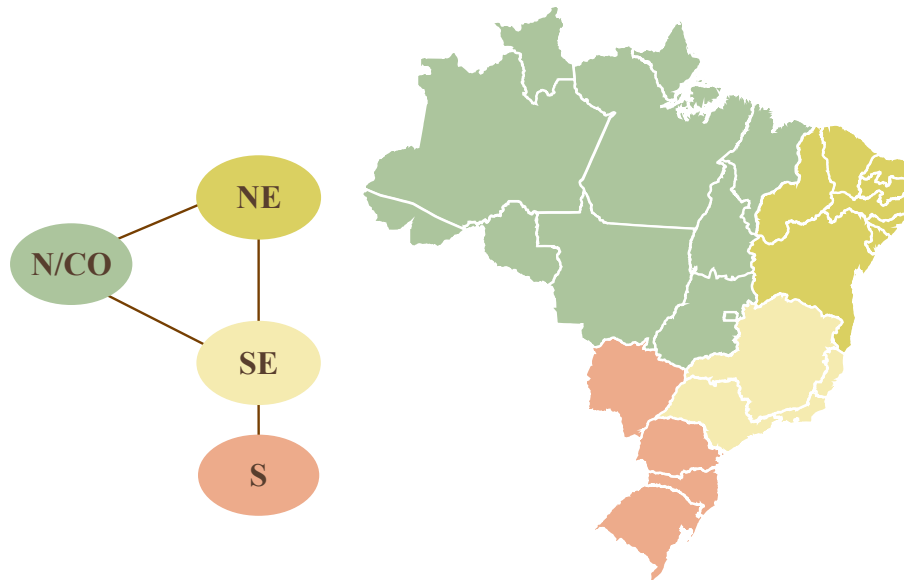
em que MM_j é a máquina de maior potência da área de controle j , CL_j a carga líquida da área j calculada em 2.1 e MM_p é a “Maior Máquina Probabilística”¹ (ONS, 2022b). Dessa forma, a reserva operativa de uma área é dada por:

$$RPO_j = R1_j + R2e_j + R3_j, \quad (2.4)$$

a respeito da $R2r_j$ será abordado mais sobre essa reserva na subseção 2.2.2.

As Figuras 11 e 12 representam as áreas de controle no SIN e em uma rede de distribuição, respectivamente. Com isso, mostra-se que o mesmo esquema de controle de frequência pode ser aplicado em sistemas de menor porte no nível de distribuição. Além disso, com a metodologia empregada anteriormente, é possível calcular as reservas primária e secundária para uma única microrrede.

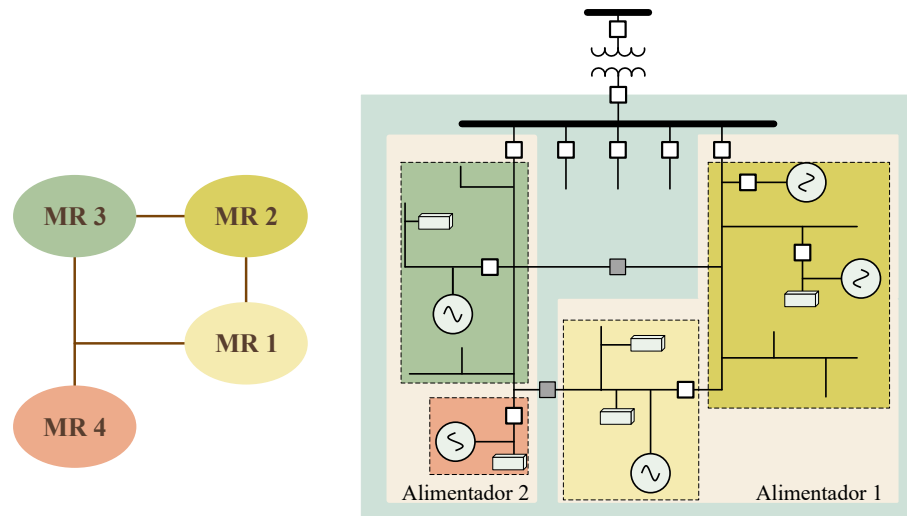
Figura 11 – Sistema interligado nacional dividido em áreas de controle



Fonte: elaborada pela autora (2025).

¹ É o valor de potência da maior máquina teórica que atenderia a reserva operativa do sistema. Essa reserva é encontrada através de métodos probabilístico considerando diferentes cenários de contingência e de variação da carga e da geração.

Figura 12 – Rede de distribuição dividida em microrredes



Fonte: elaborada pela autora (2025).

2.2.1 Controle primário


O controle primário de frequência é facilmente empregado quando as fontes primárias utilizam máquinas síncronas para a transformação da energia. Isso porque é o regulador de velocidade o responsável pela ação desse controle quando há variação na frequência. Dessa forma, esse controle é descentralizado e realizado localmente com a reserva de potência primária da máquina. Quando a inserção de novas fontes e recursos de baixa inércia, como usinas eólicas, ou sem inércia natural, como os sistemas fotovoltaicos e bancos de baterias, é significativa, a contribuição desses recursos com a reserva primária de potência operativa se torna essencial.

No Brasil, desde novembro de 2023, empreendimentos de geração eólica e fotovoltaica com potência superior a 10 MW são solicitados a contribuir com o suporte de potência ativa e reativa em regime de frequência não nominal de acordo com o submódulo 2.10 do Procedimentos de Rede (Prorede). Entretanto, embora esse documento apresente requisitos de desempenho para o controle primário desses recursos, o mesmo afirma que não há a obrigação de reserva de potência operativa por essas centrais geradoras, mas sim de utilizar sua eventual capacidade ociosa em casos de subfrequência (ONS, 2023c). Para microgeração e minigeração distribuída, também foram exigidos períodos mínimos de suportabilidade a variações de frequência e tensão no módulo 3 do Procedimentos de Distribuição (Prodistrib).

A Figura 13 apresenta os dados compilados de tempo mínimo de suportabilidade durante eventos de frequência não nominal exigidos pelo Prodistrib e Prorede. Observa-se que

a faixa de operação contínua das termelétricas é menor, enquanto nas hidrelétricas é maior. Portanto, as hidrelétricas são capazes de suportar desvios de frequência mais amplos.

Figura 13 – Comparação do período mínimo de permanência para diferentes recursos após eventos transitórios de variação de frequência



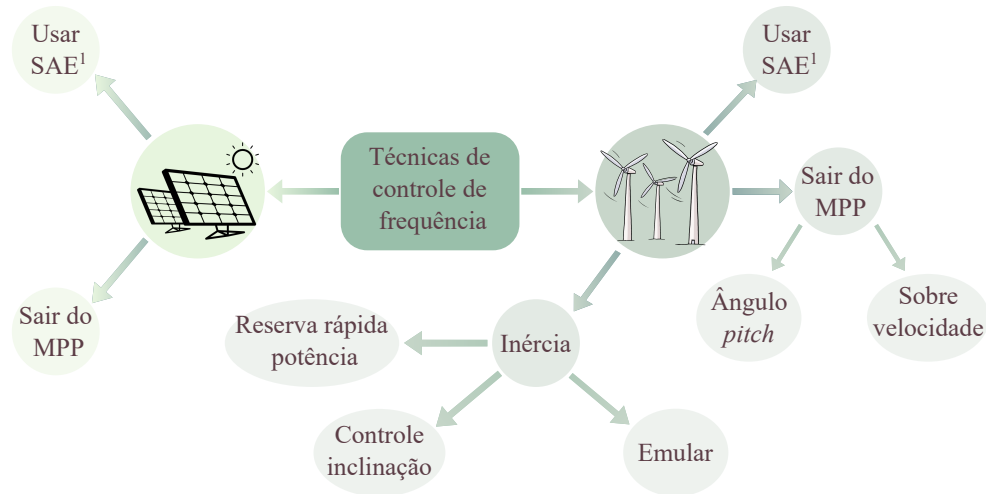
Fonte: elaborada pela autora (2025).

Para aplicações em microrredes operando no modo *off-grid*, todos os recursos são importantes para manter o equilíbrio carga-geração. Dessa forma, os recursos conectados por meio de conversores eletrônicos para contribuir com a suportabilidade devem possuir o modo de operação controle de tensão. Além disso, devem possuir sensibilidade à variação de frequência para que os controles de suportabilidade operem adequadamente, não sendo necessário um relé de proteção específico.

Para as fontes de natureza estocástica reagir à sobrefrequência é relativamente simples, por depender apenas de uma redução na potência injetada, entretanto, a reação à subfrequência exige mais dos controles operacionais e pode comprometer a eficiência em regime permanente. A Figura 14 mostra os principais métodos apresentados na literatura para o controle primário das fontes eólica e fotovoltaica. Em Fernández-Guillamón *et al.* (2019), esses métodos são amplamente discutidos.

Embora os sistemas de armazenamento de energia sejam apresentados como solução para a contribuição das fontes de natureza estocástica no nível de controle primário, raramente é discutido o tamanho desses sistemas, bem como seria a responsabilidade sobre os custos de sua implantação (FINI *et al.*, 2023). Sair do Ponto de Máxima Potência (do inglês, MPP) também é viável como forma de contribuição dessas fontes para o controle primário de frequência; no entanto, em regime permanente, reduziria a eficiência dos geradores, pois eles precisariam deixar de gerar entre 10% e 15% do valor de MPP (ZHU *et al.*, 2020). Para a fonte eólica, tem-se ainda

Figura 14 – Controles de frequência para fontes de natureza estocástica



¹SAE: Sistema de armazenamento de energia

Fonte: adaptada de Fernández-Guillamón *et al.* (2019).

a emulação da inércia requerida pelo sistema (YOUSEF *et al.*, 2021) e o controle por inclinação, cuja diferença está nas malhas internas de corrente e tensão (OFIR *et al.*, 2018). Tem-se ainda a resposta à demanda sendo utilizada como uma forma de controle primário sugerida por Bosaletsi *et al.* (2023), na qual o controle de cargas térmicas poderia seguir uma inclinação que permitiria uma resposta a desvios de frequência.

Nesta seção, foi dada ênfase no controle de frequência devido aos objetivos do trabalho, mas também porque o controle de magnitude da tensão dispõe de mais dispositivos independentes da fonte primária, como, por exemplo, capacitores e reatores, para atender às necessidades do sistema. Entretanto, reforça-se que as fontes têm responsabilidades nessa manutenção da tensão elétrica em níveis adequados de acordo com os códigos de rede.

2.2.2 Controle secundário


No Brasil, o controle secundário de frequência é feito por unidades de geração, escolhidas pelo ONS e autorizadas pela Aneel. Essa escolha é baseada em estudos realizados pelo operador com contribuição da EPE resultando no Parecer Técnico para a Prestação de Serviços Ancilares (ONS, 2021). Somente as Usina(s) Hidrelétrica(s) (UHE) fazem parte do controle secundário e as Usina(s) Termelétrica(s) (UTE) são requisitadas para restaurar as reservas primárias e secundárias, inclusive da água vertida pelas UHE durante a atuação do controle secundário. As usinas que atuam no controle secundário de frequência formam o

Controle Automático de Geração (CAG) e são remuneradas anualmente pelo serviço prestado, através dos Encargos de Serviços do Sistema (ESS) custeados pelos consumidores.

A equação 2.2 mostra a divisão da reserva de potência operativa secundária em duas partes: elevação e redução. A capacidade de redução é necessária quando a ocorrência de um evento resulta na elevação da velocidade das máquinas. Portanto, a redução de potência deve ser alocada para que as máquinas não entrem em faixas proibitivas de operação. Essas condições podem ser decorrentes de questões técnicas, como a cavitação em máquinas hidráulicas ou a vazão mínima sanitária, ou econômicas, como a redução acentuada de eficiência.

Já a capacidade de elevação requer uma potência adicional da unidade geradora. Essas capacidades podem ser alocadas para diferentes unidades geradoras dentre as que compõem o CAG ou para a mesma unidade, a depender do despacho. A Figura 15 mostra um exemplo de faixa de operação ótima e proibida. A faixa de eficiência da máquina pode não ser atendida devido às condições e à necessidade de manter a inércia do sistema. Essa questão é ainda mais preocupante quando a operação fora da faixa mais eficiente resulta em alto custo variável, como ocorre em usinas térmicas (VELASCO, 2004).

Figura 15 – Curva de eficiência por potência total entregue



Fonte: elaborada pela autora (2025).

Em mercados de energia mais abertos, o controle secundário é contratado por meio de leilões, e há diversidade de produtos para o controle de frequência, incluindo controle rápido de frequência. Isso torna o sistema mais competitivo e oferece a oportunidade para outras tecnologias, além dos recursos hidráulicos e térmicos, se adaptarem e participarem desse mercado.

2.2.3 Controle terciário

O controle terciário, quando acionado, já ocorre nos valores de frequência da operação normal. O objetivo é que o sistema retorne ao cenário de despacho ótimo que saiu devido ao evento e recomponha as reservas secundárias das fontes responsáveis dentre as participantes do CAG, além de reestabelecer os fluxos de potência entre áreas de controle.

No Brasil, a RPO terciária pode ser zero, desde que a $RPO_{sistema}$ calculada probabilisticamente, seja menor que 5% da carga do sistema. Para o estudo, um risco máximo de não atendimento à carga é determinado. A reserva operativa no controle terciário pode ser composta por uma parcela não girante, ou seja, máquinas que estão prontas para entrar em operação quando necessário.


As termelétricas podem ser utilizadas nesse nível de controle, mas somente aquelas mais flexíveis, que têm menor tempo de permanência ligadas e cujas rampas de ligamento e desligamento têm maior inclinação. Esse tipo de flexibilidade também é um produto em mercados de energia mais abertos, tornando-se mais necessário à medida que aumenta a participação de fontes variáveis.

2.3 Programação do despacho de recursos

O despacho de recursos consiste em comandos ou instruções para o aumento/redução da produção de energia elétrica ou para o corte de carga (resposta à demanda), com o objetivo de manter o sistema funcionando adequadamente e atendendo à demanda. Cada recurso energético possui suas particularidades e custos associados, sendo necessário realizar um processo de otimização para estabelecer a melhor utilização. A Figura 16 ilustra os três processos mais conhecidos na operação das redes elétricas: autodespacho, Compromisso da Unidade (do inglês, UC) e Despacho Econômico (do inglês, ED).

O modelo de despacho descentralizado é conhecido como autodespacho (em inglês, *self-dispatch*). Tipo de despacho comum na Europa (CONEJO; BARINGO, 2018), o proprietário do recurso escolhe quando e quanto de energia será produzida. Esses agentes, quando desejam uma maior independência do mercado de energia, realizam a programação da geração de acordo com seus contratos de venda de energia de longo prazo. Para manter a segurança do sistema, essas programações são enviadas ao operador da rede para que despachos adicionais sejam realizados para manutenção de reserva operativa. Além disso, quando as programações não são

Figura 16 – Modelos de otimização na operação de redes elétricas



Fonte: elaborada pela autora (2025).

cumpridas, esses agentes estão sujeitos a sanções e multas (GLOWACKI, 2023b).

O modelo centralizado é realizado pelo operador do sistema e avalia simultaneamente as questões de balanço, restrições da rede e reserva operativa (GLOWACKI, 2023a). Comumente usado nos Estados Unidos (CONEJO; BARINGO, 2018), esse modelo, como mostra a Figura 16, divide-se em dois problemas: o compromisso da unidade (em inglês, *unit commitment*) e o despacho econômico (em inglês, *economic dispatch*).

O *unit commitment* consiste na escolha dos intervalos que cada um dos recursos disponíveis deve entrar em operação. Essa programação é um problema de otimização, que envolve variáveis binárias (liga/desliga) e deve ser avaliada para horizontes de tempo de um dia, uma semana ou um mês. Para cada recurso, diversas restrições e custos são considerados. Por exemplo, para as termelétricas, são considerados o tempo e o custo das rampas de elevação e redução de potência, o tempo mínimo que o recurso precisa ficar ligado depois de acionado e o tempo mínimo de desligamento antes de ser acionado novamente. Para as hidrelétricas, essa programação também pode ser realizada, avaliando-se as potências mínimas de operação, a eficiência da máquina e o custo futuro.

O despacho econômico é uma etapa posterior ao UC e também é um problema de otimização. É realizado para cada intervalo de despacho de forma independente, uma vez que já se sabe quais unidades estarão em operação naquele intervalo. O objetivo desse problema é determinar quais referências de potência devem ser enviadas para cada um dos recursos despacháveis, de modo a atender à carga com o menor custo possível e maior benefício para os consumidores (CONEJO; BARINGO, 2018). Na seção 2.5.1, a modelagem matemática dos problemas citados é apresentada.

No Brasil, há um modelo híbrido de programação e despacho, isso porque nem todas as fontes conectadas ao SIN são consideradas na programação e despacho realizado pelo operador. Assim, o ONS realiza uma classificação das unidades de geração, revisada sempre que necessário, dividindo-as em categorias:

- a) Tipo I são usinas de quaisquer recursos primários ligadas ou não à rede básica que causem impacto na programação eletroenergética do sistema e/ou auxiliem na resolução de problemas operativos;
- b) Tipo II-A são as fontes hidráulicas com capacidade superior a 30 MW e fontes térmicas ou híbridas com Custo Variável Unitário (CVU) ² declarado maior que zero;
- c) Tipo II-B são fontes hidráulicas, cujos reservatórios impactam nas usinas Tipo I;
- d) Tipo II-C são fontes que formam um conjunto de usinas, conectadas a um único ponto, e indicadas para operar com uma única representação no ONS;
- e) Tipo III são os outros recursos que não estão dentro das classificações anteriores.

Portanto, somente os recursos que impactam na segurança ou podem contribuir na solução de problemas operacionais na rede básica (tensões superiores a 230kV) participam da programação e despacho centralizados (Tipo I e Tipo II-A). As unidades Tipo III são livres para promover seu autodespacho. Enquanto as unidades Tipo II-B e Tipo II-C participam da programação centralizada, mas têm liberdade para determinar suas referências de potência nos intervalos em que foram designadas para operar.

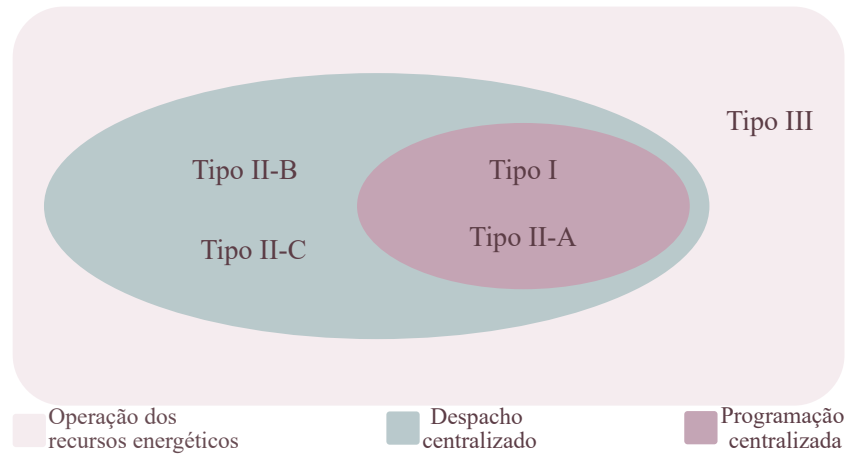
A Figura 17 mostra como se dá a operação das fontes de acordo com a classificação do ONS. As usinas que prestam serviços ancilares, como, por exemplo, o controle secundário de frequência, estão entre as que são despachadas centralizadamente a cada 30 minutos. As usinas que são programadas, mas não despachadas, entram na Programação Mensal de Operação (PMO) que é atualizada semanalmente. Além disso, sua programação é definida para o dia seguinte através da Programação Diária de Operação (PDO), não havendo mudanças significativas para o despacho realizado a cada 30 minutos.

As fontes eólicas e fotovoltaicas, bem como as Micro e Minigeração Distribuída (MMGD) participam da programação dos recursos por meio das previsões de geração (ONS, 2023d).

Nos sistemas de pequeno porte, a principal preocupação no despacho é manter as

² CVU: custo variável associado principalmente ao combustível consumido pelas termelétricas, que deve ser pago quando elas são despachadas pelo ONS.

Figura 17 – Programação e despacho das usinas por tipo



Fonte: elaborada pela autora (2025).

reservas operativas nos níveis adequados e, para isso, devido à baixa capacidade, todos os recursos são importantes. A proposição deste trabalho é realizar um despacho de curtíssimo prazo de forma distribuída, entretanto, utilizando a função objetiva de despacho econômico centralizado, portanto, buscando o bem-estar social.

2.4 Mercado de energia e o despacho

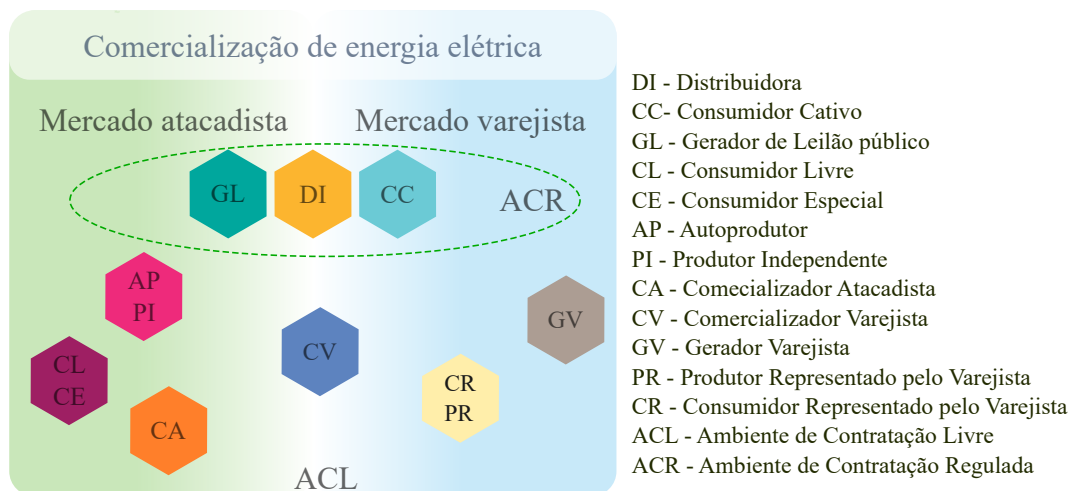
A comercialização da energia elétrica é uma parte importante dos sistemas elétricos de potência. É mediante regras bem definidas que é possível uma tarifa viável aos consumidores, bem como uma remuneração adequada aos investidores, responsáveis pela expansão e manutenção dos ativos. Para atingir o equilíbrio financeiro entre fornecedores e consumidores, é necessário desagregar os setores de transmissão e distribuição, os quais são monopólios naturais, dos setores de geração e comercialização de energia elétrica, sendo potencialmente competitivos (MAGALHÃES; PARENTE, 2009).

A energia pode ser comercializada de duas maneiras: no atacado e no varejo. No atacado, a energia é vendida em grandes volumes, geralmente por meio de contratos de longo prazo, o que torna a operação mais econômica para os consumidores e mais previsível para os fornecedores. Este modelo é utilizado por consumidores e geradores de grande porte, assim como por comercializadores. Já no varejo, a energia é destinada ao consumidor convencional, que adquire em menor escala e em contratos de curto prazo.

A Figura 18 mostra como está dividido o mercado atacadista e varejista de energia

no Brasil dentro dos Ambiente de Contratação Regulada (ACR) e Ambiente de Contratação Livre (ACL). Destacam-se as distribuidoras e os comercializadores varejistas que atuam tanto no mercado de atacado quanto no de varejo.

Figura 18 – Mercados de Energia



Fonte: elaborada pela autora (2025).

O ACR foi instituído para proteger os consumidores cativos, aqueles que não podem escolher o fornecedor da sua energia. Nesse ambiente, acontece compra e venda de energia no atacado entre distribuidoras de energia elétrica e os geradores de serviço público, que ocorrem por meio de leilões, garantindo que as concessionárias de distribuição comprem energia a preços competitivos. A venda e compra de energia no varejo acontece entre distribuidora e consumidor final.

Já o ACL é formado por consumidores livres e especiais, produtores independentes, autoprodutores, comercializadores atacadistas, além dos comercializadores e produtores independentes com habilitação varejista. Os agentes com habilitação de varejistas podem representar consumidores e produtores de energia sem limite de demanda contratada do mercado cativo no mercado livre. Hoje, esses representados só podem ser acessantes do sistema se conectados em média e alta tensão, mas em 2028 qualquer consumidor poderá ser representado por um agente varejista.

O mercado brasileiro de energia é muito particular comparado aos outros países, visto que foi preciso, na sua abertura, se adaptar ao despacho centralizado realizado pelo operador, utilizando o modelo de menor custo sistêmico, conforme Tabela 1.

Isso se deve a algumas particularidades importantes: o sistema de hidrelétricas em bacias, onde a unidade a montante influencia as unidades a jusante; análise de *trade-off* entre custo presente e futuro da energia, em que se decide utilizar ou não térmicas com base na previsão de vazão afluyente das hidrelétricas; e o sistema interligado nacional de dimensão continental, que apresenta diferentes condições para as fontes renováveis durante o ano nas diferentes regiões geoeletricas.

Além disso, no Brasil, a responsabilidade pela medição contábil da energia e liquidação financeira de contratos entre compradores e vendedores nos ambientes de contratação livre e regulado é da CCEE. Dessa forma, a função da CCEE é apenas de regulação do mercado de energia elétrica, diferindo da maioria dos países nos quais a rede e o mercado são controlados por uma única organização, como é possível ver na Tabela 1.

Tabela 1 – Agentes de operação de mercado e da rede elétrica

País	Mercado (Região)	Operador de rede	Operador de mercado	Modelo de despacho
Austrália	NEM (Leste e Sudeste) WEM (Ocidental)	AEMO	AEMO	Centralizado, baseado em ofertas
Brasil	Brasil(SIN)	ONS	CCEE	Centralizado, baseado em custo
Canadá	Alberta	AESO	AESO	Centralizado, baseado em ofertas
EUA	Califórnia Meio Atlântico New England	CAISO PJM ISO-NE	CAISO PJM ISO-NE	Centralizado, baseado em ofertas
Espanha Portugal	Mercado Ibérico	REE(Espanha) REN(Portugal)	OMIE ^a OMIP ^b	Autodespacho
Países da Grã-Bretanha	Grã-Bretanha	National Grid ESO	National Grid ESO	Autodespacho

Fonte: adaptada de EPE (2021).

Nota: ^amercado de curto prazo de responsabilidade da Espanha (atende os dois países); ^bmercado de longo prazo de responsabilidade de Portugal (atende os dois países).

Uma forte interação entre a CCEE e o ONS é evidenciada no Prorede e nos Procedimentos e Regras de Comercialização, inclusive com compartilhamento de dados de medição e de modelos matemáticos. Entretanto, devido às particularidades do SIN, o mercado de energia elétrica tornou-se bastante desacoplado da operação do sistema, entretanto com diversos mecanismos para tornar a comercialização mais próxima da operação ³.

³ Um exemplo é o Mecanismo de Realocação de Energia (MRE), procedimento contábil de distribuição de energia

O crescente uso de fontes que têm capacidade variável de geração e uma redução percentual da participação das fontes de origem hidráulica apontam para a necessidade de um mercado de energia com critérios de capacidade e de flexibilidade. Dessa forma, vários estudos vêm sendo realizados pela Aneel, EPE e ONS para tornar o mercado de energia mais dinâmico (EPE, 2021).

A criação de um mercado de serviços ancilares é uma das soluções mais vistas em outros países, principalmente, com a diversificação de produtos e a concorrência que tende a beneficiar e incentivar os recursos mais flexíveis com oportunidade também para resposta à demanda. Outra tendência observada em mercados de energia elétrica de aproximar a operação e a comercialização da energia é o aumento da granularidade temporal e espacial. Além disso, o despacho das fontes baseia-se em lances de oferta e de demanda tanto no modelo centralizado como no modelo de autodespacho no mercado de curto prazo.

A granularidade espacial relaciona-se ao preço locacional da energia elétrica, em que, dependendo das condições de operação, a geração e/ou a redução do consumo é incentivada, ou desestimulada, a depender do local de conexão e do estado de congestionamento da rede, ou seja, custos diferentes para diferentes nós. Já a granularidade temporal refere-se aos intervalos de tempo importantes que interferem na operação e no mercado, os principais são:


- a) período de despacho: relaciona-se ao intervalo de atualização em que são dadas instruções/comandos aos recursos energéticos para manterem, reduzirem ou aumentarem a geração, ou a carga, quando há programas de resposta à demanda. Em geral, existem informações de pré-despacho antes do *gate closure* para dar oportunidade para os agentes ajustarem suas ofertas;
- b) *gate closure* ou prazo de encerramento (tradução livre): limite de tempo que existe entre as negociações no mercado de curto prazo e o despacho em tempo real. Esse prazo é importante para que o operador da rede realize os ajuste necessários quanto mais perto do intervalo de despacho, mais interessante para os agentes, pois menores são as incertezas nas previsões das fontes variáveis e das cargas. Entretanto, em países que dependem de fontes pouco flexíveis para atender o desbalanço, o operador do sistema pode precisar de um tempo maior para que esses recursos estejam prontos quando necessários (PETITET *et al.*, 2019);

elétrica entre as hidrelétricas participantes, como uma forma de “adiantamento” às usinas que não geraram no período devido ao despacho centralizado.

- c) período ou intervalo de liquidação: está relacionado aos intervalos em que se contabiliza financeiramente os desbalanços ocorridos, atribuindo aos agentes causadores custos ou receitas. Quanto maior esse intervalo em relação ao período de despacho, mais distante estarão a operação física e contábil, diminuindo o incentivo para os recursos mais flexíveis.

A Figura 19 mostra um exemplo de um mercado cujo intervalo de despacho é igual a t_d , um período de liquidação de $2t_d$ e um prazo de encerramento de $4t_d$. A Tabela 2 mostra exemplos de granularidade temporal em alguns mercados.

Figura 19 – Exemplo de granularidade temporal



Fonte: elaborada pela autora (2025).

Tabela 2 – Exemplos de granularidade temporal

País/Mercado	Intervalo de despacho	Período de Liquidação	Gate closure
Austrália/NEM	5 min	5 min	às 12:30 de D-1 ^a
Austrália/WEM	5 min	5 min ^b	15 min
Brasil/SIN	30 min	60 min	-
Canadá/Alberta	5 min	60 min	120 min
EUA/Califórnia	5 min	15 min	75 min
União Europeia ^c	15 min	15 min	<30min

Fonte: elaborada pela autora (2025).

Nota: ^a Dia anterior ao dia do despacho; ^b Previsão de plena implementação em 2025; ^c Existe uma tendência de harmonização nos mercados de energia europeus para que a negociação entre países se torne mais fácil.

No Brasil, a granularidade espacial do SIN é regional, e as diferenças de preço ocorrem nas quatro regiões geoeletricas apresentadas na Figura 11. E a granularidade temporal

foi reduzida, desde 2021, com a introdução do Preço de Liquidação das Diferenças (PLD), para horário, e o despacho semi-horário realizado pelo ONS a cada 30 minutos.

Por isso, os agentes que antes realizavam a modulação por patamares (carga leve, média ou pesada) agora fazem a modulação do consumo/geração para cada hora do dia, com o objetivo de se expor menos aos custos do mercado de curto prazo. Entre os critérios acordados entre vendedores e compradores, existe a modulação por seguimento de carga, que oferece maior flexibilidade; no entanto, são contratos mais onerosos. Esse tipo de contrato assemelha-se ao autodespacho adotado principalmente na Europa (GLOWACKI, 2023a).

Entre os mercados que estão na vanguarda do aumento de granularidade temporal está a Austrália. A Austrália tem dois mercados de energia elétrica, ambos operados pelo *Australian Energy Market Operator* (AEMO), mas em regiões diferentes do país que não são interligadas eletricamente. A Austrália Ocidental é atendida pelo *Wholesale Electricity Market* (WEM), que deve concluir sua transição em 2025 para intervalos de despacho e de liquidação de 5 minutos. Isso porque uma série de adaptações e mudanças técnicas foram necessárias, principalmente nos sistemas de medição de energia elétrica (VARMA, 2019). Já o *gate closure* está em vigência, conforme determinado pelas regras do WEM, com intervalo de 15 minutos (AUSTRALIA, 2024).

O *National Electricity Market* (NEM) atende o sul e o leste da Austrália. Nesse mercado, desde 2021, foi reduzido o período de liquidação de 30 minutos para 5 minutos, se tornando igual ao intervalo de despacho que já era de 5 minutos. Essa mudança já vinha sendo estudada desde 2017. Sobre o *gate closure*, conforme o AEMO (2024) a finalização de ofertas de compra e venda de energia ocorre às 12h30min do dia anterior a entrega.

Em Alberta, os intervalos de despacho já são de 5 minutos (AESO, 2024c), a liquidação é realizada a cada hora, o preço de liquidação tem de ser divulgado a cada 70 minutos pelo operador baseado no custo marginal de operação (AESO, 2024a). Já o prazo de encerramento de lances acontece até duas horas antes do intervalo de liquidação (AESO, 2024b).

O CAISO também faz o despacho dos recursos a cada 5 minutos, enquanto o prazo de encerramento dos lances de compra e venda de energia deve ocorrer 75 minutos antes do tempo real (CAISO, 2024). O período de liquidação da carga é uma média do preço dos mercados de 5 min e 15 min para uma hora. Já geração é paga no preço real dos mercados em relação ao desbalanço negociado anteriormente. Essa diferença causou diversos problemas, portanto, estão em mudança de metodologia para uma que aproxime mais o que foi pago do tempo real (CAISO,

2023).

A União Europeia através do novo regulamento Parliament (2024) deve uniformizar os tempos de liquidação e o *gate closure* para intervalos de 15 minutos e intervalos inferiores a 30 minutos, respectivamente. Com isso deve facilitar a negociação entre os mercados de energia que tem interligações em praticamente todo o continente, reduzindo o valor principalmente nos momentos de congestionamento dos sistemas elétricos. Já o intervalo de monitoramento do estado da rede e da troca de informação entre os agentes e o operador do sistema são realizadas a cada 15 minutos desde 2017 (PARLIAMENT, 2017).

Através desse levantamento, nota-se que os intervalos de despacho tem uma tendência de redução a medida que os mercados de energia e de serviços ancilares se tornam mais competitivos. Com isso há maior facilidade na introdução de tecnologias mais flexíveis nos sistemas elétricos. Esse trabalho, portanto, busca um método de otimização de despacho que já considere a necessidade de um mercado de energia mais aberto, mesmo que para recursos de menor porte agregados formando microrredes.

2.5 Otimização na operação de sistemas elétricos de potência

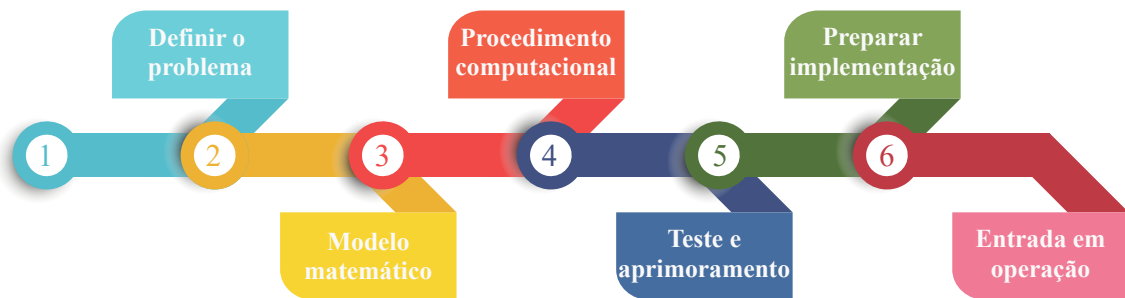
Uma microrrede inteligente, como integrante das REI, deve coordenar as necessidades e capacidades de todos os geradores e usuários finais, bem como atender às limitações dos operadores da rede de distribuição e dos negociadores no mercado de eletricidade. Com isso, o conjunto deve operar da forma mais eficiente possível, minimizando custos e maximizando a confiabilidade e a estabilidade do sistema.

Na operação das microrredes e dos SEP, o sistema de gerenciamento de energia é responsável pelo UC e ED dos recursos, na medida em que se escolhe quais unidades devem disponibilizar recursos de entrega de energia e de consumo de energia e em quais momentos esses recursos devem entrar em operação. Quanto maior a quantidade e a diversidade dos recursos energéticos, mais complexo é esse problema.

Diversos métodos são aplicados na realização de otimizações em SEP, seja na alocação de recursos para expansão da rede ou no planejamento da operação. De forma mais ampla e interdisciplinar, as técnicas de otimização desenvolvidas são um conjunto de etapas da pesquisa operacional, campo da matemática aplicada. A Figura 20 mostra todas as etapas de um processo de pesquisa operacional, enquanto a otimização abrange os passos de 1 a 4 (HILLIER *et al.*, 2006). Dessa forma, uma otimização consiste em encontrar uma resposta quantitativa ótima

para um problema ou uma tarefa (objetivo) cujos recursos (variáveis) são escassos e existem limitações técnicas e/ou operacionais (restrições).

Figura 20 – Etapas de uma aplicação de pesquisa operacional



Fonte: elaborada pela autora (2025).

A escolha da melhor resposta é realizada baseada em um modelo matemático (etapa 2). Para criar esse modelo, é necessário conhecer profundamente o problema e delimitar o(s) objetivo(s) e as variáveis de decisão, bem como estabelecer as limitações conhecidas ou desejáveis (etapa 1). Os algoritmos de resolução são implementados computacionalmente (etapa 3) e, através dos resultados, modificações no modelo ou nos algoritmos podem ser realizadas (etapa 4). As etapas 5 e 6 estão relacionadas às adequações de ferramentas e procedimentos operacionais que tornarão viáveis a utilização dos resultados.

Múltiplos são os objetivos que podem ser adotados para a solução do problema de despacho de recursos de eletricidade, e isso depende de quem está tomando a decisão. Os consumidores querem elevar seu nível de satisfação ao utilizar a energia elétrica que depende da quantidade e do preço disponível. Por outro lado, o operador do sistema almeja a estabilidade do sistema, aliado ao menor custo global, avaliando o custo de oportunidade na utilização de diferentes fontes primárias, dos sistemas de armazenamento e dos eventuais cortes de carga, como parte da estratégia de resposta à demanda. Já os investidores querem maximizar seus lucros.

Outras metas que podem ser adotadas ou mesmo impostas em determinados sistemas baseiam-se na minimização das perdas elétricas e dos custos ambientais e na maximização da potência de algum recurso específico e/ou do tempo de vida dos equipamentos. Entretanto, o objetivo mais comum nesse tipo de estudo é orientado pelo menor custo global do sistema que atenda adequadamente às cargas (VERA *et al.*, 2019).

2.5.1 Modelos de otimização para a operação de recursos energéticos

O autodespacho, o *unit commitment* e o despacho econômico estão dentro do escopo de operação das redes elétricas e visam determinar as ações de controle para que os recursos energéticos controláveis atinjam a potência de saída desejável. A diferença principal está nas funções objetivo, nas variáveis de otimização e nas restrições.

O modelo apresentado a seguir é para uma otimização de autodespacho de objetivo único que baseia-se na maximização do lucro do investidor (CONEJO; BARINGO, 2018). Excluindo os custos operacionais internos, apenas o preço da energia elétrica a ser vendida ou comprada é importante na tomada de decisão. Dessa forma, o operador individualmente otimiza seu despacho, a função objetivo é descrita por:

$$\max_{\Xi} \sum_t \left[\lambda_t \cdot p_{it} - \left(C_i^V \cdot p_{it} + C_i^F \cdot u_{it} + C_i^{SU} \cdot y_{it} + C_i^{SD} \cdot z_{it} \right) \right] \quad (2.5)$$

o conjunto de variáveis $\Xi = \{p_{it}, u_{it}, y_{it}, z_{it}\}$ são as saídas que darão o maior lucro àquela unidade de geração para a previsão do preço da energia, λ_t , em cada instante t . Leva-se em consideração no custo total de operação da unidade as parcelas C_i^V , C_i^F , C_i^{SU} e C_i^{SD} , respectivamente, custos variáveis, fixos, rampa de subida e rampa da descida. O problema estará sujeito às restrições:

$$\begin{aligned} u_{it} \cdot P_i^{min} &\leq p_{it} \leq u_{it} \cdot P_i^{max}, \forall t \\ p_{it} - p_{i(t-1)} &\leq R_i^U \cdot u_{i(t-1)} + R_i^{SU} \cdot y_{it}, \forall t \\ p_{i(t-1)} - p_{it} &\leq R_i^D \cdot u_{it} + R_i^{SD} \cdot z_{it}, \forall t \\ y_{it} - z_{it} &= u_{it} - u_{i(t-1)}, \forall t \\ y_{it} + z_{it} &\leq 1, \forall t \\ u_{it}, y_{it}, z_{it} &\in \{0, 1\}, \forall t \end{aligned} \quad (2.6)$$

em que as variáveis de saída da otimização são potência de saída, p_{it} , do recurso i no intervalo de tempo t e as variáveis binárias u_{it} , y_{it} , z_{it} representam, em 1, equipamento em operação, início de rampa de subida, início de rampa de descida. Tem-se ainda os limites operacionais do equipamento sendo P_i^{max} , P_i^{min} , R_i^U , R_i^{SU} , R_i^D , R_i^{SD} , respectivamente, potência máxima e potência mínima de operação, inclinações mínima e máxima da rampa de subida e as inclinações mínima e máxima da rampa de descida.

No problema de autodespacho, o equilíbrio carga-geração não é uma responsabilidade desse agente, pois $i = 1$. Esse equilíbrio é mantido pelo operador através de recursos obtidos dentro do mercado de serviços ancilares. Nos problemas de *unit commitment* e despacho

econômico, essa situação é considerada como uma restrição, pois todos os recursos disponíveis, $i > 1$, já estão envolvidos no problema.

O *unit commitment* é realizado, em geral, para um horizonte de 24 horas, o resultado mais relevante desse estudo é determinar quais horários as unidades de geração devem ser ligadas e desligadas (CONEJO; BARINGO, 2018). Por isso, são considerados os custos de rampa e o tempo mínimo que as unidades devem permanecer conectadas e desconectadas. A função objetivo é o custo mínimo de operação:

$$\min_{\underline{\Xi}} \sum_t \sum_i \left(C_i^V \cdot p_{it} + C_i^F \cdot u_{it} + C_i^{SU} \cdot y_{it} + C_i^{SD} \cdot z_{it} \right), \quad (2.7)$$

e as restrições do problema são:

$$\begin{aligned} y_{it} - z_{it} &= u_{it} - u_{i(t-1)}, \quad \forall i, \quad \forall t, \\ y_{it} + z_{it} &\leq 1, \quad \forall i, \quad \forall t, \\ u_{it} \cdot P_i^{min} &\leq p_{it} \leq u_{it} \cdot P_i^{max}, \quad \forall i, \quad \forall t, \\ p_{it} - p_{i(t-1)} &\leq R_i^U \cdot u_{i(t-1)} + R_i^{SU} \cdot y_{it}, \quad \forall i, \quad \forall t, \\ p_{i(t-1)} - p_{it} &\leq R_i^D \cdot u_{it} + R_i^{SD} \cdot z_{it}, \quad \forall i, \quad \forall t, \\ \sum_i p_{it} &= P_t^D, \quad \forall t, \\ \sum_i P_i^{max} \cdot u_{it} &\geq P_t^D + RPO_t, \quad \forall t, \\ u_{it}, y_{it}, z_{it} &\in \{0, 1\}, \quad \forall i, \quad \forall t, \end{aligned} \quad (2.8)$$

em que P_t^D e RPO_t são a demanda e a reserva de capacidade em cada período t .

Os dois modelos anteriores possuem variáveis binárias/inteiras, u_{it}, y_{it}, z_{it} e reais p_{it} . Tornam-se, dessa forma, problemas que podem ser resolvidos por Programação Linear Inteira Mista (do inglês, MILP) (WOOD *et al.*, 2013). Caso os custos sejam representados por funções não lineares, outras técnicas devem ser adotadas.

O despacho econômico é uma etapa posterior ao *unit commitment* em que já se sabe se a unidade estará em operação. A otimização é realizada para um único intervalo de operação, logo, apenas os custos variáveis são considerados. Nesses casos, comumente, esses custos são representados por funções não lineares, então outras técnicas de resolução são comumente adotadas como lista de prioridades, Programação Dinâmica (PD) e Relaxação Lagrangiana (RL) (WOOD *et al.*, 2013).

A função a ser minimizada, portanto, no despacho econômico engloba todos os custos de despacho, incluindo custos associados a programas de resposta à demanda:

$$\min_{\Xi} \sum_i C_i(p_i), \quad (2.9)$$

em que C_i é uma função custo, diferente para cada tipo de recurso i utilizado e depende da potência disponível do recurso, p_i . Uma função custo muito comum na literatura é a polinomial de segundo grau para fontes térmicas. O conjunto de soluções obtidas $\Xi = [p_1, p_2, \dots, p_i]$ deve satisfazer as seguintes restrições:

$$\begin{aligned} P_i^{\min} &\leq p_i \leq P_i^{\max}, \quad \forall i \\ \sum_i p_i &= P^D \end{aligned} \quad (2.10)$$

O despacho econômico é o modelo matemático a ser otimizado neste trabalho. As funções de custo de cada um dos recursos serão apresentadas no capítulo 3. Um novo cálculo de despacho será realizado a cada intervalo de cinco minutos, com previsões de geração intermitente e carga mais próximas do real. Com isso, é possível organizar a operação da microrrede para que ela possa participar, como uma unidade, dos mercados de energia de maior granularidade temporal.

2.5.2 Métodos de otimização

Depois de conhecidos os modelos matemáticos do problema, a etapa seguinte é a escolha do método de otimização. Um mesmo problema pode ser resolvido de várias formas; a escolha depende do nível de detalhamento ou simplificação considerado.

Nos sistemas elétricos de potência, inúmeros problemas devem ser otimizados, como posicionamento e quantidade de equipamentos, minimização de perdas, intervalo entre manutenções e ajuste de equipamentos (MOLZAHN *et al.*, 2017), (LEE; EL-SHARKAWI, 2008). O despacho das fontes e demais recursos energéticos é o mais conhecido.

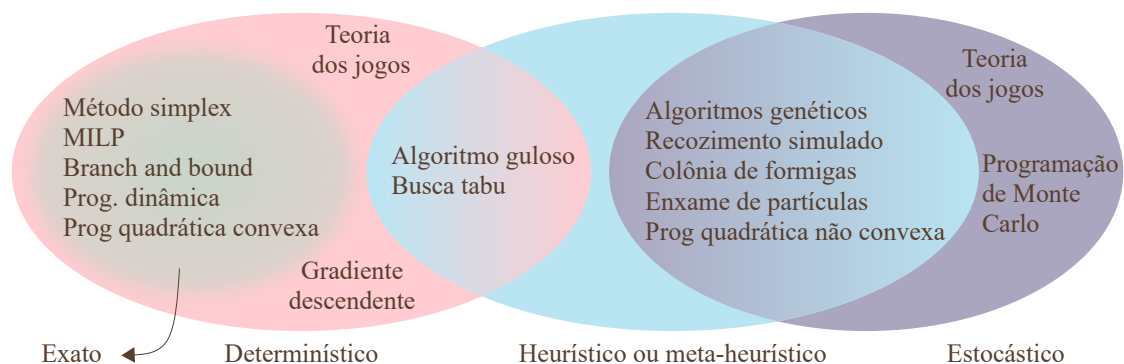
Dependendo da característica temporal do problema, alguns métodos são mais indicados do que outros. Problemas do tipo *off-line*, como a compra e a instalação de chaves de manobra (GOMES *et al.*, 2023), podem utilizar técnicas com longos períodos de convergência. Já soluções *on-line* precisam de métodos que possam fornecer respostas imediatas, como casos relacionados à reconfiguração da rede elétrica após a atuação do sistema de proteção (SAMPAIO *et al.*, 2022).

As características distintas dos problemas de otimização orientam a escolha do método mais adequado. Por exemplo, a otimização do número de chaves em um alimentador de distribuição possui variáveis discretas, enquanto o posicionamento das chaves nas linhas de distribuição é um problema cuja variável de interesse é contínua. Esses problemas naturalmente possuem restrições e podem ser modelados apenas com função objetivo e restrições lineares, ou alguma não linearidade importante pode ser adicionada ao modelo para uma melhor representação.

O despacho econômico é um modelo de variáveis contínuas que geralmente é não linear e apresenta diversas restrições operacionais. Já o *unit commitment* e o autodespacho são modelos também não lineares com restrições, mas que utilizam variáveis mistas.

Embora não exista uma classificação universalmente aceita para métodos de otimização, alguns aspectos podem diferenciar suas implementações e a precisão dos resultados. A Figura 21 ilustra a interseção de diferentes abordagens, agrupando-as em métodos exatos, heurísticos ou meta-heurísticos⁴, determinísticos e estocásticos.

Figura 21 – Classificação das características do problema



Fonte: elaborada pela autora (2025).

Os métodos determinísticos, amplamente conhecidos e utilizados devido à sua reprodutibilidade, são aqueles que, para as mesmas condições iniciais e parâmetros, sempre geram a mesma solução. Quando a solução encontrada é ótima globalmente, o método é classificado como exato, sendo, portanto, um subconjunto dos determinísticos. Muitos problemas são linearizados para permitir a aplicação de técnicas baseadas em Programação Linear, que fazem parte dos métodos com respostas exatas. Por outro lado, métodos estocásticos incorporam elementos de aleatoriedade ou probabilidade na busca pela solução ótima e apresentam resultados

⁴ Heurísticas são regras práticas para resolver problemas, enquanto meta-heurísticas combinam essas regras de maneira estruturada e coordenada para resolver problemas específicos de otimização.

variáveis. Eles realizam inúmeras repetições para chegar a um resultado aceitável, mas não garantem o ótimo global.

Quando os sistemas são mais complexos e as não-linearidades não podem ser desconsideradas, a busca por outros métodos é preferível, e as meta-heurísticas podem se tornar uma opção viável. Meta-heurísticas são altamente adaptáveis, o que tem impulsionado seu uso e desenvolvimento desde os anos 1970, quando os primeiros algoritmos foram estabelecidos. Em Rajwar *et al.* (2023), foi realizado um levantamento de mais de 500 meta-heurísticas diferentes e híbridas na literatura. Essas técnicas são amplamente utilizadas em problemas não lineares, com a vantagem de não necessitarem de derivadas da função objetivo. Elas são classificadas com base em sua inspiração: algoritmos evolucionários, como os algoritmos genéticos; inteligência de grupo, como o enxame de partículas; algoritmos baseados em leis da física, como o recozimento simulado; e outras inspirações, como o *Football Game Inspired Algorithm*.

Neste trabalho, o PSO foi a técnica de otimização base utilizada para a realização do despacho econômico dos recursos de uma microrrede de energia elétrica. Uma das vantagens do PSO é sua simplicidade, que possibilita o paralelismo distribuído de meta-heurísticas com a utilização dos *hardwares* de cada um dos recursos. Além disso, o despacho, por ser um problema de variáveis contínuas, é adequado às características do algoritmo.

2.6 Considerações finais

Este capítulo apresentou as informações necessárias para o entendimento do trabalho proposto, que consiste na realização de despacho de curtíssimo prazo com o menor custo global para microrredes de energia elétrica.

Para alcançar os objetivos, foram avaliadas as principais características dos recursos energéticos disponíveis e os controles associados. Foi mostrada a relação entre o despacho e os mercados de energia, apresentando a tendência da granularidade temporal para que recursos energéticos mais flexíveis tenham oportunidade, em vista da grande incorporação de fontes variáveis.

Por fim, os conceitos básicos para a modelagem do problema e os cuidados que devem ser realizados para garantir estabilidade são discutidos, bem como a classificação dos métodos de otimização e os motivos pela escolha do PSO como base.

3 MÉTODOS E FERRAMENTA COMPUTACIONAL PARA GERENCIAMENTO DE RECURSOS DE MICRORREDES

A busca pela transformação dos SEP em redes elétricas inteligentes é responsável pela modernização e intensa adoção de automação e controle, principalmente, no nível de distribuição de energia elétrica. À medida que essas tecnologias se tornam mais acessíveis, econômica e tecnicamente, possibilita a formação de microrredes no próprio sistema de distribuição de média e/ou baixa tensão.

Essas microrredes têm pequena dimensão tanto no nível de potência quanto na dispersão territorial dos recursos. Entretanto, são importantes os requisitos, tais como controle automático, sistemas inteligentes de medição e monitoramento e a integração de RED, entre eles os VRE. Para alcançar uma eficiência energética ótima e, ao mesmo tempo, satisfazer as necessidades energéticas dos consumidores, é preciso gerenciar as capacidades disponíveis para operar o sistema da melhor forma possível, minimizando os custos e maximizando a confiabilidade.

Dessa forma, este capítulo apresenta o ambiente de simulação utilizado e as ferramentas de modelagem e otimização para realizar o gerenciamento de RED. Por fim, mostram-se as particularidades na implementação dos algoritmos meta-heurísticos distribuídos utilizados na otimização.

3.1 Co-simulação

Ao representar e implementar soluções para sistemas complexos, como microrredes, é importante a utilização de plataformas multifuncionais que possam agregar diferentes aspectos a serem analisados até uma reprodução mais próxima possível da realidade.

Análises estáticas, como fluxo de potência e curto-circuito, e dinâmicas, como transitórios eletromecânicos e sistemas de controle, possuem equacionamentos não lineares e com diversas equações diferenciais, tornando os modelos mais complexos e a simulação por um único *solver* computacionalmente mais onerosa (FARROKHSERESHT *et al.*, 2021). Para estabelecer interoperabilidade entre modelos e *solvers* de diferentes proprietários, usuários e plataformas, começaram a ser realizadas integrações criando co-simulações dos sistemas, o que torna os projetos desenvolvidos mais fáceis de serem reutilizados, proporcionando uma vida útil mais longa, mesmo com a chegada de novas tecnologias.

Essas co-simulações motivaram a criação de uma padronização, chamada *Functio-*

nal Mock-up Interface (FMI). Diversos fabricantes disponibilizam a conversão de modelos em arquivos *Functional Mock-up Unit* (FMU), que facilitam a troca de informações e mantêm a confidencialidade da modelagem, tais como Dspace, Typhoon HIL, Bosch, Siemens, Matlab/Simulink, Etas (desenvolvedor de aplicações para veículos elétricos), entre outros (ASSOCIATION, 2024).

Nesse mesmo contexto, de facilitar a co-simulação e, portanto, a representação de sistemas, foram criados *frameworks* para que os desenvolvedores se concentrem nas ferramentas e não nas *Application Programming Interface* (API) entre os simuladores. O Mosaik é uma dessas plataformas voltadas especialmente para co-simulações de REI.

Além de adaptadores para utilizar modelos FMU, o Mosaik também disponibiliza os passos para a criação de interface entre simuladores que ainda não possuem a padronização FMI, tornando-o uma plataforma mais dinâmica. A interação entre os simuladores pelo Mosaik, a partir da versão 3.0, pode ser baseada no tempo, em eventos ou híbrida (OFFIS, 2024).

Neste trabalho, a distribuição de algoritmos meta-heurísticos é realizada através da utilização de agentes inteligentes. O ambiente de co-simulação adotado foi baseado no API desenvolvido e apresentado Melo *et al.* (2020). O API torna possível a integração da plataforma de modelagem de agentes, *Python Agent Development Framework* (Pade), e o Mosaik.

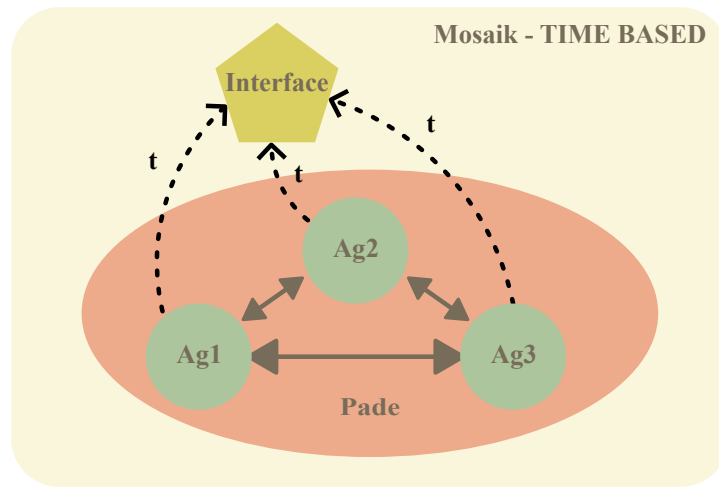
Cada recurso energético tem um agente inteligente associado, e cada agente é configurado para o Mosaik como um simulador diferente. A troca de informações entre os agentes e a interface Mosaik, nesse momento de desenvolvimento, é apenas o tempo de simulação para sincronizar a troca de mensagens necessária para os objetivos do trabalho, como observado na Figura 22. Trabalhos futuros podem inserir outros simuladores de redes, tais como *PandaPower*, *DigSilent* ou *OpenDSS*, e a troca de informações entre os *softwares* será realizada por essa interface. A adição desses *softwares* deve permitir a análise de fluxo de carga e melhor modelagem da rede elétrica que não foi tratada neste trabalho.

3.1.1 *Sistemas multiagentes*

O sistema multiagentes é uma área de estudo que trata sobre a interação de agentes inteligentes autônomos que recebem estímulos do ambiente, processam informações e executam ações nesse ambiente. A inteligência desses agentes torna possível a interação entre eles, proporcionando cooperação e competição na busca de melhores resultados globais.

A utilização do SMA é uma forma de implementar controle distribuído, uma alterna-

Figura 22 – Ambiente de co-simulação



Fonte: elaborada pela autora (2025).

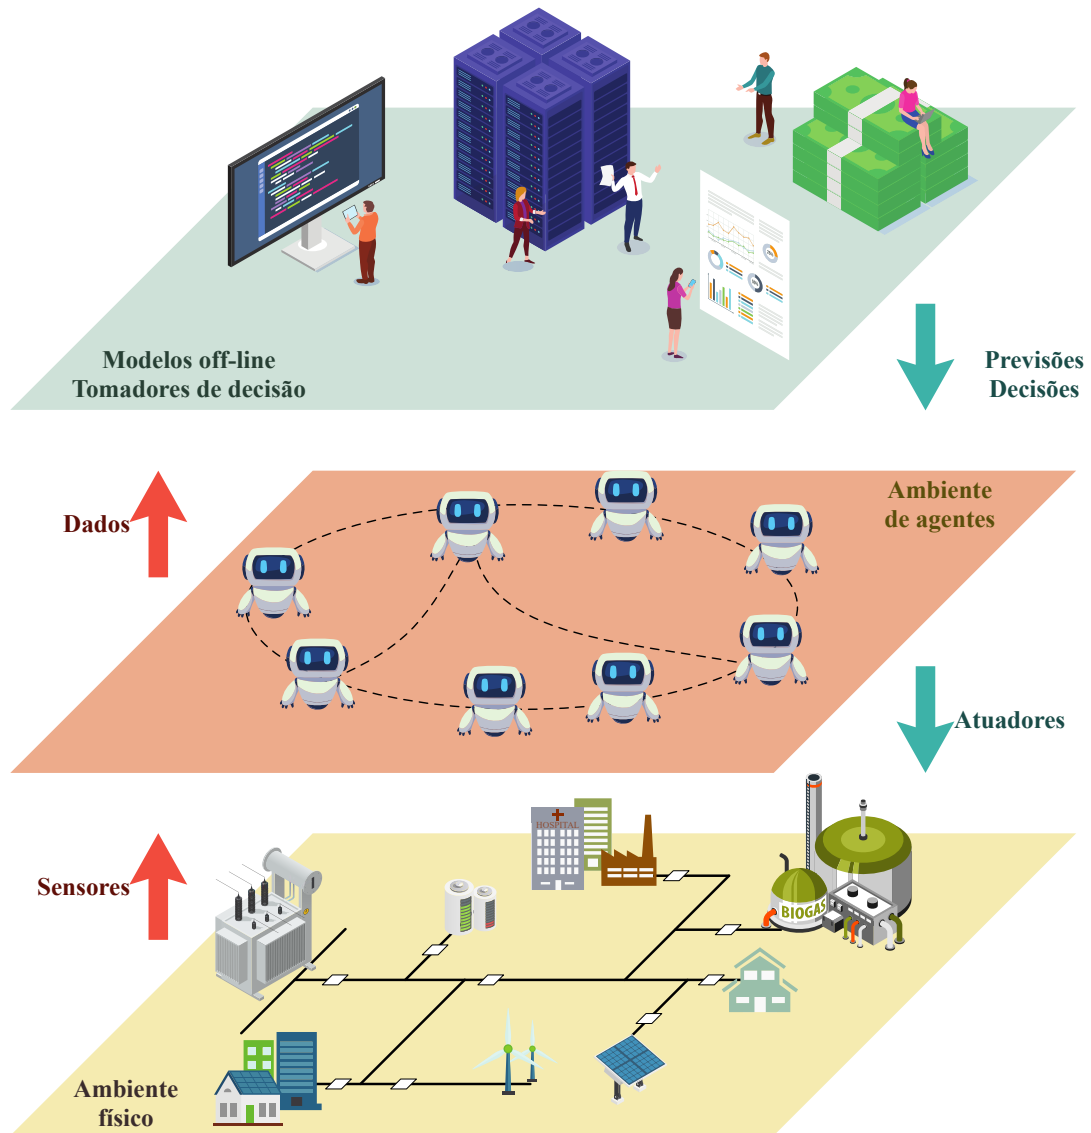
tiva interessante para o gerenciamento dos recursos de microrredes. A dispersão dos recursos de uma microrrede é limitada, por isso a comunicação entre os agentes é mais simples, possibilitando a adoção de um sistema de gerenciamento de energia distribuído, que possui a vantagem de resolver problemas complexos de forma escalonável.

A Figura 23 mostra três camadas da interação entre agentes, componentes físicos e tomadores de decisões, bem como o fluxo de informação entre elas. A primeira camada é o ambiente físico, em que a energia é gerada e consumida. Nessa camada, existem sensores e medidores que avaliam o estado da rede e fazem medições de grandezas, como corrente e tensão elétrica, velocidade do vento, irradiação solar e temperatura, entre outras. Esses equipamentos são responsáveis por fornecer aos agentes todas as informações necessárias para que as melhores decisões sejam tomadas. É ainda nesse nível que se encontram os atuadores, equipamentos que podem alterar o funcionamento e as condições de operação.

O segundo nível é o espaço de interação entre os agentes. Essa é a camada na qual os agentes trocam informações e decidem sobre sua atuação na camada física. Esse trabalho está focado nesse nível, em que os agentes trocam informações e valores intermediários durante a otimização do custo de operação da microrrede para melhorar o resultado global. São observadas as características básicas para que esses agentes sejam considerados inteligentes: reatividade, pró-atividade e habilidade social (SAMPALIO, 2017).

Esses três aspectos podem ser observados desde a entrada em operação até sua saída, com a solicitação de participação, associação a uma rede de comunicação, capacidade de verificar quais são os seus vizinhos mais próximos, na atualização de dados de previsão, na competição e

Figura 23 – Camadas de interação do sistema multiagente



Fonte: adaptada de Dorsch *et al.* (2016).

cooperação durante a execução do algoritmo de otimização.

O terceiro nível da Figura 23 mostra o armazenamento e análise de dados para a criação e melhoria de modelos matemáticos de previsão da geração por fontes variáveis ou da carga. É também nessa camada que os responsáveis pelas decisões alteram os parâmetros dos agentes, tornando-os mais ou menos flexíveis.

Neste trabalho, o ambiente de agentes será representado no Pade. A plataforma pode ser aplicada em sistemas reais e utiliza protocolos de troca de mensagens no padrão *Foundation for Intelligent Physical Agents* (FIPA). Apresentada, em 2015, por Melo (2015) é amplamente utilizada em sistemas elétricos de potência (SAMPAlO, 2017; MELO *et al.*, 2019; ALMEIDA,

2019; MELO *et al.*, 2020).

O padrão FIPA aceito pela *IEEE Computer Society* é utilizado para garantir a interoperabilidade de agentes, norteados os desenvolvedores de *softwares*. Nesse padrão, existem protocolos de comunicação que estabelecem os métodos para a troca de informações entre agentes.

No Pade, os três protocolos mais importantes estão implementados: *Fipa-Request*, *Fipa-Subscribe* e *Fipa-Contract-Net*. O primeiro determina como deve ser o envio de uma solicitação simples e a resposta ao pedido. O *Fipa-Subscribe* estabelece a entrega de mensagens de informação para diversos agentes, simultaneamente, que devem estar inscritos junto a um agente que tem a função de editor. Por fim, o *Fipa-Contract-Net* é utilizado para situações em que é necessária uma negociação entre agentes. Neste trabalho, foram utilizados os dois primeiros protocolos, que são descritos na seção 3.1.3.

3.1.2 Configurações de tempo na co-simulação

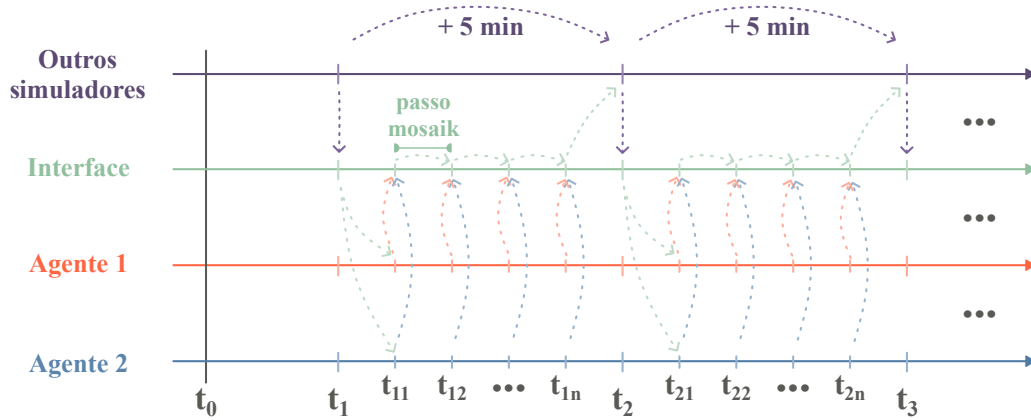
Entre os paradigmas de simulação disponíveis no Mosaik, utilizou-se o *time-based*, que é uma forma de simular mais próxima do mundo físico, embora o tempo seja discretizado. Cada passo de simulação é atribuído a um intervalo de tempo, que depende das necessidades do estudo e da capacidade computacional disponível (OFFIS, 2024). A compatibilização entre os tempos dos simuladores é uma responsabilidade do Mosaik, no qual o menor intervalo de tempo entre os simuladores é atribuído a um passo do Mosaik.

Uma das configurações dos cenários de simulação é a quantidade de passos a serem executados. Neste trabalho, foi adotada a razão de $500ms/passos$, ou seja, para cada 5 minutos a serem simulados, são executados 600 passos. Em geral, o tempo de execução de uma simulação é inferior ao tempo dos fenômenos reais. Por isso, o Mosaik é importante neste ambiente de co-simulação. A cada passo da simulação, pode haver processamento mais lento dentro de alguns agentes devido à execução de comportamentos ou troca de mensagens entre eles. O Mosaik impede, por exemplo, que os agentes que não estão em processamento no momento avancem etapas sem que os outros os acompanhem. Dessa forma, um novo passo somente é executado quando todos os agentes enviam sua informação de tempo para a interface do Mosaik.

A Figura 24 mostra exemplo de troca de informações utilizando uma interface do Mosaik. Os outros simuladores podem ser modelos de previsão de variáveis estocásticas, simuladores de rede elétrica, entre outros. Neste trabalho, os outros simuladores são propostos

como desenvolvimentos futuros. Não é apresentada a troca de informações entre os agentes, pois essa interação ocorre dentro do Pade por mensagens no padrão FIPA e são detalhadas nas próximas seções.

Figura 24 – Relação de tempo entre simuladores



Fonte: elaborada pela autora (2025).

3.1.3 Protocolos de comunicação e a função plug-and-play

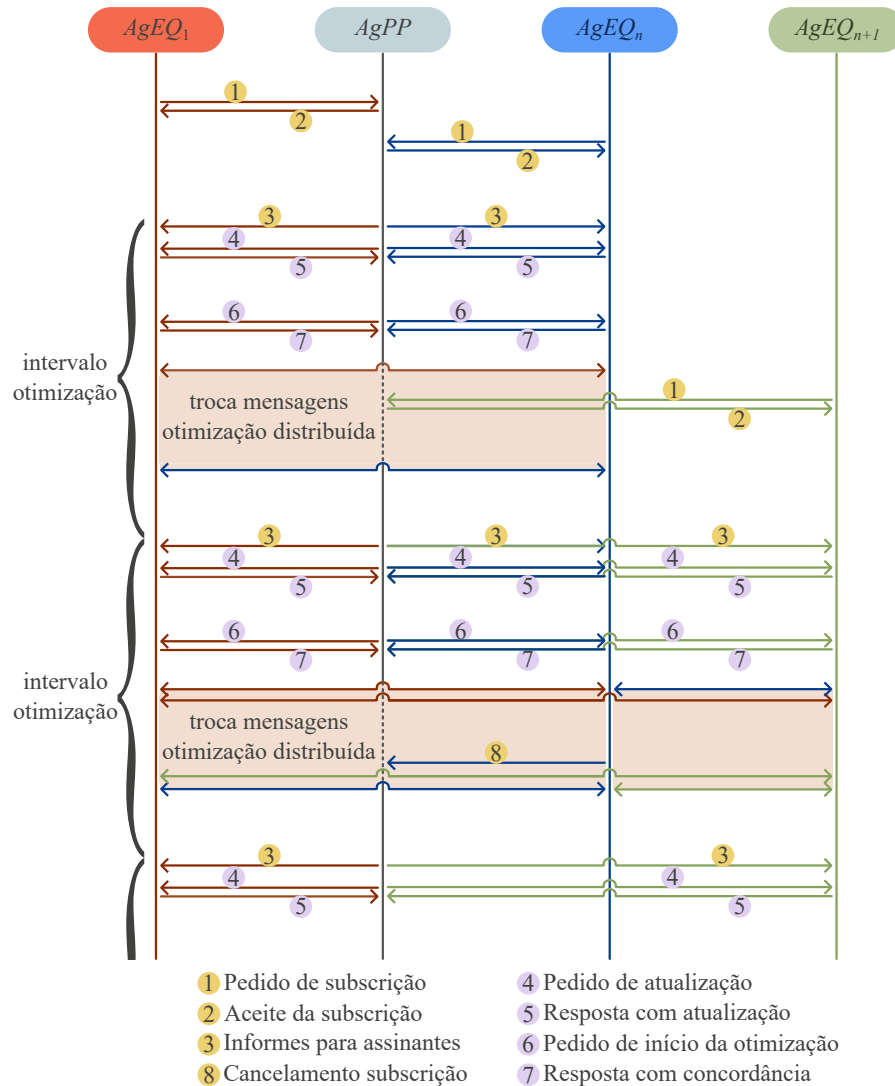
As simulações que serão apresentadas no próximo capítulo serão implementadas tanto com algoritmos de otimização centralizados, por meio de um agente coordenador das entradas, denominado agente *plug-and-play*, quanto de forma distribuída nos agentes de cada um dos recursos energéticos. Ambas as implementações serão realizadas para possibilitar uma comparação entre os métodos.

A distribuição dos algoritmos de otimização foi realizada dentro dos agentes e dois dos protocolos do padrão FIPA foram utilizados nas trocas de informações. O protocolo *Fipa-Subscribe* é utilizado com a função de fazer conhecer e tornar público aos demais agentes aqueles que estão disponíveis e aptos para participar da otimização. O protocolo *Fipa-Request* é usado durante a execução da otimização distribuída.

A Figura 25 apresenta a troca de mensagens necessárias para estabelecer e iniciar a otimização distribuída. São representados três Agentes do tipo Equipamento ($AgEQ_1$, $AgEQ_n$ e $AgEQ_{n+1}$), que representam qualquer um dos recursos energéticos da microrrede, e o Agente *plug-and-play* ($AgPP$) que tem a função de coordenar a entrada dos recursos. No $AgPP$, também foram implementados os algoritmos PSO e *Multiagent Particle Swarm Optimazation* - Otimização por enxame de partículas multiagentes (MAPSO) de forma centralizada, a fim de comparar

os resultados com a otimização distribuída. As cores das mensagens foram diferenciadas para mostrar em quais momentos cada protocolo é utilizado.

Figura 25 – Tipos de mensagens e a troca entre os agentes durante a otimização



Fonte: elaborada pela autora (2025).

O *Fipa-Subscribe* tem as mensagens identificadas com a cor amarela e as numerações 1, 2, 3 e 8. Essas mensagens são responsáveis pela operação *plug-and-play*, implementada para adequar a entrada e saída de componentes na otimização. O sistema multiagente é utilizado para a implementação da funcionalidade, tornando a simulação flexível e dinâmica. Ao adotar esse processo, a otimização é ajustada automaticamente aos recursos disponíveis a cada intervalo de simulação.

O *Fipa-Request* tem suas mensagens nas cores lilás e os números 4, 5, 6 e 7. Essas

mensagens são utilizadas antes do início da otimização. Enquanto as mensagens 4 e 5 são utilizadas mesmo quando a otimização é implementada de forma centralizada, pois atualizam as informações de cada equipamento, já as mensagens 6 e 7 são utilizadas para sincronização da otimização distribuída.

3.1.3.1 Função *plug-and-play*

A função *plug-and-play* é importante para aplicações reais e comum aos dispositivos inteligentes. Na Figura 25, são apresentados dois intervalos completos de otimização e o início de um terceiro intervalo. A funcionalidade começa quando os agentes solicitam subscrição na lista de agentes ativos ao *AgPP*, o que corresponde às mensagens do tipo 1. A resposta com o aceite (mensagem tipo 2) do *AgPP* ocorre no mesmo passo de simulação.

O novo intervalo de otimização inicia com o *AgPP* enviando a lista de agentes ativos a todos os participantes da otimização, mensagens tipo 3. Logo em seguida envia mensagens *REQUEST* (tipo 4) para os agentes da sua lista de ativos. Essa mensagem é o pedido de atualização dos parâmetros e das previsões dos recursos de energia renovável variável e das cargas para o intervalo a ser otimizado. Na mensagem *INFORM* dada como resposta (tipo 5), além das previsões, é possível alterar os parâmetros dos dispositivos. Entre os exemplos de mudança de parâmetros têm-se o grau de flexibilidade da carga para a resposta à demanda ou a potência máxima de descarregamento dos sistemas de armazenamento.

As mensagens 6 e 7 servem apenas para sincronizar os agentes no mesmo passo de simulação. Essas mensagens são utilizadas apenas na simulação distribuída, os algoritmos de otimização centralizados não necessitam desse artifício.

As próximas mensagens, responsáveis pela distribuição do algoritmo, serão detalhadas nas seções seguintes. Entretanto, durante essas trocas de mensagens, caso a quantidade de agentes aumente ou diminua, isso será atualizado apenas no próximo período de otimização, como pode ser observado na Figura 25. No primeiro intervalo, ocorre a entrada de um novo agente EQ_{n+1} ; a otimização já está em curso, portanto, o dispositivo só participará da otimização no próximo intervalo. No segundo intervalo da figura, o agente EQ_n solicita o cancelamento da subscrição (mensagem tipo 8), sinalizando sua saída da rede, o que também será atualizado no próximo intervalo.

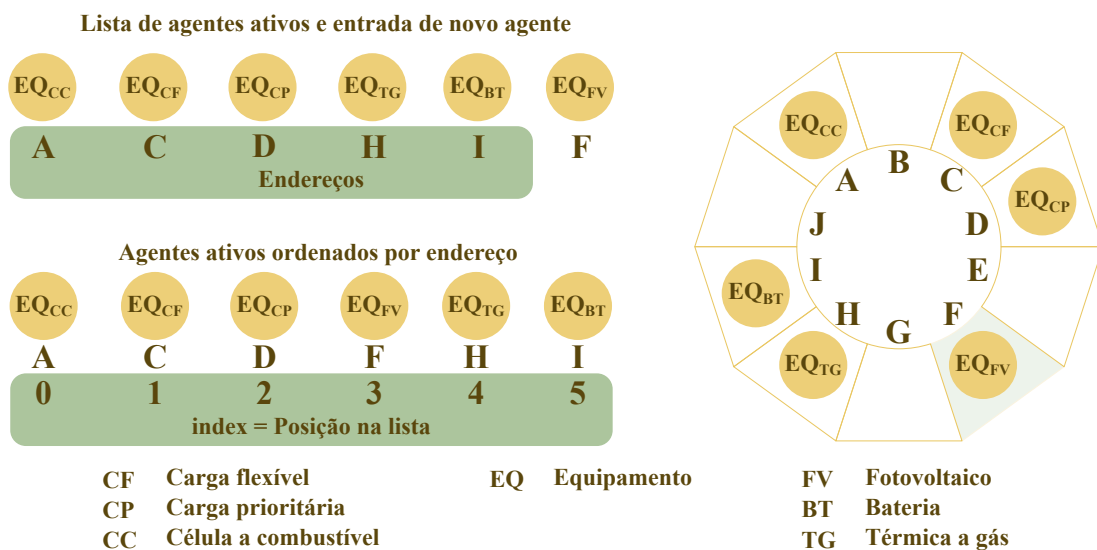
3.1.3.2 Lista de vizinhos

A lista de vizinhos é determinada por cada agente, com base na lista de agentes ativos enviada pelo *AgPP* (conteúdo da mensagem tipo 3) no início de cada novo intervalo de otimização. A lista de agentes ativos é formada pelos pedidos de subscrição ou de cancelamento dos agentes participantes da otimização. Portanto, antes de cada intervalo de otimização, ela é atualizada sempre que houver alguma alteração.

As Figuras 26 e 27 mostram um exemplo de ordenamento de vizinhos por endereços. A configuração entre vizinhos, neste trabalho, foi designada em anel, mas sendo possível mais de 2 vizinhos. Dependendo da dispersão desses recursos, os endereços podem ser previamente mapeados, como veículos elétricos em um estacionamento. Ou essa determinação pode ser realizada mediante geolocalização dos equipamentos. Por simplicidade e para ilustrar a funcionalidade, foram considerados endereços previamente mapeados e identificados por letras.

Na Figura 26, são listados 5 agentes em seus respectivos endereços e a chegada do agente EQ_{FV} , que envia por mensagem de subscrição seu endereço de localização. O *AgPP* realiza a atualização do ordenamento e, em seguida, envia as mensagens aos seus assinantes com a lista de agentes ativos. A Figura 26 também ilustra o mapeamento dos endereços e o posicionamento dos agentes após a integração do novo recurso energético.

Figura 26 – Exemplo de atualização da lista de agentes ativos com a entrada de um novo agente equipamento



Fonte: elaborada pela autora (2025).

Nota: Em *Python*, a indexação dos vetores inicia do zero.

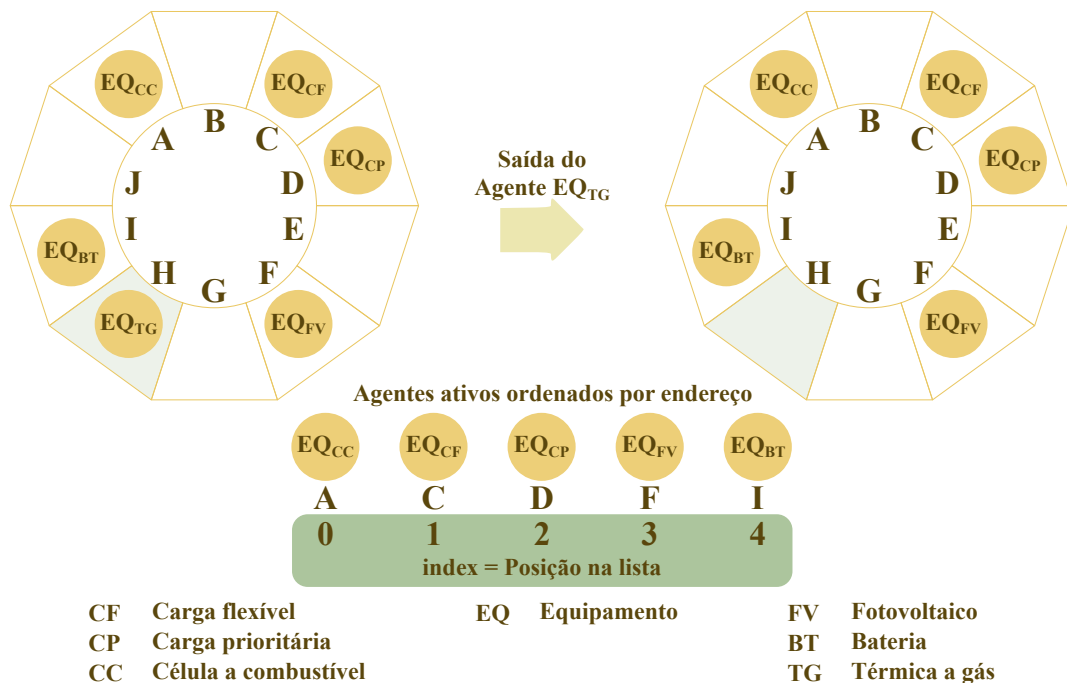
Recebida a lista de agentes ordenados por endereço, cada agente equipamento deve identificar os seus vizinhos. O Algoritmo 1 no apêndice A mostra como os vizinhos são determinados neste trabalho. A regra de formação dos laços de comunicação pode ser alterada pelo tomador de decisão, considerando, por exemplo, a rede de comunicação disponível.

Para o exemplo da Figura 26, e um número máximo de vizinhos igual a 2, têm-se como resultado para cada agente sua lista de vizinhos:

$$\begin{aligned} listaVZ_{EQ_{CC}} &= \{EQ_{CF}, EQ_{BT}\}, & listaVZ_{EQ_{CF}} &= \{EQ_{CP}, EQ_{CC}\}, \\ listaVZ_{EQ_{CP}} &= \{EQ_{FV}, EQ_{CF}\}, & listaVZ_{EQ_{FV}} &= \{EQ_{TG}, EQ_{CP}\}, \\ listaVZ_{EQ_{TG}} &= \{EQ_{BT}, EQ_{FV}\}, & listaVZ_{EQ_{BT}} &= \{EQ_{CC}, EQ_{TG}\}. \end{aligned} \quad (3.1)$$

A Figura 27 ilustra o reordenamento dos vizinhos quando ocorre uma alteração. No exemplo apresentado, o agente EQ_{TG} sai da otimização e, em seguida, a lista de posições é atualizada. O posicionamento dos agentes, antes e após a saída, também é mostrado na Figura 27.

Figura 27 – Exemplo de atualização de agentes ativos com saída de um agente equipamento



Fonte: elaborada pela autora (2025).

O resultado da lista de vizinhos que cada agente obtém para a nova condição é:

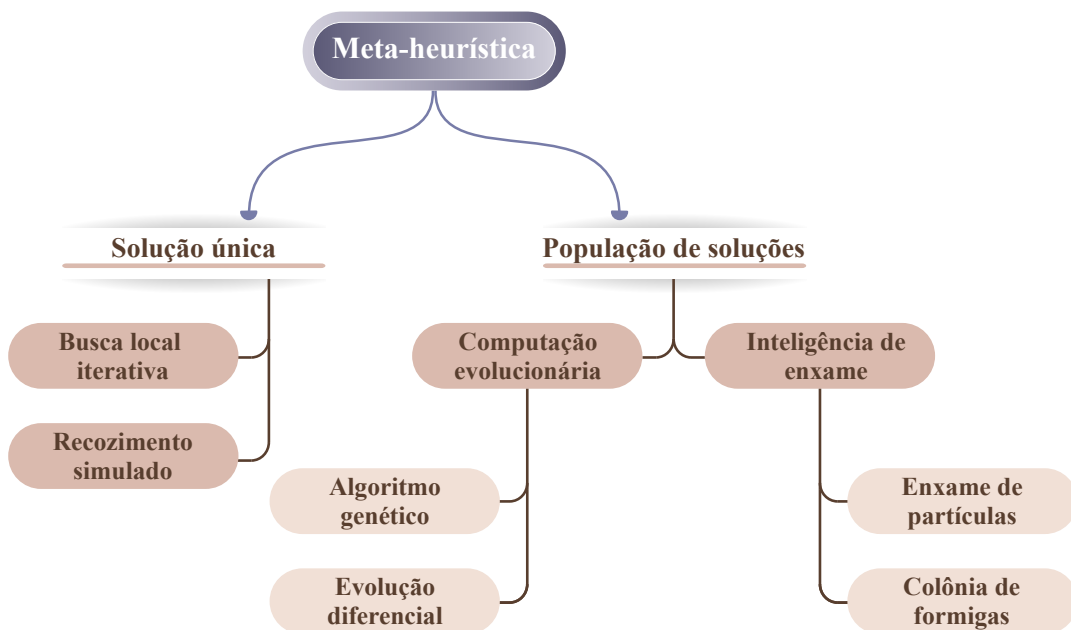
$$\begin{aligned} listaVZ_{EQ_{CC}} &= \{EQ_{CF}, EQ_{BT}\}, & listaVZ_{EQ_{CF}} &= \{EQ_{CP}, EQ_{CC}\}, \\ listaVZ_{EQ_{CP}} &= \{EQ_{FV}, EQ_{CF}\}, & listaVZ_{EQ_{FV}} &= \{EQ_{BT}, EQ_{CP}\}, \\ listaVZ_{EQ_{BT}} &= \{EQ_{CC}, EQ_{FV}\}. \end{aligned} \quad (3.2)$$

É a partir da lista de vizinhos que cada agente vai solicitar informações, para a etapa de competição e cooperação entre os agentes.

3.2 Meta-heurística para otimização em microrredes

Diversos métodos meta-heurísticos para otimização estão presentes na literatura. Uma divisão bastante comum classifica esses métodos em dois grupos principais. O primeiro grupo inclui os métodos que partem de uma única solução, como a busca local iterativa e o recozimento simulado. O segundo grupo abrange os métodos baseados em populações de soluções. Entre eles, encontram-se o algoritmo genético e a evolução diferencial, que fazem parte da computação evolucionária. Além disso, o enxame de partículas e a colônia de formigas, que pertencem aos métodos de inteligência de enxame, também são exemplos clássicos (EZUGWU *et al.*, 2021). Esses métodos estão ilustrados na Figura 28.

Figura 28 – Classificação de meta-heurísticas



Fonte: adaptada de Ezugwu *et al.* (2021)

Essas metodologias têm um conflito característico de critérios de busca que influenciam significativamente os resultados obtidos. Para uma otimização mais eficaz, é necessário estabelecer equilíbrio entre *exploration* ou exploração global (tradução livre) e *exploitation* ou exploração local (tradução livre)¹. Quando não se diversifica a busca por todo o espaço de soluções adequadamente, os algoritmos podem ficar presos em ótimos locais. E se não houver intensificação da busca em regiões promissoras, a solução ótima pode não ser encontrada.

A Figura 29 mostra que os algoritmos baseados em populações, em geral, são mais relevantes na diversificação de soluções devido à busca aleatória realizada no espaço de soluções. Já os algoritmos de solução única têm uma busca local mais intensa.

Figura 29 – Conflito de critérios em meta-heurísticas



Fonte: adaptada de Talbi (2009).

Para cada um desses algoritmos, existem proposições para melhor equilibrar esses dois critérios. Neste trabalho, a principal meta-heurística utilizada foi PSO e, na seção 3.2.1, a forma clássica para equilibrar os critérios de busca deste algoritmo é apresentada.

Devido à natureza distribuída dos recursos energéticos e com o intuito de utilizar métodos de otimização meta-heurístico por sua simplicidade e rapidez, utilizou-se o SMA para distribuir esses algoritmos. À medida que o número de equipamentos no sistema cresce e, consequentemente, também as variáveis a serem otimizadas, a utilização de algoritmos distribuídos deve garantir a busca por soluções viáveis e próximas da ótima em um tempo de execução razoável, a fim de atender ao despacho de curtíssimo prazo.

3.2.1 Otimização por enxame de partículas

Essa meta-heurística foi apresentada pela primeira vez por Kennedy e Eberhart (1995) baseada no comportamento social de pássaros e peixes durante deslocamentos. Desde então, inúmeros estudos foram e continuam sendo realizados, e diversas modificações e associações

¹ Termos, em português, ambos traduzidos como exploração. Entretanto, no contexto de otimização, *exploration* significa diversificar a procura por soluções em novas regiões do espaço de busca, enquanto *exploitation* é a intensificação da busca próximo das melhores soluções já encontradas.

foram propostas com o objetivo de reduzir as desvantagens do algoritmo, que podem ser listadas como:

- a) sensibilidade aos parâmetros;
- b) convergência prematura;
- c) dificuldade de utilizar variáveis inteiras;
- d) dificuldade de equilibrar exploração local e global.

Entre as modificações e associações já implementadas têm-se as que alteram a forma de atualização da velocidade e da posição, a topologia social entre as partículas, o operador de busca e a função objetivo (JAIN *et al.*, 2022).

Uma das primeiras modificações foi realizada por Shi e Eberhart (1998) em que se acrescentou o coeficiente de inércia na equação da velocidade:

$$\mathbf{V}_{k+1} = \omega[k] \cdot \mathbf{V}_k + cv_1 \cdot \mathbf{R}_1 \odot (\mathbf{P}_{best} - \mathbf{X}_k) + cv_2 \cdot \mathbf{R}_2 \odot (\mathbf{G}_{best} - \mathbf{X}_k), \quad (3.3)$$

sendo essa velocidade responsável pela atualização da posição das partículas:

$$\mathbf{X}_{k+1} = \mathbf{V}_{k+1} + \mathbf{X}_k. \quad (3.4)$$

Em que \mathbf{X}_k e \mathbf{V}_k são as posições e velocidades das partículas atualizadas a cada iteração k , possuem as mesmas dimensões, relacionadas ao tamanho da população, n_p , e ao número de variáveis do problema, n_{var} . Os coeficientes de velocidade, cv_1 e cv_2 , determinam a influência entre a melhor informação da própria partícula e a melhor informação da vizinhança, respectivamente. Enquanto a característica randômica do algoritmo é dada por \mathbf{R}_1 e \mathbf{R}_2 , que são matrizes da mesma dimensão de \mathbf{X} e \mathbf{V} , cujos elementos são números reais e variam no intervalo $[0, 1]$. E, por fim, \odot é o produto de Hadamard que indica a multiplicação elemento a elemento entre duas matrizes.

\mathbf{P}_{best} é a população formada pelas melhores posições que cada partícula já alcançou e, também, tem a mesma dimensão de \mathbf{X} . Já \mathbf{G}_{best} é a melhor solução encontrada, portanto, sua dimensão é $[1, n_{var}]$. O coeficiente de inércia ω é uma forma de limitar a velocidade, equilibrando a exploração global e local do espaço de soluções. Ele é decrescido linearmente entre um valor máximo, ω_{max} , e um valor mínimo, ω_{min} , como apresentado em:

$$\omega[k] = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{k_{max}} \cdot k, \quad (3.5)$$

na qual os valores ω_{max} e ω_{min} são definidos como 0,9 e 0,4, respectivamente. E k_{max} é o número máximo de iterações.

Essa versão é denominada comumente como PSO padrão, seu pseudo código é apresentado em Algoritmo 2 no apêndice A. Algumas características podem ser destacadas:

- a) a velocidade é limitada indiretamente pelo coeficiente de inércia;
- b) a primeira iteração terá valor máximo de $\omega = 0,9$, indicando velocidades mais altas, portanto maior amplitude de exploração no espaço de soluções;
- c) a última iteração terá valor mínimo de $\omega = 0,4$, indicando velocidades reduzidas, portanto maior detalhamento de uma região de busca;
- d) os coeficientes de velocidade são considerados iguais, ou seja, a partícula considera em igual proporção seu próprio conhecimento e o conhecimento do conjunto;
- e) em relação à topologia das partículas, esse PSO considera que todas as partículas são vizinhas entre si. Dessa forma, o G_{best} é igual para todas elas.

Esse algoritmo tem característica centralizada, em que as informações são trocadas somente entre as partículas (possíveis soluções do problema). A centralização se dá por a função objetivo ser única, diferente de métodos como consenso e difusão, cuja otimização é determinística por meio de gradientes e a função objetivo é dividida em parcelas (CES, 2023).

3.2.2 Otimização por enxame de partículas multiagente

O algoritmo MAPSO foi desenvolvido por Zhao *et al.* (2005) e também é centralizado, consiste em uma modificação do PSO na topologia das partículas e na adição da etapa de competição e cooperação entre as partículas chamadas de agentes ², além de envolver uma etapa de autoaprendizado.

Neste trabalho, a otimização distribuída é realizada através da interação entre os agentes equipamentos e com base em uma das etapas do MAPSO. Dessa forma, para melhor compreender seu funcionamento, o Algoritmo 3 no apêndice A mostra a principal concepção do método e as etapas comuns ao PSO padrão.


A primeira mudança em relação ao PSO é a criação do ambiente de vizinhança. O conceito de vizinhança já havia sido proposto por Suganthan (1999), entretanto, essa primeira abordagem determina a vizinhança por uma média em relação às posições alcançadas a cada iteração. Além disso, as vizinhas somente influenciavam no valor de atualização das velocidades, em que se usava um $local_{best}$ no lugar do g_{best} da equação 3.3.

² Neste trabalho, a partícula não é chamada de agente. Quando for utilizado o termo agente, estará relacionado ao agente do SMA e não às possíveis soluções do problema.

No modelo MAPSO, as partículas têm um endereço inicial e suas vizinhas são sempre as mesmas partículas a cada iteração. Esse ambiente de soluções a ser criado pode ter vários formatos e dimensões (KUMAR *et al.*, 2009; KUMAR *et al.*, 2011). Em Kumar *et al.* (2009), além do plano comumente encontrado, é explorada a vizinhança linear e cúbica.

A Figura 30 mostra algumas possibilidades de ambientes e variações na quantidade de vizinhos para cada partícula, bem como a identificação numérica dos endereços. Outro parâmetro que pode ser alterado na construção do ambiente é a quantidade de vizinhos. Os exemplos comuns são a utilização de 4 (ZHAO *et al.*, 2005; SHUNMUGALATHA; SLOCHANAL, 2008) ou 8 partículas vizinhas (LIU *et al.*, 2018; WANG *et al.*, 2022).

Figura 30 – Possibilidades de ambientes para algoritmo MAPSO




Fonte: elaborada pela autora (2025).

Na implementação do algoritmo, essa etapa de construção do ambiente consiste em dar a conhecer o endereço de suas vizinhas a cada partícula. Esse passo, se o número de partículas e vizinhas for fixo, é possível de ser fornecido como parâmetro do algoritmo, não sendo necessário o cálculo a cada nova execução. No Apêndice A, o Algoritmo 4 e sua continuação, o Algoritmo 5, mostram como os endereços de um ambiente plano com uma vizinhança de 4 partículas são armazenados para serem utilizados na execução do algoritmo.

A Figura 31 mostra um exemplo simples da etapa de competição e cooperação entre as soluções vizinhas. Nesse caso, o ambiente adotado foi um plano 4x4, em que cada partícula tem 4 vizinhas.

Figura 31 – Exemplo da etapa de competição e cooperação do algoritmo MAPSO



Fonte: elaborada pela autora (2025).

A Figura 31a mostra a partícula de endereço [1,4], cujos vizinhos têm os endereços $\{[1,1], [1,3], [2,4], [4,4]\}$. Essa partícula vence a competição, pois sua função objetivo apresenta o menor valor. Assim, ela mantém sua posição, ou seja, as variáveis de otimização do problema não são alteradas.

Na mesma iteração, a Figura 31b traz a partícula [1,3] como perdedora na etapa de competição para sua vizinha de endereço [2,3], cuja função *fitness* é inferior. Quando a partícula perde, tem-se a etapa de cooperação. A cooperação ocorre com a criação de uma nova partícula que substituirá a perdedora. A nova partícula tem seus valores definidos em cooperação com as informações da vizinha vencedora, conforme:

$$m_l^{nova} = m_l^{venc} + rnd \cdot (m_l^{venc} - m_l^{perd}), \quad \text{para } l = \{1, \dots, n_{var}\}, \quad (3.6)$$

na qual m_l são as variáveis que compõem uma solução x do problema, portanto, l corresponde ao número de variáveis. Dessa forma, m_l^{nova} , m_l^{venc} , m_l^{perd} são variáveis da nova partícula, da

vencedora e da perdedora, respectivamente, e, por fim, rnd é um número aleatório do intervalo $[-1, 1]$.

Após a criação da nova partícula, deve-se encontrar seu novo valor de *fitness* e avaliar se é melhor que o anterior. Caso seja melhor, deve-se atualizar p_{best} e $fit_{p_{best}}$. E se uma das novas partículas for melhor que g_{best} , esse valor também deve ser atualizado, bem como $fit_{g_{best}}$.

Finalizada a etapa de competição e cooperação, as etapas seguintes são iguais ao PSO padrão, com atualização da velocidade e posição das partículas, além da verificação de melhores resultados. A última etapa do MAPSO é definida como *self-learning*. Essa etapa adicional pode ser realizada de diferentes formas e seu objetivo é aumentar a *explotation* do algoritmo.

A proposição original da etapa de autoaprendizado é a geração de um ambiente semelhante ao da etapa de competição e cooperação, mas de menor dimensão. Todas as soluções desse ambiente seriam geradas a partir de uma única partícula, a g_{best} daquela iteração, entretanto limitando sua variação aleatória em um raio que será reduzido algumas vezes (ZHAO *et al.*, 2005). Esse processo de redução do raio também é iterativo e interno à iteração principal, tornando o algoritmo mais lento.

O método utilizado por Wang *et al.* (2022) para o autoaprendizado foi baseado na equação logística, utilizada no algoritmo de busca caótico que já foi associado ao PSO antes em Liu *et al.* (2005), Hefny e Azab (2010). E aplicada também somente na melhor partícula da iteração.

3.3 Paralelismo distribuído de meta-heurísticas no ambiente de agentes inteligentes

O paralelismo de meta-heurísticas consiste em distribuir o processamento do algoritmo. Essa divisão pode ser restrita aos núcleos de processamento de uma única máquina, com compartilhamento de memória, sem a necessidade de técnicas avançadas de comunicação. Alternativamente, pode ser realizada em *hardwares* totalmente separados, exigindo a comunicação entre os recursos; essa forma de implementação é considerada distribuída. O método distribuído visa resolver problemas que, se executados em apenas uma máquina, seriam extremamente onerosos.

Essa técnica é particularmente interessante para a solução de problemas em tempo real. A redução do tempo de busca, a melhoria da qualidade das soluções, a maior robustez e a solução de problemas de grande escala são as principais vantagens de algumas dessas

implementações (TALBI, 2009).

3.3.1 Níveis de paralelismo de meta-heurísticas

Há três níveis hierárquicos para o paralelismo de meta-heurísticas: algoritmo, iteração e solução. No nível de algoritmo, o paralelismo pode acontecer de forma independente ou cooperativa. Na forma independente, os algoritmos não têm mudança no comportamento, portanto, é interessante operarem com diferentes parâmetros e diferentes soluções/populações iniciais. Já na forma cooperativa de paralelismo, há a troca de informações durante a execução dos algoritmos, implicando em mudança no comportamento. Para realizar o paralelismo cooperativo, é necessário determinar:

- a) qual informação deve ser trocada: uma solução, um conjunto de soluções ou um parâmetro de memória;
- b) quando deve ocorrer a troca de informação: a cada n iterações (necessidade de sincronização) ou de forma aleatória (assíncrona);
- c) quem deve receber essas informações: topologia de troca de informações;
- d) como essa informação deve ser utilizada: a melhor solução vai ser simplesmente atualizada ou algum processo vai ocorrer.

O paralelismo no nível de iteração não causa mudanças no comportamento do algoritmo. Isso porque apenas na avaliação das melhores soluções, etapa que mais consome recursos computacionais, ocorre a divisão da população para execução da tarefa em diferentes *hardwares*. Nesse nível, também há possibilidade de trocas de informações serem síncronas e assíncronas.

O paralelismo no nível da solução é interessante quando a função objetivo e/ou as restrições podem ser particionadas, ou seja, quando é necessário tratar uma grande quantidade de dados. O algoritmo mantém o mesmo padrão de execução como se fosse realizado em uma única máquina. Entretanto, devido ao paralelismo, cada *hardware* deve avaliar um segmento da solução que foi dividido.

A Tabela 3 resume as propriedades discutidas para cada nível de implementação. Algumas características podem ser destacadas: o paralelismo de solução depende do problema e nem sempre pode ser utilizado; apenas o paralelismo no nível de algoritmo altera o comportamento do método e apenas se aplicado no modo cooperativo; os paralelismos de iteração e de solução só ganham em eficiência computacional, enquanto o paralelismo de algoritmos deve ter

um aumento na eficácia dos resultados.

Tabela 3 – Diferença do paralelismo de meta-heurísticas por nível

Nível do paralelismo	Influência do problema	Altera o comportamento	Granularidade do paralelismo	Objetivo com paralelismo
Algoritmo	Independente	Sim	Meta-heurística	Eficácia
Iteração	Independente	Não	Iteração	Eficiência
Solução	Dependente	Não	Solução	Eficiência

Fonte: adaptada de Talbi (2009).

3.3.2 Implementação das meta-heurísticas por meio do sistema multiagente

Neste trabalho, o paralelismo distribuído de meta-heurísticas é implementado no nível do algoritmo de forma cooperativa, utilizando toda a estrutura de protocolos de comunicação dos SMA. Para efeito de comparação, também foram implementados os algoritmos sem nenhum paralelismo, de forma centralizada em um único agente, o *AgPP*.


Na simulação do paralelismo distribuído, foram adicionadas etapas adicionais de competição e cooperação. Existe a dependência da troca de informações a cada iteração entre os agentes; portanto, a comunicação deve ser síncrona. Os algoritmos em paralelo são executados dentro dos agentes associados aos recursos energéticos, e a topologia de troca de informações é em anel, conforme mostrado na seção 3.1.3.2.

A informação compartilhada é a melhor solução de cada algoritmo, e ela não é simplesmente atualizada entre os algoritmos em paralelo, pois uma etapa de competição e cooperação baseada no algoritmo MAPSO é realizada. Logo, uma nova partícula é gerada pela equação 3.6, resultante da troca de informações entre vizinhos. A Figura 32 mostra a dinâmica da troca de informações a cada iteração das meta-heurísticas em paralelo.

As Figuras 33 e 34 mostram a dinâmica de troca de mensagens dentro dos *AgPP* e *AgEQ*, respectivamente. Dentro de um intervalo de otimização, são apresentadas as mensagens entre os agentes que são relevantes para a otimização, tanto para meta-heurísticas implementadas de forma centralizada quanto distribuída. Já a Figura 35 é o fluxograma das etapas dos algoritmos adotados neste trabalho, PSO e MAPSO, realizadas internamente aos agentes. Na cor lilás, destaca-se o momento dentro da iteração que ocorre a etapa de competição e cooperação entre agentes na implementação distribuída.

Um intervalo de otimização representa os cálculos realizados para o despacho nos

Figura 32 – Troca de informações na simulação do paralelismo distribuído de meta-heurísticas



Fonte: elaborada pela autora (2025).

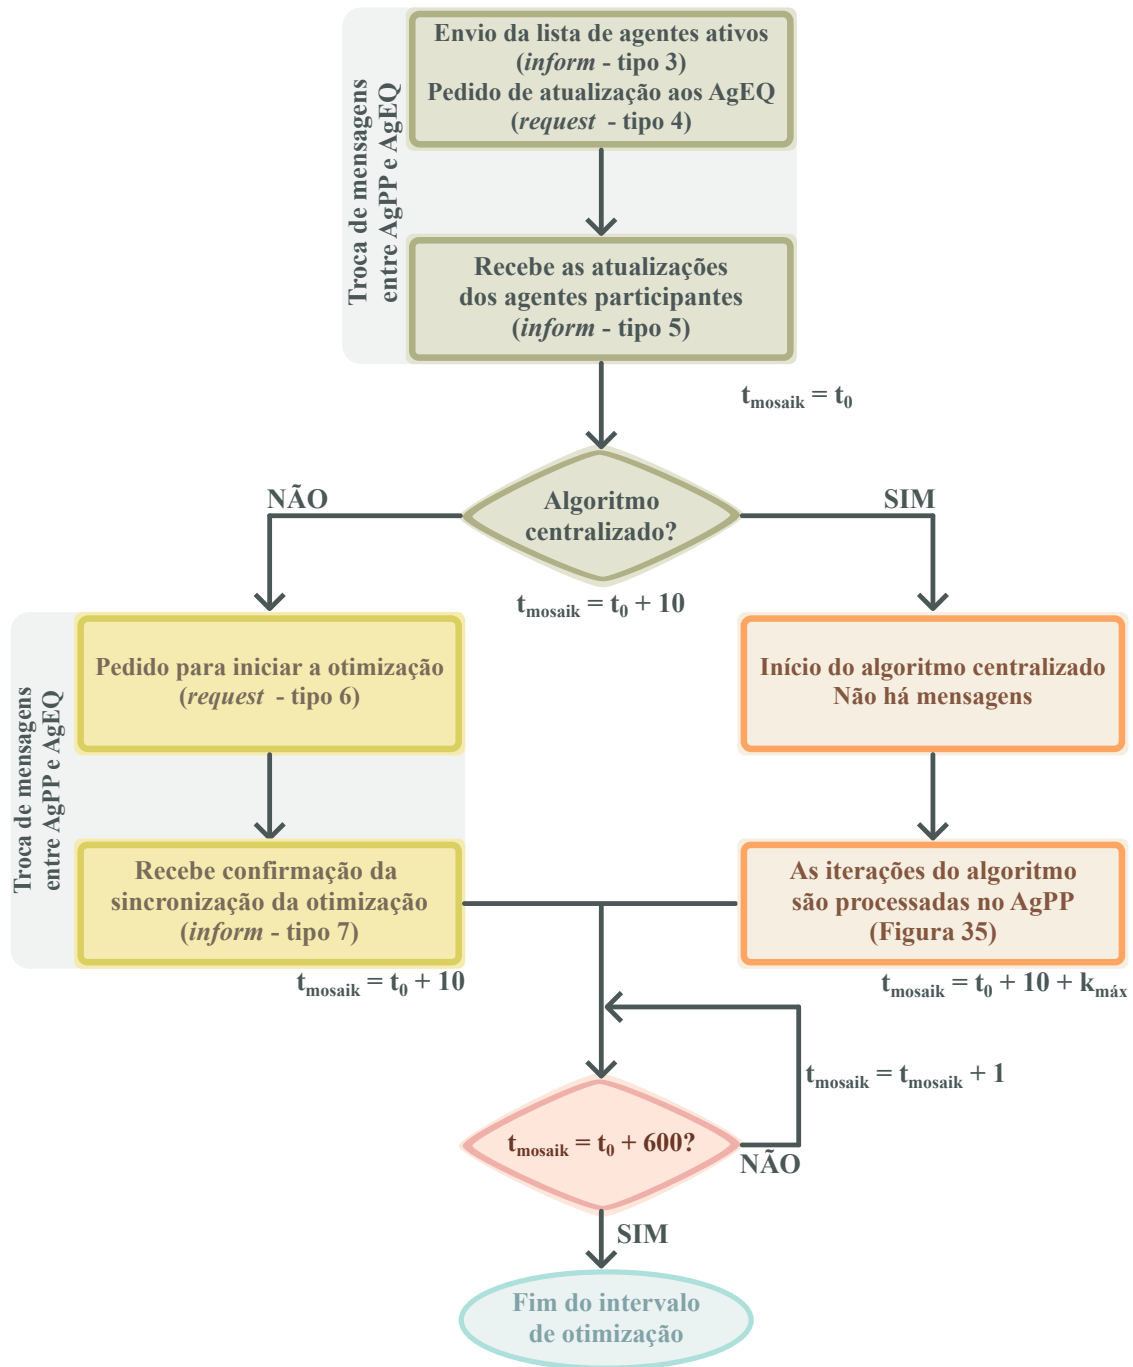
Nota: No sistema implementado, a informação trocada em um primeiro momento é a *fitness_gbest*. Optou-se por colocar a partícula *gbest* na Figura por ser a informação mais representativa na troca de mensagens.

próximos 5 minutos, que inicia em t_0 . A primeira ação, que ocorre tanto para problemas centralizados quanto distribuídos, é o envio da lista de agentes ativos. Essa mensagem é enviada pelo *AgPP* a todos os agentes que pediram subscrição até o instante $t_0 - 1$. Simultaneamente, outra mensagem é enviada, também pelo *AgPP*, requerendo a atualização dos parâmetros dos agentes que devem participar da otimização no intervalo atual.

Os agentes equipamentos reagem às duas mensagens. Para a primeira mensagem, determinam sua lista de vizinhos com os quais irão interagir durante a otimização em paralelo. A quantidade de vizinhos pode variar e é independente para cada equipamento. Embora as simulações tenham sido realizadas com comunicação em anel simples, a função *plug-ang-play* garante que qualquer topologia de rede pode ser criada e atualizada a cada nova entrada de equipamento.

A segunda mensagem recebida pelos *AgEQ* exige uma resposta com a atualização de seus parâmetros. Nessa mensagem, são enviadas as previsões de carga e de geração das fontes variáveis, assim como os parâmetros da função objetivo. Com base nesses parâmetros, os proprietários dos recursos podem repassar ao *AgPP* os dados necessários para a formação de uma nova função custo, incluindo o aumento no custo do combustível, mudanças nos níveis de

Figura 33 – Etapas de atuação do agente *plug-and-play* durante a otimização



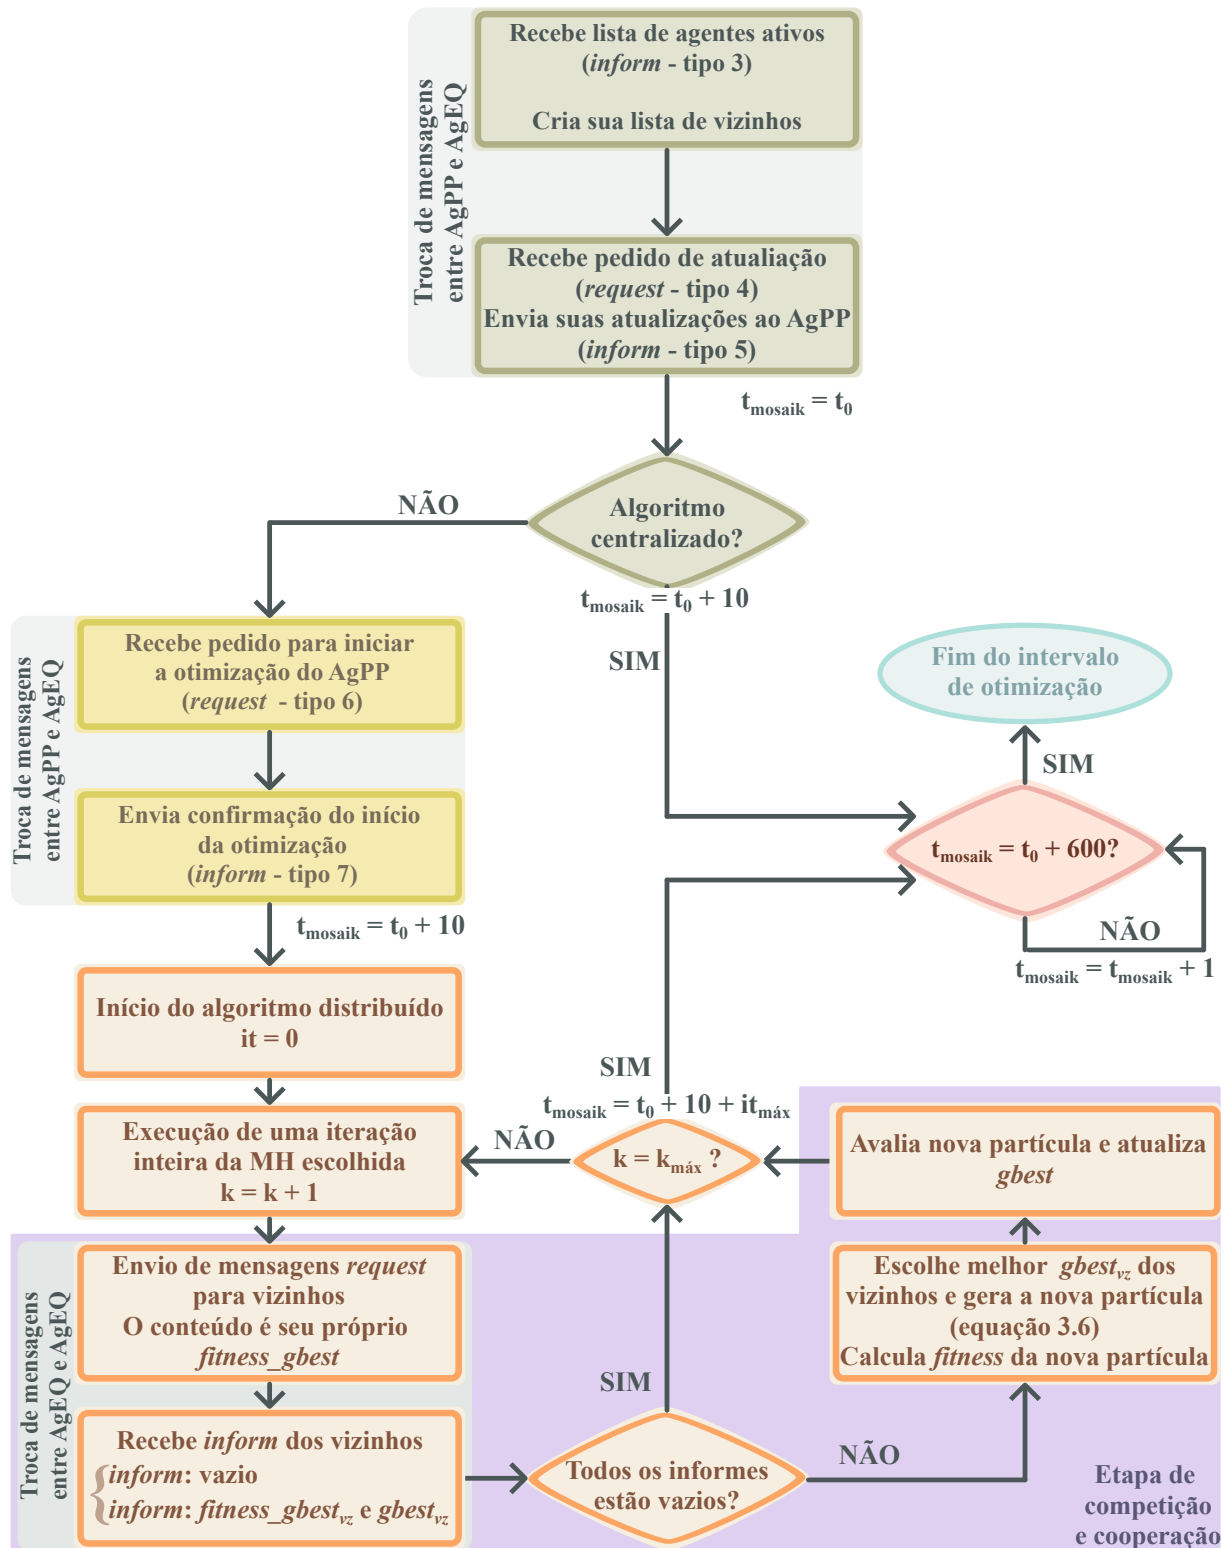
Fonte: elaborada pela autora (2025).

Nota: Os tipos de mensagens são os mesmo da Figura 25.

flexibilidade da carga e restrições no uso dos armazenadores.

As seções em destaque na parte superior dos fluxogramas nas Figuras 33 e 34 mostram as primeiras ações logo que o intervalo de otimização inicia com a troca de mensagens entre *AgPP* e *AgEQ*. Considerando a discretização do tempo utilizada pelo Mosaik, importante na sincronização de mensagens, apenas 10 passos de simulação após receber as atualizações, a

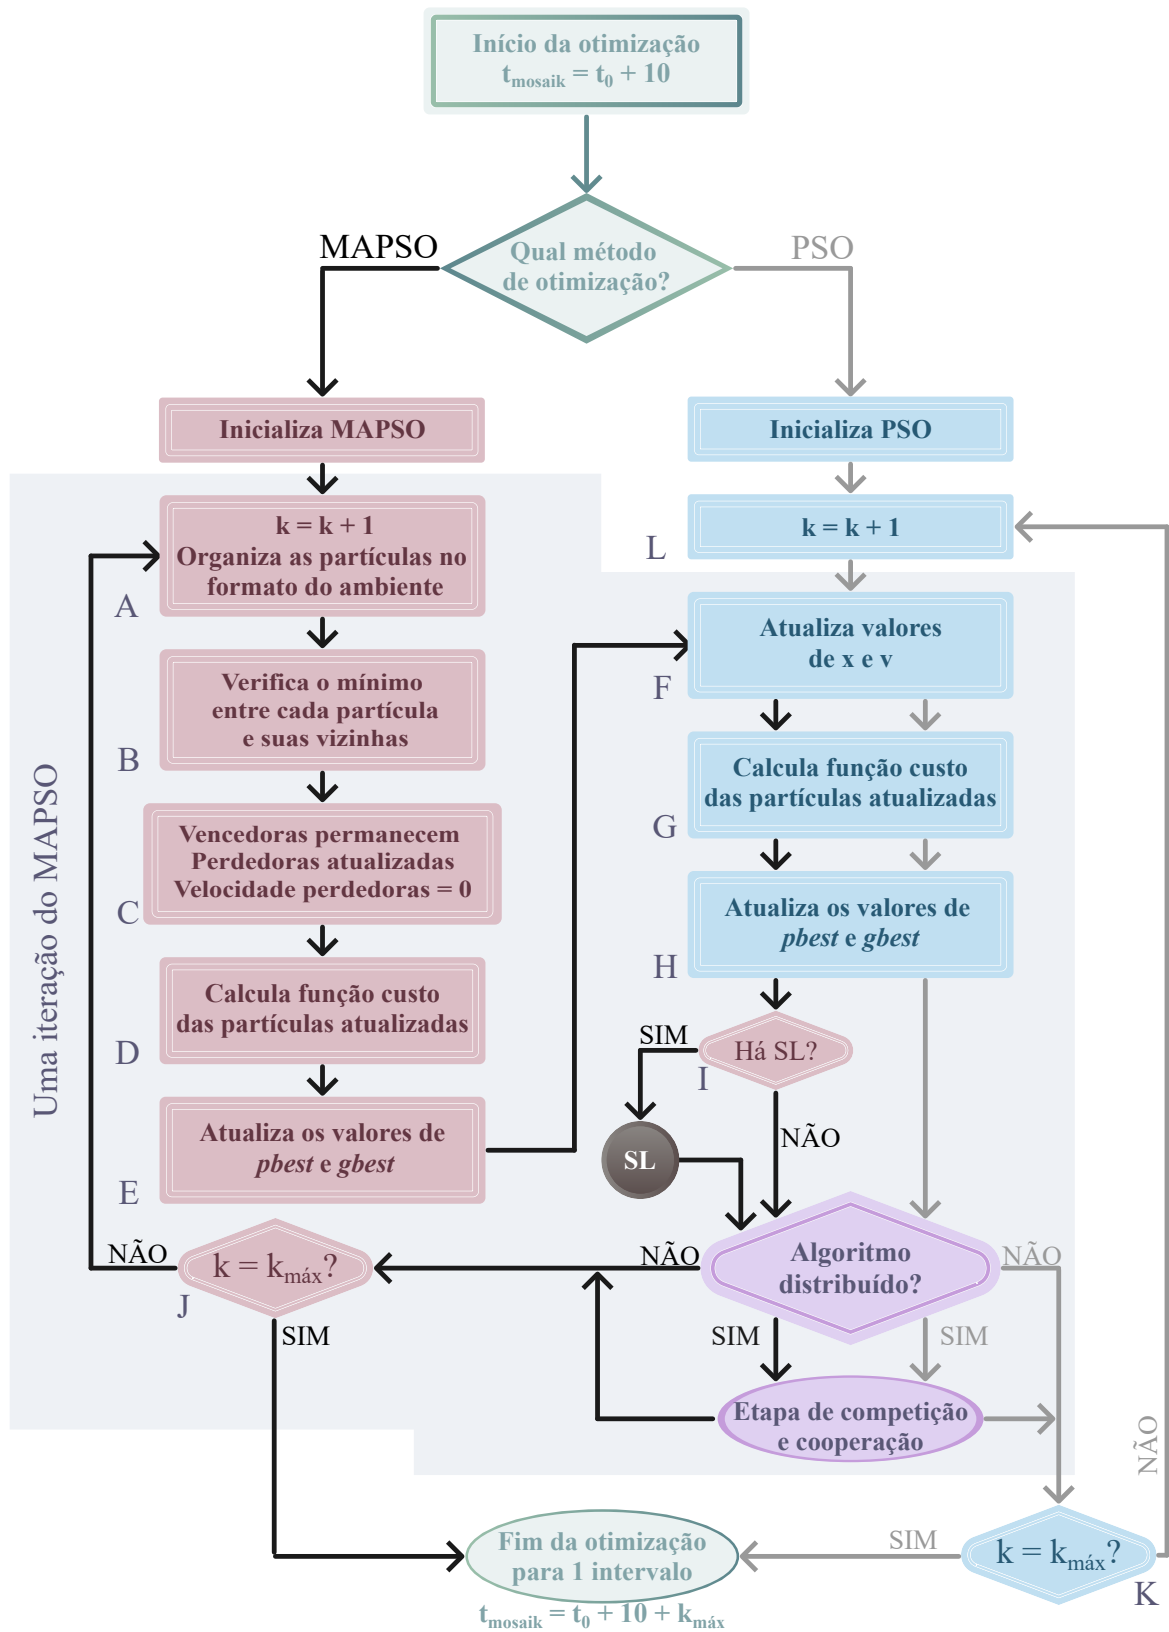
Figura 34 – Etapas de atuação do agente equipamento durante a otimização



Fonte: elaborada pela autora (2025).

Nota: Os tipos de mensagens são os mesmo da Figura 25.

Figura 35 – Fluxograma detalhado com as etapas dos algoritmos de otimização disponíveis



Fonte: elaborada pela autora (2025).

Nota: SL significa *self learning*.

próxima etapa se inicia.

3.3.2.1 *Meta-heurísticas sem paralelismo e centralizadas no agente plug-and-play*

As meta-heurísticas centralizadas foram implementadas dentro do *AgPP*, o que reduz a troca de mensagens, tornando a execução mais rápida e aumentando a confidencialidade das informações.

A Figura 34 mostra que, quando o algoritmo é centralizado, nenhuma ação ocorre no *AgEQ*, pois todo o processamento está no *AgPP*. Como observado na Figura 33, não há troca de mensagens e o processamento é interno, detalhado na Figura 35.

As etapas do PSO centralizado são destacadas em azul com setas cinzas, as mesmas listadas no Algoritmo 2. As etapas L, F, G, H e K são repetidas a cada novo passo de simulação. O fim da otimização acontece quando o critério de parada é alcançado, ou seja, o número máximo de iterações.

As etapas do MAPSO centralizado também são apresentadas na Figura 35, incluindo as etapas que são comuns ao PSO padrão. Sem troca de mensagens, as etapas em sequência, após a inicialização, são A, B, C, D, E, F, G, H, I e J. Mostra-se também a etapa de *self learning* como uma etapa opcional. Qualquer que seja o algoritmo escolhido, os passos acontecem nas indicações em laranja da Figura 33.

3.3.2.2 *Meta-heurísticas em paralelo distribuídas entre os agentes equipamentos*

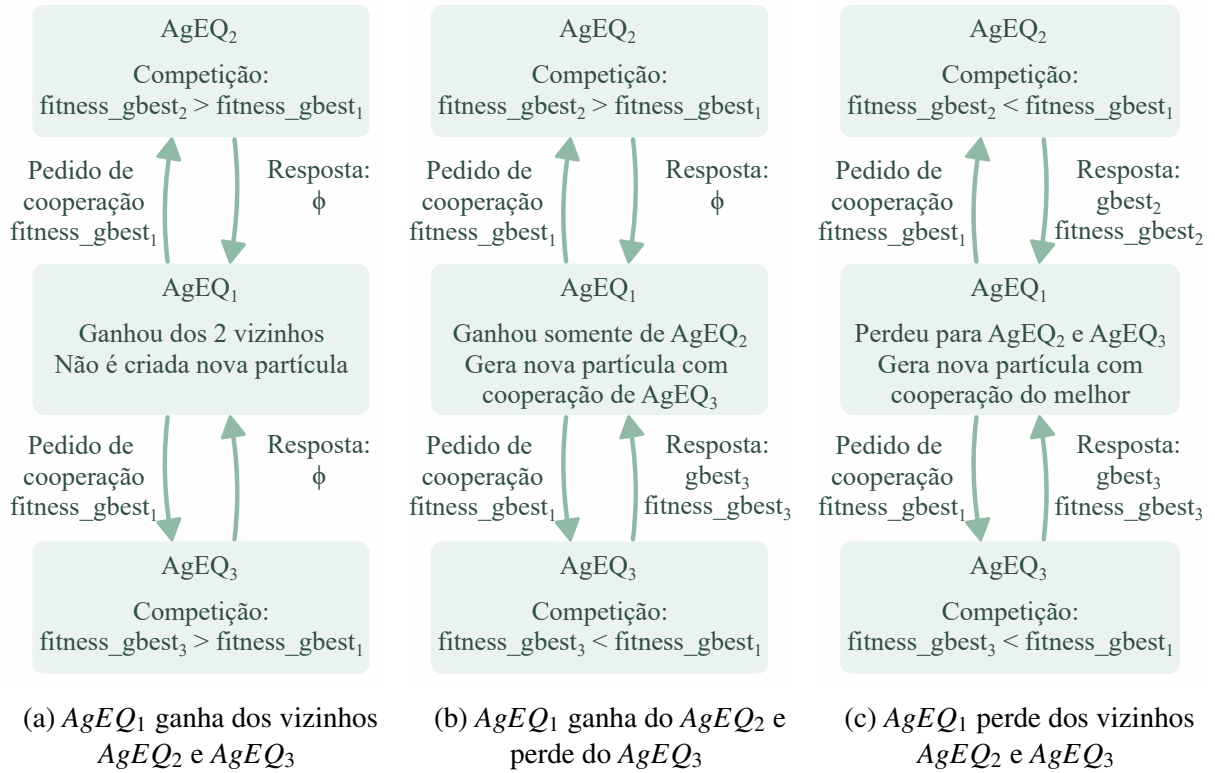
As meta-heurísticas distribuídas são implementadas em cada um dos *AgEQ*. A inicialização ocorre somente com o pedido do *AgPP*, permitindo a sincronização entre todos os agentes. As Figuras 34 e 35 mostram o momento do algoritmo em que ocorre a troca de informações entre os *AgEQ*, caracterizando o paralelismo de meta-heurísticas. A área em lilás da Figura 34 destaca todos os passos realizados nesse processo.

A etapa de compartilhamento de informações ocorre após cada iteração do algoritmo. Os *AgEQ* enviam aos seus vizinhos uma mensagem de pedido de cooperação. No conteúdo da mensagem, envia-se o valor do *fitness_gbest*.

As respostas dos vizinhos ao pedido podem ser vazias, quando o emissor da mensagem tem seu *fitness_gbest* melhor que o do receptor, ou podem conter os valores de *fitness_gbest* e *gbest* quando o receptor tem uma solução melhor. A Figura 36 mostra os três tipos de ocorrências possíveis. O exemplo mostra o *AgEQ₁* como emissor do pedido de

cooperação e os $AgEQ_2$ e $AgEQ_3$ como os seus vizinhos.

Figura 36 – Exemplo da etapa de competição e cooperação entre agentes do sistema SMA.



Fonte: elaborada pela autora (2025).

Na Figura 36a, o valor de $fitness_gbest_1$ enviado, juntamente com o pedido de cooperação, é inferior ao $fitness_gbest$ dos agentes 2 e 3. Portanto, esses agentes não podem cooperar e a resposta à solicitação é vazia.

Já a Figura 36b mostra que o valor da função objetivo do $AgEQ_3$ é inferior ao valor enviado pelo agente emissor do pedido. Dessa forma, a resposta contém o valor de $gbest_3$ e da função objetivo dessa partícula. Com os valores de $gbest_3$ e $gbest_1$, uma nova partícula é gerada a partir da equação 3.6 e, em seguida, testada. Caso ela seja melhor, $gbest_1$ é substituída pela nova partícula.

Por fim, a Figura 36c apresenta a situação em que o $AgEQ_1$ perde para os dois agentes vizinhos. A diferença dessa situação para a anterior é simplesmente que, entre todos os vizinhos que ganharam, aquele que vai cooperar na geração de uma nova partícula é o agente que tiver a menor função *fitness*.

3.4 Modelagem da função objetivo dos recursos distribuídos

A função objetivo utilizada neste trabalho para o despacho dos recursos energéticos a cada 5 minutos foi apresentada na seção 2.5.1. Por conveniência, ela é apresentada novamente com mais detalhes:

$$\begin{aligned}
 C_{total} &= \min_{\underline{\mathbf{E}}} \sum_i C_i(p_i) \\
 P_i^{min} &\leq p_i \leq P_i^{max}, \quad \forall i \\
 \sum_i p_i &= 0.
 \end{aligned} \tag{3.7}$$

Ao minimizar a função, busca-se reduzir o custo total, C_{total} , mas considera-se também o bem-estar dos consumidores através da maximização da função utilidade. Mais detalhes sobre a função utilidade são apresentados na seção 3.4.2.

O problema de otimização ainda terá i restrições de desigualdade devido à capacidade de utilização de cada um dos recursos. Essas restrições, que estabelecem limites mínimos e máximos para os recursos, são fáceis de serem tratadas dentro das meta-heurísticas, visto que essas inequações se referem justamente às variáveis do problema de otimização. E, nesses algoritmos, é inerente uma etapa de verificação dos limites de variáveis e de adequação, caso alguma restrição tenha sido violada.

No problema deste trabalho, apenas a restrição de igualdade associada ao balanço de potência dos recursos deve ser obedecida. Portanto, para que o somatório seja zero, os elementos de produção de energia têm sinal positivo, enquanto os elementos de consumo possuem sinal negativo.


As restrições de igualdade não existem intrinsecamente no problema e, portanto, precisam ser modeladas como penalidades. Existem diversas formas de considerar as restrições de igualdade, desde formas simples e intuitivas a recursos adaptativos (CARVALHO, 2014). Readequando o problema, a penalidade colocada dentro da função objetivo é o somatório das potências. Sendo a restrição obedecida, não interfere no C_{total} . Todavia, se a restrição não for atendida, a função custo vai crescer, não sendo a solução apropriada. A constante m é sempre positiva e maior que um e deve ser da mesma ordem de grandeza do custo do recurso mais oneroso do problema.

$$C_{total} = \min_{\Xi} \left[\sum_i C_i(p_i) + m \cdot \left(\sum_i p_i \right)^2 \right] \quad (3.8)$$

$$P_i^{min} \leq p_i \leq P_i^{max}, \quad \forall i$$

A Figura 37 apresenta os recursos da microrrede utilizados nos estudos de caso do capítulo 4. Entre os recursos representados na microrrede estão fontes despacháveis, cargas com diferentes graus de flexibilidade, sistema de armazenamento e fonte de natureza estocástica. As funções de custo utilizadas no problema de despacho da microrrede, que compõem o C_{total} , são apresentadas nas seções seguintes.

Figura 37 – Recursos energéticos da microrrede simulada



Fonte: elaborada pela autora (2025).

3.4.1 Fontes despacháveis

As duas principais fontes despacháveis são as termelétricas e as hidrelétricas. A modelagem dos custos das hidrelétricas é baseada no custo futuro e no custo imediato da energia,

quando essas unidades possuem reservatório de regulação. Entretanto, centrais geradoras de pequeno porte geralmente operam a fio d'água, portanto, sem capacidade de regulação. Dessa forma, a modelagem dessas usinas pode seguir as das fontes de natureza estocástica. Já a modelagem do custo associado aos recursos térmicos é amplamente utilizada na literatura como uma função quadrática (CONEJO; BARINGO, 2018; WOOD *et al.*, 2013), dada por:

$$C_{term_i}(p_i) = a_i \cdot p_i^2 + b_i \cdot p_i + c_i \quad (3.9)$$

em que p_i é a potência fornecida pela fonte e a_i , b_i e c_i são os coeficientes atribuídos a cada fonte i . O custo fixo é representado por c_i , enquanto b_i e a_i representam os custos linear e quadrático, respectivamente, em função da potência fornecida. A potência máxima que essa fonte pode assumir é a potência nominal e a potência mínima vai depender do recurso utilizado. Para um recurso totalmente flexível, a menor potência seria zero, entretanto, há recursos com um certo grau de inflexibilidade que deve ser considerado para estabelecer os limites de operação.

Essa equação pode ser modelada para valores por unidade, sendo necessário a adequação dos coeficientes, utilizando valores de base para o custo, $Custo_{i,base}$, e para a potência da fonte, $P_{i,base}$. Dessa forma, os coeficientes originais são modificados por:


$$\begin{aligned} a_{i,pu} &= a_i \cdot \frac{P_{i,base}^2}{Custo_{i,base}} \\ b_{i,pu} &= b_i \cdot \frac{P_{i,base}}{Custo_{i,base}} \\ c_{i,pu} &= c_i \cdot \frac{1}{Custo_{i,base}} \end{aligned} \quad (3.10)$$

em que o somatório dos coeficientes, $a_{i,pu}$, $b_{i,pu}$ e $c_{i,pu}$, deve ser igual a 1.

A Figura 38 mostra as funções objetivo para 3 diferentes fontes com os coeficientes em por unidade. As bases de potência e custo utilizadas para cada uma das curvas são as bases de cada unidade para que se possa comparar apenas a influência dos coeficientes. Entretanto, quando as funções estiverem sendo somadas formando a função C_{total} , uma base única deve ser utilizada para todos os recursos energéticos.

Observa-se que cada fonte possui custo fixo diferente, variando entre 1,5% e 30%. A curva na cor preta tem uma característica predominante linear, já a curva na cor verde tem a maior parcela quadrática do exemplo apresentado.

Figura 38 – Análise de sensibilidade da função custo das fontes despacháveis às variações nos coeficientes normalizados



Fonte: elaborada pela autora (2025).

3.4.2 Cargas

A função objetivo, essencial para a gestão de cargas, é uma função de utilidade, também conhecida como bem-estar social (*social welfare*, em inglês). Esta função estabelece o limite de benefício que um consumidor pode obter ao utilizar energia, levando em consideração um custo associado. Quando otimizada, a função de utilidade deve ser maximizada. Isso resulta no benefício máximo para o consumidor, conforme ilustrado na Figura 39a. A formulação matemática, apresentada a seguir, é comumente adotada na literatura (ALI *et al.*, 2019; NIROMANDFAM *et al.*, 2020):

$$Utilidade_i(p_i) = \begin{cases} a_i \cdot p_i^2 + b_i \cdot p_i, & \text{se } 0 \leq p_i \leq \frac{-b_i}{2 \cdot a_i} \\ \frac{-b_i^2}{4 \cdot a_i}, & \text{se } p_i > \frac{-b_i}{2 \cdot a_i} \end{cases} \quad (3.11)$$

em que p_i é a potência consumida pela carga, que, por convenção, é sempre maior que zero. Portanto, os coeficientes a_i e b_i devem possuir sinais opostos. Além disso, como se trata de uma função de máximo, o coeficiente a_i deve ser negativo.

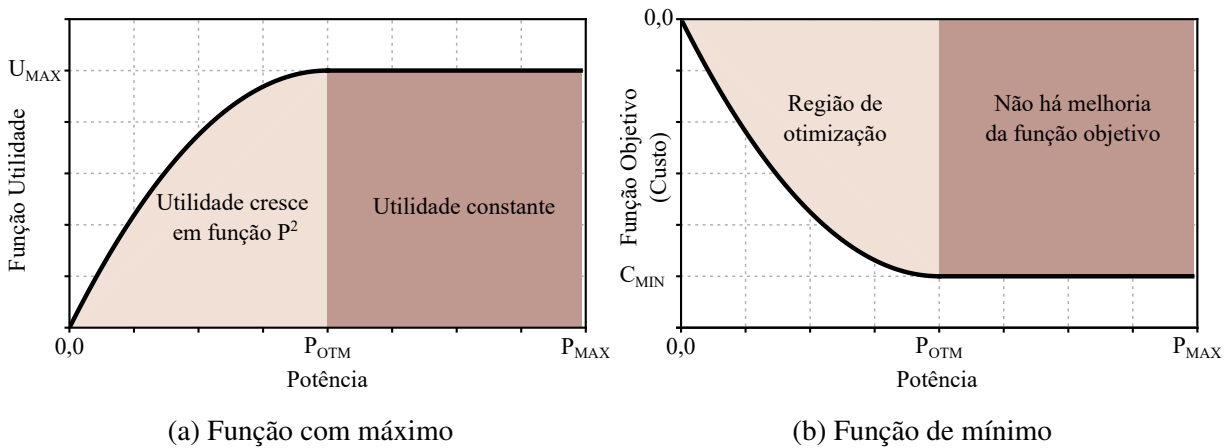
A função quadrática, definida para o primeiro intervalo do domínio, possui o coeficiente independente igual a zero. Isso ocorre porque não existe benefício para o consumidor quando a potência consumida é igual a zero; portanto, faz parte do modelo o ponto (0,0). Para o restante do domínio do modelo, a função é definida como uma constante, como na Figura 39a. Isso indica que, a partir de um determinado valor ótimo de potência consumida, não há mais ganhos em termos de utilidade.

A função custo, que depende da demanda da carga, é uma das parcelas no problema de otimização que busca minimizar o custo total, conforme a Equação 3.7. Essa função de custo deve ser a função de utilidade refletida em relação ao eixo x :

$$C_{load_i}(p_i) = -Utilidade_i \quad (3.12)$$

a representação gráfica da função custo quadrática é apresentada na Figura 39b.

Figura 39 – Função utilidade da carga transformada em função objetivo do problema



Fonte: elaborada pela autora (2025).

Ao considerar a função custo, os coeficientes a_i e b_i têm os sinais invertidos, portanto, para a função objetivo do problema a_i tem sinal positivo. Esses coeficientes também podem ser colocados em pu, como apresentado na equação 3.10. Constata-se que em valores por unidade do próprio recurso, $P_{i,base}$ e $C_{i,base}$, os valores de a_i e b_i são fixos em 1 e -2, respectivamente. Portanto, no valor de potência ótima (1 pu) o custo será mínimo (-1 pu). Observando essas características da modelagem, fica mais fácil determinar níveis de prioridade para as cargas em um cenário de resposta à demanda.

Embora a função quadrática seja muito utilizada, principalmente por sua derivada simples, outra opção é utilizar a função exponencial, dada pela expressão:


$$C_{load_i}(p_i) = K_i \cdot \left(1 - \frac{2}{1 + e^{-\beta_i \cdot p_i}} \right) \quad (3.13)$$

em que K_i altera a amplitude, enquanto o β_i é responsável por alterar o decaimento da função custo da carga i . A lei de formação exponencial tem todo o domínio representado por um único termo. Em métodos de otimização como o PSO, não há necessidade das funções derivadas.

A Figura 40 apresenta o comportamento da função custo mantendo um valor fixo de K_i e variando o coeficiente β_i . Há uma crescente inflexibilidade das cargas à medida que o valor

de β_i cresce. Portanto, a carga mais flexível seria a representada pelo $\beta_i = 1$. Essa modelagem é interessante, pois com apenas um parâmetro é possível definir graus de flexibilidade para cargas. Já alterando o valor de K_i , define-se diferentes níveis de prioridade para as cargas a depender dos valores das fontes disponíveis.

Figura 40 – Função custo da carga modelada por função exponencial



Fonte: elaborada pela autora

Para colocar a função exponencial em valores por unidade, é necessário dividir K_i pelo $Custo_{i,base}$, e o β_i deve ser multiplicado pela potência de base $P_{i,base}$:

$$K_{i,pu} = K_i \cdot \frac{1}{Custo_{i,base}} \quad (3.14)$$

$$\beta_{i,pu} = \beta_i \cdot P_{i,base}$$

com isso, é possível utilizar a potência do recurso i em pu na Equação 3.13.

3.4.3 Sistema de armazenamento de energia

Os armazenadores de energia não possuem uma modelagem unânime de seus custos na literatura, em algumas propostas inclusive têm seus custos desconsiderados (HUO *et al.*, 2022). Sendo as baterias os recursos mais utilizados como armazenadores, diferentes funções objetivo já foram propostas para o despacho econômico ou *unit commitment* de recursos energéticos em microrredes (WANG *et al.*, 2018; WANG *et al.*, 2021; DANESHVAR *et al.*, 2020; ZHANG *et al.*, 2023; PREMKUMAR *et al.*, 2023). Observou-se nesses trabalhos que o mais comum é considerar apenas rendimentos, η_i^{car} e η_i^{des} , e potências, p_i^{car} e p_i^{des} , de carregamento e descarregamento, respectivamente. A seguir é apresentada a forma simplificada da modelagem

dos custos para esses sistemas:

$$C_{bat_i} = \begin{cases} K_i \cdot (\eta_i^{car} \cdot p_i^{car}), & \text{se a bateria estiver em carga} \\ K_i \cdot \left(\frac{1}{\eta_i^{des}} \cdot p_i^{des} \right), & \text{se a bateria estiver em descarga} \end{cases} \quad (3.15)$$

em que K_i é o custo nominal para descarregar o sistema de armazenamento de energia quando o *State of Charge (SoC)* é igual a 1. Os intervalos de tempo considerados nas equações originais foram suprimidos, pois neste trabalho a análise é realizada para um único intervalo.

A Equação 3.15 não considera o *SoC* do armazenador na definição dos custos, apenas limita as potências p_i^{car} e p_i^{des} . Considerar o estado da carga nos custos é importante para que o recurso esteja disponível quando os custos dos recursos disponíveis forem muito altos. Outra observação é que ambas as potências são consideradas positivas, portanto, o custo também sempre será positivo, seja no modo de carga ou de descarga do sistema. Essa equação pode ser simplificada ao considerar os rendimentos η_i^{car} e η_i^{des} iguais, bem como ao considerar os sinais positivo e negativo para a potência, durante a descarga e a carga da bateria, respectivamente:

$$C_{bat_i}(p_i) = K_i \cdot \left(\text{sign}(p_i) \cdot p_i \cdot \eta_i^{-\text{sign}(p_i)} \right), \quad (3.16)$$

em que $\text{sign}(p_i)$ é o sinal da potência no sistema de armazenamento, positivo para entrega de energia e negativo para o consumo. Os limites operativos são determinados através do *SoC*, conforme:

$$\left(\frac{soc - soc_{max}}{soc_{max} - soc_{min}} \right) \cdot P_i^{car,max} \leq p_i \leq \left(\frac{soc - soc_{min}}{soc_{max} - soc_{min}} \right) \cdot P_i^{des,max}, \quad (3.17)$$


em que soc , soc_{max} e soc_{min} são, respectivamente, o estado da carga atual, os valores máximo e mínimos admissíveis pelo sistema de armazenamento para o *SoC*. Já $P_i^{des,max}$ e $P_i^{car,max}$ são as potências máximas admissíveis para o descarregamento e carregamento do sistema.

A Figura 41 mostra como o custo no uso da bateria é indiferente ao estado de carregamento, variando apenas os limites de operação. Para a construção do gráfico dessa figura, foram considerados $soc_{min} = 0,2$ e $soc_{max} = 1$, além de considerar $P_i^{des,max} = P_i^{car,max}$.

Nota-se que com o menor valor de estado da carga, somente é permitido o carregamento, enquanto para o valor máximo, apenas a descarga é permitida. Nos valores intermediários, tanto a carga quanto a descarga das baterias são permitidas, mas com limites diferentes para cada uma.

Para um melhor gerenciamento dos recursos de armazenamento de energia, no qual, à medida que o recurso fica mais escasso, maior é o seu custo, optou-se por utilizar a modelagem

Figura 41 – Função custo do sistema de armazenamento de energia para diferentes valores de SoC e comparação entre dois rendimentos



Fonte: elaborada pela autora (2025).

proposta por Azevedo (2016). Neste modelo, além dos custos do sistema de armazenamento independerm da tecnologia, são consideradas diferentes faixas de custos com a variação do SoC :

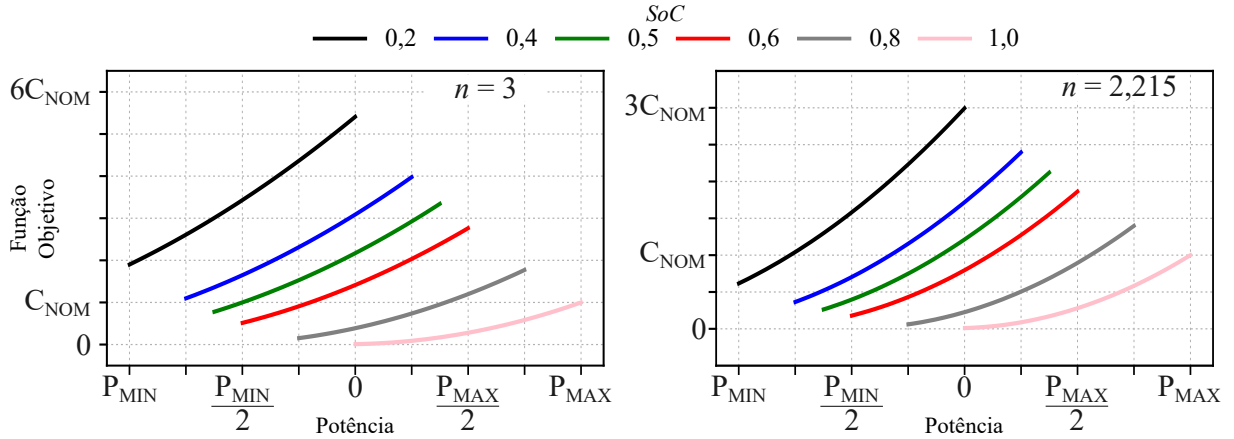
$$C_{sa_i}(p_i) = a_i \cdot [p_i + n \cdot P_i^{max} \cdot (1 - soc_i)]^2 + b_i \cdot [p_i + n \cdot P_i^{max} \cdot (1 - soc_i)] + c_i, \quad (3.18)$$

em que C_{sa_i} é o custo para o sistema de armazenamento i para uma potência entregue igual a p_i . O estado da carga atual é soc_i e P_i^{max} é a potência máxima de descarregamento nominal, portanto, a limitação deve ocorrer da mesma forma que na Equação 3.17. Os coeficientes a_i , b_i e c_i têm as mesmas funções dos coeficientes apresentados para os outros recursos. Colocando a equação em por unidade, além das considerações realizadas nas Equações 3.10 é necessário dividir P_i^{max} pela potência de base considerada.

Na modelagem desenvolvida por Azevedo (2016), o valor de n é igual a 3. Entretanto, ao avaliar a função para os coeficientes escolhidos, como pode ser visto na Figura 42, o custo para carregar a bateria ficaria elevado mesmo na condição de menor SoC . Optou-se, então, por

reduzir o valor de n para que o custo máximo de carregamento seja, no máximo, igual a 3 vezes o custo nominal, C_{NOM} . O valor obtido para as condições descritas foi de 2,215.

Figura 42 – Função custo quadrática do sistema de armazenamento de energia para diferentes valores de SoC e valores de n .



Fonte: elaborada pela autora (2025).

Nota: Os coeficiente $a_{i,pu}$, $b_{i,pu}$ e $c_{i,pu}$ considerados na geração das figuras foi 0,9, 0,09 e 0,01.

3.4.4 Fontes não despacháveis

São consideradas fontes não despacháveis a eólica, a fotovoltaica e pequenas hidrelétricas sem capacidade de regulação. Nenhum desses recursos primários tem custo variável associado aos combustíveis, nem sua utilização afeta de forma significativa a vida útil desses equipamentos, como ocorre com as baterias em função da quantidade de ciclos de carga e descarga.

Dessa forma, não utilizar esses recursos quando estão disponíveis é um contrassenso às necessidades ambientais do planeta, pois, ao maximizar o uso de fontes renováveis, reduz-se a dependência de fontes não renováveis e ajuda a mitigar os impactos ambientais.

Nos problemas de despacho para a redução do custo total, como o realizado neste trabalho, é praticável a utilização de custo zero para essas fontes não despacháveis. Entretanto, para a segurança sistêmica, é necessário conhecer a previsão dessas fontes, que são também de natureza estocástica, e considerá-las na restrição de balanço de potência.

3.4.5 Reserva operativa

Como o despacho dos recursos é realizado a cada 5 minutos e as previsões de curto prazo, em geral, têm um erro menor que 5%, a reserva operativa foi considerada como um erro de 3% dos sistemas de previsão para a geração fotovoltaica e para a carga, sendo sempre considerado erro na escassez dos recursos. Portanto, a reserva de potência operativa de elevação da microrrede $RPOe_{MR}$ é dada por:

$$RPOe_{MR} = 3\% \cdot (P_{carga}^{pre} + P_{nd}^{pre}), \quad (3.19)$$

em que P_{carga}^{pre} e P_{nd}^{pre} são a previsão total da carga e dos recursos não despacháveis, respectivamente.

Dessa forma, os agentes que rodam suas previsões, quando enviam seus dados para a resolução do algoritmo, já consideram a variação que deve ser destinada à reserva operativa. Então, os agentes do tipo carga e recurso não despachável enviam suas previsões de potência com os valores corrigidos:

$$\begin{aligned} P_{carga} &= 1,03 \cdot P_{carga}^{pre}, \\ P_{nd} &= 0,97 \cdot P_{nd}^{pre}. \end{aligned} \quad (3.20)$$

3.5 Considerações finais

Este capítulo apresentou as ferramentas e os métodos utilizados para a otimização de microrredes. Além dos recursos de co-simulação empregados na implementação do paralelismo de meta-heurísticas, destacou-se como são realizadas as etapas de troca de mensagens, competição e cooperação entre os agentes equipamentos que formam uma microrrede.

Por fim, as funções objetivo de cada um dos agentes foram detalhadas e analisadas, tornando factível a parametrização dos recursos que serão utilizados nos estudos de caso apresentados no próximo capítulo.

4 RESULTADOS E DISCUSSÃO

Neste capítulo, serão apresentados e discutidos os resultados da aplicação dos métodos e ferramentas abordados no capítulo anterior para o gerenciamento de uma microrrede de energia elétrica. Diante de um mercado de energia elétrica cada vez mais aberto, a otimização realizada aqui pode ser considerada em duas perspectivas de funcionamento. A primeira seria uma microrrede ilhada da rede elétrica principal, formando redes independentes semelhantes às comunidades de energia renovável da União Europeia. A segunda perspectiva da otimização implementada seria uma microrrede conectada e dispersa, em que os recursos, tanto cargas quanto geradores e armazenadores, estão submetidos a um comercializador varejista, com contratos de intercâmbio zero com a distribuidora, de forma semelhante a uma *Virtual Power Plant*.

Como apresentado na Figura 37 da seção 3.4, os recursos utilizados no estudo de caso deste trabalho são: gerador fotovoltaico, dois geradores térmicos, acionados pela queima de gás e de biomassa, sistema de armazenamento por baterias e cargas elétricas com diferentes níveis de prioridade para a participação de programas de resposta à demanda.

O estudo de caso envolve a representação de uma microrrede em média tensão, de 13,8 kV. Dessa forma, o dimensionamento dos recursos foi realizado com base na resolução nº 1000 de 2021, na qual centrais geradoras com potência instalada superior a 75 kW e menor que 30 MW são instaladas nesse nível de tensão, exceto se sua conexão afetar a confiabilidade e a segurança operativa do sistema (ANEEL, 2021).

O despacho realizado nos estudos de caso a seguir desconsidera as perdas elétricas; portanto, não foi realizado o estudo de fluxo de potência com as limitações da rede em consideração. Essas implementações são sugeridas como trabalhos futuros. Neste trabalho, o objetivo é otimizar o despacho de energia ativa para um sistema de pequeno porte com recursos reduzidos; portanto, caso seja necessário devido aos custos ou à indisponibilidade de recursos, deve haver corte na carga atendida.

4.1 Implementação do sistema

Todos os códigos foram desenvolvidos em *Python* versão 3.8.18, que é compatível com a versão mais estável do Pade. A versão 3.1.1 do Mosaik foi utilizada no desenvolvimento.

Nenhuma biblioteca ou pacote adicional foi necessário para a implementação dos códigos das meta-heurísticas. Devido à distribuição do algoritmo, a inicialização das variáveis e a

etapa iterativa são realizadas separadamente, em passos distintos no Mosaik. Os pseudo-códigos dessas etapas para o PSO encontram-se no apêndice A, apresentados nos Algoritmos 7 e 8.

4.2 Parametrização dos recursos

As fontes térmicas escolhidas são baseadas em biomassa e em gás natural para diferenciar os custos relacionados e, conseqüentemente, proporcionar maior flexibilidade à microrrede. Os coeficientes das equações de custo são determinados em por unidade para os valores nominais do recurso. Além disso, optou-se por estabelecer um custo mínimo de 10% para cada uma das parcelas desses recursos.

Dessa forma, os custos fixo, linear e quadrático da energia da biomassa foram de 10%, 80% e 10%, respectivamente. Já para a geração baseada em gás natural, os coeficientes foram de 10%, 40% e 50%. Uma parcela maior de custo linear foi atribuída à fonte de biomassa devido ao processamento realizado antes da queima desse combustível, que é proporcional à quantidade e qualidade dos recursos. Já para o gás natural, o custo quadrático foi 10% superior ao linear. A escolha foi baseada nos riscos associados a essas fontes, como desabastecimento e/ou variações em mercados internacionais que afetam o preço interno desse insumo.

Diversos documentos foram analisados para estabelecer parâmetros aceitáveis de custo nominal da fonte, potência nominal e valor de inflexibilidade, na mesma ordem de grandeza das fontes escolhidas para o estudo de caso. Entre os documentos avaliados estão o PMO, que divulga o CVU, e o relatório de disponibilidade de usinas térmicas, sempre considerando unidades de geração com o mesmo tipo de combustível. Os documentos utilizados são do mês de novembro de 2024 e foram disponibilizados pelo ONS na seção de dados abertos dessa instituição (ONS, 2024a; ONS, 2024b).

Os sistemas de armazenamento a baterias, que são mais compatíveis com os sistemas de distribuição e, conseqüentemente, com as microrredes, têm sua vida útil limitada pelo número de ciclos de carga e descarga, bem como pelas altas temperaturas, que, por sua vez, estão relacionadas à corrente de operação. Por isso, a maior parte do custo está associada ao custo quadrático, atribuído o valor do coeficiente de 90%. Outra particularidade desses sistemas é sua característica nominal, que é expressa em capacidade (Ah ou MWh). A limitação de potência também é determinada pelos fabricantes em função dessa capacidade. Enquanto para o carregamento o valor típico de carga é 20% da capacidade nominal, a descarga pode chegar a 50%.

Portanto, o dimensionamento foi realizado de modo que a potência máxima de descarga fosse de até 30 MW, resultando em uma capacidade de 60 MWh. O custo nominal considerado para esse recurso foi de 10% superior ao custo do gás natural. Como no Brasil ainda não existem valores típicos de remuneração para armazenadores, e com o intuito de remunerar esse recurso em função de sua flexibilidade, esse valor foi adotado.

As cargas são modeladas em função de sua utilidade, como discutido na seção 3.4.2, os coeficientes da sua função objetivo, em pu, têm os valores de 1 e -2. Os valores reais são obtidos em função da potência nominal e do custo nominal, que no caso das cargas é um custo hipotético de não atendimento da demanda. Esse valor pode variar em função da importância de atendimento da carga. Para cargas prioritárias, esse custo nominal deve ser muito maior que o custo dos outros recursos, enquanto que para cargas mais flexíveis esse valor pode variar em função da disponibilidade de oferecer recursos de resposta à demanda.

A Tabela 4 apresenta resumidamente os parâmetros adotados para as simulações. Os coeficientes são fornecidos em pu, com base nos valores do próprio equipamento. Para construir a função objetivo em pu, é necessário converter esses coeficientes para uma única base. Além disso, os valores máximos dos recursos variáveis são dados pelas curvas apresentadas nas Figuras 43a e 43b, que indicam os valores para cada instante dos 288 intervalos de otimização simulados ao longo de um dia.

Tabela 4 – Estabelecimentos dos parâmetros das funções objetivo de cada recurso da microrrede

Recurso energético	P_{nom} [MW]	P_{min} [MW]	P_{max} [MW]	a_i [pu]	b_i [pu]	c_i [pu]	Custo energia [\$/MWh]	Custo capacidade [\$/MW]
Carga prioritária	20	0	P_{CP}	1	-2	0	375	31,25
Carga flexível	30	0	P_{CF}	1	-2	0	250	20,83
Térmica a gás natural	25	0	25	0,5	0,4	0,1	250	20,83
Térmica a biomassa	20	2	20	0,1	0,8	0,1	115	9,58
Armazenamento ^a	60h	-12	30	0,9	0,09	0,01	275	22,92
Sistema fotovoltaico	30	0	P_{FV}	0	0	0	0	0


Fonte: elaborada pela autora (2025).

Nota: ^a A capacidade do sistema de armazenamento de 60MWh.

Os custos nominais para as fontes térmicas foram escolhidos com base em custos reais dessas fontes. Os custos dos outros recursos foram determinados com base na razoabilidade e são apresentados na Tabela 4. Os valores estão em MWh, e para serem utilizados na transformação de base devem estar em \$/MW. Para essa transformação, foi calculada a energia do recurso consumida ou produzida no intervalo de despacho, 5 minutos, com os recursos operando

em seus valores nominais.

Figura 43 – Estimativas de previsão dos recursos variáveis.



Fonte: elaborada pela autora (2025).

A Tabela 5 apresenta os valores dos coeficientes calculados em valores reais. A importância de apresentar primeiro esses valores em unidades pu (pu) e, somente depois, transformá-los, é garantir que a escolha desses parâmetros durante a modelagem seja feita de forma consciente e adequada aos objetivos desejados.

Tabela 5 – Parâmetros das funções objetivo em unidades padrões

Recurso energético	a_i [\$/ MW^2]	b_i [\$/ MW]	c_i [\$]
Cargas prioritárias	0,07813	-3,12500	0
Cargas flexíveis	0,02315	-1,38889	0
Térmica a gás natural	0,01667	0,33334	2,08334
Térmica a biomassa	0,00240	0,38334	0,95834
Armazenamento	0,02292	0,06875	0,22917

Fonte: elaborada pela autor(2024).

4.3 Convergência das variáveis em meta-heurísticas distribuídas

A primeira análise realizada consiste em avaliar se as meta-heurísticas distribuídas, ao final do número de iterações, convergem para o mesmo valor para cada uma das variáveis do problema. O parâmetro alterado nas simulações para avaliar essa característica é o número de etapas de competição e cooperação que devem ocorrer entre os agentes do SMA.

A primeira simulação foi realizada com troca de mensagens a cada iteração. Foram realizadas outras simulações com a comunicação entre os agentes ocorrendo a cada 5, 10, 25, 50 e 100 iterações da meta-heurística. Todas as simulações foram realizadas para 500 iterações no total. Portanto, no último teste, ocorreram apenas 5 etapas de competição e cooperação.

Além disso, foram consideradas três simulações distribuídas diferentes para cada estudo de caso. A Tabela 6 mostra as duas primeiras simulações com meta-heurísticas adotadas iguais para todos os agentes. Enquanto a última simulação distribuída estabeleceu que os *AgCP*, *AgCF* e *AgBT* executassem o PSO e os outros agentes, o algoritmo MAPSO. Os parâmetros considerados para todas as meta-heurísticas são apresentados na Tabela 7.

Tabela 6 – Meta-heurística executada por cada agente nos três simulações distribuídas implementadas.

	Simulação distribuída 1	Simulação distribuída 2	Simulação distribuída 3
<i>AgCP</i>	PSO	MAPSO	PSO
<i>AgCF</i>	PSO	MAPSO	PSO
<i>AgTG</i>	PSO	MAPSO	MAPSO
<i>AgTB</i>	PSO	MAPSO	MAPSO
<i>AgBT</i>	PSO	MAPSO	PSO
<i>AgFV</i>	PSO	MAPSO	MAPSO

Fonte: elaborada pela autora (2025).

Tabela 7 – Parâmetros do PSO e MAPSO

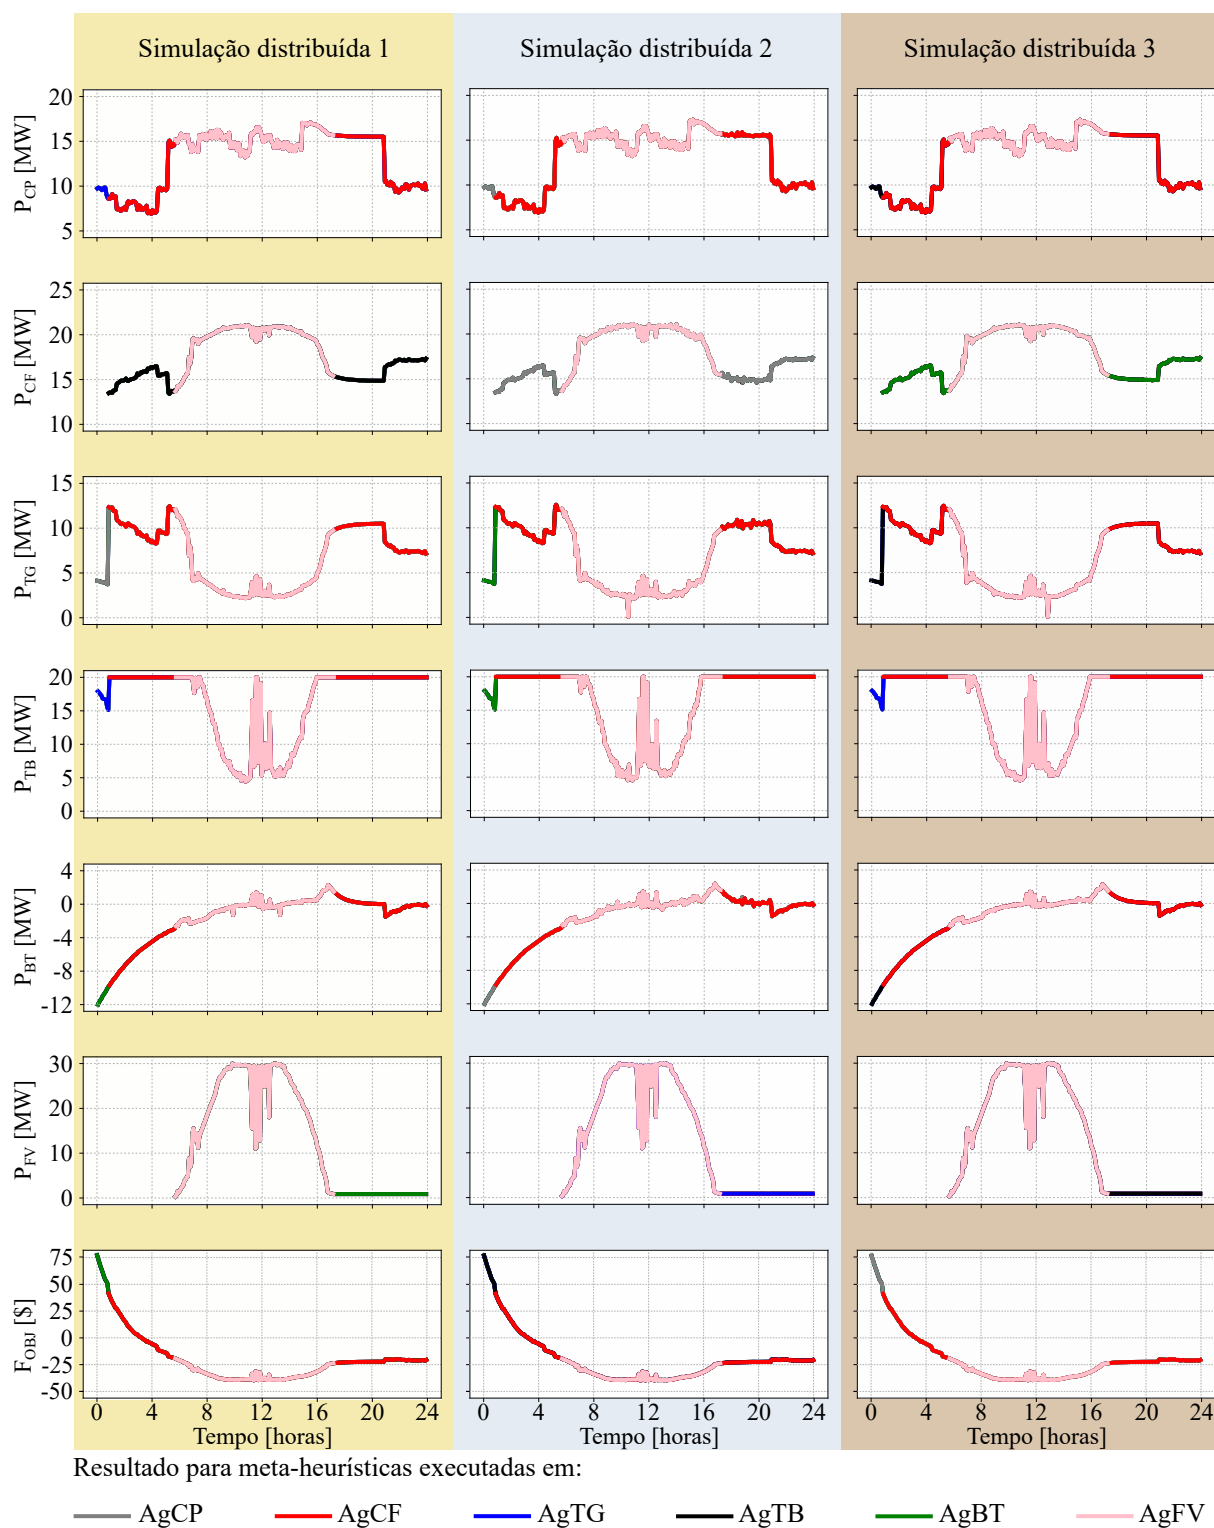
Parâmetro	Valor	Parâmetro	Valor
Número de partículas	25	Multiplicador penalidade ^b	500
Número de iterações	500	C_{base} [\$]	1000
Coefficiente <i>explotation</i> ^a	2	P_{base} [MW]	100
Coefficiente <i>exploration</i> ^a	2		

Fonte: elaborada pela autora (2025).

Nota: ^aEquação 3.3. ^bEquação 3.8.

A simulação foi realizada para um dia completo. Para cada um dos 288 intervalos de despacho simulados, foram consideradas as variações na previsão de carga e de geração fotovoltaica. O sistema de armazenamento foi considerado inicialmente com *SoC* no seu valor mínimo de 20%. Outras considerações foram entrada e saída de agentes ao longo do dia. O *AgCF* inicia sua participação no décimo intervalo de otimização, permanecendo até o final do dia. Já o *AgFV* entra na otimização no intervalo correspondente ao horário de 05h40min, permanecendo até às 17h10min, participando de 138 intervalos de otimização.

Figura 44 – Convergência entre meta-heurísticas distribuídas com troca de mensagens a cada iteração.



Fonte: elaborada pela autora (2025).

As Figuras 44 e 45 apresentam graficamente os resultados para cada uma das variáveis otimizadas, bem como da função objetivo para o caso de maior e menor troca de mensagens,

respectivamente. As figuras são estruturadas da mesma forma, cada coluna de gráficos apresenta os resultados para os diferentes paralelismos adotados. E cada linha de gráficos mostra as saídas das variáveis ao final do número de iteração, para cada intervalo de 5 minutos durante um dia.

Na apresentação dos resultados, cada linha é o resultado de uma das meta-heurísticas executadas durante a simulação. A Figura 44 mostra uma convergência visualmente perfeita para as três simulações realizadas. Já pela Figura 45, é possível notar que há diferença nos valores finais de saída de cada meta-heurística, embora note-se pequenas amplitudes de variação.

As variações ocorreram mais significativamente entre os períodos de 08h00min e 16h00min, período de maior produção da fonte fotovoltaica, que tem o menor custo e, portanto, alta prioridade de utilização. Essas variações apenas são perceptíveis na Figura 45 em que a etapa de competição e cooperação só ocorre a cada 100 iterações, menor fluxo de troca de mensagens.

Devido à sobreposição das linhas, especialmente na Figura 44, a visualização dos resultados pode ser comprometida. Por isso, as camadas de visualização foram alteradas nas duas figuras de forma aleatória para mostrar que os resultados das seis meta-heurísticas estão representados em cada gráfico. Outras formas de visualizar as sobreposições não foram satisfatórias, pois interfeririam na percepção da convergência analisada.

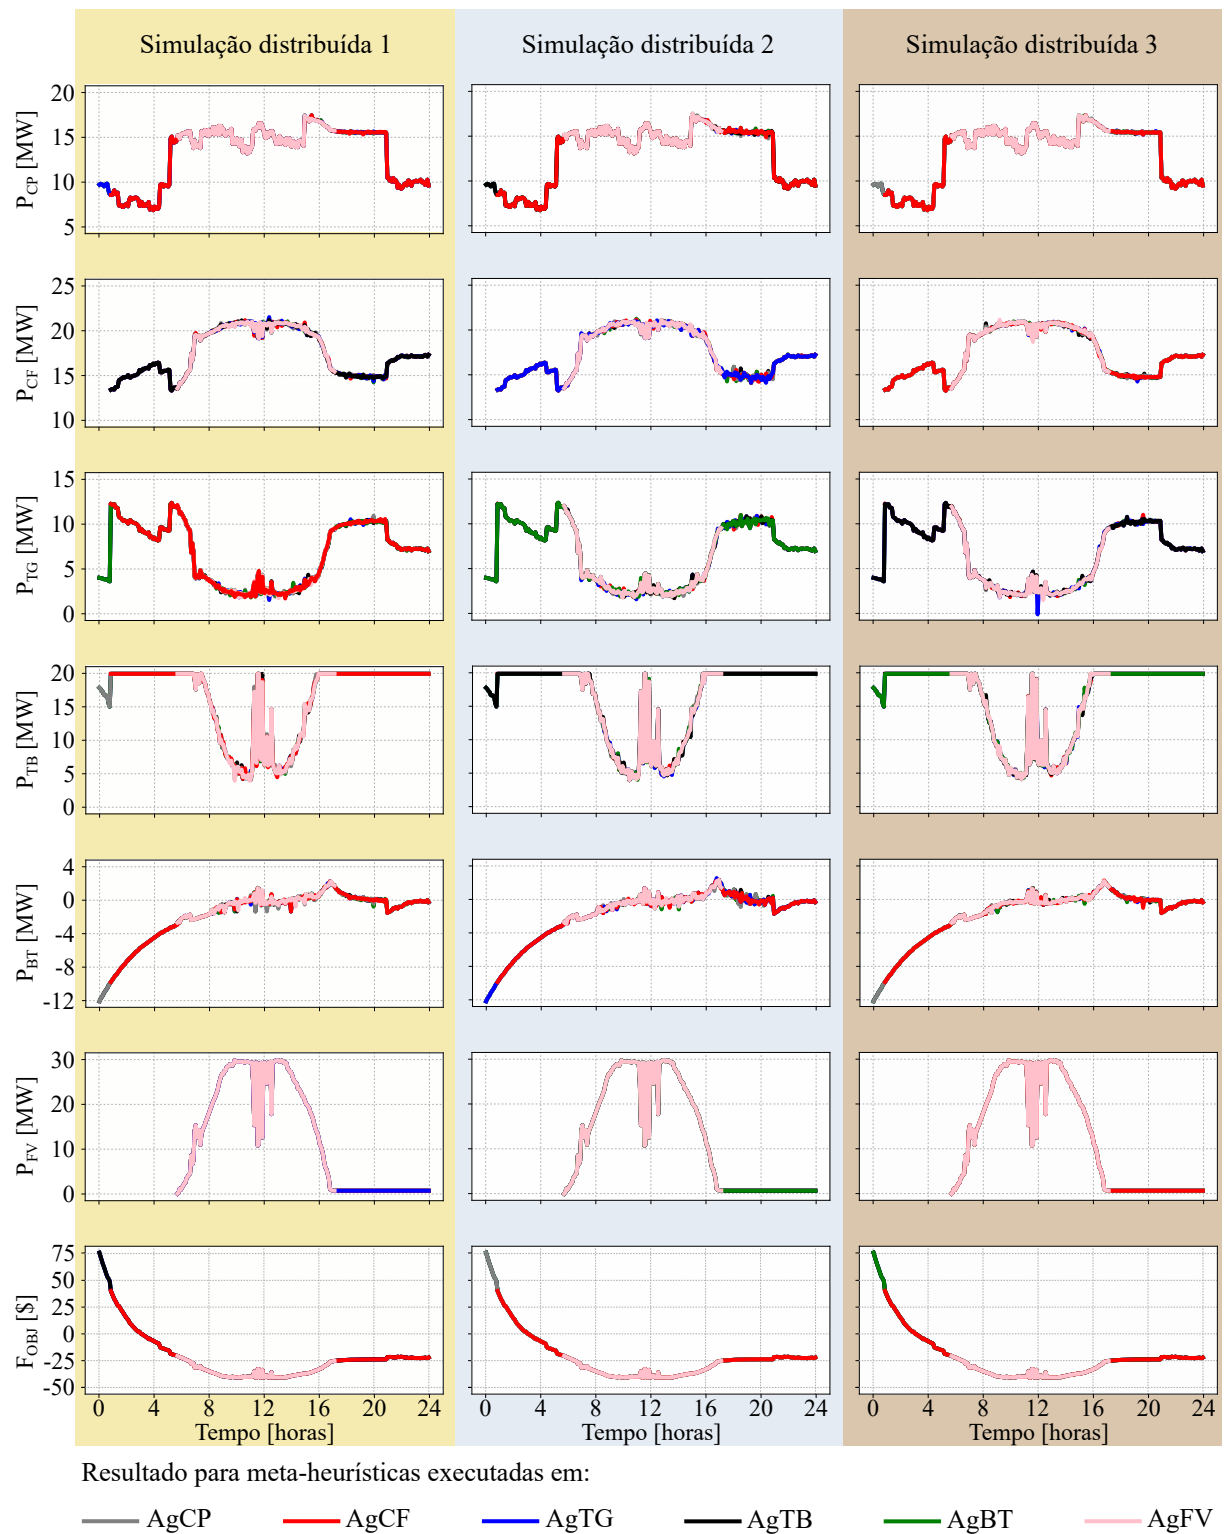
A visualização dos gráficos é interessante, pois permite notar a entrada do *AgCF* e do *AgFV* na otimização, mostrando a ferramenta *plug-and-play* para um sistema que deve operar no curtíssimo prazo. Entretanto, apenas uma avaliação numérica pode qualificar adequadamente as formas implementadas de paralelismo distribuído de meta-heurísticas.

Dessa forma, um dos intervalos de otimização foi destacado como exemplo de avaliação da convergência entre as meta-heurísticas distribuídas. Para esse intervalo, a meta-heurística presente em cada agente retorna valores de potência para cada recurso energético, que são as variáveis de saída da otimização. A avaliação consiste em verificar a variação máxima das variáveis de saída ao final da otimização daquele intervalo.

As Tabelas 8, 9 e 10 mostram o intervalo de otimização correspondente ao horário de 15h25min. Nesse horário, as previsões eram 17,45 MW para a carga prioritária, 27,24 MW para a carga flexível e 17,75 MW de produção de energia fotovoltaica, e o *SoC* do banco de baterias era de 90,94%.

A Tabela 8 mostra o caso em que não há convergência das variáveis, mas a função objetivo converge, mostrando o motivo pelo qual a função objetivo pode convergir e as variáveis não. A Tabela 9 mostra o caso mais provável, quando as variáveis convergem, necessariamente,

Figura 45 – Convergência entre meta-heurísticas distribuídas com troca de mensagens a cada 100 iterações



Fonte: elaborada pela autora (2025).

a função objetivo também vai convergir.

Por fim, a Tabela 10 apresenta o caso em que variáveis e função objetivo não con-

Tabela 8 – Variação máxima das variáveis de saída para simulação distribuída 1 com envio de mensagens a cada 5 iterações

Variável	$AgCP$	$AgCF$	$AgTG$	$AgTB$	$AgBT$	$AgFV$	Δ_{max}
P_{CP} [MW]	17,01	17,01	16,95	17,01	16,95	16,95	0,06
P_{CF} [MW]	19,70	19,70	19,70	19,70	19,70	19,70	0,00
P_{TG} [MW]	3,79	3,79	3,83	3,79	3,83	3,83	0,04
P_{TB} [MW]	16,27	16,27	16,22	16,27	16,22	16,22	0,05
P_{BT} [MW]	0,52	0,52	0,48	0,52	0,48	0,48	0,04
P_{FV} [MW]	17,75	17,75	17,75	17,75	17,75	17,75	0,00
f_{obj} [\$]	-34,976	-34,976	-34,976	-34,976	-34,976	-34,976	0,00

Fonte: elaborada pela autora (2025).

Tabela 9 – Variação máxima das variáveis para simulação distribuída 2 com envio de mensagens a cada 5 iterações.

Variável	$AgCP$	$AgCF$	$AgTG$	$AgTB$	$AgBT$	$AgFV$	Δ_{max}
P_{CP} [MW]	17,07	17,07	17,07	17,07	17,07	17,07	0,00
P_{CF} [MW]	20,12	20,12	20,12	20,12	20,12	20,12	0,00
P_{TG} [MW]	3,88	3,88	3,88	3,88	3,88	3,80	0,00
P_{TB} [MW]	16,78	16,78	16,78	16,78	16,78	16,78	0,00
P_{BT} [MW]	0,44	0,44	0,44	0,44	0,44	0,44	0,00
P_{FV} [MW]	17,75	17,75	17,75	17,75	17,75	17,75	0,00
f_{obj} [\$]	-34,904	-34,904	-34,904	-34,904	-34,904	-34,904	0,00

Fonte: elaborada pela autora (2025).

vergem. A construção das tabelas levou em consideração um arredondamento de quatro casas decimais para as variáveis e 6 casas decimais para a função objetivo. Além disso, os valores em MW e \$ foram obtidos dos valores em pu depois do arredondamento. A questão de arredondamentos influenciou os resultados, que serão tratados novamente após os ajustes dos modelos nas seções seguintes. Nas próximas avaliações, não serão considerados arredondamentos, exceto aqueles realizados automaticamente pelo Python ao armazenar os dados, que retornam valores com até 17 casas decimais.

Tabela 10 – Variação máxima das variáveis para simulação distribuída 3 com envio de mensagens a cada 5 iterações.

Variável	$AgCP$	$AgCF$	$AgTG$	$AgTB$	$AgBT$	$AgFV$	Δ_{max}
P_{CP} [MW]	16,92	16,94	16,95	16,94	16,94	16,94	0,03
P_{CF} [MW]	19,89	19,91	19,91	19,91	19,91	19,91	0,02
P_{TG} [MW]	4,13	4,13	4,13	4,13	4,13	4,13	0,00
P_{TB} [MW]	16,59	16,68	16,68	16,68	16,68	16,68	0,07
P_{BT} [MW]	0,35	0,31	0,31	0,31	0,31	0,31	0,04
P_{FV} [MW]	17,75	17,75	17,75	17,75	17,75	17,75	0,00
f_{obj} [\$]	-34,971	-34,970	-34,970	-34,970	-34,970	-34,970	0,001

Fonte: elaborada pela autora (2025).

A Tabela 11 apresenta os resultados para todos os casos simulados, inclusive os que não foram apresentados graficamente, simplesmente porque não apresentam mudanças significativas em relação aos resultados apresentados nas Figuras 44 e 45.

Tabela 11 – Convergência das variáveis de saída e da função objetivo total para os 288 intervalos de otimização.

Número de it para cada CC ^a	Simulação distribuída 1			Simulação distribuída 2			Simulação distribuída 3		
	var	f_{obj}	Δ_{max}	var	f_{obj}	Δ_{max}	var	f_{obj}	Δ_{max}
1	280	286	0,04 MW	276	284	0,90 MW	275	287	0,04 MW
5	238	284	0,24 MW	237	277	0,87 MW	244	284	0,19 MW
10	199	280	0,46 MW	215	259	1,42 MW	201	286	0,22 MW
25	119	267	0,89 MW	167	225	1,52 MW	148	276	0,53 MW
50	88	230	0,89 MW	135	201	1,30 MW	107	245	2,08 MW
100	65	154	2,34 MW	103	144	2,06 MW	80	164	2,50 MW

Fonte: elaborada pela autora (2025).

Nota: ^a Etapa de competição e cooperação.

A primeira coluna da Tabela 11 apresenta a frequência com que a etapa de competição e cooperação deve ocorrer em função do número de iterações. A primeira linha dessa tabela mostra os resultados das simulações representados nos gráficos da Figura 44. Já a última linha corresponde aos valores obtidos para as simulações da Figura 45.

Para cada paralelismo, foram colocadas três colunas. A coluna identificada como “var” indica em quantos intervalos do dia todas as variáveis de saída convergiram entre as meta-heurísticas em paralelo. Isso significa que o intervalo não é contabilizado, se pelo menos uma das variáveis de saída tiver valores diferentes ao final do intervalo de otimização em duas ou mais meta-heurísticas em execução. A coluna f_{obj} também apresenta a convergência, mas observando o valor final da função objetivo. Por fim, a coluna Δ_{max} mostra a máxima variação absoluta para qualquer uma das variáveis de saída em qualquer um dos intervalos em que não houve convergência.

A menor interação entre os agentes, devido à redução no fluxo de troca de mensagens, resulta em uma queda no sincronismo das variáveis. Esse sincronismo é importante para a otimização distribuída, garantindo que, ao final do período de otimização, cada agente tenha o valor de potência correto para seu próprio despacho.

Observando os resultados de um dia de simulação, a simulação distribuída 1 com troca de informações a cada iteração apresenta o melhor desempenho, pois todas as variáveis convergiram em 280 dos 288 intervalos simulados. Apresentou também a menor variação entre

as variáveis de saída, que corresponde a apenas 0,2% da potência nominal do menor dos recursos.


Destaca-se que, nessa primeira avaliação, não se está verificando a performance do algoritmo em obter a melhor solução, mas sim observando a característica distribuída da implementação para a aplicação proposta.

Essa análise enfatizou a possibilidade do paralelismo de meta-heurísticas para um despacho de forma distribuída. Observou-se que pode ser utilizado, mas deve-se garantir que a variação entre as variáveis de saída dos participantes seja reduzida. Variações nos parâmetros dos algoritmos, como o aumento do número de partículas ou coeficientes característicos diferentes entre as meta-heurísticas em paralelo, podem ser realizadas de forma a obter menores variações com uma menor frequência de troca de mensagens.

4.3.1 Análise das respostas de saída

O dia simulado nessa seção tem as saídas apresentadas nas Figuras 44 e 45. Para os modelos e métodos utilizados, as saídas observadas são de uma resposta ótima ou próxima da ótima, já que a otimização é realizada por meta-heurística. Entretanto, o interesse de manter a carga prioritária totalmente atendida não é atendido. Percebe-se que há corte de carga tanto para a carga flexível quanto para a carga prioritária, como pode ser observado na Figura 46.

Figura 46 – Corte de carga




Fonte: elaborada pela autora (2025).

Independente do método de paralelismo ou da meta-heurística utilizada, sempre há corte da carga prioritária. Mesmo com o sistema de armazenamento com uma carga entre 80% e 90% para os períodos entre 15h00 e 21h00, em que há corte de carga prioritária mais significativo. A Figura 47 mostra a variação ao longo do dia do *SoC* da bateria. Devido aos resultados obtidos,

uma análise do modelo de carga será realizada na seção 4.4 com o objetivo de eliminar o corte de carga prioritária.

Figura 47 – Valor inicial SoC de 20%



Fonte: elaborada pela autora (2025).

Com essa análise, conclui-se que o custo de não atendimento à carga prioritária não está suficientemente maior em relação ao custo dos outros recursos. Portanto, como se deseja modelar uma carga que deve ser plenamente atendida, tem-se que aumentar o custo de não atendimento da carga e/ou reduzir o custo dos outros recursos, como, por exemplo, a bateria. Na próxima seção, além de ser avaliada a convergência dos algoritmos, outro modelo de carga vai ser analisado.

4.4 Análise probabilística

Nesta seção, os métodos distribuídos são comparados com os métodos implementados centralizadamente, com o objetivo de avaliar seus desempenhos. Além disso, a função objetivo da carga é modificada para avaliar opções de modelagem, de modo que cargas prioritárias sejam completamente atendidas antes de outras cargas. São estabelecidos três casos de estudo: o primeiro altera o modelo da função custo da carga, o segundo faz os ajustes na parametrização de acordo com os resultados do primeiro caso e o terceiro caso altera a parametrização da função custo das baterias para avaliar modificações no comportamento do recurso. Os dados apresentados são resultados de 50 execuções de cada um dos 5 métodos avaliados, sendo dois métodos centralizados (PSO e MAPSO) e três métodos distribuídos.

Entre os métodos distribuídos, há os homogêneos, nos quais todos os agentes executam a mesma meta-heurística (PSO ou MAPSO). Também há o método distribuído heterogêneo,

no qual os agentes executam pelo menos duas meta-heurísticas diferentes. Nos casos simulados nesta seção, foram atribuídos coeficientes cv_1 e cv_2 diferentes para a equação 3.3 nas meta-heurísticas distribuídas. Para os *AgCP*, *AgFV* e *AgBT*, os valores foram iguais a 2,2, e os demais agentes utilizaram valores iguais a 2. Essa variação é uma das vantagens do paralelismo, utilizar parâmetros diferentes que ajudem na busca da melhor solução.

As características iniciais são apresentadas na Tabela 12, com valores das previsões de carga e geração fotovoltaica, bem como o *SoC* inicial e o número de partículas. Para uma comparação mais justa entre as simulações, tentou-se aproximar o número de partículas entre os métodos de execução e as meta-heurísticas. Além disso, foi necessário determinar o número de linhas e colunas do ambiente de partículas do MAPSO. A escolha foi realizada partindo da execução distribuída com 25 partículas por agente. Nos métodos distribuídos que utilizam o MAPSO, o ambiente é construído no plano 5x5.

Tabela 12 – Parâmetros da próximas simulações

Geração fotovoltaica	Carga flexível	Carga prioritária	<i>SoC</i> inicial	Número de Partículas		Troca de mensagens Distribuído
				Centralizado	Distribuído	
18,51 MW	28,14 MW	15,2 MW	50%	156	25/Ag	10 iterações/msg

Fonte: elaborada pela autora (2025).

Os métodos centralizados devem, portanto, ter o número de partículas igual ao total de partículas dos métodos distribuídos, ou seja, o número de agentes multiplicado por 25. Dessa forma, o número de partículas deveria ser 150. Para a construção do ambiente do MAPSO centralizado, utilizou-se a regra definida no Algoritmo 6 no apêndice A, com o intuito de usar o número de linhas e de colunas aproximadamente iguais. Logo, ficou determinado que o MAPSO teria 12 linhas e 13 colunas, resultando em um total de 156 partículas para ambas as meta-heurísticas centralizadas.

4.4.1 Caso 1 - Avaliação do modelo exponencial da carga

Essa simulação foi realizada com a mudança na modelagem das cargas, utilizando a função exponencial apresentada na Equação 3.13. A Tabela 13 apresenta o valor dos parâmetros do modelo. Os valores de $\beta_{i,pu}$ foram escolhidos de forma que, quando colocados na mesma base, tivessem a relação de 5/1, sendo 5 relacionada à carga mais prioritária. Os custos foram os mesmos apresentados anteriormente.


Tabela 13 – Parâmetros do modelo exponencial da carga nos próprios valores de base

Tipo	$K_{i,pu}$	$\beta_{i,pu}$	$Custo_{i,base}$	$P_{i,base}$	K_i	β_i
Carga prioritária	1	1	31,25 \$	20 MW	31,25 \$	0,05 MW ⁻¹
Carga flexível	1	0.3	20,83 \$	30 MW	20,83 \$	0,01 MW ⁻¹

Fonte: elaborada pela autora (2025).

A Figura 48 mostra a evolução da função objetivo durante as 500 iterações executadas. Já a Figura 49 apresenta com mais detalhes as iterações até a 150^a, indicando que, na maioria dos casos, o MAPSO já converge para a melhor solução com menos de 50 iterações. Ambos os algoritmos apresentam soluções que não alcançam o melhor valor possível, com um erro constante até o final da execução. O tempo de execução dos dois algoritmos, embora aparentemente próximos, apresenta um aumento de 21,26% a mais para cada execução do MAPSO em relação ao PSO.

Figura 48 – Resposta após 500 iterações para os algoritmos centralizados




Fonte: elaborada pela autora (2025).

A Figura 50 mostra a convergência das meta-heurísticas em cada agente para os três modelos de paralelismo. A primeira e a segunda colunas apresentam o paralelismo exclusivo do PSO e do MAPSO, respectivamente. A terceira coluna mostra o resultado para algoritmos diferentes em paralelo.

Nos três tipos de paralelismo distribuído, a influência da etapa de competição e cooperação pode ser observada de forma mais significativa no PSO, com diversos degraus de redução de larguras repetidas, mostrando várias reduções na função objetivo a cada 10 iterações, em função da frequência da troca de mensagens entre os agentes.

Figura 49 – Detalhe da convergência da função objetivo para os algoritmos centralizados



Fonte: elaborada pela autora (2025).

Por fim, a Tabela 14 mostra as variáveis de saída obtidas para a melhor solução. Como esperado, não há corte de carga prioritária; entretanto, a carga flexível não é atendida em nenhum percentual, mesmo com a função objetivo apresentando um custo de não atendimento superior ao custo de operação da térmica a biomassa. O modelo adotado para a carga prioritária atende aos requisitos, mas os parâmetros da carga flexível não. Portanto, uma outra abordagem será apresentada para o novo caso.

Tabela 14 – Variáveis de saída da otimização

Variável	Valor
Carga prioritária	15,20 MW
Carga flexível	0
Térmica a gás	1,97 MW
Térmica a biomassa	3.24 MW
Baterias ^a	-7,5 MW
Geração fotovoltaica	18,51 MW

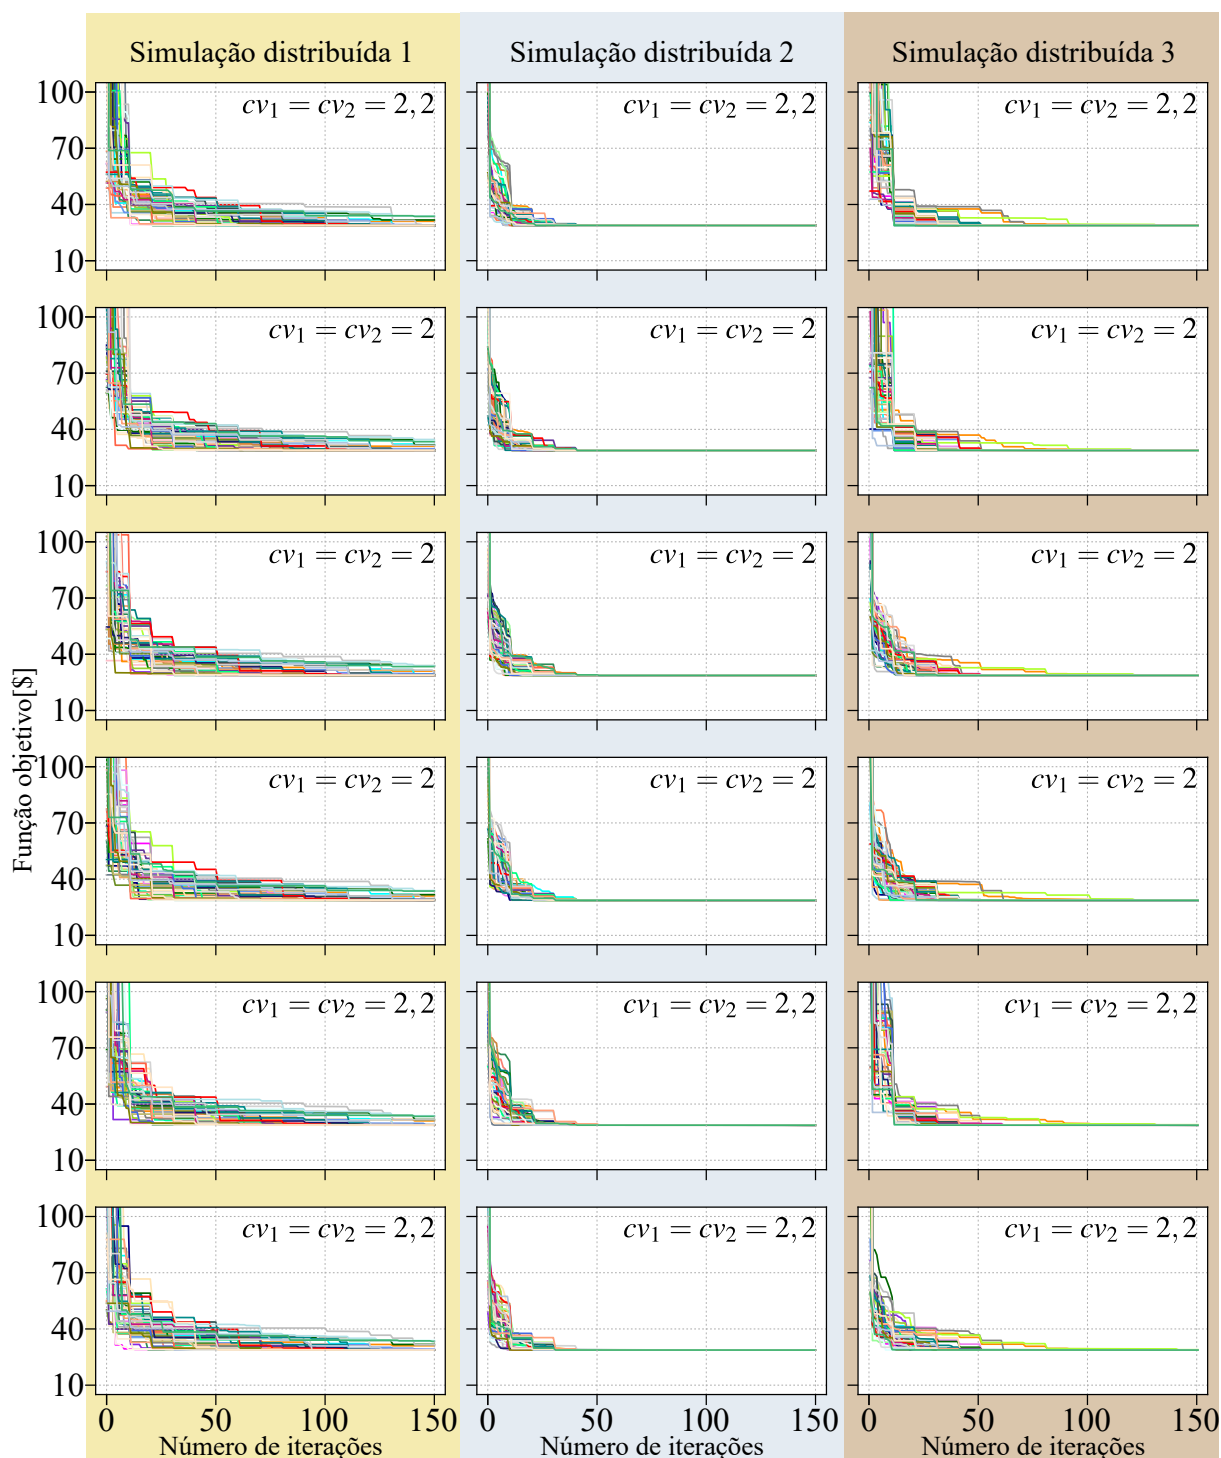
Fonte: elaborada pela autora (2025).

Nota: ^a Bateria em carregamento.

4.4.2 Caso 2 - Adequação da parametrização no modelo exponencial da carga

A mudança realizada nesta simulação alterou apenas o coeficiente $\beta_{i,pu}$ da função exponencial da carga flexível, elevando-o para 1,5 pu. O objetivo dessa alteração é garantir que, ao serem colocadas na mesma base, a carga flexível tenha uma função objetivo com a mesma

Figura 50 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 1




Fonte: elaborada pela autora (2025).

inclinação da carga prioritária, de modo que a prioridade de atendimento seja determinada exclusivamente pelo custo de não atendimento, o qual é maior para as cargas prioritárias.

A Figura 51 mostra o comportamento do PSO e do MAPSO até 150ª iteração, não

foram apresentadas todas as iterações, pois o objetivo é comparar com os métodos distribuídos. O MAPSO novamente apresentou melhor convergência para todas as execuções.

Figura 51 – Convergência da função objetivo para os algoritmos centralizados caso 2



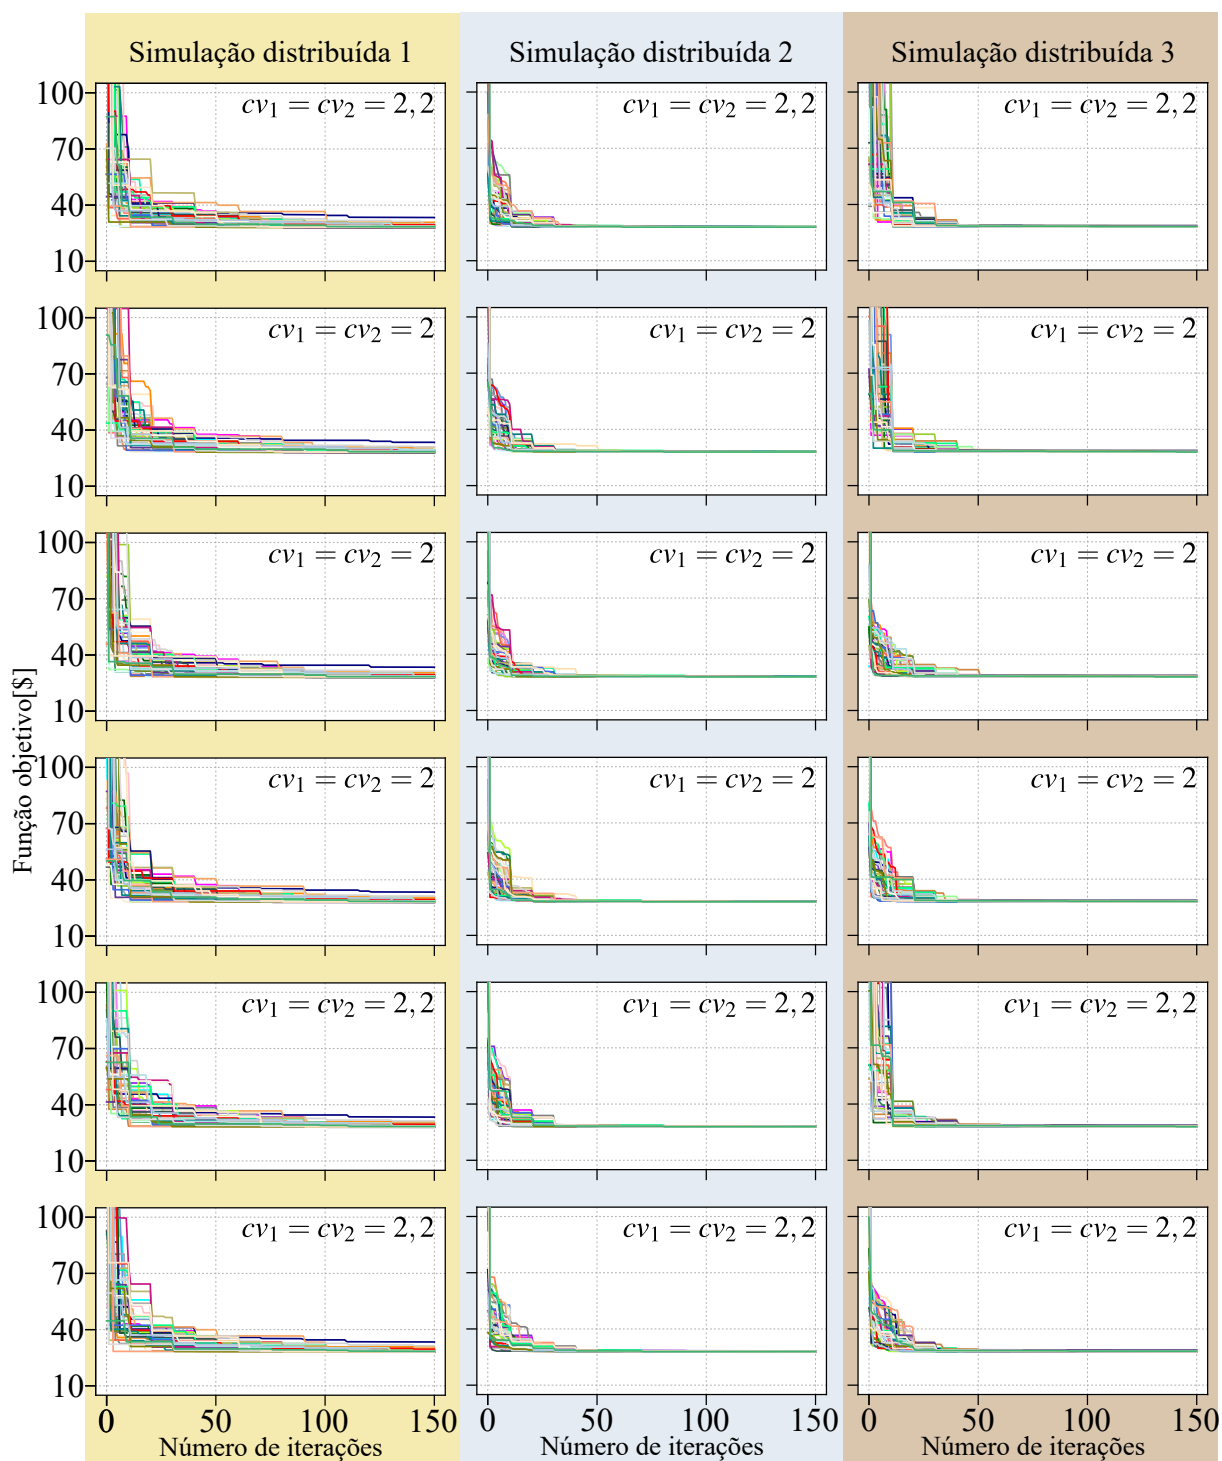
Fonte: elaborada pela autora (2025).

A Figura 52 apresenta a convergência dos algoritmos distribuídos para cada uma das meta-heurísticas aplicadas. Considerando que o número total de partículas na execução centralizada (156) e na distribuída (150) é praticamente igual, o PSO distribuído apresenta um desempenho superior em relação à sua versão centralizada. O MAPSO, mesmo na versão centralizada, mostra um desempenho superior, indicando que o número de trocas de mensagens na versão distribuída pode ser reduzido de forma a garantir a otimização distribuída, mas com um impacto mínimo no resultado final.

A modificação na parametrização do modelo da carga flexível produziu efeito, alcançando o resultado desejado. Assim, é possível ajustar a flexibilidade da carga por meio da modificação de seu valor nominal de custo. Com o aumento desse custo, a carga tende a ter sua prioridade de atendimento aumentada, funcionando como um parâmetro de concorrência na modelagem das cargas. A Tabela 15 mostra as saídas das variáveis para a melhor resposta.

O sistema de armazenamento para os casos anteriores apresentou o mesmo valor de carregamento, atingindo seu limite para o valor do SoC . No próximo caso, o custo nominal desse recurso será alterado para observar sua resposta à nova condição estabelecida.

Figura 52 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 2



Fonte: elaborada pela autora (2025).

Tabela 15 – Variáveis de saída da otimização

Variável	Valor
Carga prioritária	15,20 MW
Carga flexível	12,91 MW
Térmica a gás	3,68 MW
Térmica a biomassa	14,82 MW
Baterias ^a	-7,5 MW
Geração fotovoltaica	18,51 MW

Fonte: elaborada pela autora (2025).

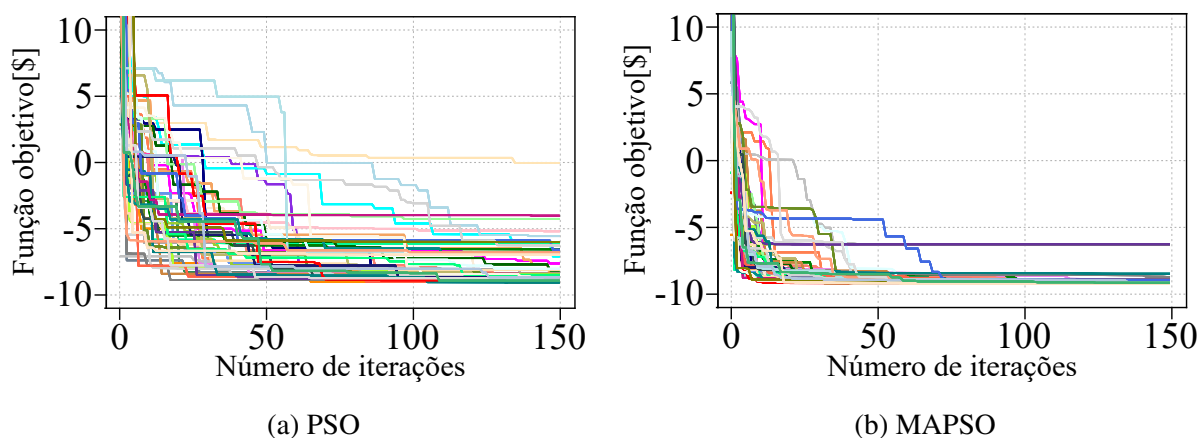
Nota: ^a Bateria em carregamento.

4.4.3 Caso 3 - Alteração na parametrização do modelo da bateria e valor inicial do SoC

Neste caso, o valor do custo do sistema de armazenamento foi reduzido para o mesmo custo nominal da geração térmica a gás, e o SoC inicial foi elevado para 95%. A alteração no custo nominal resultou em novos coeficientes em unidades padrão. Contudo, os valores de $a_{i,pu}$, $b_{i,pu}$ e $c_{i,pu}$ apresentados na Tabela 4 não foram alterados.

As Figuras 53 e 54 ilustram a convergência dos métodos de otimização centralizados e distribuídos, respectivamente. Neste cenário, o MAPSO distribuído obteve resultado discretamente melhor que sua versão centralizada, mostrando que esse algoritmo tem eficácia na busca de melhores soluções. Portanto, em aplicações distribuídas, é interessante que exista pelo menos um agente executando essa meta-heurística.

Figura 53 – Convergência da função objetivo para os algoritmos centralizados caso 3



Fonte: elaborada pela autora (2025).

Em relação ao PSO distribuído, ele pode melhorar seu desempenho com o aumento da interação entre os agentes. Nos três casos simulados nesta seção, a frequência de ocorrência da etapa de competição foi estabelecida para ocorrer a cada 10 iterações, mas esse intervalo pode ser reduzido a depender dos canais de comunicação disponíveis.

O melhor resultado obtido nas simulações está apresentado na Tabela 16. A bateria, que carregava nas considerações anteriores propostas, começou a entregar energia ao sistema neste caso, mas com potência reduzida em relação à sua potência nominal. Outros casos precisam ser avaliados, como baixa produção fotovoltaica ou carga maior.

Tabela 16 – Variáveis de saída da otimização caso 3

Variável	Valor
Carga prioritária	15,20 MW
Carga flexível	12,63 MW
Térmica a gás	3,78 MW
Térmica a biomassa	2 MW
Baterias ^a	4,93 MW
Geração fotovoltaica	18,51 MW

Fonte: elaborada pela autora (2025).

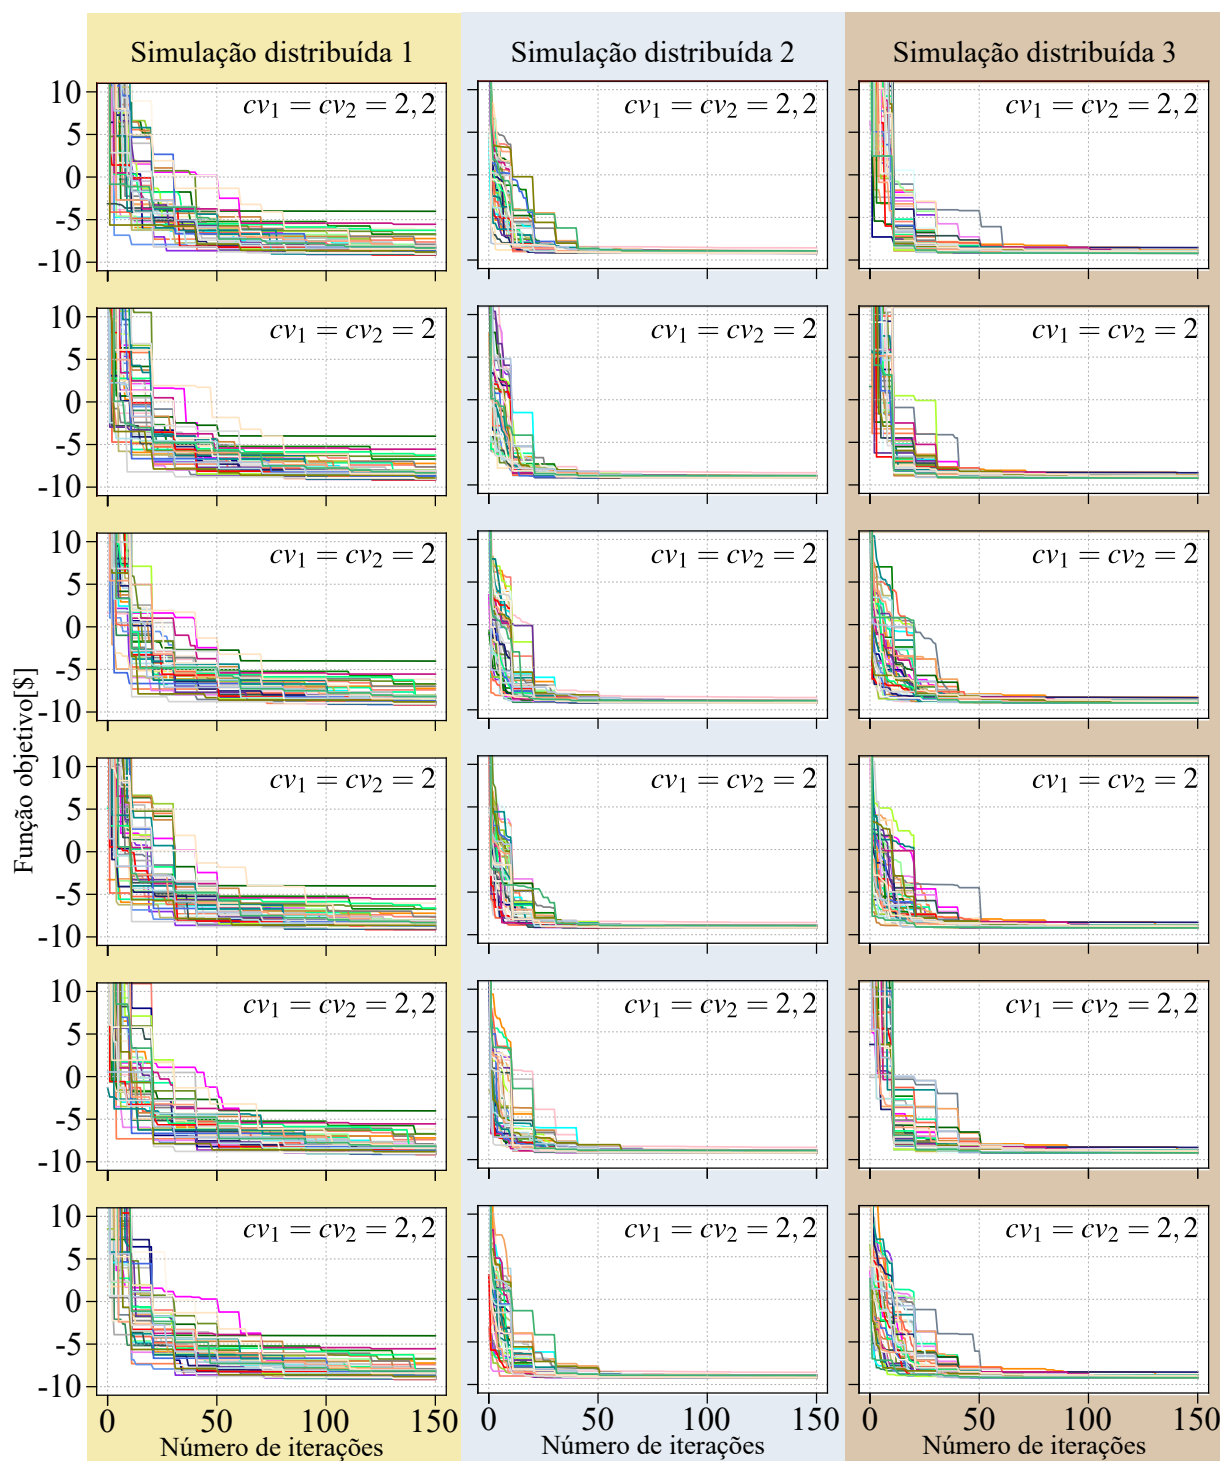
Nota: ^a Bateria descarregando.

Outra avaliação necessária envolve as gerações térmicas. Na solução, a térmica a gás, mesmo com custo superior, produz mais do que a térmica a biomassa.

O gráfico tipo *boxplot*, apresentado na Figura 55, é uma ferramenta útil para entender os resultados obtidos. Em cada gráfico, é apresentada a estatística das variáveis de saída para todos os cinco métodos simulados. O eixo y indica qual variável está sendo avaliada. Para o modelo distribuído, optou-se por apresentar o resultado de uma única meta-heurística, pois os dados são referentes apenas à última iteração, sendo todos muito próximos entre si.

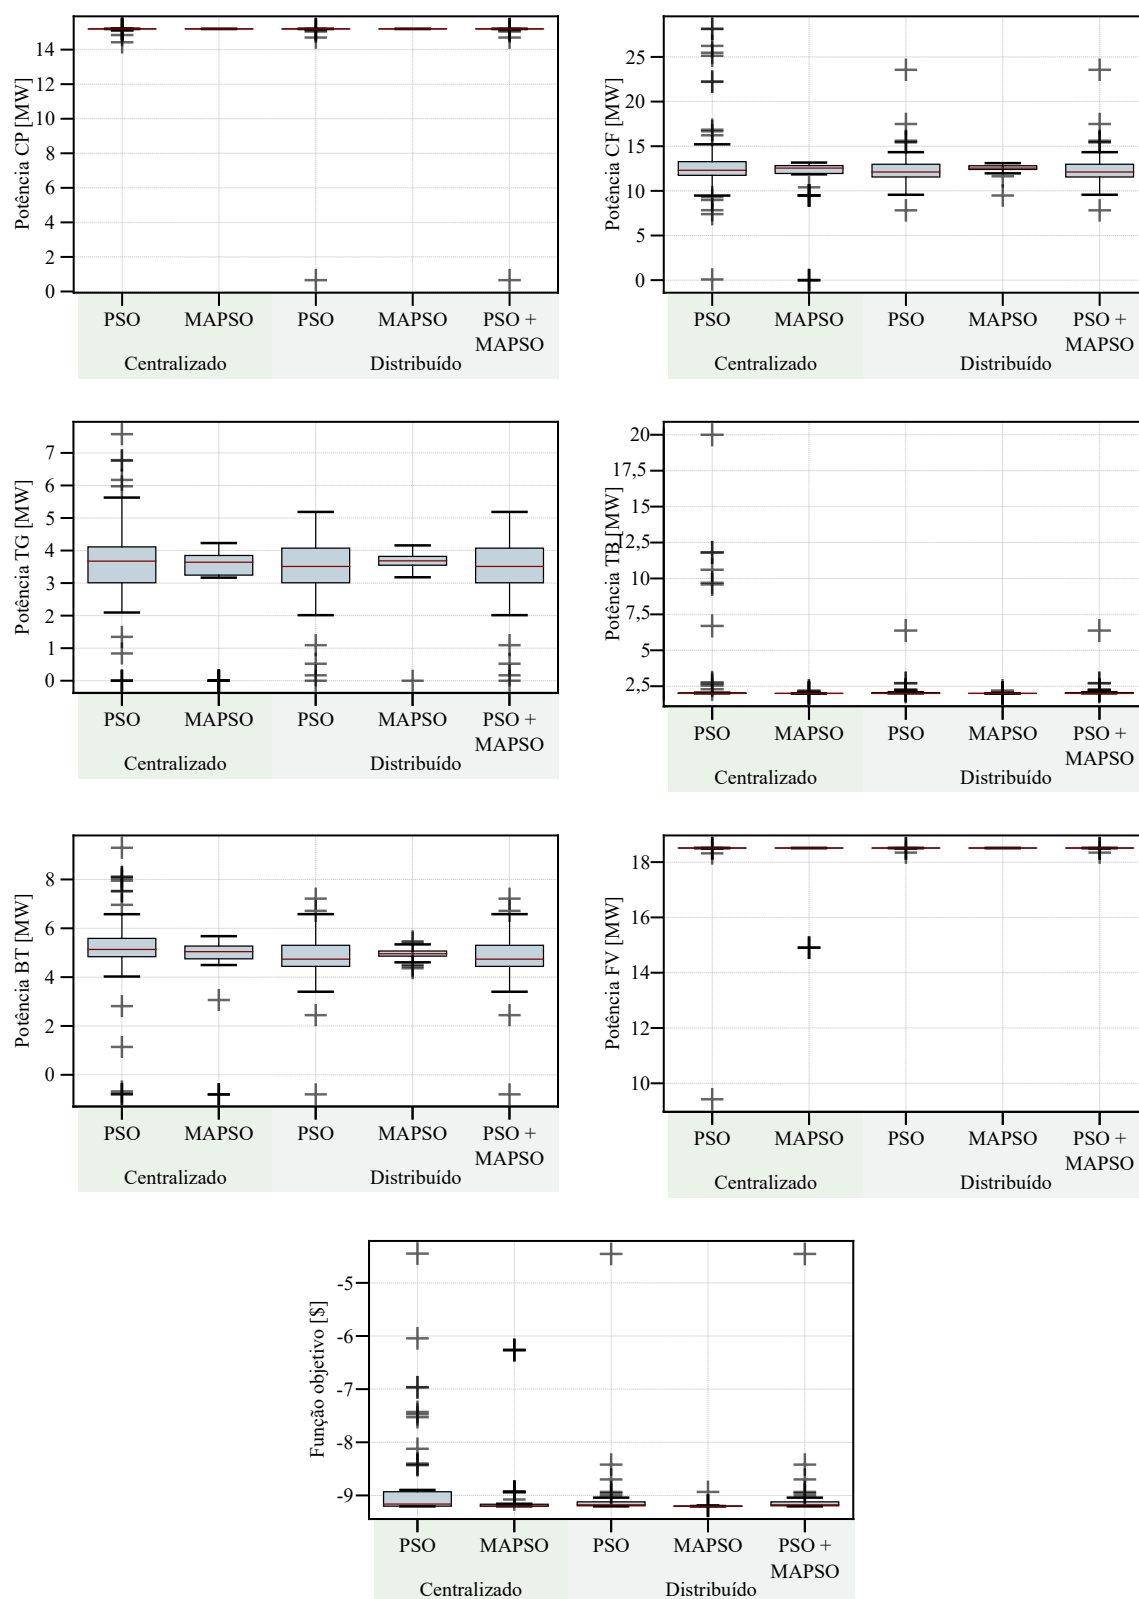
Ao avaliar esses resultados, nota-se que o algoritmo apresentou pouca variação na produção da térmica a biomassa. O comportamento foi semelhante ao dos recursos carga prioritária e geração fotovoltaica, cujos modelos devem garantir que a carga seja plenamente atendida e que a geração fotovoltaica não seja limitada. Dessa forma, realizar uma nova avaliação da parametrização adotada para esses recursos pode indicar se há problemas nos modelos ou se a resposta está adequada às condições e restrições impostas pelo problema.

Figura 54 – Resultado da convergência da função objetivo para 50 execuções do paralelismo distribuído de meta-heurísticas - caso 3



Fonte: elaborada pela autora (2025).

Figura 55 – Estatística das variáveis de saída e da função objetivo para as 50 execuções do caso 3



Fonte: elaborada pela autora (2025).

4.4.4 Avaliação do tempo de execução

A simulação distribuída 2 se destaca entre os três métodos distribuídos; entretanto, com maior tempo de execução, apresentando um aumento percentual médio de 69,64% em relação à simulação distribuída 1, exclusivamente de PSO. Esse aumento no tempo de execução é compreensível devido à característica da implementação do *self-learning* e dos demais cálculos adicionais. A etapa de autoaprendizado implementada no MAPSO, embora com poucos cálculos, é um processo iterativo dentro de outro, o que acarreta um custo computacional significativo.

O método que mescla as duas meta-heurísticas, simulação distribuída 3, tem desempenho intermediário entre os dois métodos exclusivos, o que se reflete também no tempo de execução intermediário, com acréscimo médio de 38% em relação à versão de paralelismo distribuído de PSO.

Os tempos de execução dos três casos simulados estão apresentados na Tabela 17. Esses tempos são completos, considerando a entrada de operação dos agentes, a atualização de previsão e a troca de mensagens antes do início e durante a execução, no caso dos métodos distribuídos.

É importante salientar que a execução das meta-heurísticas em paralelo foi realizada utilizando a mesma máquina e o mesmo processamento. Em aplicações reais, uma das vantagens das meta-heurísticas em paralelo é justamente o processo distribuído em *hardwares* diferentes, especialmente quando há escalabilidade do problema.

Tabela 17 – Tempo total de 50 execuções e a média considerando apenas 1 execução para cada um dos algoritmos

Algoritmo	Caso 1		Caso 2		Caso 3	
	Total	Média	Total	Média	Total	Média
PSO centralizado	02min07seg	2,54seg	02min15seg	2,70seg	02min25seg	2,90seg
MAPSO centralizado	02min34seg	3,08seg	02min50seg	3,40seg	02min38seg	3,16seg
PSO distribuído	04min07seg	5,56seg	04min16seg	5,12seg	04min15seg	5,10seg
MAPSO distribuído	06min59seg	8,38seg	07min13seg	8,66seg	06min58seg	8,36seg
MAPSO+PSO distribuído	05min42seg	6,84seg	06min13seg	7,46seg	05min56seg	7,12seg

Fonte: elaborada pela autora (2025).

4.5 Análise de convergência com modelos ajustados

Nesta seção, será analisada novamente a convergência dos algoritmos, avaliando o comportamento das cargas durante o dia ao ser adotado o modelo exponencial, conforme determinado na seção 4.4.2. Todos os outros parâmetros foram mantidos iguais aos da seção 4.3.

A Tabela 18 apresenta os resultados da convergência dos algoritmos com o novo modelo de carga, sem considerar arredondamentos. Em relação à convergência, os resultados refletem de forma mais precisa os dados analisados nos casos da seção 4.4, com o melhor desempenho registrado para o caso em que todos os algoritmos utilizam MAPSO, com o maior número de mensagens trocadas. Em segundo lugar, está a distribuição dos algoritmos que utilizam MAPSO em 3 dos 6 agentes, evidenciando que esse algoritmo é uma escolha interessante para o problema proposto.

Tabela 18 – Convergência das variáveis de saída e da função objetivo total para os 288 intervalos de otimização

Número de it para cada CC ^a	Simulação distribuída 1			Simulação distribuída 2			Simulação distribuída 3		
	var	f_{obj}	Δ_{max}	var	f_{obj}	Δ_{max}	var	f_{obj}	Δ_{max}
1	274	283	2,32 MW	283	288	0,42 MW	280	288	0,45 MW
10	188	248	9,98 MW	239	286	1,68 MW	226	281	3,44 MW
100	10	29	15,54 MW	63	236	8,42 MW	30	164	10,35 MW

Fonte: elaborada pela autora (2025).

Nota: ^a Etapa de competição e cooperação.


No Apêndice B, são apresentadas as figuras que representam as simulações utilizadas para a construção da tabela. O método distribuído, com troca de mensagens a cada 100 iterações, não é adequado, pois as variações encontradas são da mesma magnitude da capacidade dos recursos. Com a troca de mensagens a cada 10 iterações, a distribuição exclusivamente da meta-heurística PSO também não deve ser adotada. Embora o número de intervalos de convergência das variáveis seja maior, os valores absolutos das variações foram superiores aos da simulação distribuída 2, com troca de informações a cada 100 iterações.

Os casos que apresentaram os melhores resultados foram aqueles com troca de mensagens a cada iteração na simulação distribuída 2, que obteve a menor variação entre as variáveis otimizadas. A convergência da função objetivo em um maior número de intervalos do que a convergência das variáveis indica que implementações que envolvem a troca da partícula completa, e não apenas do valor da função custo associada, podem melhorar a convergência em

todos os casos.

A Figura 56 mostra o corte de carga para o melhor resultado de convergência, obtido com a implementação da simulação distribuída 2 e troca de informações a cada iteração. O modelo de carga funcionou como esperado, sem cortes na carga prioritária em todos os 288 intervalos de otimização do dia. Já a carga flexível apresentou cortes variáveis, dependendo da disponibilidade das outras fontes e de seus respectivos custos.

Figura 56 – Corte de carga durante a simulação do dia



Fonte: elaborada pela autora (2025).

4.6 Considerações finais

Neste capítulo, foram apresentados os recursos da microrrede utilizada nos estudos desenvolvidos. Foram apresentados cada um dos recursos e discutidas as escolhas dos coeficientes das funções objetivo para cada um deles.

Em seguida, a simulação para um dia inteiro de otimização foi apresentada, avaliou-se com isso os três métodos de paralelismo distribuído e a influência da troca de mensagens na convergência das variáveis.

Com essa simulação inicial, observou-se corte na carga prioritária, optou-se por utilizar outro modelo para as cargas. No primeiro momento, o modelo e os parâmetros escolhidos atenderam à carga prioritária, mas a carga flexível era totalmente cortada.

Uma nova parametrização foi realizada, atendendo aos dois tipos de carga. Enquanto os modelos eram alterados, o desempenho dos métodos distribuídos foi verificado e comparado com os métodos implementados de forma centralizada. Nesse contexto, a meta-heurística MAPSO se mostrou mais eficaz, apresentando resultados mais precisos em ambos os modelos

de implementação. Portanto, em uma implementação em *hardwares* paralelos, seria possível aumentar o número de partículas de cada agente, obtendo resultados significativamente melhores do que os obtidos com a implementação centralizada.

Os resultados obtidos para o dia completo indicam que as alterações realizadas nos modelos foram suficientes para modelar adequadamente os recursos energéticos. A convergência, mesmo desconsiderando os arredondamentos prematuros, manteve-se estável para trocas de mensagem a cada 1 ou 10 iterações.

5 CONCLUSÕES E TRABALHOS FUTUROS

A formação de microrredes pode se tornar um modelo de negócio em diversas regiões, como as comunidades de energia renovável da União Europeia já reguladas. Esses sistemas de porte reduzido têm as mesmas características das redes de grande dimensão; portanto, além dos controles de frequência e tensão, precisam otimizar seus recursos. Essa otimização, além da redução do custo operacional, pode ser uma ferramenta para a agregação e participação nos mercados de energia elétrica.

A função do operador de mercado e da rede de energia elétrica, frequentemente unificada em diversos países, tem se aperfeiçoado com a redução dos prazos tanto para negociação quanto para despacho de recursos energéticos. Essa evolução visa otimizar a remuneração de fontes mais flexíveis em resposta à crescente variabilidade da geração de energia elétrica. A prática de realizar despachos de recursos a cada 5 minutos é comum em diversos sistemas elétricos globais, enquanto no Brasil a duração padrão desses intervalos é atualmente de 30 minutos. A Empresa de Pesquisa Energética (EPE) tem conduzido estudos comparativos, analisando as experiências internacionais e os potenciais benefícios dessas práticas para o sistema elétrico brasileiro.

Dessa forma, o estudo realizado neste trabalho avaliou a possibilidade de implementação de meta-heurísticas de forma distribuída para a otimização de recursos energéticos seguindo a tendência do despacho a cada 5 minutos. Essa avaliação foi realizada no ambiente de co-simulação através de agentes associados aos equipamentos que atualmente possuem certa capacidade de processamento interessante para a proposição do paralelismo de meta-heurísticas. Os resultados apontam para a possibilidade dessa utilização, com a vantagem de, por ser distribuído, ser um método tolerante à falha. A troca de mensagens e a etapa de competição e cooperação acrescentada ao paralelismo mostram uma melhoria dos resultados com a aplicação no PSO distribuído. Outra observação é que o algoritmo MAPSO, mesmo na aplicação centralizada, apresenta bons resultados, indicando que, para redes maiores e com mais recursos, a implementação de pelo menos um dos algoritmos no paralelismo distribuído deve ser ele.

Tanto na análise de convergência de variáveis de saída da otimização quanto na análise probabilística, o algoritmo MAPSO implementado com paralelismo distribuído apresentou os melhores resultados. Na análise de convergência, a variação máxima foi menor que 2% da potência nominal do menor dos recursos, isso mostra que as meta-heurísticas em paralelo convergem sem necessidade de comunicação ao final do processo. Enquanto na análise probabilística, o

paralelismo distribuído exclusivo de MAPSO mostrou que entre as 50 execuções realizadas para um mesmo intervalo, o desvio padrão máximo relativo alcançado para as variáveis foi de 15%, enquanto a função objetivo o desvio padrão relativo foi de apenas 0,42%. O segundo melhor método analisado foi o paralelismo distribuído com 3 PSO e 3 MAPSO sendo executados nos agentes. Esse método pode ser adequado quando houver diferenças expressivas na capacidade de processamento dos *hardwares* distribuídos, sendo utilizados nos equipamentos de maior capacidade o algoritmo MAPSO e nos equipamentos mais básicos o algoritmo PSO.

Além dos métodos de otimização, os modelos que descrevem o problema são importantes para o fechamento dos resultados. Neste trabalho, a escolha adequada dos modelos das fontes e dos recursos energéticos foi o maior desafio. Embora uma análise detalhada de cada modelo tenha sido realizada durante o trabalho, a validação de modelos de custo com recursos reais é difícil de ser alcançada sem dados detalhados. Neste estudo, utilizou-se apenas indicações com base na Programação Mensal de Operação disponibilizada pelo ONS para estimar o custo dos recursos energéticos.

O estudo, portanto, propõe um método simples para a realização da otimização de recursos distribuídos e com capacidade de processamento também distribuída, com o objetivo de tornar as microrredes mais robustas e competitivas.

Como trabalhos futuros, propõem-se a distribuição do algoritmo em *hardwares* diferentes para verificar como ficariam os tempos de troca de informações e execução paralela. Além disso, propõem-se a consideração do intercâmbio de energia com a rede elétrica, considerando o custo variável da energia para diferentes programas de resposta à demanda. Por fim, pode ser implementado ainda o modelo de carregamento de veículos elétricos.

REFERÊNCIAS

- AEMO, E. M. M. Spot market operations timetable - versão 1.9. In: **Executive General Manager Operations**. [S. l.: s. n.], 2024.
- AESO. Section 201.6 pricing. In: ALBERTA ELECTRIC SYSTEM OPERATOR. **Complete Set of ISO Rules**. Calgary, 2024. p. 321.
- AESO. Section 203.3 energy restatements. In: ALBERTA ELECTRIC SYSTEM OPERATOR. **Complete Set of ISO Rules**. Calgary, 2024. p. 321.
- AESO. Section 301.2 iso directives. In: ALBERTA ELECTRIC SYSTEM OPERATOR. **Complete Set of ISO Rules**. Calgary, 2024. p. 321.
- ALBA, E. **Parallel metaheuristics: a new class of algorithms**. [S. l.]: John Wiley & Sons, 2005.
- ALI, H.; HUSSAIN, A.; BUI, V.-H.; JEON, J.; KIM, H.-M. Welfare maximization-based distributed demand response for islanded multi-microgrid networks using diffusion strategy. **Energies**, v. 12, n. 19, 2019. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/12/19/3701>.
- ALMEIDA, M. P.; PERPIÑÁN, O.; NARVARTE, L. Pv power forecast using a nonparametric pv model. **Solar Energy**, v. 115, p. 354–368, 2015. ISSN 0038-092X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0038092X15001218>.
- ALMEIDA, R. G. **Gerenciamento e controle distribuído hierárquico primário e secundário aplicado a microrrede CA**. 137 p. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia - Universidade Federal do Ceará, Fortaleza, 2019. Disponível em: <http://repositorio.ufc.br/handle/riufc/44456>.
- ALVIM, C. F.; MAFRA, O. Y.; PAREDES, L.; GUIMARÃES, L. O tratado de proibição de armas nucleares e a posição do Brasil na Área nuclear. **Economia e Energia - Revista**, v. 97, dezembro 2017. ISSN 1518-2932.
- AMINI, M. H.; JADDIVADA, R.; MISHRA, S.; KARABASOGLU, O. Distributed security constrained economic dispatch. In: **2015 IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA)**. [S. l.: s. n.], 2015. p. 1–6.
- ANEEL. **Resolução Normativa Nº 1.000, de 7 de dezembro de 2021**. 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-1.008-de-15-de-marco-de-2022-386769604>. Acesso em: 08 ago. 2024.
- ANEEL. **Resolução Normativa Nº 1.040, de 30 de agosto de 2022**. 2022. Disponível em: www2.aneel.gov.br/cedoc/ren20221040.html. Acesso em: 08 ago. 2024.
- ANEEL. **Geração: relatórios e indicadores relacionados ao segmento de geração de energia elétrica**. 2024. <https://www.gov.br/aneel/pt-br/centrais-de-conteudos/relatorios-e-indicadores/geracao>. Acesso em: 22 nov de 2024.
- ASSOCIATION, I. H. **2023 World Hydropower Outlook**. London, 2023.
- ASSOCIATION, M. **FMI tools**. 2024. Acesso em: 29 set 2024. Disponível em: <https://fmi-standard.org/tools/>.

AUSTRALIA, G. of W. Specific transitional provisions – gate closure. In: **Wholesale Electricity Market Rules**. [S. n.], 2024. Disponível em: https://www.wa.gov.au/system/files/2024-07/wholesale_electricity_market_rules_-_27_july_2024.pdf.

AZEVEDO, R. de. **Fully decentralized multi-agent system for optimal microgrid control**. 133 p. Dissertação (Mestrado) – Florida International University, 2016. Disponível em: <https://digitalcommons.fiu.edu/etd/2461/>.

BORKOWSKI, D.; MAJDAK, M. Small hydropower plants with variable speed operation—an optimal operation curve determination. **Energies**, v. 13, n. 23, 2020. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/13/23/6230>.

BOSALETSI, O.; CRONJE, W.; MASISI, L. Demand side frequency control in low inertia power system. In: **2023 International Conference on Power Electronics and Energy (ICPEE)**. [S. l.: s. n.], 2023. p. 1–5.

BRAUN, M.; STRAUSS, P. A review on aggregation approaches of controllable distributed energy units in electrical power systems. **International Journal of Distributed Energy Resources**, v. 4, n. 4, p. 297–319, 2008.

CAISO. Real-time load settlement price calculation causing revenue imbalances. In: CALIFORNIA INDEPENDENT SYSTEM OPERATOR. Folsom: Department of Market Monitoring, 2023. p. 27.

CAISO. Real-time market activities. In: CALIFORNIA INDEPENDENT SYSTEM OPERATOR. **Operating Procedure**. Folsom, 2024. v. 11.5, p. 12.

CARVALHO, É. d. C. R. **Solução de problemas de otimização com restrições usando estratégias de penalização adaptativa e um algoritmo do tipo PSO**. Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, 2014.

CCEE. **Nota Técnica 045/2019 - Segundo relatório de análise do projeto piloto de resposta a demanda**. [S. l.], 2019. Disponível em: www.ccee.org.br/o/ccee/documentos/CCEE_649052.

CEPEL. Programa de análise de confiabilidade composta e cálculo de reserva operativa. In: **Manual do usuário**. [S. n.], 2021. Acesso em: 01 jun 2024. Disponível em: <https://dre.cepel.br/manual/nh2/>.

CES, N. P. L. **Otimização econômica do sistema de gerenciamento distribuído de energia de microrredes CA**. 104 p. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia - Universidade Federal do Ceará, Fortaleza, 2023. Disponível em: <http://repositorio.ufc.br/handle/riufc/74134>.

CGEC. **Capstone Hydrogen Development**. 2024. <https://www.capstonegreenenergy.com/products/hydrogen-products/hydrogen-microturbine>.

CHEN, J.; LIU, X.; KARAM, I. Short-term economic dispatch incorporating renewable power generations with plug-in electric vehicles considering emissions reduction. **Environment, Development and Sustainability**, Springer, p. 1–26, 2024.

COHOON, J.; HEGDE, S.; MARTIN, W.; RICHARDS, D. **Punctuated Equilibria: A Parallel Genetic Algorithm**. [S. l.], 1987.

CONEJO, A. J.; BARINGO, L. **Power system operations**. [S. l.]: Springer, 2018. v. 11.

DAI, Q.; HUO, X.; HAO, Y.; YU, R. Spatio-temporal prediction for distributed pv generation system based on deep learning neural network model. **Frontiers in Energy Research**, Frontiers, v. 11, p. 1204032, 2023.

DANESHVAR, M.; MOHAMMADI-IVATLOO, B.; ABAPOUR, M.; ASADI, S. Energy exchange control in multiple microgrids with transactive energy management. **Journal of Modern Power Systems and Clean Energy**, SGEPRI, v. 8, n. 4, p. 719–726, 2020.

DORSCH, N.; KURTZ, F.; DALHUES, S.; ROBITZKY, L.; HÄGER, U.; WIETFELD, C. Intertwined: Software-defined communication networks for multi-agent system-based smart grid control. In: **2016 IEEE International Conference on Smart Grid Communications (SmartGridComm)**. [S. l.: s. n.], 2016. p. 254–259.

EIA. **Electricity explained Energy storage for electricity generation**. 2023. <https://www.eia.gov/energyexplained/electricity/energy-storage-for-electricity-generation.php>.

EL-SEHIEMY, R. A.; EL-HOSSEINI, M. A.; HASSANIEN, A. E. Multiobjective real-coded genetic algorithm for economic/environmental dispatch problem. **Studies in Informatics and Control**, v. 22, n. 2, p. 113–122, 2013.

EPE. Serviços ancilares sob a ótica de planejamento da expansão. In: **Nota Técnica EPE-DEE-NT-090/2021**. [S. l.: s. n.], 2021.

ESPINA, E.; LLANOS, J.; BURGOS-MELLADO, C.; CÁRDENAS-DOBSON, R.; MARTÍNEZ-GÓMEZ, M.; SÁEZ, D. Distributed control strategies for microgrids: An overview. **IEEE Access**, v. 8, p. 193412–193448, 2020.

EZUGWU, A. E.; SHUKLA, A. K.; NATH, R.; AKINYELU, A. A.; AGUSHAKA, J. O.; CHIROMA, H.; MUHURI, P. K. Metaheuristics: a comprehensive overview and classification along with bibliometric analysis. **Artificial Intelligence Review**, Springer, v. 54, p. 4237–4316, 2021.

FANG, X.; MISRA, S.; XUE, G.; YANG, D. Smart grid — the new and improved power grid: A survey. **IEEE Communications Surveys & Tutorials**, v. 14, n. 4, p. 944–980, 2012.

FARROKHSERESHT, N.; MEER, A. A. van der; TORRES, J. R.; MEIJDEN, M. A. M. M. van der. Mosaik and fmi-based co-simulation applied to transient stability analysis of grid-forming converter modulated wind power plants. **Applied Sciences**, v. 11, n. 5, 2021. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/11/5/2410>.

FERNÁNDEZ-GUILLAMÓN, A.; GÓMEZ-LÁZARO, E.; MULJADI, E.; MOLINA-GARCÍA Ángel. Power systems with high renewable energy sources: A review of inertia and frequency control strategies over time. **Renewable and Sustainable Energy Reviews**, v. 115, p. 109369, 2019. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032119305775>.

FINI, M. H.; GOLSHAN, M. E. H.; MARTÍ, J. R.; KETABI, A. Determining the required frequency control reserve and capacity and location of synchronous and virtual inertial resources. **IEEE Transactions on Sustainable Energy**, v. 14, n. 1, p. 27–38, 2023.

- GIES, D.; RAHMAT-SAMII, Y. Particle swarm optimization for reconfigurable phase-differentiated array design. **Microwave and Optical Technology Letters**, v. 38, n. 3, p. 168–175, 2003. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/mop.11005>.
- GLOWACKI, M. **Central Dispatch Model**. 2023. Acessado: 2024-07-19. Disponível em: emissions-euets.com/internal-electricity-market-glossary/600-central-dispatch-system.
- GLOWACKI, M. **Self-Dispatch System (Electricity Balancing Market)**. 2023. Acessado: 2024-07-19. Disponível em: emissions-euets.com/self-dispatch-system.
- GOMES, A. C.; LEÃO, R. P. S.; PRATA, B. de A.; TOFOLI, F. L.; SAMPAIO, R. F.; BARROSO, G. C. Optimal placement of manual and remote-controlled switches based on the pareto front. **International Journal of Electrical Power & Energy Systems**, v. 147, p. 108894, 2023. ISSN 0142-0615.
- GRISALES-NOREÑA, L. F.; MONTOYA, O. D.; RAMOS-PAJA, C. A. An energy management system for optimal operation of bss in dc distributed generation environments based on a parallel pso algorithm. **Journal of Energy Storage**, Elsevier, v. 29, p. 101488, 2020.
- GRISALES-NOREÑA, L. F.; OCAMPO-TORO, J. A.; MONTOYA-GIRALDO, O. D.; MONTANO, J.; HERNANDEZ, J. Optimal operation of battery storage systems in standalone and grid-connected dc microgrids using parallel metaheuristic optimization algorithms. **Journal of Energy Storage**, Elsevier, v. 65, p. 107240, 2023.
- HARRISON, J.; DESMYTER, R. **Delta-ee Webinar: The Rise of Local Energy Systems**. 2019. Disponível em: <https://www.youtube.com/watch?v=InP-1FY3MLw>.
- HEFNY, H. A.; AZAB, S. S. Chaotic particle swarm optimization. In: IEEE. **2010 The 7th International Conference on Informatics and Systems (INFOS)**. [S. l.], 2010. p. 1–8.
- HILLIER, F.; LIEBERMAN, G.; GRIESI, A. **Introdução à pesquisa operacional**. McGraw-Hill, 2006. ISBN 9788586804687. Disponível em: <https://books.google.com.br/books?id=3x-XPgAACAAJ>.
- HUO, Y.; BOUFFARD, F.; JOÓS, G. Integrating learning and explicit model predictive control for unit commitment in microgrids. **Applied Energy**, Elsevier, v. 306, p. 118026, 2022.
- IRENA. **Innovation landscape brief: Increasing time granularity in electricity markets**. Abu Dhabi, 2019. ISBN: 978-92-9260-127-0.
- JAIN, M.; SAIHJPAL, V.; SINGH, N.; SINGH, S. B. An overview of variants and advancements of pso algorithm. **Applied Sciences**, v. 12, n. 17, 2022. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/12/17/8392>.
- JANNUZZI, G. d. M.; SWISHER, J.; REDLINGER, R. **Planejamento Integrado De Recursos Energéticos Oferta, demanda e suas Interfaces**. 2018. [S. l.]: CAMPINAS-IEI BRASIL, 2018.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of ICNN'95 - International Conference on Neural Networks**. [S. l.: s. n.], 1995. v. 4, p. 1942–1948 vol.4.
- KUMAR, R.; SHARMA, D.; KUMAR, A. A new hybrid multi-agent-based particle swarm optimisation technique. **International Journal of Bio-Inspired Computation**, Inderscience Publishers, v. 1, n. 4, p. 259–269, 2009.

KUMAR, R.; SHARMA, D.; SADU, A. A hybrid multi-agent based particle swarm optimization algorithm for economic power dispatch. **International journal of electrical power & energy systems**, Elsevier, v. 33, n. 1, p. 115–123, 2011.

LEE, K.; EL-SHARKAWI, M. **Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems**. Wiley, 2008. (IEEE Press Series on Power and Energy Systems). ISBN 9780470225851. Disponível em: <https://books.google.com.br/books?id=ZHRTmJfyVYC>.

LIANG, H.; ZHUANG, W. Stochastic modeling and optimization in a microgrid: A survey. **Energies**, v. 7, n. 4, p. 2027–2050, 2014. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/7/4/2027>.

LIU, B.; WANG, L.; JIN, Y.-H.; TANG, F.; HUANG, D.-X. Improved particle swarm optimization combined with chaos. **Chaos, Solitons & Fractals**, Elsevier, v. 25, n. 5, p. 1261–1271, 2005.

LIU, J.; HE, D.; WEI, Q.; YAN, S. Energy storage coordination in energy internet based on multi-agent particle swarm optimization. **Applied Sciences**, MDPI, v. 8, n. 9, p. 1520, 2018.

LUDOVICO, P.; VERDE, I.; GOMES, J. P. Energia nuclear: Riscos e potencialidades em relação a outras fontes de energia. **Informativo Eletrônico do Setor Elétrico**, setembro 2023.

MAGALHÃES, G.; PARENTE, V. Do mercado atacadista à câmara de comercialização de energia elétrica: A evolução de um novo paradigma regulatório no Brasil. **Revista Brasileira de Energia**, v. 15, n. 2, p. 59–79, 2009.

MCTI. **Em 60 anos, média de dias seguidos sem chuva aumenta de 80 para 100 no Brasil, aponta estudo do INPE**. 2024. <https://www.gov.br/inpe/pt-br/assuntos/ultimas-noticias/em-60-anos-media-de-dias-seguidos-sem-chuva-aumenta-de-80-para-100-no-brasil-aponta-estudo-do-inpe>. Accessed: 2024-10-11.

MELO, L. S. **Desenvolvimento de uma plataforma para implementação de sistemas multiagentes com aplicação para recomposição automática de sistemas de distribuição de energia elétrica**. 121 p. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia - Universidade Federal do Ceará, 2015. Disponível em: <http://repositorio.ufc.br/handle/riufc/13773>.

MELO, L. S. **Modelo de simulação computacional multidomínio para análise de redes elétricas inteligentes com aplicação em transações econômicas de energia**. 188 p. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia - Universidade Federal do Ceará, Fortaleza, 2022. Disponível em: <http://repositorio.ufc.br/handle/riufc/66268>.

MELO, L. S.; SAMPAIO, R. F.; LEÃO, R. P. S.; BARROSO, G. C.; BEZERRA, J. R. Python-based multi-agent platform for application on power grids. **International transactions on electrical energy systems**, Wiley Online Library, v. 29, n. 6, p. e12012, 2019.

MELO, L. S.; SARAIVA, F. d. O.; LEÃO, R. P. S.; SAMPAIO, R. F.; BARROSO, G. C. Mosaik and pade: multiagents and co-simulation for smart grids modeling. **Revista de Informática Teórica e Aplicada**, v. 27, n. 2, p. 107–115, 2020.

- MOLZAHN, D. K.; DÖRFLER, F.; SANDBERG, H.; LOW, S. H.; CHAKRABARTI, S.; BALDICK, R.; LAVAEI, J. A survey of distributed optimization and control algorithms for electric power systems. **IEEE Transactions on Smart Grid**, v. 8, n. 6, p. 2941–2962, 2017.
- NADERMAHMOUDI, E.; AMRAEE, T.; OSKOUEE, S. S. Stochastic very short-term economic dispatch for wind power operation using flexible ramp reserve. **International Transactions on Electrical Energy Systems**, Wiley Online Library, v. 30, n. 8, p. e12454, 2020.
- NAKIGANDA, A. M.; ARISTIDOU, P. Resilient microgrid scheduling with secure frequency and voltage transient response. **IEEE Transactions on Power Systems**, v. 38, n. 4, p. 3580–3592, 2023.
- NIROMANDFAM, A.; YAZDANKHAH, A. S.; KAZEMZADEH, R. Modeling demand response based on utility function considering wind profit maximization in the day-ahead market. **Journal of Cleaner Production**, v. 251, p. 119317, 2020. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652619341873>.
- OFFIS. **Scheduling and simulation execution**. 2024. Acesso em: 29 set 2024. Disponível em: mosaik.readthedocs.io/en/latest/scheduler.html#time-paradigms.
- OFIR, R.; MARKOVIC, U.; ARISTIDOU, P.; HUG, G. Droop vs. virtual inertia: Comparison from the perspective of converter operation mode. In: **2018 IEEE International Energy Conference (ENERGYCON)**. [S. l.: s. n.], 2018. p. 1–6.
- OLIVEIRA, F. J. A. d. **O planejamento da operação energética no sistema : conceitos, modelagem matemática, previsão de geração e carga**. São Paulo: Artliber, 2020. 402 p. ISBN: 978-92-9260-127-0.
- ONS. **Desenvolvimento Metodológico para previsão de geração de fonte eólica**. Rio de Janeiro, 2018.
- ONS. Análise técnica dos serviços ancilares de suporte de reativos, controle secundário de frequência e autorrestabelecimento integral. In: **Procedimentos de Rede, Submódulo 3.11**. [S. l.: s. n.], 2021. Vigência: 17/09/2021.
- ONS. **Plano anual da operação energética dos sistemas isolados para 2023**. Rio de Janeiro, 2022.
- ONS. Referência técnica - conceitos básicos para o controle de geração. In: **Manual de Procedimentos da Operação**. [S. l.: s. n.], 2022. Vigência: 17/06/2022.
- ONS. **Projeto Meta II**. Rio de Janeiro, 2023. Disponível em: ons.org.br/Paginas/Noticias/Projeto-Meta-II.aspx.
- ONS. **Relatório de Análise de Perturbação do dia 15/08/2023 às 08h30min**. [S. l.], 2023. Disponível em: https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/RAP%202023.08.15%2008h30min%20vers%C3%A3o%20final%20com%20anexos%20de%20diverg%C3%Aancia_Final.pdf.
- ONS. Submódulo 2.10 - requisitos técnicos mínimos para a conexão às instalações de transmissão. In: **Procedimentos de Rede**. [S. l.: s. n.], 2023. Vigência: 01/11/2023.
- ONS. Submódulo 4.5 - programação diária da operação. In: **Procedimentos de Rede**. [S. l.: s. n.], 2023. Vigência: 06/12/2023.

ONS. **Disponibilidade de usinas**. 2024. Acesso em: 19 nov de 2024. Disponível em: https://dados.ons.org.br/dataset/disponibilidade_usina.

ONS. **Relatório Executivo do programa mensal de operação**. 2024. Acesso em: 19 nov de 2024. Disponível em: https://dados.ons.org.br/dataset/disponibilidade_usina.

PARLIAMENT, E. Commission regulation (eu) 2017/1485. In: THE EUROPEAN COMMISSION. Bruxelas: Official Journal of the European Union, 2017. Disponível em: <http://data.europa.eu/eli/reg/2017/1485/oj>.

PARLIAMENT, E. Regulation (eu) 2024/1747. In: THE EUROPEAN PARLIAMENT AND THE COUNCIL. Bruxelas: Official Journal of the European Union, 2024. ISSN 1977-0677. Disponível em: <http://data.europa.eu/eli/reg/2024/1747/oj>.

PETITET, M.; PERROT, M.; MATHIEU, S.; ERNST, D.; PHULPIN, Y. Impact of gate closure time on the efficiency of power systems balancing. **Energy Policy**, v. 129, p. 562–573, 2019. ISSN 0301-4215. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0301421519301223>.

PREMKUMAR, M.; SOWMYA, R.; RAMAKRISHNAN, C.; JANGIR, P.; HOUSSEIN, E. H.; DEB, S.; KUMAR, N. M. An efficient and reliable scheduling algorithm for unit commitment scheme in microgrid systems using enhanced mixed integer particle swarm optimizer considering uncertainties. **Energy Reports**, Elsevier, v. 9, p. 1029–1053, 2023.

RAJWAR, K.; DEEP, K.; DAS, S. An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges. **Artificial Intelligence Review**, Springer, v. 56, n. 11, p. 13187–13257, 2023.

REI. **Battery Storage to Efficiently Achieve Renewable Energy Integration**. Tokyo, 2023. 58 p. Disponível em: www.renewable-ei.org/en/.

RIGO-MARIANI, R.; SARENI, B.; ROBOAM, X.; TURPIN, C. Optimal power dispatching strategies in smart-microgrids with storage. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 40, p. 649–658, 2014.

ROSA, C.; COIMBRA, M.; BARBOSA, P.; CHANTRE, C.; ROSENTAL, R. Microrredes: benefícios e desafios para o setor elétrico brasileiro. **Informativo Eletrônico do Setor Elétrico**, fevereiro 2022.

SAMPAIO, F. C.; TOFOLI, F. L.; MELO, L. S.; BARROSO, G. C.; SAMPAIO, R. F.; LEÃO, R. P. S. Adaptive fuzzy directional bat algorithm for the optimal coordination of protection systems based on directional overcurrent relays. **Electric Power Systems Research**, v. 211, p. 108619, 2022. ISSN 0378-7796.

SAMPAIO, R. F. **Sistema de automação distribuído: uma abordagem baseada em multiagente aplicada a sistemas de distribuição de energia elétrica em média tensão**. 226 p. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia - Universidade Federal do Ceará, Fortaleza, 2017. Disponível em: <http://repositorio.ufc.br/handle/riufc/28423>.

SCE. **CRITICAL PEAK PRICING (CPP) FOR BUSINESSES - A brief guide with facts, tips, and helpful answers**. [S. l.], 2022.

SHAFIK, M. B.; CHEN, H.; RASHED, G. I.; EL-SEHIEMY, R. A. Adaptive multi objective parallel seeker optimization algorithm for incorporating tcsc devices into optimal power flow framework. **IEEE Access**, IEEE, v. 7, p. 36934–36947, 2019.

SHI, Y.; EBERHART, R. A modified particle swarm optimizer. In: IEEE. **1998 IEEE international conference on evolutionary computation proceedings. IEEE world congress on computational intelligence (Cat. No. 98TH8360)**. [S. l.], 1998. p. 69–73.

SHUNMUGALATHA, A.; SLOCHANAL, S. M. R. Application of hybrid multiagent-based particle swarm optimization to optimal reactive power dispatch. **Electric Power Components and Systems**, Taylor & Francis, v. 36, n. 8, p. 788–800, 2008.

SOARES, A.; ANTUNES, C. H.; OLIVEIRA, C.; GOMES Álvaro. A multi-objective genetic approach to domestic load scheduling in an energy management system. **Energy**, v. 77, p. 144–152, 2014. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544214006689>.

SOSHINSKAYA, M.; CRIJNS-GRAUS, W. H.; GUERRERO, J. M.; VASQUEZ, J. C. Microgrids: Experiences, barriers and success factors. **Renewable and Sustainable Energy Reviews**, v. 40, p. 659–672, 2014. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032114006583>.

STANELYTE, D.; RADZIUKYNIENE, N.; RADZIUKYNAS, V. Overview of demand-response services: A review. **Energies**, MDPI, v. 15, n. 5, p. 1659, 2022.

SUGANTHAN, P. N. Particle swarm optimiser with neighbourhood operator. In: IEEE. **Proceedings of the 1999 congress on evolutionary computation-CEC99 (Cat. No. 99TH8406)**. [S. l.], 1999. v. 3, p. 1958–1962.

SUN, Y.; CHU, S.-C.; HU, P.; WATADA, J.; SI, M.; PAN, J.-S. Overview of parallel computing for meta-heuristic algorithms. **J. Netw. Intell**, v. 7, n. 3, p. 656–684, 2022.

TAJANI, A.; BOGNER-STRAUSS, J. Diretiva (ue) 2018/2001 do parlamento europeu e do conselho de 11 de dezembro de 2018 relativa à promoção da utilização de energia de fontes renováveis (reformulação). **Jornal Oficial da União Europeia**, L 328, p. 82–209, dezembro 2018.

TAJANI, A.; CIAMBA, G. Diretiva (ue) 2019/944 do parlamento europeu e do conselho de 5 de junho de 2019 relativa a regras comuns para o mercado interno da eletricidade e que altera a diretiva 2012/27/ue (reformulação). **Jornal Oficial da União Europeia**, L 158, p. 125–198, junho 2019.

TALBI, E.-G. **Metaheuristics: From Design to Implementation**. [S. l.]: John Wiley Sons, 2009. 593 p. ISBN 978-0-470-27858-1.

TSAI, C.-F.; TSAI, C.-W.; TSENG, C.-C. A new and efficient ant-based heuristic method for solving the traveling salesman problem. **Expert Systems**, v. 20, n. 4, p. 179–186, 2003. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/1468-0394.00242>.

VARDAKAS, J. S.; ZORBA, N.; VERIKOUKIS, C. V. A survey on demand response programs in smart grids: Pricing methods and optimization algorithms. **IEEE Communications Surveys & Tutorials**, IEEE, v. 17, n. 1, p. 152–178, 2014.

VARMA, A. **Information Paper - Market Settlement: Implementation of five-minute settlement, uplift payments and Essential System Services settlement**. [S. l.], 2019.

VELASCO, C. J. Metodologia para o cálculo do valor do serviço e da remuneração dos agentes fornecedores de reservas operativas. **Rio de Janeiro, RJ, Brasil: PUC-Rio, Departamento de Engenharia Elétrica**, 2004.

VERA, Y. E. G.; DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. Energy management in microgrids with renewable energy sources: A literature review. **Applied Sciences**, v. 9, n. 18, 2019. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/9/18/3854>.

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.

WANG, L.; AN, X.; XU, H.; ZHANG, Y. Multi-agent-based collaborative regulation optimization for microgrid economic dispatch under a time-based price mechanism. **Electric Power Systems Research**, Elsevier, v. 213, p. 108760, 2022.

WANG, Z.; WANG, L.; LI, Z.; CHENG, X.; LI, Q. Optimal distributed transaction of multiple microgrids in grid-connected and islanded modes considering unit commitment scheme. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 132, p. 107146, 2021.

WOOD, A.; WOLLENBERG, B.; SHEBLÉ, G. **Power Generation, Operation, and Control**. [S. l.]: Wiley, 2013. ISBN 9780471790556.

XIANGPING, M.; HUAGUANG, Z.; WANYU, T. A hybrid method of ga and bp for short-term economic dispatch of hydrothermal power systems. **mathematics and computers in simulation**, Elsevier, v. 51, n. 3-4, p. 341–348, 2000.

YOUSEF, M. Y.; MOSA, M. A.; ALI, A.; MASRY, S. M. E.; GHANY, A. A. Frequency response enhancement of an ac micro-grid has renewable energy resources based generators using inertia controller. **Electric Power Systems Research**, v. 196, p. 107194, 2021. ISSN 0378-7796. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378779621001759>.

ZHANG, H.; HUI, Q. Parallel multiagent coordination optimization algorithm: implementation, evaluation, and applications. **IEEE Transactions on Automation Science and Engineering**, IEEE, v. 14, n. 2, p. 984–995, 2016.

ZHANG, X.; CHEN, W.; DAI, C.; CAI, W. Dynamic multi-group self-adaptive differential evolution algorithm for reactive power optimization. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 32, n. 5, p. 351–357, 2010.

ZHANG, Y.; LAN, T.; HU, W. A two-stage robust optimization microgrid model considering carbon trading and demand response. **Sustainability**, MDPI, v. 15, n. 19, p. 14592, 2023.

ZHAO, B.; GUO, C.; CAO, Y. A multiagent-based particle swarm optimization approach for optimal reactive power dispatch. **IEEE Transactions on Power Systems**, v. 20, n. 2, p. 1070–1078, 2005.

ZHU, Z.; DU, S.; ZHANG, L.; QI, Q. A new coordinated control strategy to improve the frequency stability of microgrid based on de-loaded capacity of wind turbine. In: **2020 5th Asia Conference on Power and Electrical Engineering (ACPEE)**. [S. l.: s. n.], 2020. p. 645–651.

APÊNDICE A – ALGORITMOS IMPLEMENTADOS

O Algoritmo 1 apresenta a forma como os agentes equipamentos estabelecem sua vizinhança para a troca de informações.

Algoritmo 1: Construção da lista de vizinhos

Entrada: *listaAG_ativos* (lista de agentes ativos), nVZ_{max} (número máximo de vizinhos)

Dados: *listaVZ* (lista vazia de vizinhos)

```

1  início
2      1. Determinar número de agentes ativos:
3       $nAG\_ativos = \dim(listaAG\_ativos)$       /* dim é a dimensão do vetor */
4      2. Fazer avaliação condicional para determinar o número de vizinhos  $nVZ$ :
5      se  $nAG\_ativos \leq nVZ_{max}$  então
6          |  $nVZ = nAG\_ativos - 1$ 
7      senão
8          |  $nVZ = nVZ_{max}$ 
9      fim
10     3. Identificar próprio index, myindex, na listaAG_ativos.
11     4. Atualizar listaAG_ativos e nAG_ativos, retirando sua própria identificação:
12      $nAG\_ativos = \dim(listaAG\_ativos)$       /* dim é a dimensão do vetor */
13     5. Determinar a lista de vizinhos:
14     para i de 0 até ( $nVZ - 1$ ) faça
15         |  $indexVZ = myindex + prx\_inteiro(i/2) \cdot (-1)^i$       /* prx_inteiro(a) é o
16         | inteiro seguinte ao número a */
17         se  $indexVZ \geq nAG\_ativos$  então
18             |  $indexVZ = indexVZ - nAG\_ativos$ 
19         fim
20     fim
21      $listaVZ = listaVZ + listaAG\_ativos[indexVZ]$ 
21 fim

```

Saída: *listaVZ*

O Algoritmo 2 apresenta todas as etapas de implementação de um PSO padrão.

Algoritmo 2: PSO padrão

Dados: n_{var} , F_{obj} (função objetivo), LI (limite inferior) e LS (limite superior).

Entrada: n_p , it_{max} , ω , c_1 e c_2

1 **início**

2 P1. Inicializar randomicamente a população inicial de posição das partículas, P_0 , e as velocidades, limitando-as por LI e LS

3 P2. Calcular o valor de $F_{obj}(P_0)$

4 P3. Atribuir valores de $fit_{pbest} = F_{obj}(P_0)$ e $P_{best} = P_0$

5 P4. Verificar o mínimo de fit_{pbest} e atribuir a fit_{gbest} , bem com a partícula correspondente para $gbest$.

6 **para** k de 1 até k_{max} **faça**

7 P5. Atualizar velocidades usando 3.3.

8 P6. Atualizar posições usando 3.4.

9 P7. Para todas as variáveis de x fora intervalo $[LI, LS]$, atribuir o valor limite correspondente.

10 P8. Calcular o valor de F_{obj} para a nova população P_k .

11 P9. Para cada elemento da população, comparar o valor obtido com o valor armazenado em fit_{pbest} . Se o valor atualizado for menor, a posição correspondente deve ser atualizada tanto em P_{best} como em fit_{pbest} .

12 P10. Avaliar se há algum valor em fit_{pbest} inferior a fit_{gbest} , se houver, o valor deve ser armazenado em fit_{gbest} , bem como a partícula correspondente, em $gbest$.

13 **fim**

14 **fim**

Saída: $gbest$ (melhor solução encontrada)

O Algoritmo 3 apresenta a sequência de etapas de implementação de um MAPSO.

Algoritmo 3: MAPSO

Dados: n_{var} , F_{obj} (função objetivo), LI (limite inferior) e LS (limite superior).

Entrada: n_p , it_{max} , ω , c_1 e c_2

```

1  início
2  M1. Criação do ambiente de vizinhança entre partículas e definição da quantidade de
    vizinhos cada partícula deve ter.
    /* MESMAS ETAPAS PSO PADRÃO ver Algoritmo 2 */
3  P1, P2, P3 e P4
4  para  $it$  de 1 até  $it_{max}$  faça
    /* ETAPA DE COMPETIÇÃO E COOPERAÇÃO ENTRE PARTÍCULAS */
5  M2. Cada partícula compara sua função fitness com as partículas vizinhas:
6      M2.1 Se a partícula for a melhor, ela mantém seu valor para as próximas
7      etapas.
8      M2.2 Se a partícula não for a melhor, ela será atualizada combinando seus
9      valores com os da melhor partícula da sua vizinhança.
10 M3. Para as partículas modificadas:
11 M3.1 Quando necessário, colocar as variáveis de  $x$  dentro do intervalo
12  $[LI, LS]$ .
13 M3.2 Calcular o valor de  $F_{obj}$ .
14 M3.3 Comparar os valores obtidos no item anterior com  $fit_{pbest}$  e  $fit_{gbest}$ 
15 e atualizá-los quando for o caso.
    /* MESMAS ETAPAS PSO PADRÃO ver Algoritmo 2 */
16 P5, P6, P7, P8, P9 e P10
    /* ETAPA DE AUTOAPRENDIZADO */
17 fim
18 fim
Saída:  $g_{best}$  (melhor solução encontrada)

```

A função **ambiente_solucão** é apresentada pelo Algoritmo 4, como resultado tem-se um conjunto de índices $[i, j]$, que são os endereços das partículas vizinhas. Informação necessária para execução da etapa de competição e cooperação do MAPSO.

Algoritmo 4: Construção do ambiente de soluções do MAPSO - Parte 1

```

1  Função ambiente_solucão(número de linhas, colunas e partículas vizinhas):
    Entrada: linha, coluna, num_part_vz
    Resultado: indx_lin, indx_col      /* cada linha das matrizes compõe os
                                         endereços [x,y] usados na etapa de competição e
                                         cooperação */
2  para x de 1 até (linha·coluna) faça
3      para y de 1 até (num_part_vz + 1) faça
4          /* guarda o próprio endereço */
5          se y = 1 então
6              indx_lin[x,y] ← il
7              indx_col[x,y] ← ic
8          senão
9              /* guarda o endereço dos vizinhos */
10             indx_lin[x,y], indx_col[x,y] ← guardar_indices(x,y,il,ic)
11          fim
12      fim
13  fim
    retorna indx_lin, indx_col

```

A função **guardar_indices**, observada em Algoritmo 5, tem como resposta dois números inteiros que correspondem à linha e à coluna da partícula vizinha. Essa função foi implementada para um espaço de solução plano com apenas quatro vizinhos; entretanto, é possível expandi-la para que mais vizinhos possam ser adicionados.

Algoritmo 5: Construção do ambiente de soluções do MAPSO - Parte 2

```

1  Função guardar_indices(x,y,il,ic):
2      caso y = 2 faça
3          se ic ≠ coluna então
4              indx_lin[x,y] ← il
5              indx_col[x,y] ← ic + 1          /* endereço vizinho da direita */
6          senão
7              indx_lin[x,y] ← il
8              indx_col[x,y] ← 1
9          fim
10     caso y = 3 faça
11         se ic = 1 então
12             indx_lin[x,y] ← il
13             indx_col[x,y] ← ic - 1          /* endereço vizinho da esquerda */
14         senão
15             indx_lin[x,y] ← il
16             indx_col[x,y] ← coluna - 1
17         fim
18     caso y = 4 faça
19         se il ≠ linha então
20             indx_lin[x,y] ← il + 1
21             indx_col[x,y] ← ic          /* endereço vizinho de baixo */
22         senão
23             indx_lin[x,y] ← 1
24             indx_col[x,y] ← ic
25         fim
26     caso y = 5 faça
27         se il = 1 então
28             indx_lin[x,y] ← il - 1
29             indx_col[x,y] ← ic          /* endereço vizinho de cima */
30         senão
31             indx_lin[x,y] ← linha - 1
32             indx_col[x,y] ← ic
33         fim
34     retorna indx_lin[x,y],indx_col[x,y]
35 fim

```

O Algoritmo 6 determina qual a dimensão da matriz que torna o número de partículas do MAPSO semelhante ao especificado para o PSO. Usado apenas para que a comparação entre os dois seja mais justa.

Algoritmo 6: Aproximar número de soluções do PSO para o ambiente do MAPSO

```

1  Função pso2mapso(número de partículas):
    Entrada:  $n$ 
    Resultado: linha, coluna          /* ambiente de soluções mapso */
2  linha = inteiro( $\sqrt{n}$ )
3  erro =  $|n - \text{linha}^2|/n$ 
4  se resto( $n/\sqrt{n}$ ) = 0 ou erro  $\leq 0.01$  então
5      coluna  $\leftarrow$  linha
6      retorna linha, coluna          /* fim algoritmo */
7  senão
8      para  $i$  de 1 até 3 faça
9          coluna  $\leftarrow$  linha +  $i$ 
10         erro1  $\leftarrow |n - \text{linha} \cdot \text{coluna}|/n$ 
11         se erro1 = 0 então
12             retorna linha, coluna          /* fim algoritmo */
13         fim
14         erro2  $\leftarrow |n - (\text{linha} - 1) \cdot \text{coluna}|/n$ 
15         se erro2 = 0 então
16             linha = linha - 1
17             retorna linha, coluna          /* fim algoritmo */
18         fim
19         se erro1  $\leq 0.1$  ou erro2  $\leq 0.1$  então
20             se erro1  $\leq$  erro2 então
21                 retorna linha, coluna          /* fim algoritmo */
22             senão
23                 linha  $\leftarrow$  linha - 1
24                 retorna linha, coluna          /* fim algoritmo */
25             fim
26         fim
27     fim
28 fim
29 fim

```

O Algoritmo 7 apresenta a inicialização do PSO realizada dentro de cada um dos agentes participantes da distribuição de meta-heurísticas.

Algoritmo 7: Inicialização das variáveis PSO

```

1 Função inicializar_PSO(dic_agentes, n, max_iter):
2   f ← cost_function           /* função custo para os agentes ativos */
3   LI, LS ← dic_agentes       /* limites inferiores e superiores */
4   nvar ← número_agentes_ativos w ← vetor(0,9 ; 0)[max_iter] /* vetor de
    pesos, que varia entre 0,9 e 0, cujos valores intermediários são
    igualmente espaçados */
5   v ← matriz_zeros[n,nvar]   /* matriz inicial de velocidades */
    /* matriz inicial de posições, variáveis geradas com base nos
    seus valores mínimos e máximos, contidos em LI e LS */
6   x ← rand_uniforme(LI ; LS)[n,nvar]
7   pbest ← x
8   fit_pbest ← f(x) /* cálculo de função custo com os valores iniciais
    */
9   arg_min ← argumento_valor_mínimo (fit_pbest)
10  fit_gbest ← fit_pbest(arg_min)
11  gbest ← pbest(arg_min)
12  retorna x, v, pbest, fit_pbest, gbest, fit_gbest, w
13 fim

```

O Algoritmo 8 apresenta a etapa de iteração do PSO executada a cada novo passo do Mosaik após inicializado o processo de otimização.

Algoritmo 8: Iteração PSO

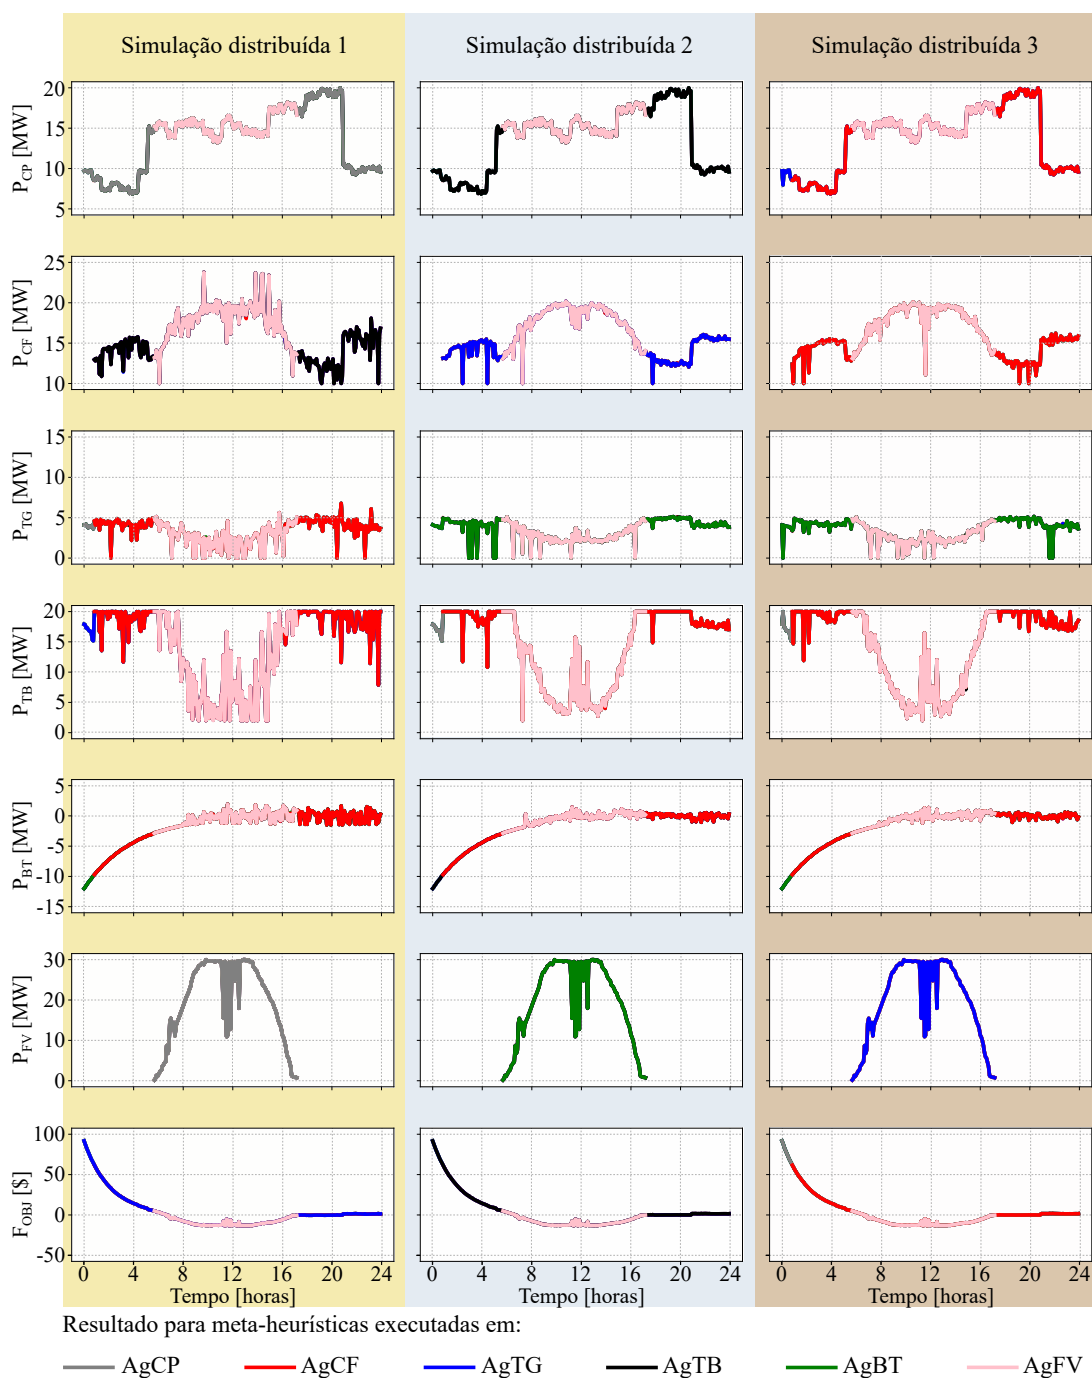
```

1 Função iteracao_PSO(x, v, pbest, fit_pbest, gbest, fit_gbest, w):
2   rdm_g ← rand_uniforme(0 ; 1)[n,nvar]
3   rdm_p ← rand_uniforme(0 ; 1)[n,nvar]
4   v ← w[it]*v + c1*(gbest - x)*rdm_g + c2*(pbest - x)*rdm_p
5   x ← x + v
6   para i de 1 até nvar faça
7     se x[:,i] ≤ LI[i] então
8       | x[:,i] ← LI[i]
9     fim
10    se x[:,i] ≥ LS[i] então
11      | x[:,i] ← LS[i]
12    fim
13  fim
14  fit ← f(x)
15  retorna x, v, pbest, fit_pbest, gbest, fit_gbest, w
16 fim

```

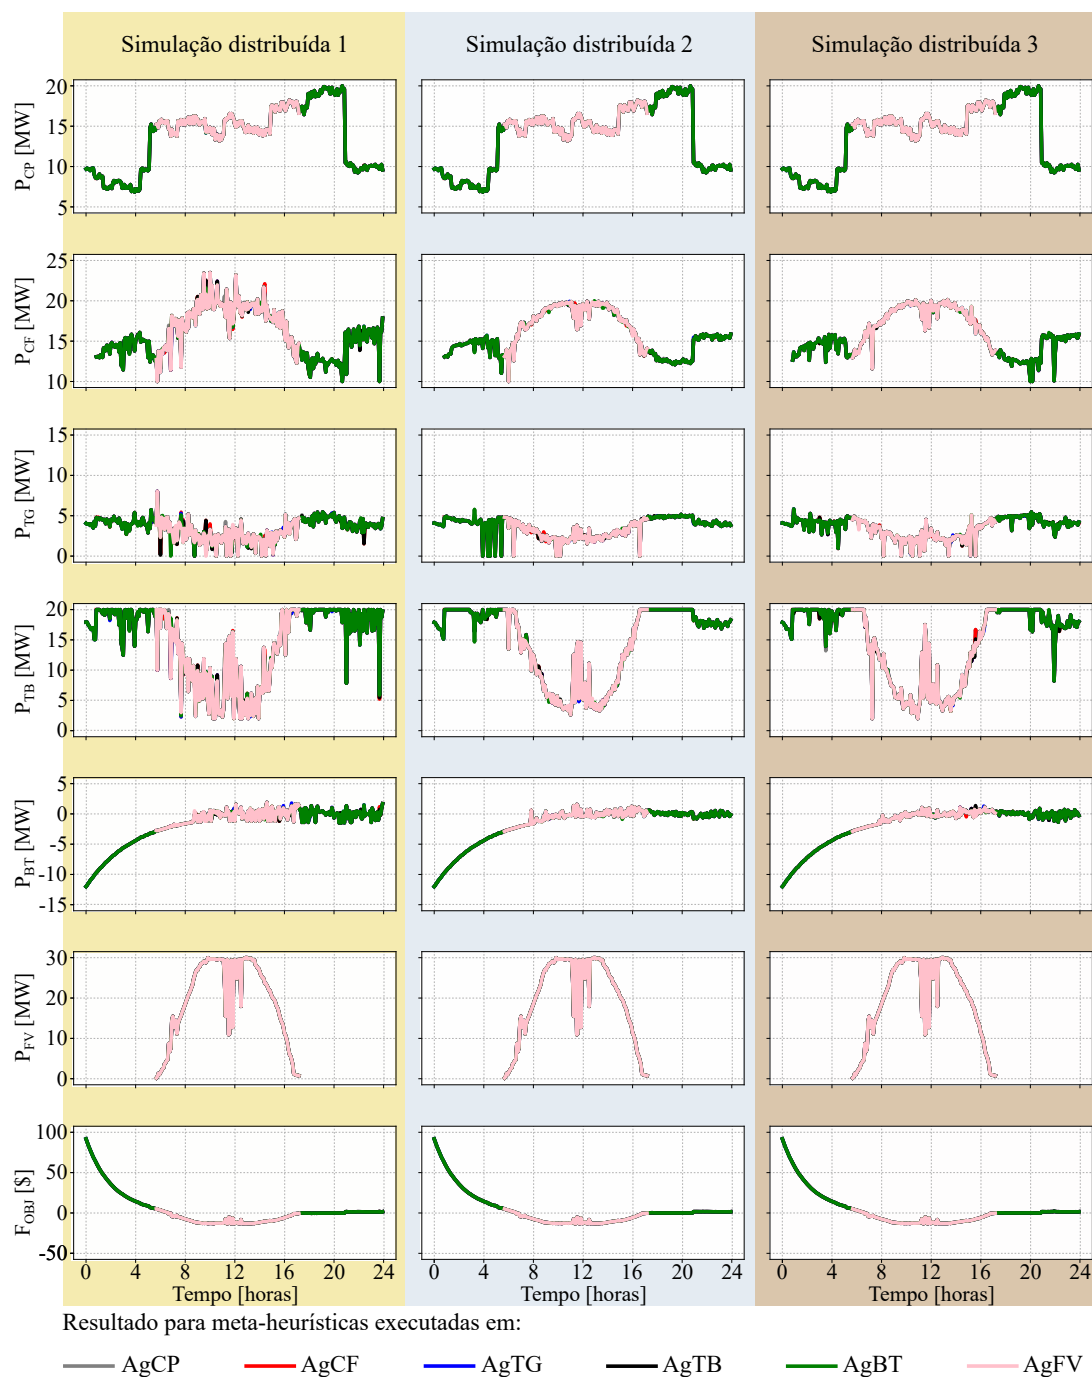
APÊNDICE B – RESULTADOS PARA A SIMULAÇÃO DE UM DIA APÓS READEQUAÇÕES DOS MODELOS

Figura 57 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada iteração.



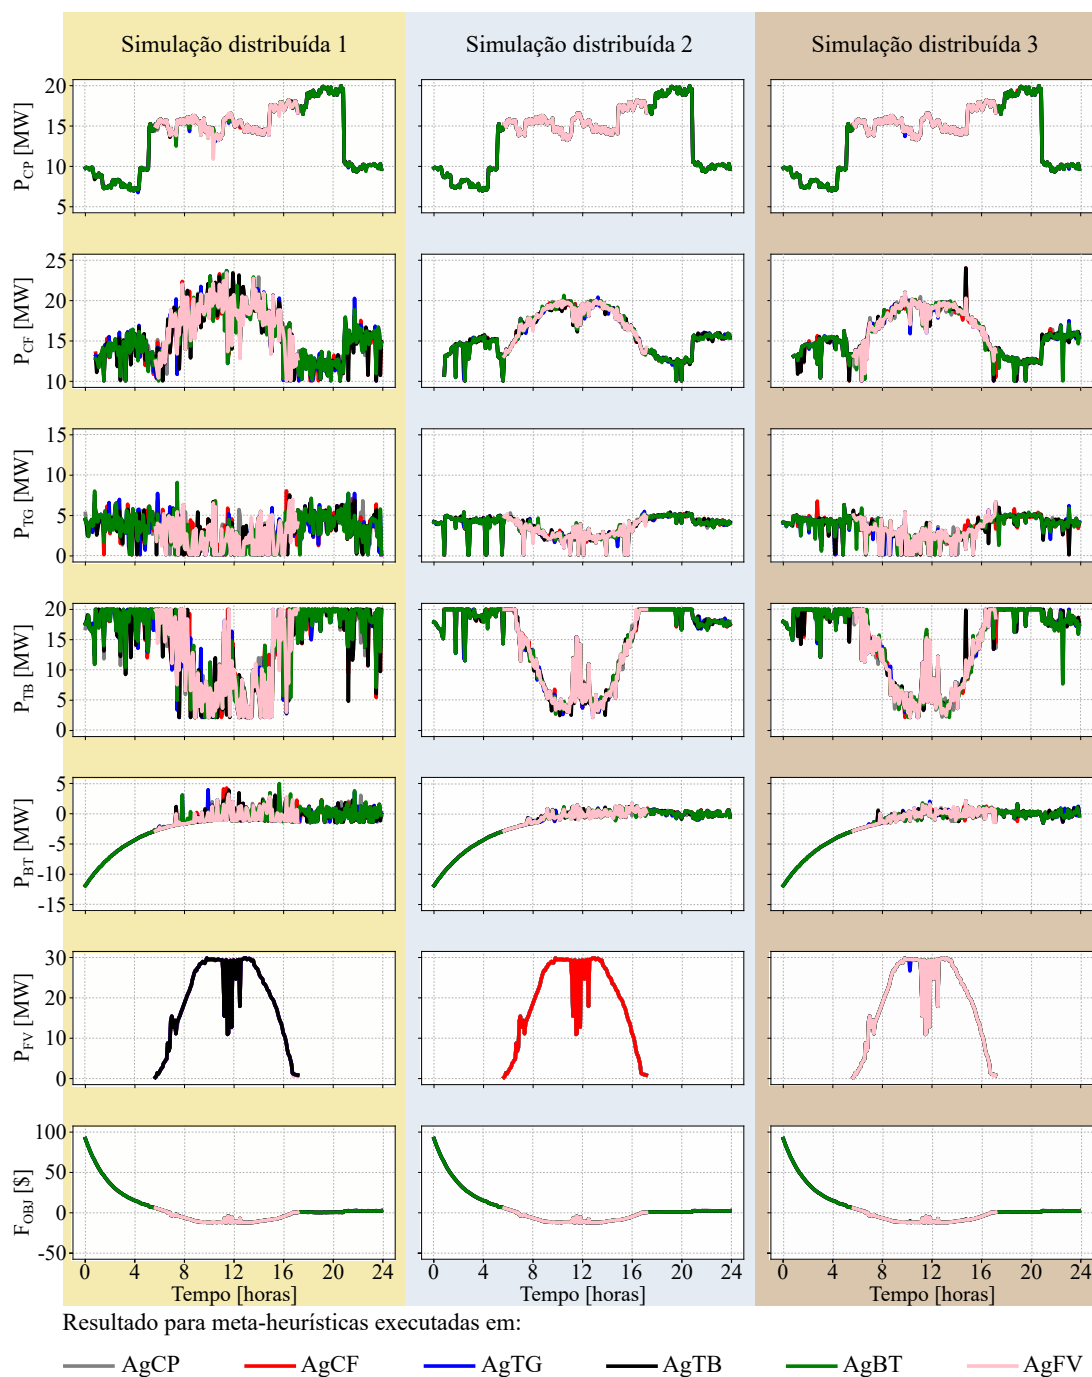
Fonte: elaborada pela autora (2025).

Figura 58 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada 10 iterações.



Fonte: elaborada pela autora (2025).

Figura 59 – Convergência entre meta-heurísticas em paralelo com troca de mensagens a cada 100 iterações.



Fonte: elaborada pela autora (2025).