



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

# **UMA ABORDAGEM EVOLUTIVA E HÍBRIDA PARA A SOLUÇÃO DE PROBLEMAS DE FLUXO DE POTÊNCIA ÓTIMO**

**CAROLINA GIL MARCELINO**

Orientador: Paulo Eduardo Maciel de Almeida  
CEFET-MG

Coorientadora: Elizabeth Fialho Wanner  
CEFET-MG

BELO HORIZONTE  
JUNHO DE 2017

**CAROLINA GIL MARCELINO**

# **UMA ABORDAGEM EVOLUTIVA E HÍBRIDA PARA A SOLUÇÃO DE PROBLEMAS DE FLUXO DE POTÊNCIA ÓTIMO**

Tese de Doutorado apresentada ao Programa de Pós-graduação em Modelagem Matemática e Computacional do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito final para a obtenção do título de Doutor em Modelagem Matemática e Computacional.

Área de concentração: Modelagem Matemática e Computacional

Linha de pesquisa: Sistemas Inteligentes

Orientador: Paulo Eduardo Maciel de Almeida  
CEFET-MG

Coorientadora: Elizabeth Fialho Wanner  
CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL  
BELO HORIZONTE  
JUNHO DE 2017



SERVIÇO PÚBLICO FEDERAL  
MINISTÉRIO DA EDUCAÇÃO  
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
COORDENAÇÃO DO PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

ATA DA 3ª SESSÃO PÚBLICA DE APRESENTAÇÃO E DEFESA DE TESE DE DOUTORADO, REQUISITO PARA A OBTENÇÃO DO TÍTULO DE DOUTOR EM MODELAGEM MATEMÁTICA E COMPUTACIONAL. Em 09 de junho de 2017, no Auditório do Prédio do Departamento de Eletrotécnica e Eletrônica – Prédio 19 – 2º Andar, Campus II do Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG, reuniu-se, às 9 horas, a Banca Examinadora, designada para este fim, pelo Colegiado do Programa de Pós-Graduação *Stricto Sensu* em Modelagem Matemática e Computacional, constituída pelos professores: Dr. Paulo Eduardo Maciel de Almeida (Orientador), Dr<sup>a</sup>. Elizabeth Fialho Wanner (Coorientadora), Dr. Heder Soares Bernadino, Dr. Felipe Campelo Franca Pinto, Dr. Marcone Jamilson Freitas Souza e Dr. Flávio Vinícius Cruzeiro Martins, para examinar o trabalho da doutoranda Carolina Gil Marcelino, sob o título “*UMA ABORDAGEM EVOLUTIVA E HÍBRIDA PARA SOLUÇÃO DE PROBLEMAS DE FLUXO DE POTÊNCIA ÓTIMO*”. O Prof. Dr. Paulo Eduardo Maciel de Almeida, como Presidente da Banca Examinadora, declarou aberta a sessão, passando a palavra à candidata, para que esta expusesse sua Tese de doutorado. Terminada a exposição, o Presidente passou a palavra aos membros da Banca Examinadora, que iniciaram a arguição, na seguinte ordem: Dr. Heder Soares Bernadino, Dr. Felipe Campelo Franca Pinto, Dr. Marcone Jamilson Freitas Souza, Dr. Flávio Vinícius Cruzeiro Martins, Dr<sup>a</sup>. Elizabeth Fialho Wanner e Dr. Paulo Eduardo Maciel de Almeida. Terminada a arguição, reuniu-se a Banca Examinadora, isoladamente, para deliberação. Terminada a reunião, o Presidente deu conhecimento à candidata de que sua Tese foi aprovada, devendo a redação final da Tese de Doutorado incorporar as contribuições da Banca Examinadora. A Banca definiu ainda que a entrega dos exemplares com a redação final deverá ser feita em, no máximo, 90 (noventa) dias. Nada mais havendo a tratar, o Presidente declarou encerrada a sessão, cujas atividades são registradas nesta Ata, lavrada, a qual assina, juntamente com os demais membros da Banca Examinadora. Belo Horizonte, 09 de junho de 2017.

Prof. Dr. Paulo Eduardo Maciel de Almeida  
Centro Federal de Educação Tecnológica de Minas Gerais

Prof<sup>a</sup>. Dr<sup>a</sup>. Elizabeth Fialho Wanner  
Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Heder Soares Bernadino  
Universidade Federal de Juiz de Fora

Prof. Dr. Felipe Campelo Franca Pinto  
Universidade Federal de Minas Gerais

Prof. Dr. Marcone Jamilson Freitas Souza  
Universidade Federal de Ouro Preto

Prof. Dr. Flávio Vinícius Cruzeiro Martins  
Centro Federal de Educação Tecnológica de Minas Gerais

M314a Marcelino, Carolina Gil.  
Uma abordagem evolutiva e híbrida para a solução de problemas de  
fluxo de potência ótimo / Carolina Gil Marcelino. – 2017.  
xviii, 120 f. : il.

Tese de doutorado apresentada ao Programa de Pós-Graduação em  
Modelagem Matemática e Computacional.

Orientador: Paulo Eduardo Maciel de Almeida.

Coorientadora: Elizabeth Fialho Wanner.

Referências: f. 190-120.

Tese (doutorado) – Centro Federal de Educação Tecnológica de  
Minas Gerais.

1. Inteligência artificial – Teses. 2. Algoritmos – Teses. 3. Sistemas  
de energia elétrica – Modelagem matemática – Teses. 4. Otimização  
matemática – Teses. I. Almeida, Paulo Eduardo Maciel de. II. Wanner,  
Elizabeth Fialho. III. Centro Federal de Educação Tecnológica de Minas  
Gerais. IV. Título.

CDD 006.3

Aos meus avós e aos meus pais. Me ensinaram e inspiraram a ser uma pessoa de bem.

# Agradecimentos

Ser grato é uma das maiores qualidades que uma pessoa pode adquirir ao longo da vida. Externo aqui a minha gratidão para aqueles que me ajudaram nestes anos a construir uma nova versão de mim. A Deus, por prover o pleno sustento durante a caminhada. Aos meus pais Herbert e Marília, aos meus irmãos Herbert F., Camila e Thiago por todo investimento de amor, carinho, paciência e também financeiro. Sem vocês nada poderia ter acontecido, os amo incondicionalmente. Aos familiares pelo apreço e bons momentos.

Aos meus orientadores. Palavras muitas vezes não são suficientes para expressar tudo que se sente. Prof. Paulo Eduardo Maciel de Almeida, a caminhada junto ao senhor desde o mestrado enriqueceu minha vida de conhecimento e coragem. Olhar para os anos anteriores, me faz enxergar o quanto eu cresci. Obrigada por possuir uma resiliência paternal no decorrer da orientação e por sempre acreditar na minha capacidade. Prof.<sup>a</sup> Elizabeth Fialho Wanner, sou grata a você pela orientação aplicada à minha formação acadêmica e pessoal. Por apoiar sempre, pelo carinho e amizade. Por seu aguçado instinto maternal, por sua tenacidade em enxergar a vida e por extrapolar limites. Tudo isto me impulsionou a ser melhor. Certamente, esta orientação conjunta de vocês me fez bem!

Ao Prof. Vladimiro Miranda e ao Dr. Leonel Carvalho, agradeço por me receberem no INESC TEC, instituto associado à Faculdade de Engenharia do Porto (FEUP), em um período de mobilidade. Obrigada pela oportunidade e confiança. Trabalhar neste grupo de pesquisa me deu uma visão amplamente aplicada para a realidade presente nos problemas reais da área da energia elétrica. Ao Leonel, obrigada pela disponibilidade e amizade.

Ao Dr. Marcel Weil, agradeço por me receber em um estágio doutoral no ITAS do *Karlsruhe Institute für Technologie* (KIT). Obrigada por me motivar a conhecer novas tecnologias e pelo incentivo em aperfeiçoar um sistema *microgrid* híbrido. Por me receber no *ITAS-SysTEEM* tão bem e me dar a oportunidade de trabalhar junto ao Manuel Baumann, um grande ser humano que hoje posso chamar de amigo. A vocês um sonoro *Vielen Dank!*

Nada se constrói sozinho, por isso meus sinceros agradecimentos aos alunos de IC que trabalharam comigo: Daniel Fonseca, Vitor Peixoto e Gustavo Borba, obrigada pela responsabilidade dedicada à pesquisa, pela amizade construída meio ao caos! Aos amigos que adquiri por onde andei: Denise Souza, Felipe Duarte, Samara Leal, Rafaela Moreira, Moisés Ramos, Victor Torres, Renan Santos, Nathalia Rodrigues, Renato Neves, Natália Candian, Maryegli Fuss, Christina Merz, Franka Steiner e Aditya Desai.

Ao CEFET-MG, agradeço por possibilitar grandes feitos nestes anos da minha vida. Ao corpo docente do PPGMMC e também à equipe administrativa. Ao financiamento investido pela CAPES, FAPEMIG, CNPq e BE MUNDUS *project* na formação adquirida.

*“Não é o mais forte que sobrevive, nem o mais inteligente, mas o que melhor se adapta às mudanças.” (Charles Darwin, uma paráfrase de: *On the Origin of Species*, 1872)*

# Resumo

Nos últimos anos, tem-se percebido uma preocupação crescente em relação ao uso racional da energia. Os países desenvolvidos têm realizado campanhas relacionadas à projeção e prospecção de novas soluções eficazes na indústria, entre elas a busca objetiva pelo uso adequado das fontes de energia elétrica. Esta forma de energia é considerada de suma importância para o desenvolvimento social e econômico. Garantir a eficiência energética visando a sustentabilidade e a minimização do uso de recursos se torna um grande desafio. Controlar grandes sistemas de geração e transmissão de energia elétrica é uma tarefa complexa, por ser um problema não-linear e possuir um alto número de restrições agregadas. Neste contexto, o estudo e a proposição de novos métodos para solucionar problemas de Fluxo de Potência Ótimo (OPF) se tornam temas de alta prioridade no cenário mundial. Este trabalho propõe e implementa algoritmos evolucionários híbridos e os aplica para solução destes problemas. Dois novos algoritmos híbridos C-DEEPSO e hC-DEEPSO são propostos e apresentados, os quais resolvem dada a dificuldade de cada problema elétrico em sua necessidade os problemas: de despacho elétrico em uma usina hidrelétrica, do controle da geração elétrica em uma planta eólica, os problemas OPF com restrições de segurança em grandes redes e o problema do despacho elétrico em um modelo de *microgrid* híbrido aperfeiçoado. Neste caso, um método de tomada de decisão foi utilizado *a posteriori* para definir o melhor sistema de armazenamento de energia para a rede proposta. Experimentos simulados foram executados em um computador de alto desempenho, e a análise deles foi realizada a partir de técnicas de inferência estatística, indicando que os algoritmos propostos se mostraram eficientes e competitivos na solução dos problemas estudados.

**Palavras-chave:** Inteligência Computacional; Algoritmos Evolucionários; Hibridização; Fluxo de Potência Ótimo; Eficiência Energética.

# Abstract

In recent years, a growing concern about the rational use of energy has been noticed. Developed countries have carried out campaigns related to the projection and prospection of effective solutions in the industry. Among them, the objective search for adequate ways to use electric energy sources is very common. This particular energy source is considered to be very important for social and economic development. Ensuring energetic efficiency aiming at sustainability and minimizing the use of resources becomes a big challenge. Controlling large power generation and transmission systems is a complex task, given the high number of aggregate constraints. In this context, the study and proposal of new methods to solve Optimal Power Flow (OPF) problems becomes a matter of priority in the World scenario. This work proposes hybrid evolutionary algorithms and the application of them to solve these problems. Two versions of a hybrid algorithm are proposed and presented, which solve: the problem of electrical dispatch in a hydroelectric power plant, the problem of electrical dispatch in a wind power plant, OPF problems with security constraints on large networks and electrical dispatch problem in a new hybrid microgrid model, in which case a decision-making method was used a posteriori to define the best battery energy storage system for proposed grid network. Simulated experiments were conducted using a high performance computer, and analysis was realized by means of statistical inference. Conclusions indicate that the proposed algorithms showed to be efficient and competitive to the solution of studied problems.

**Keywords:** Computational Intelligence; Evolutionary Algorithms; Hybridization; Optimal Power Flow; Energy Efficiency.

# Lista de Figuras

Figura 1 – Breve Taxonomia da IA. . . . .	2
Figura 2 – Comparativo da matriz Energética em 2015. Fonte: EPE (2016) . . . . .	5
Figura 3 – Comparativo da matriz Energética entre os anos 2014 e 2015. Fonte: EPE (2016) . . . . .	5
Figura 4 – Fontes de energia renováveis. Possuem o potencial de fornecer 3078 vezes as atuais necessidades globais de energia. Fonte: adaptado de (ELLABBAN; ABU-RUB; BLAABJERG, 2014)). . . . .	6
Figura 5 – Representação gráfica do funcionamento TOPSIS em 2D. Adaptado de: (CHAUHAN; VAISH, 2013) . . . . .	39
Figura 6 – Fluxograma do modelo MCDA adotado para avaliação de tecnologias. . . . .	40
Figura 7 – Exemplo dos principais componentes presentes em uma UHE. A energia potencial da água é transformada em energia cinética, pela força da gravidade presente no conduto forçado. Por sua vez, a energia mecânica pode ser observada pelo movimento giratório da turbina pela água. O gerador então produz energia elétrica que é transformada e posteriormente transmitida por meio das linhas. Adaptado de Tucuri (Acessado em 16/06/2017). . . . .	42
Figura 8 – Representação de uma Usina Eólica - <i>Offshore</i> . A velocidade do vento proporciona a rotação da turbina por meio de suas pás. O gerador converte a energia cinética em energia elétrica, que é então, transmitida por um cabo submarino até o transformador onde a energia elétrica é convertida para transmissão. Adaptado de Marcelino et al. (2016). . . . .	48
Figura 9 – Esquema elétrico de um típico sistema de controle WPP- <i>Offshore</i> . . . . .	49
Figura 10 – Diagrama unifilar do Sistema IEEE de 57 barras . . . . .	50
Figura 11 – Diagrama unifilar do Sistema IEEE de 118 barras. . . . .	52
Figura 12 – Diagrama unifilar do Sistema IEEE de 300 barras . . . . .	53
Figura 13 – Configuração simplificada de um HMGS incluindo BESS. . . . .	54
Figura 14 – Série de dados que representa as entradas para o modelo HMGS. A velocidade média anual do vento está na faixa de $[1,6] m/s$ . A radiação solar presente nesta área é baixa e está em torno de $[0,1] W/m^2$ . A demanda de carga foi gerada com dados de 24 horas para 100 casas e replicadas para um ano. . . . .	55
Figura 15 – Visão geral do modelo simplificado para otimização HMGS. . . . .	58
Figura 16 – Ilustração da equação de movimento para C-DEEPSO, tendo como atrator o termo de assimilação em que no PSO é utilizado o termo de memória. . . . .	61

Figura 17 – Exemplos de trajetórias espirais logarítmicas usando a Equação(37). Diferentes valores de taxa de convergência $r$ produzem comportamentos de forma espiral distintos. No gráfico à esquerda pode ser vista uma trajetória usando $r = 0.95; \theta = \pi/4$ , enquanto à direita é percebida uma trajetória usando $r = 0.90; \theta = \pi/4$ . . . . .	64
Figura 18 – Exemplos de trajetórias espirais logarítmicas usando a Equação (41). Valores diferentes da taxa de convergência $r$ produzem comportamentos de forma espiral distintos. (a) representa a trajetória espiral usando $r =$ $0,95; \theta = \pi/4$ e (b) mostra a trajetória espiral usando $r = 0,90; \theta =$ $\pi/4$ . A coluna do lado direito mostra uma versão rotacionada da espiral correspondente. . . . .	66
Figura 19 – Exemplos de trajetórias espirais logarítmicas usando a Equação (41). Valores diferentes da taxa de convergência $r$ produzem comportamentos de forma espiral distintos. (a) trajetória usando $r = 0.95, \theta = \pi/4$ e $popsize = 25$ , (b) $r = 0.95, \theta = \pi/4$ e $popsize = 50$ , (c) $r = 0.80,$ $\theta = \pi/4, popsize = 25$ e (d) $r = 0.95, \theta = \pi/7$ e $popsize = 25$ . . . . .	66
Figura 20 – Um exemplo de uma espiral inversa aditiva, em um espaço tridimensional, vista do ponto central $(0,0,0)$ . . . . .	67
Figura 21 – Representação gráfica da Função de Rosenbrock - 2D . . . . .	70
Figura 22 – Exemplo de convergência - Função de Rosenbrock - 2D . . . . .	70
Figura 23 – Curva de convergência média - Sistema 57 barras/ ORDP . . . . .	72
Figura 24 – Gráficos de Caixa - Sistema 57 barras/ ORDP . . . . .	73
Figura 25 – Resultado do Teste de Tukey - Sistema 57 barras/ ORDP . . . . .	74
Figura 26 – <i>Boxplot</i> comparativo entre os algoritmos C-DEEPSO e DE/best/1/bin. . . . .	78
Figura 27 – Fronteira de Pareto para demanda de energia de $320MW$ . . . . .	78
Figura 28 – Comparação entre Fronteiras de Pareto combinadas. . . . .	80
Figura 29 – Teste de Tukey - <i>S-metric</i> de NSGA-II e SPEA2. . . . .	81
Figura 30 – Perfil de potência - saída da WPP) (ERLICH et al., 2014b). . . . .	82
Figura 31 – Potência de saída gerada pela WPP (resultado médio) - uma comparação entre os algoritmos C-DEEPSO, MVMO e DEEPSO. . . . .	83
Figura 32 – Expansão (cenários 14-31). . . . .	83
Figura 33 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 57 barras no problema ORPD. . . . .	91
Figura 34 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 57 barras no problema OARPD. . . . .	91

Figura 35 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 118 barras no problema ORPD . . . . .	92
Figura 36 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 300 barras no problema ORPD. . . . .	93
Figura 37 – Histograma do Teste de Permutação em que os algoritmos PSO e C-DEEPSO são comparados. O resultado indica com 95% de confiança que existem diferenças entre as médias apresentadas pelos algoritmos, já que o ponto observado está fora dos limiares de confiança. . . . .	96
Figura 38 – Exemplo da operação do sistema para o verão - Dados de entrada: vento, radiação solar e carga. . . . .	97
Figura 39 – Exemplo da operação do sistema para o inverno - Dados de entrada: vento, radiação solar e carga. . . . .	97
Figura 40 – Parcela anual total de geração: eólica, radiação solar, excedente e rede pública. . . . .	98
Figura 41 – Geração de eletricidade por hora (h)/ano para o modelo HMGS via otimização realizada pelo algoritmo C-DEEPSO. . . . .	99
Figura 42 – Geração de eletricidade por hora (h)/ano para o modelo HMGS via otimização realizada pelo algoritmo C-DEEPSO. . . . .	99
Figura 43 – Obtenção de pesos individuais e médios a partir dos especialistas em HMGS. . . . .	100
Figura 44 – Resultados de TOPSIS a partir de C-DEEPSO e AHP. . . . .	101

# Lista de Tabelas

Tabela 1 – Escala de comparação de pareamento AHP. . . . .	36
Tabela 2 – Índices de consistência. Fonte (SAATY, 1987) . . . . .	38
Tabela 3 – Coeficientes Operativos. Fonte: (MARCELINO, 2012) . . . . .	42
Tabela 4 – Parâmetros usados no modelo . . . . .	43
Tabela 5 – Sistema IEEE 41 - WPP . . . . .	49
Tabela 6 – Dados de entrada tecno-econômicos para o BESS dentro do HMGS considerado valores de custo médio. . . . .	56
Tabela 7 – Parâmetros utilizados no modelo. . . . .	56
Tabela 8 – Parâmetros usados para gerar a trajetória espiral em 2D . . . . .	64
Tabela 9 – Parâmetros usados para gerar a Figura 19. . . . .	65
Tabela 10 – Comparativo dos resultados da otimização - media ( $M$ ) e desvio ( $D$ ) . .	71
Tabela 11 – Comparando resultados com T-test - Função de Rosenbrock . . . . .	72
Tabela 12 – Valores médios e de desvio padrão para diferentes centros para geração de amostras espirais logarítmicas. . . . .	75
Tabela 13 – Comparação de resultados usando T-test em uma avaliação <i>post hoc</i> . .	75
Tabela 14 – Parâmetros de inicialização dos algoritmos mono e multiobjetivo . . . .	77
Tabela 15 – Relatório geral referente à demanda de $320MW$ . . . . .	79
Tabela 16 – Resultado da Análise de Variância - <i>S-metric</i> . . . . .	81
Tabela 17 – Definição de parâmetros de inicialização de C-DEEPSO. . . . .	82
Tabela 18 – Resultados dos algoritmos C-DEEPSO, DEEPSO e MVMO . . . . .	84
Tabela 19 – Resultados dos algoritmos C-DEEPSO, DEEPSO and MVMO . . . . .	85
Tabela 20 – Resultados da ANOVA e do Teste de Tukey. . . . .	87
Tabela 21 – Resultado da ANOVA e do Teste de Tukey. . . . .	88
Tabela 22 – Parâmetros de inicialização do algoritmo hC-DEEPSO . . . . .	90
Tabela 23 – Valores médios e de desvio padrão para hC-DEEPSO, DEEPSO, ICDE e MVNO ( os três últimos extraídos de (ERLICH et al., 2014b)) em problemas de ORPD e OARDP usando os três cenários de teste. . . . .	94
Tabela 24 – Comparação de resultados usando T-test em uma avaliação <i>post hoc</i> nos problemas ORDP. . . . .	95
Tabela 25 – Comparação de resultados usando T-test em uma avaliação <i>post hoc</i> nos problemas OARDP. . . . .	95
Tabela 26 – Parâmetros de inicialização dos algoritmos. . . . .	96
Tabela 27 – Resultados de otimização obtido para cada BESS . . . . .	100

# Lista de Quadros

Quadro 1 – Vantagens e Desvantagens das técnicas empregadas na solução de OPF. . . . .	16
Quadro 2 – Sumário de métodos já utilizados para solução de problemas OPF. . .	17
Quadro 3 – Sumário de métodos já utilizados para solução de problemas OPF. . .	18
Quadro 4 – Características do Sistema IEEE de 57 barras . . . . .	50
Quadro 5 – Características do Sistema IEEE de 118 barras. . . . .	51
Quadro 6 – Características do Sistema IEEE de 300 barras . . . . .	52
Quadro 7 – Descrição dos termos da equação de movimento . . . . .	60

# Lista de Algoritmos

Algoritmo 1 – <i>Pseudocódigo do algoritmo de Evolução Diferencial.</i> Adaptado: Das e Suganthan (2011) . . . . .	31
Algoritmo 2 – <i>Pseudocódigo de um AE multiobjetivo generalista</i> . . . . .	33
Algoritmo 3 – <i>Pseudocódigo do algoritmo C-DEEPSO.</i> . . . . .	63
Algoritmo 4 – <i>Pseudocódigo Spiral Local Search (SLS)</i> . . . . .	68

# Lista de Abreviaturas e Siglas

ACO	Otimização por colônia de formigas
AE	Algoritmos Evolucionários
AG	Algoritmos Genéticos
AHP	<i>Analytic Hierarchy Process</i>
AIS	Sistemas Imunológicos Artificiais
AMPSO	<i>Adaptative Modified Particle Swarm Optimization</i>
ANN	Redes Neurais Artificiais
ANOVA	Análise de Variância
BESS	<i>Battery Energy Storage Systems</i>
CCA	<i>Classic Compensatory Approach</i>
C-DEEPSO	<i>Canonical Differential evolutionary Particle Swarm Optimization</i>
CIS	<i>Closeness to Ideal Solution</i>
COE	Custo da Eletricidade
CR	<i>Consistency Ratio</i>
DE	<i>Differential Evolution</i>
DEEPSO	<i>Differential Evolutionary Particle Swarm Optimization</i>
DOE	<i>Design of Experiments</i>
EE	Estratégias Evolucionárias
EPE	Empresa do Planejamento Energético
EPSO	<i>Evolutionary Particle Swarm Optimization</i>
GMM	<i>Geometrical Mean Method</i>
hC-DEEPSO	<i>Hybrid Canonical Differential Evolutionary Particle Swarm Optimization</i>
HMGS	Sistema Microgrid Híbrido
HSD	<i>Honestly Significant Difference</i>

IA	Inteligência Artificial
IC	Inteligência Computacional
ICDE	<i>Differential Evolution Algorithm with a Modified Archiving-based Tradeoff Model</i>
LFP	<i>Lithium Iron Phosphate</i>
LPSP	Probabilidade de Perda de Carga
MCC	Modo Controle Conjunto
MCDA	<i>Multi Criteria Decision Analysis</i>
MCO	Modo Controle Otimizado
MIGA	<i>Mixed-Integer Genetic Algorithm</i>
MOAIA	<i>Multi-objective Adaptive Immune Algorithm</i>
MODE	<i>Multiobjective Differential Evolution</i>
MOGA	<i>Multiobjective Genetic Algorithm</i>
MVMO	<i>Mean-Variance Mapping Optimization</i>
NaNiCl	<i>Sodium Nickel Chloride</i>
NaS	<i>Sodium Sulfur</i>
NCA	<i>Lithium Nickel Cobalt Aluminum Oxide</i>
NPGA	<i>Niched Pareto Genetic Algorithm</i>
NSGA	<i>Nondominated Sorting Genetic Algorithm</i>
OA	<i>Outranking Approaches</i>
OARPD	<i>Optimal Active and Reactive Power Dispatch</i>
OCDE	Organização para a Cooperação e Desenvolvimento Econômico
OLTC	<i>On-Load TAP Changer</i>
ONS	Operador Nacional do Sistema
OPF	<i>Optimal Power Flow</i>
ORPD	<i>Optimal Reactive Power Dispatch</i>

PCC	<i>Point of Common Coupling</i>
PG	Programação Genética
PSO	<i>Particle Swarm Optimization</i>
PV	<i>Photovoltaics</i>
RES	<i>Renewable energy Sources</i>
RS	<i>Renewable Source</i>
SARGA	<i>Self-Adaptative Real Coded Genetic Algorithm</i>
SCOPF	<i>Security Constrained Optmal Power Flow</i>
SLS	<i>Spiral Local Search</i>
SOA	<i>Spiral Optimization Algorithm</i>
SPEA	<i>Strenght Pareto Evolutionary Algorithm</i>
TOPSIS	<i>Technique for Order Preference by Similarity to Ideal Solution</i>
UHE	Usinas Hidrelétricas
VRLA	<i>Valve Regulated Lead Acid</i>
WPP	<i>Wind Power Plant</i>

# Sumário

<b>1 – Introdução</b>	<b>1</b>
1.1 Paradigma Evolucionário	2
1.2 Energia Elétrica no Brasil	4
1.3 Fontes Renováveis de Energia	6
1.3.1 Energia hidrelétrica	6
1.3.2 Energia Solar e Eólica	7
1.4 Geração e Transmissão da Energia Elétrica	8
1.5 Objetivos	8
1.5.1 Objetivo Geral	8
1.5.2 Objetivos Específicos	9
1.6 Metodologia	9
1.6.1 Planejamento de experimentos	10
1.7 Organização do Trabalho	12
<b>2 – Revisão da Literatura</b>	<b>14</b>
2.1 Fluxo de Potência Ótimo	15
2.1.1 Trabalhos Relacionados	15
2.2 Fluxo de Potência Ótimo com Restrições de Segurança	19
2.3 Despacho Elétrico em UHE	21
2.4 Sistemas <i>Microgrids</i>	22
2.5 Considerações Finais	23
<b>3 – Fundamentação Teórica</b>	<b>26</b>
3.1 Otimização	26
3.1.1 Otimização Mono-objetivo	26
3.1.2 Otimização Multiobjetivo	27
3.1.3 Otimização por Escalarização de objetivos	27
3.2 Algoritmos Evolucionários	28
3.2.1 O algoritmo de Evolução Diferencial	29
3.2.2 O algoritmo EPSO	31
3.2.3 Algoritmos Evolucionários Multiobjetivo	32
3.2.3.1 O algoritmo NSGA-II	33
3.2.3.2 O algoritmo SPEA2	34
3.3 Análise de Decisão Multicritério	35
3.4 Considerações Finais	40

<b>4 – Caracterização do Problema e Estudos de Casos</b> . . . . .	<b>41</b>
4.1 Formulação Matemática do Despacho em UHE . . . . .	41
4.2 Formulação Matemática do SCOPF . . . . .	44
4.3 Cenários de estudo em SCOPF . . . . .	47
4.3.1 Sistema IEEE 41 - WPP-Offshore . . . . .	48
4.3.2 Sistema IEEE de 57 barras . . . . .	49
4.3.3 Sistema IEEE de 118 barras . . . . .	51
4.3.4 Sistema IEEE de 300 barras . . . . .	51
4.4 Sistema <i>Microgrid</i> híbrido . . . . .	54
4.4.1 Um estudo de caso na Alemanha . . . . .	54
4.4.2 Modelo matemático de HMGS . . . . .	56
4.5 Considerações Finais . . . . .	58
<b>5 – Proposição e desenvolvimento de novos Algoritmos Evolucionários</b> . . . . .	<b>59</b>
5.1 Algoritmo C-DEEPSO . . . . .	59
5.2 Proposta de operador para Busca Local . . . . .	63
5.3 Testes preliminares para validação do hC-DEEPSO . . . . .	69
5.4 Considerações Finais . . . . .	76
<b>6 – Experimentos e Resultados</b> . . . . .	<b>77</b>
6.1 Problema de Despacho Elétrico em UHE . . . . .	77
6.1.1 Mono-objetivo vs. Multiobjetivo . . . . .	78
6.1.2 Apuração de desempenho dos algoritmos multiobjetivo . . . . .	80
6.2 Problemas SCOPF - Experimentos e resultados . . . . .	81
6.2.1 Sistema IEEE 41 - minimização de perdas em WPP . . . . .	81
6.2.2 Sistemas IEEE de 57, 118 e 300 barras . . . . .	89
6.2.2.1 Ajuste de Parâmetros Estratégicos . . . . .	89
6.2.2.2 Análise de Desempenho . . . . .	92
6.3 Otimização em um Sistema <i>Microgrid</i> Híbrido . . . . .	95
6.3.1 Uma análise de solução obtida via C-DEEPSO . . . . .	96
6.3.2 Avaliação BESS com uso de AHP+TOPSIS . . . . .	100
6.4 Considerações Finais . . . . .	101
<b>7 – Conclusão</b> . . . . .	<b>103</b>
7.1 Trabalhos Futuros . . . . .	106
7.2 Considerações Finais . . . . .	107
<b>Referências</b> . . . . .	<b>109</b>

# 1 Introdução

Inteligência Artificial (IA) é uma área de pesquisa da computação dedicada a buscar métodos ou dispositivos computacionais que possuam ou multipliquem a capacidade racional do ser humano de resolver problemas, pensar ou, de forma ampla, ser inteligente. A Inteligência Computacional (IC) é uma subárea da IA que busca, por meio de técnicas inspiradas na natureza, o desenvolvimento de sistemas inteligentes que imitem aspectos do comportamento humano, tais como: aprendizado, percepção, raciocínio, evolução e adaptação (CARVALHO; BRAGA; LUDERMIR, 2003). Dentre essas técnicas, vêm se sobressaindo desde os anos 1980 os Algoritmos Evolucionários (AE). Estes mecanismos podem ser descritos como metaheurísticas que partem dos princípios observados na biologia, relativos a adaptação dos seres vivos ao meio. O embasamento presente em AE se atribui no fato dos mecanismos observados na natureza possuírem a capacidade de solucionar diversos problemas de alta complexidade, quando traduzidos em procedimentos computacionais.

Segundo Gaspar-Cunha, Takahashi e Antunes (2013) a primeira metáfora sugerida foi a da evolução natural dos seres vivos, em que um conjunto de vetores de variáveis de decisão, comumente chamados de indivíduos passariam pelo ciclo evolutivo de seleção, recombinação e mutação, assim sofrendo alterações aleatórias produzindo novas soluções até o objetivo principal ser alcançado. O processo evolutivo baseado na adaptação das espécies ou na migração das aves em busca de alimento, contemplam a pesquisa e busca no espaço, em que diversas alternativas são obtidas para se alcançar o objetivo final, em um ambiente que possui alta dimensionalidade no trato de funções complexas que necessitam de um fluxo evolutivo constante. Estes fenômenos naturais vem sendo observados e demonstraram sucesso na evolução das espécies e por isto é suposto que estas estruturas possam ser construídas computacionalmente no tratamento dos problemas de otimização matemática.

Na realidade apresentada no contexto prático, problemas de otimização em larga escala podem ser encontrados em inúmeras aplicações do mundo real, tais como controle industrial, biomedicina, finanças, logística, aeroespacial, controle de infestações dentre muitos outros. Estes problemas são afetados pela alta dimensionalidade em diversos aspectos: quanto maior a dimensão do problema, maior é o espaço de busca; quanto maior a dimensão do problema, maior é o risco de ocorrência de alterações em algumas características deste problema relacionadas à escala. Tipicamente, estes problemas apresentam alta dificuldade de solução devido à complexidade inerente de encontrar soluções ótimas. Devido a isto, novos métodos de otimização, estão sendo propostos para superar os obstáculos impostos pela dimensionalidade (BEYER; SCHWEFEL; WEGENER, 2002), (LI et al., 2013).

No contexto dos problemas reais em larga escala, uma definição clara e precisa de eficiência energética é um desafio, no entanto, o melhor manejo de recursos hídricos, tanto para o abastecimento da população, quanto para a geração de energia elétrica deve ser alcançado. Não obstante, é necessário pensar em novas formas de geração de energia elétrica, com foco nas fontes renováveis e também o gerenciamento da produção e transmissão de toda energia elétrica produzida. A aplicação de conceitos de inteligência computacional, especificamente os relacionados a AE para melhorias, no que tange a eficiência na geração e transmissão da energia elétrica, torna-se uma possibilidade relevante para pesquisa e para sua aplicação real nos sistemas de geração existentes. Esta tese propõe o desenvolvimento e o aperfeiçoamento de AE híbridos para aplicação na solução de problemas relacionados ao fluxo de potência ótimo visando a atingir a eficiência energética.

## 1.1 Paradigma Evolucionário

Consensualmente, entende-se que a IA está embasada em três paradigmas: o Conexionista, o Evolucionário e o Simbolista, sendo que cada um deles engloba algumas técnicas da área de IC (KONAR, 2005). A Figura 1 mostra uma breve Taxonomia da IA, com foco nas técnicas pioneiras de AE.

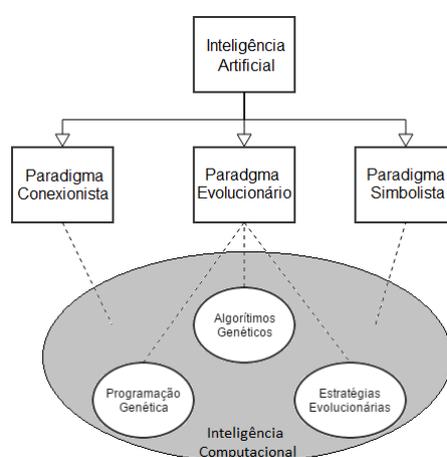


Figura 1 – Breve Taxonomia da IA.

A IC inclui um conjunto de técnicas, compostas de algoritmos de busca, denominadas AE. Tais algoritmos podem ser considerados metaheurísticas inspiradas nos princípios de evolução orgânica que implementam otimização probabilística. Nas últimas décadas, AE se tornaram uma ferramenta vastamente utilizada para realização de busca em modelos de otimização e simulação computacional. Os primeiros achados de material técnico sobre AE são datados dos anos 60 (BEYER; SCHWEFEL; WEGENER, 2002).

Algoritmos Genéticos (AG) são uma classe particular de AE que usam técnicas inspiradas na biologia evolutiva como hereditariedade, mutação, seleção natural e cruzamento

para modificar e melhorar soluções de um dado problema, comumente codificadas em vetores binários ou reais (GOLDBERG, 1989). Um grande desafio na área da computação é fazer com que computadores realizem tarefas de solução de problemas sem a interação humana direta. A Programação Genética (PG) procura responder a este desafio provendo um método para criação automática de programas, dada a descrição em alto nível de um problema. Em PG, os indivíduos de uma população são programas ao invés de vetores de valores binários ou reais (KOZA, 1998). Estratégias Evolucionárias (EE) foram propostas para resolver problemas de controle em que mutações são normalmente distribuídas para se obter diferentes vetores de valores reais (RECHENBERG, 1973).

Em suas primeiras versões, EE utilizavam apenas operadores de seleção e mutação e posteriormente, foi adicionado o uso do operador de cruzamento. Existem técnicas clássicas de otimização, tais como Métodos de Direção de Busca e Métodos de Exclusão de Semiespaços, que apesar de eficientes e apresentarem provas formais de convergência, usualmente são aplicadas quando há garantia de convexidade e/ou diferenciabilidade. Em problemas nos quais a estrutura da função objetivo não é conhecida, uma alternativa interessante é usar AE. Eles podem ser aplicados na solução de um problema genérico, não sendo necessário saber se o mesmo é diferenciável, convexo, unimodal ou multimodal. Entretanto, como desvantagem, se paga o preço de não haver uma prova formal de convergência para máximos e mínimos globais. AE são algoritmos baseados em população, ou seja, a cada passo são geradas várias soluções, logo eles também são adequados para aplicação na solução de problemas com abordagem multiobjetivo, uma vez que no mundo prático grande parte dos problemas possuem múltiplos objetivos.

Pelo fato de possuir mais de uma solução pertinente, a abordagem multiobjetivo pode envolver dois estágios principais: a obtenção de um conjunto de soluções eficientes e a tomada de decisão para eleger aquela que caracteriza a solução ótima que atenda dois ou mais objetivos. A priori, estratégias de ponto único também resolvem esta modalidade de problemas obtendo uma solução por vez, porém na aplicação de problemas práticos algumas objeções podem existir no mundo real, como a dificuldade de obtenção de soluções devido ao alto número de restrições ou até mesmo a perda de informação em alguns casos atreladas a estes problemas. Métodos mono-objetivo, realizando a soma ponderada de diversas funções ou transformando objetivos em restrições do problema, também podem ser usualmente utilizados para solução de problemas com múltiplos objetivos.

Um problema interessante no âmbito prático, voltado à produção energética, a ser resolvido com uso de AE é do despacho elétrico em usinas hidrelétricas. É esperado que a produção de energia atenda a premissas de eficiência energética, como o uso adequado de recursos hídricos no planejamento da operação. Por sua vez, podem ser aplicados ao tratamento do despacho em plantas eólicas visando minimização de perdas, dentre outros aspectos. AE também podem ser utilizados para encontrar a melhor disposição de equi-

pamentos pertencentes a uma rede de fonte renovável, composta de painéis fotovoltaicos, geradores eólicos e bancos de armazenamento, minimizando os custos da operação e as perdas de energia no sistema.

Da mesma forma, AE são capazes de solucionar problemas complexos relacionados a geração e transmissão de energia em grandes redes espalhadas pelo território de um país. O controle da operação nestas redes pode ter como intuito a minimização dos custos de produção e/ou das perdas de energia elétrica durante sua transmissão incorporando garantia de qualidade de serviço, relacionadas a segurança e minimização de falhas. Esta operação é considerada de larga escala, pois garantir que a rede opere de modo eficiente no funcionamento de grandes equipamentos, linhas e cargas possui muitas restrições e limites operativos, além da alta dimensionalidade presente no problema.

## 1.2 Energia Elétrica no Brasil

A demanda de energia elétrica é uma das principais questões emergentes na atual gestão energética no Brasil e no mundo. De acordo com o relatório anual emitido pela Empresa de Planejamento Energético (EPE), o percentual de energia elétrica de fonte renovável caiu de 84.5% para 78.3% entre 2012 e 2013 (EPE, 2016). Este fato é justificado pelas condições hidrológicas desfavoráveis nos últimos anos, mesmo levando em conta que o Brasil possui uma das mais diversificadas e extensas redes fluviais de todo o planeta. Isso foi causado por uma seca generalizada naquele período e que se mantém até hoje, trazendo a necessidade do uso de fontes não renováveis. Portanto, para atender a demanda interna de eletricidade no país, o Operador Nacional do Sistema (ONS) tomou a medida de acionar as usinas termoelétricas.

Em consequência, a geração de energia por fonte termoelétrica resultou no aumento das emissões de gás carbônico, ocasionando maior impacto ambiental. A Figura 2 mostra uma comparação da geração de energia elétrica no Brasil em relação aos países membros OCDE<sup>1</sup> e ao Mundo.

<sup>1</sup> A Organização para a Cooperação e Desenvolvimento Econômico - OCDE é uma organização internacional de 34 países que aceitam os princípios da democracia representativa e da economia de livre mercado, que procura fornecer uma plataforma para comparar políticas econômicas, solucionar problemas comuns e coordenar políticas domésticas e internacionais (OCDE, 2017)

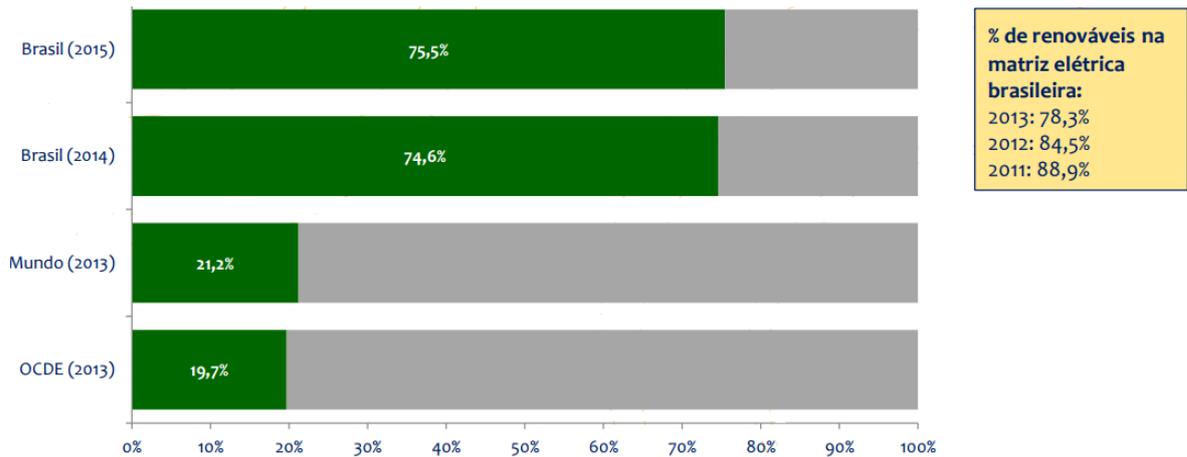


Figura 2 – Comparativo da matriz Energética em 2015. Fonte: EPE (2016)

Esta comparação revela que o Brasil tem uma vantagem em relação ao uso de energia renovável, frente ao restante do Mundo. Também é notável um crescimento da utilização das fontes renováveis entre os anos de 2014 e 2015. Isso se justifica pelo aumento da produção de energia Eólica, Biomassa e Solar, conforme o gráfico comparativo mostrado na Figura 3.

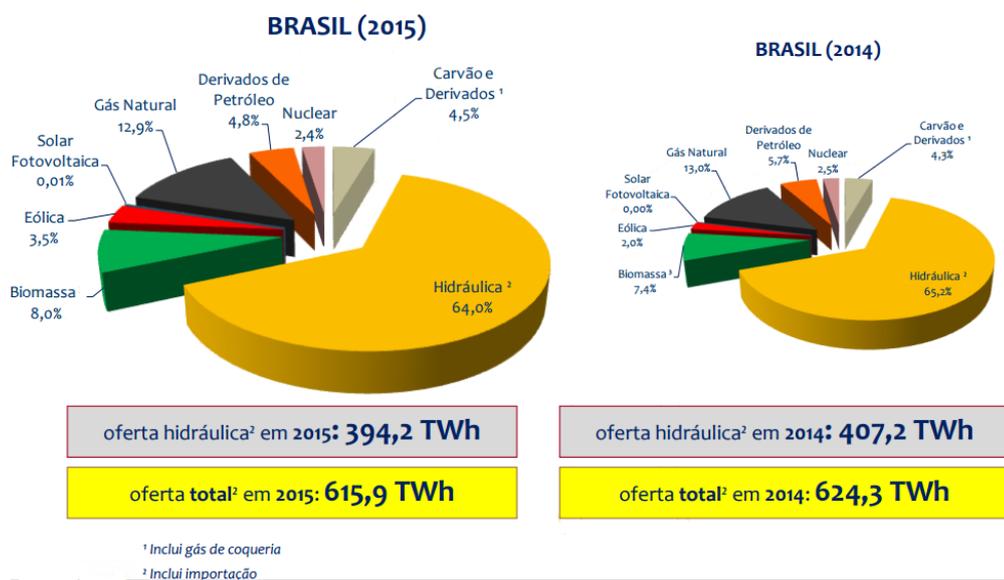


Figura 3 – Comparativo da matriz Energética entre os anos 2014 e 2015. Fonte: EPE (2016)

Dado o problema de baixa precipitação chuvosa visto nos últimos anos, o uso adequado dos recursos hídricos se tornou um tema de grande urgência no Brasil. Isto garante, em parte, que o país procure alcançar um patamar elevado no uso de energia proveniente de fonte limpa nos próximos anos. Embora o Brasil esteja avançando na produção renovável, as fontes por meio do vento e pela energia solar ainda não estão sendo exploradas em totalidade. O Brasil apresenta um clima favorável para o uso destas fontes, e

é necessário pensar e propor formas para o uso destes recursos. Isto pode proporcionar uma maior eficiência energética em nosso país.

## 1.3 Fontes Renováveis de Energia

Fontes renováveis de energia (RES, do termo em inglês *Renewable Energy Sources*) podem ser descritas como aquelas que são obtidas via recursos naturais considerados de fonte renovável e limpa. Tais fontes podem estar relacionadas diretamente com o sol (térmica, foto-química e foto-elétrica), indiretamente (eólica, hidrelétrica, biomassa e fotovoltaica) ou outros recursos naturais disponíveis, como a energia geotérmica (ELLABBAN; ABU-RUB; BLAABJERG, 2014). A Figura 4 mostra uma visão geral das fontes de energia renováveis.

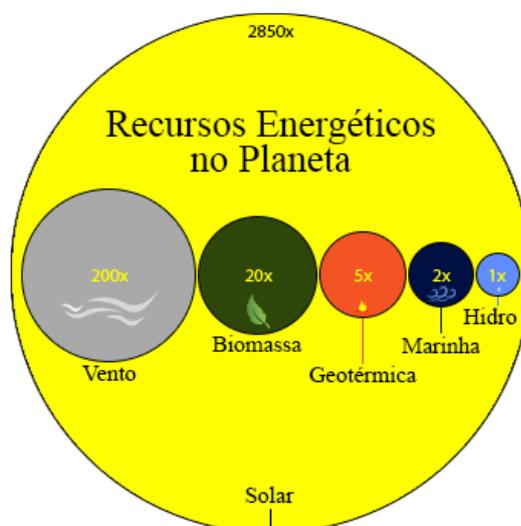


Figura 4 – Fontes de energia renováveis. Possuem o potencial de fornecer 3078 vezes as atuais necessidades globais de energia. Fonte: adaptado de (ELLABBAN; ABU-RUB; BLAABJERG, 2014)).

Este trabalho vai abordar a geração de energia elétrica nas fontes renováveis: hidrelétrica, fotovoltaica e eólica, as quais são descritas nas seções que se seguem.

### 1.3.1 Energia hidrelétrica

A energia hidrelétrica é uma fonte derivada do potencial energético da água em movimento. O fluxo constante de água, quando capturada, pode ser convertida em eletricidade usando turbinas. A forma mais predominante de geração hidrelétrica é por meio de represas situadas em plantas denominadas usinas hidrelétricas (UHE). Atrelado à dinâmica das UHE está o problema de despacho elétrico, que é definido como a atribuição de valores de operação para cada conjunto turbina-gerador de uma usina, dados alguns critérios a serem atendidos como a demanda de energia a ser produzida, limites operativos destes conjuntos entre outros.

Este problema se resume nas práticas de geração hidrelétrica adotadas atualmente no país, que não exibem preocupação com os aspectos de sustentabilidade e uso racional de recursos, como por exemplo, a eficiência energética e a economia de água. Para avançar em sua solução é proposta uma programação de despacho ótimo de unidades de geração hidrelétrica. O objetivo é a maximização da produção de energia satisfazendo as condições de operação do sistema, fazendo com que a potência elétrica possa ser gerada com o mínimo de vazão de água possível em cada unidade geradora. Em seu trabalho, [Marcelino \(2012\)](#) propôs um novo modelo de produção energética que considerava as perdas de carga inerentes aos condutos forçados, além de realizar uma regressão linear multivariável encontrando os coeficientes de uma função quadrática, para cálculo do rendimento das unidades geradoras.

Tal abordagem obteve êxito em seus experimentos, por demonstrar economia de água durante a simulação de geração, concluindo que os algoritmos de Evolução Diferencial (DE, do termo em inglês *Differential Evolution*) implementados obtiveram melhores resultados quando comparados aos encontrados pelos AG. Em primeiro plano, este trabalho apresenta a extensão do modelo de otimização da produção energética de [Marcelino \(2012\)](#), [Marcelino, Wanner e Almeida \(2013\)](#) com a adição de um novo objetivo. Logo, o tratamento deste problema relacionado à eficiência energética se torna uma abordagem multiobjetivo. Este problema é um estudo de caso tratado nesta tese e será detalhado na Seção 4.1.

### 1.3.2 Energia Solar e Eólica

A geração de energia solar envolve o uso da radiação solar para fornecer água quente, a partir de sistemas solares térmicos, ou eletricidade via energia solar fotovoltaica (PV, do termo inglês *Photovoltaics*). O bloco básico de um sistema PV é a célula fotovoltaica, que é um dispositivo semicondutor que converte a energia solar em eletricidade de corrente contínua. As células fotovoltaicas são interligadas a partir de um módulo fotovoltaico, tipicamente de 50 até 200W ([BHUIYAN et al., 2002](#)). Os módulos de PV, combinados com um conjunto de componentes adicionais do sistema dependentes da aplicação (por exemplo, inversores, baterias, componentes elétricos e sistemas de processamento), formam um sistema fotovoltaico. PV são altamente modulares, isto é, os módulos podem ser ligados ao gerador para fornecer potência variando de alguns *watts* a dezenas de *megawatts*.

A geração de energia eólica vem sendo utilizada há alguns séculos, embora, no passado, seu uso tenha se restringido prioritariamente a aplicações mecânicas, como o moinho de vento. Atualmente, esta fonte energética pode ser também empregada como a transformação da energia cinética do vento em eletricidade. Nas últimas décadas, este uso, especialmente em alguns países na Europa, tem sofrido um importante desenvolvimento como as grandes construções de parques eólicos instalados no mar ou na superfície ([JABR; PAL, 2009](#)). Explorar maneiras de otimizar o fluxo de energia em usinas eólicas é altamente

justificável, uma vez que as preocupações e escassez de energia levaram os países a investir em diferentes RES (GEORGESCU et al., 2010). Atualmente no Brasil, há uma necessidade latente de energia de baixo custo e de fonte limpa. O país sofre uma crise energética, uma vez que a sua principal fonte, provenientes de usinas hidrelétricas, vem sendo reduzida devido à severa estiagem que vem ocorrendo nos últimos anos.

## 1.4 Geração e Transmissão da Energia Elétrica

Uma preocupação das grandes empresas produtoras de energia elétrica está relacionada ao custo da operação. Um problema clássico, voltado à abordagem de produção e transmissão de energia elétrica, é o do Fluxo de Potência Ótimo (OPF, do termo em inglês *Optimal Power Flow*). Geralmente, um problema específico de OPF pode ser expresso como a redução dos custos de produção de uma rede elétrica. No entanto, muitos outros objetivos também são possíveis, tais como a minimização das alterações nos controles, das perdas no sistema ou da emissão de poluentes (ABIDO, 2002). Uma abordagem mais completa é a agregação de restrições de segurança, o classificando então como um Fluxo de Potência Ótimo com Restrições de Segurança (SCOPF, do termo em inglês *Security Constrained Optimal Power flow*).

Independente da função objetivo, um OPF também deve resolver todo o conjunto de restrições de energia, e no caso de uma abordagem com condições de segurança atreladas, o número de restrições tende a aumentar. As restrições de igualdade estão associadas com o equilíbrio de potência ativa e reativa em cada equipamento e às equações de fluxo de potência. Nas restrições de desigualdade estão inclusos os limites operacionais, ou seja, os limites das variáveis de controle, os fluxos de linha e tensões (magnitude e ângulo) incorporando ou não restrições de segurança. Em OPF ou SCOPF abordagens multiobjetivo podem ser realizadas via concatenação de duas ou mais funções objetivo simples (FRANK; STEPONAVICE; REBENNACK, 2012a).

## 1.5 Objetivos

### 1.5.1 Objetivo Geral

O objetivo geral deste trabalho é contribuir para a eficiência energética e o uso sustentável da energia elétrica no campo da otimização e pesquisa operacional, visando a solução dos seguintes problemas específicos: problemas de Fluxo de Potência Ótimo no despacho elétrico em usinas hidrelétricas e eólicas, bem como no despacho elétrico em redes *microgrid*. Além disso, procura-se otimizar problemas de Fluxo de Potência com Restrições de Segurança no despacho ativo/reactivo em redes larga escala.

## 1.5.2 Objetivos Específicos

- Desenvolver e validar um novo algoritmo evolucionário híbrido, que incorpore conceitos de teoria evolutiva, inteligência de enxames e espirais logarítmicas;
- Propor e implementar um operador de busca local acoplado ao algoritmo que auxilie no processo de busca;
- Aplicar o algoritmo na solução de problemas SCOPF em modelos de otimização no despacho reativo (ORPD) e ativo/reactivo (OARPD);
- Propor e implementar melhorias em um modelo de despacho elétrico em usinas hidrelétricas;
- Aprimorar um modelo de um sistema *microgrid* e otimizar seu funcionamento;
- Realizar experimentos simulados e avaliar os resultados obtidos com emprego de técnicas de estatística inferencial, visando em alguns casos, comparar os resultados obtidos com os oriundos da literatura.

## 1.6 Metodologia

A pesquisa realizada neste trabalho pode ser classificada, em relação à sua natureza, como sendo do tipo aplicada, pois tem como objetivo gerar conhecimentos práticos para a solução de problemas específicos. A seguir são apresentadas as etapas de metodologia realizadas para o cumprimento dos objetivos propostos:

1. **Revisão da Literatura:** visa observar os trabalhos existentes que abordam a solução de problemas OPF e SCOPF em grandes redes. O levantamento também incorpora trabalhos a respeito de sistemas *microgrids* e despacho em usinas hidrelétricas;
2. **Fundamentação Teórica:** objetiva discutir os conceitos pertinentes a otimização, alguns algoritmos populacionais/evolucionários e uma técnica de análise de decisão multicritério.
3. **Caracterização do Problema:** caracteriza e conceitua OPF em diferentes abordagens, as quais incluem o despacho elétrico em redes larga escala, usinas hidrelétrica, usina eólica e sistema *microgrid*.
4. **Proposta de Solução:** para solução dos estudos de casos e modelos de despacho propostos e/ou utilizados nesta pesquisa se propõe um novo algoritmo híbrido. A nova técnica usa conceitos inspirados na biologia evolutiva, na inteligência de enxames e uso de espirais logarítmicas.
5. **Validação da solução proposta:** realização de experimentos simulados computacionalmente para cada um dos problemas estudados, os quais mostraram a capacidade de solução do algoritmo proposto em obter soluções factíveis para cada um dos problemas.
6. **Avaliação dos resultados experimentais:** análise das soluções obtidas com uso

de inferência estatística na comparação com diferentes técnicas já conhecidas na literatura.

Uma vez definida a metodologia da pesquisa espera-se contribuir para a constatação da hipótese estabelecida por [Krasnogor e Smith \(2005\)](#):

*“Está agora bem estabelecido que AE puros não são bem adequados à pesquisa do ajuste fino em espaços combinatórios complexos e que hibridização com outras técnicas pode melhorar significativamente a eficiência da busca.”*

Na literatura existem diversificadas versões de algoritmos híbridos propostos aplicados à solução de problemas OPF. Pretende-se investigar uma determinada hibridização, e a pergunta que se coloca então é:

“A concepção de um novo algoritmo que incorpore conceitos de algoritmos evolutivos, inteligência de enxames, juntamente com um novo operador de busca local construído baseado em conceitos de programação matemática, realmente gera um algoritmo competitivo para solução de problemas de Fluxo de Potência Ótimo?”

Para avaliar esta hipótese um planejamento de experimentos, com uso de técnicas estatísticas, foi realizado para comparação dos resultados obtidos com demais algoritmos disponíveis na literatura, conforme descrito na Seção [1.6.1](#).

### 1.6.1 Planejamento de experimentos

O Planejamento de Experimentos, (DOE, do termo inglês *Design of Experiments*), é uma técnica utilizada para traçar ensaios de teste com eficácia. Tal técnica é realizada para definir quais dados, em que quantidade e em que condições devem ser coletados durante um determinado experimento ([MONTGOMERY, 2012](#)). Planejar bem um experimento pode satisfazer a necessidade de garantir uma maior precisão estatística possível na resposta, encurtando o tempo necessário para execução do experimento e evitando o retrabalho.

Nesta seção será apresentado, brevemente, um planejamento experimental que será realizado nesta tese, conforme:

1. Os algoritmos serão submetidos a experimentação em dois tipos de casos, de acordo com:
  - Testes de desempenho com utilização de uma conhecida função de *benchmark* conhecida na literatura, variando a dimensão do problema;
  - Estudos de caso que envolvem problemas na área de energia elétrica, especificamente: um problema de fluxo de potência na abordagem mono-objetivo, um problema de despacho elétrico em usinas hidrelétricas em uma abordagem multiobjetivo, e um problema de despacho em redes *microgrid*;

2. Para avaliar o desempenho dos algoritmos a metodologia se baseia em inferência estatística, podendo ser aplicada (caso a caso, ou não), conforme:

- Geração de curvas de convergência média com o objetivo de verificar visualmente o comportamento de cada algoritmo dado o número máximo de avaliações de função;
- Geração de gráficos de caixa (*boxplot*) para avaliar visualmente o comportamento das séries de dados, que neste caso, são as soluções dos algoritmos;
- Planejamento de experimentos com uso de testes de Hipótese, Análise de Variância, testes de comparações múltiplas e geração de curvas de superfície;

Para execução deste planejamento, algumas técnicas estatísticas podem ser utilizadas, as quais serão mencionadas brevemente uma vez que são vastamente discutidas em livros de estatística. Assim, [Montgomery \(2012\)](#) foi usado como referência base. Uma maneira visual e qualitativa de verificar o comportamento de séries de dados é feita por meio da análise de gráficos *boxplot*. Pode ser explicado por meio do seu resumo de cinco medidas formadas pelos seguintes valores: valor mínimo, máximo e quartis inferior, centralizado e superior apresentados numa caixa. O mesmo consegue em alguns casos ser eficiente, pois quando não há sobreposição de caixas na comparação de dois ou mais grupos de dados, pode-se dizer que uma série de dados é diferente de outra.

Embora métodos não paramétricos auxiliem a análise, muitos problemas requerem que uma decisão seja tomada entre aceitar ou rejeitar uma afirmação sobre algum parâmetro ou diversos parâmetros de uma ou mais séries de dados. Esta afirmação é chamada Hipótese, e o procedimento de tomada de decisão com relação a esta afirmação é denominado de Teste de Hipótese. Um teste de hipótese, que será utilizado no contexto deste trabalho, é a verificação da igualdade das médias. Tal teste pode ser expresso formalmente como,

$$\begin{cases} H_0 & : \mu_i = \mu_j, \forall i, j \\ H_1 & : \mu_i \neq \mu_j, \text{ para algum } i. \end{cases}$$

Neste caso a hipótese nula,  $H_0$ , pressupõe a igualdade das médias e a hipótese alternativa,  $H_1$ , indica a não igualdade das médias. Como visto nas premissas para aplicação de testes de hipótese, uma maneira de verificar os resultados é estabelecer se  $H_0$  foi ou não rejeitada, com um valor especificado de significância. Para tanto, surge o conceito de P-valor. Esta medida é definida como o menor nível de significância que conduz à rejeição de  $H_0$ , com os dados fornecidos. O uso do resultado de P-valor como medida é útil para reportar resultados de um teste de hipótese. Neste trabalho, para todos os experimentos a hipótese nula escolhida foi a de igualdade entre as médias. A hipótese alternativa é caracterizada então na existência de pelo menos uma média que seja diferente das demais.

O teste estatístico T-test de *Student*, ou simplesmente T-test, é uma técnica que tem o objetivo de verificar se a hipótese nula pode ou não ser rejeitada. Em alguns casos

pode não ser razoável considerar que as variâncias desconhecidas sejam iguais. Para tanto, a estatística de teste para a diferença nas médias de duas distribuições normais, com variâncias desconhecidas e não necessariamente iguais.

Outro método difundido é Análise de Variância (ANOVA), que permite avaliar informações sobre as médias de populações. A ANOVA procura verificar se existe uma diferença significativa entre as médias e se os fatores exercem influência em alguma variável dependente. Este método pode ser utilizado quando se quer decidir se as diferenças amostrais observadas são reais (causadas por diferenças significativas nas populações observadas), ou casuais (decorrentes da mera variabilidade amostral). Tipicamente na ANOVA, a hipótese nula adotada é que todos os grupos de dados são simplesmente amostras aleatórias tiradas da mesma população.

Quando a ANOVA apresenta um resultado significativo, isso indica que pelo menos um grupo é diferente dos demais. No entanto, a ANOVA não possui um indicativo de onde está a diferença encontrada. Portanto, a ANOVA é geralmente seguida por um teste específico de comparações, e o mais comumente utilizado consiste em realizar uma comparação “dois a dois”, conhecido como comparação pareada. Uma técnica de comparação pareada simples e frequentemente utilizada foi desenvolvida por Tukey sob o nome teste da diferença honestamente significativa (HSD), do inglês *Honestly Significant Difference* (ABDI; WILLIAM, 2010).

Uma técnica visual, conhecida como metodologia da superfície de resposta, pode ser definida como a associação de técnicas estatísticas e matemáticas que podem ser utilizadas na modelagem e análise experimental, em que se espera obter uma resposta na qual esta seja influenciada por muitas variáveis e o objetivo seja otimizar a resposta. Para verificar a forma de uma superfície de resposta, geralmente são gerados também seus contornos. Neste gráfico conhecido como curvas de nível, as linhas de resposta são dispostas no plano. Esta técnica foi utilizada para realizar um ajuste fino de parâmetros em um algoritmo proposto neste trabalho.

## 1.7 Organização do Trabalho

Esta tese está dividida em oito capítulos. O Capítulo 1 apresentou uma introdução ao tema desenvolvido e tratado neste trabalho, contextualizando conceitos referentes algoritmos evolucionários. Abordou também a área de eficiência energética, a produção de energia a partir de fontes renováveis e questões voltadas ao fluxo de potência ótimo e a metodologia da pesquisa adotada na execução deste trabalho bem como as técnicas estatísticas a serem utilizadas na análise de resultados. Seu propósito principal é informar o leitor acerca das etapas mais relevantes realizadas durante o desenvolvimento da pesquisa, relacionando estas ações com os objetivos propostos e descrevendo, a priori, como os

resultados dos experimentos relatados no Capítulo 6 serão analisados e avaliados.

O Capítulo 2 apresenta a revisão da literatura. O Capítulo 3 destaca a fundamentação teórica que consiste nos conceitos referentes à otimização, AE e decisão multicritério. O Capítulo 4 caracteriza o problema abordado e discute os estudos de caso definidos para realização de experimentos. O Capítulo 5 descreve os fundamentos dos algoritmos propostos neste trabalho. O Capítulo 6 apresenta os experimentos realizados e os resultados obtidos. Finalmente, o Capítulo 7 trata da conclusão, discussões finais e apresenta propostas de continuidade.

## 2 Revisão da Literatura

Sistemas de potência são constituídos essencialmente de três partes: os centros geradores, os centros consumidores e o sistema de escoamento de fluxo de potência. Este último, por sua vez, é dividido entre os sistemas de transmissão, subtransmissão e distribuição (ARCE; OHISHII; SOARES, 2002). Limites operativos nos equipamentos elétricos estão presentes de modo a assegurar a geração de energia de forma limpa e segura. Em usinas hidrelétricas (UHE) garantir a geração de potência com a utilização mínima de recursos hídricos, levando em conta suas restrições operativas e de todo sistema de potência conectado é um grande desafio. Neste contexto, o problema do despacho caracteriza-se em otimizar a eficiência produtiva de energia elétrica, ou seja, gerar maior potência com o mínimo de recurso hídrico necessário, no fluxo de potência ótimo.

O Fluxo de Potência Ótimo (OPF, do termo inglês *Optimal Power Flow*) pode ser definido como uma ferramenta cujo alvo é viabilizar condições ótimas para a operação de um sistema elétrico, dado um ou mais objetivos. O Fluxo de Potência Ótimo com Restrições de Segurança (SCOPF) é um avanço na operação de grandes redes, pois a sua formulação inclui o tratamento de situações específicas de variáveis dos sistemas de potência que influenciam na segurança de sua operação, a partir da definição de restrições. A operação nos centros de controle é realizada de forma a manter o sistema de modo seguro, garantindo que o mesmo trabalhe embora ocorram falhas em equipamentos da rede elétrica. Por exemplo, caso uma unidade geradora sofra falhas, as demais instaladas podem suprir a demanda sem que ocorra um grande desvio de frequência ou que seja necessário excluir alguma carga. Da mesma forma uma linha pode ser desconectada da rede automaticamente pelos dispositivos de segurança. Caso no despacho de energia uma reserva de carregamento das linhas for planejado, após a falha, a rede de transmissão pode operar normalmente sem interrupção ou violação de limites de carregamento em qualquer outra linha (BHASKAR; MUTHYALA; MAHESWARAPU, 2010).

Nas últimas décadas, o desenvolvimento da geração de eletricidade tem avançado e por sua vez, a gestão das redes de energia com uso de OPF vem sendo aprimorada. Associadas as grandes redes, atualmente diferentes tecnologias de *migrogrid*, como pequenas turbinas eólicas, geradores a diesel, painéis fotovoltaicos e bancos de armazenamento de energia podem ser conectados. Emergindo como opções promissoras para as necessidades da energia elétrica, tais tecnologias geralmente estão localizadas nos usuários, em residências, fazendas e afins. Ao associar diversas tecnologias, surge o conceito de redes *microgrids* híbridas (HATZIARGYRIOU, 2014). Este capítulo apresenta o levantamento do estado da arte em relação ao gerenciamento de grandes redes por meio de OPF e SCOPF, ao problema de despacho elétrico em usinas e também sobre redes *migrogrid*.

## 2.1 Fluxo de Potência Ótimo

Em um ambiente competitivo, que envolve a produção de energia, gerenciamento e planejamento ambiental, o problema de despacho de energia ativo e reativo pode ser formulado considerando uma representação de corrente alternada das redes de transmissão e pode ser resolvido usando o modelo de OPF (ABIDO, 2002). O estudo do OPF desempenha um papel importante no sistema de gestão de energia em que toda a operação do sistema é supervisionada a cada intervalo de tempo. Na grande maioria das vezes os consumidores não dependem apenas da disponibilidade da energia elétrica, mas também que o fornecimento da mesma seja confiável e seguro, possibilitando a garantia de qualidade do serviço e alimentação contínua. OPF consiste em uma avaliação dos melhores ajustes para variáveis de controle: potência ativa e tensão dos geradores, variáveis discretas relacionadas aos TAP dos transformadores, variáveis contínuas ligadas aos reatores, capacitores e outras variáveis.

Nos últimos anos, OPF tornou-se um problema importante e bastante estudado de otimização não-linear (FRANK; STEPONAVICE; REBENNACK, 2012a). Usualmente o problema de OPF é considerado como um problema de otimização em larga escala, devido a sua grande dimensionalidade, não linearidade, não convexidade e pelo fato de possuir características multimodais (ABIDO, 2002; FRANK; STEPONAVICE; REBENNACK, 2012a; BISKAS et al., 2005). Em geral, OPF busca otimizar a operação da geração de energia elétrica, transmissão, e redes de distribuição sujeitas a restrições do sistema e limites de controle. Desta maneira pode-se propor um modo para obter um objetivo comum tal como, por exemplo, a minimização do custo operacional da produção de energia (BHASKAR; MUTHYALA; MAHESWARAPU, 2010). No entanto, dentro desta estrutura, existe uma grande variedade de formulações de OPF e métodos de solução. Além disso, a natureza de OPF continua a evoluir devido à modernização dos mercados da eletricidade e à integração de recursos renováveis.

### 2.1.1 Trabalhos Relacionados

A formulação clássica de OPF foi introduzida por Carpertier (1962) e nos primeiros trabalhos a este respeito, métodos determinísticos foram discutidos e aplicados para solução desta classe de problemas. No passado, muitas abordagens já foram feitas usando tais métodos, entre eles os de maior destaque são: Método do Gradiente, Método de Newton, Método do Ponto Interior, Programação Quadrática e Programação Linear como pode ser verificado nos trabalhos de Lobato et al. (2001), Lima et al. (2003), Carvalho, Santos e Ma (2004), Tong e Lin (2005), Yan et al. (2008).

É possível descrever de maneira simples as principais vantagens e desvantagens dos métodos já utilizados para resolver este problema. O Quadro 1 apresenta um resumo

das técnicas já utilizadas para solução de diversos problemas OPF. As informações contidas no mesmo são uma análise geral de três artigos científicos de levantamento do estado da arte sobre o tema, presentes nos trabalhos de [Pandya e Joshi \(2008\)](#), [Frank, Steponavice e Rebennack \(2012a\)](#), [Frank, Steponavice e Rebennack \(2012b\)](#).

Quadro 1 – Vantagens e Desvantagens das técnicas empregadas na solução de OPF.

Metódos	Princípios	Vantagens	Desvantagens
Método do Gradiente	Usa o gradiente e a função lagrangeana como direção de busca para solução ótima.	Não é necessário o cálculo da derivada segunda, tornando o método simples	Convergência lenta; Dificuldades para tratamento de restrições.
Método do Ponto Interior	Inicia a busca no espaço a partir de um ponto "interior" e transforma restrições de desigualdade em restrições de igualdade por meio de variáveis de folga a fim de construir a função lagrangiana adicionando todas as restrições.	Mais rápido do que métodos convencionais de programação linear; eficiente e robusto em resolver problemas lineares e não lineares.	Não lida facilmente com restrições de desigualdade; sensível a condições iniciais; às vezes requer linearização.
Programação Linear	Uso de funções lineares e/ou partes de funções de custo lineares; usa fluxo de potência em corrente contínua (CC) em vez do fluxo de potência alternada (AC) fornecendo assim uma relação linear entre as injeções e linhas de fluxo.	Garantia de convergência; rápida convergência; baixo custo computacional; lida facilmente com restrições de desigualdade.	Imprecisão devido a linearização das funções de custo e restrições não-lineares;
Programação Quadrática	Usa uma função objetivo quadrática; todas as restrições são lineares.	Não requer a linearização das funções de custo.	Imprecisão durante a linearização de restrições não lineares.
Método de Newton	Aplicação da segunda derivada usando a matriz hessiana e o vetor gradiente para aproximar uma função quadrática.	Rápida convergência quando o valor ótimo é próximo; formulação flexível (para diferentes aplicações do problema OPF); eficiente e robusto.	Alto custo computacional; fortemente sensível a condições iniciais; Dificuldades para tratamento de restrições.
Metaheurísticas	Algoritmos Genéticos (AG); programação evolutiva (EP); Otimização por colônia de formigas (ACO); Sistemas Imunológicos artificiais (AIS), Redes Neurais Artificiais (ANN); algoritmos de otimização por enxame de partículas (PSO); algoritmos de Evolução Diferencial (DE).	Permite o uso de funções não-contínuas, não-convexas e não-diferenciáveis; fácil implementação.	Não há garantia de otimalidade, ou seja, a solução obtida não é garantidamente o ótimo.

Em contraposição aos métodos determinísticos que possuem desvantagens relacionadas no Quadro 1, o uso de métodos de otimização e busca não-determinísticos, como heurísticas estocásticas, métodos de busca aleatórios e métodos populacionais tem se tornado alternativas populares para solução de problemas OPF. Tais métodos possuem uma vantagem sobre os métodos determinísticos no que diz respeito ao tratamento de não-convexidade e variáveis discretas. O Quadro 2 apresenta um sumário de trabalhos relacionados que contempla métodos não-determinísticos.

Quadro 2 – Sumário de métodos já utilizados para solução de problemas OPF.

Metódo	Função Objetivo	Sistema	Informações Gerais
AG Todorovski e Rajcic (2006)	minimização dos custos totais de geração.	IEEE de 30 e 118 barras.	Quando comparado a AG, DE e PSO vistos em (VENKATESH; GNADASS; PADHY, 2003; ABIDO, 2003) mostrou obter melhores resultados médios e de desvio.
ACO Allaoua e Laoufi (2008)	minimização dos custos totais de geração.	IEEE de 30 barras.	Quando comparado a AG e EP vistos em (LAI et al., 1997; YURYEVICH; WONG, 1999) mostrou obter melhores resultados médios e de desvio.
MOAIA Huang, Haozhong e L. (2008)	minimização de perdas na transmissão.	IEEE de 30 barras.	<i>Multi-objective Adaptive Immune Algorithm</i> (MOAIA). Quando comparado ao IGA ( <i>Immune Genetic Algorithm</i> ) mostrou obter melhores resultados médios e de desvio.
SARGA Subbaraj e Rajnarayanan (2009)	minimização de perdas na transmissão.	IEEE de 14 e 30 barras.	<i>Self-Adaptive Real Coded Genetic Algorithm</i> (SARGA). Quando comparado a IEP ( <i>Improved Evolutionary programming</i> ) de (YAN; LU; YU, 2004) mostrou obter melhores resultados médios e de desvio.
DE Ela, Abido e Spea (2010)	minimização de perdas na transmissão.	IEEE de 30 barras.	Quando comparado ao Método do Gradiente (YAN; LU; YU, 2004), AG (LAI et al., 1997) e PSO (ABIDO, 2002) mostrou obter melhores resultados médios e de desvio.
DE, AG, PSO Suharto et al. (2011)	minimização dos custos totais de geração.	IEEE de 30 barras.	Quando comparado os algoritmos DE, PSO e AG obtiveram o mesmo valor médio. Porém o algoritmo DE mostrou convergir mais rapidamente.
MODE Abido e Ali (2012)	minimização dos custos e perdas.	IEEE de 30 e 118 barras.	<i>Multiobjective Differential Evolution</i> (MODE). Não houve comparação com outra técnica.
DE J.J.Liang et al. (2012)	minimização dos custos totais de geração.	IEEE de 14, 30, 57 e 118 barras.	Quando comparado a EP e PSO mostrou obter melhores resultados médios e de desvio.
PSO Kang et al. (2013)	minimização dos custos totais de geração e minimização das perdas de tensão separadamente.	IEEE de 14 barras.	Utiliza o algoritmo PSO na solução do problema. Não realizou nenhuma comparação com outras técnicas.
AG Dixit, Srivastava e Agnihotri (2014)	minimização das perdas na transmissão e minimização das perdas de tensão.	IEEE de 30 barras.	contempla uma metodologia para resolver o problema multiobjetivo incluindo a localização ótima e o tamanho ideal dos compensadores.
PSOGSA Radosavljevic et al. (2015)	minimização: dos custos totais de geração, das perdas na transmissão e das perdas de tensão.	IEEE de 30 e 118 barras.	propõe uso do algoritmo PSO acoplado ao <i>Gravitational Search Algorithm</i> GSA, como operador de mutação e resolve cada problema mono-objetivo separadamente. PSOGSA converge mais rapidamente porém não apresenta diferenças médias entre os resultados finais quando comparado a PSO e GSA.
DE Shaheen, El-Sehiemy e Farrag (2016)	minimização: dos custos totais de geração, das perdas na transmissão e das perdas de tensão.	IEEE de 30 e 57 barras.	Utiliza a estratégia DE/best/1/bin e resolve o problema multiobjetivo. Faz comparação média dos resultados de custo, os quais se apresentam melhores quando comparados com EP e GSA.

Os desenvolvimentos recentes mais promissores no campo de OPF têm sido os métodos híbridos. Em muitos casos, esses métodos têm-se mostrado mais robustos, possuindo maior velocidade de convergência às soluções ótimas do que métodos clássicos que operam sozinhos (FRANK; STEPONAVICE; REBENNACK, 2012b). O Quadro 3 apresenta os algoritmos híbridos já propostos para solução de problemas OPF.

Quadro 3 – Sumário de métodos já utilizados para solução de problemas OPF.

Metódo	Função Objetivo	Cenário de Teste	Informações Gerais
HPSOM <a href="#">Esmín, Lambert-Torres e Zambroni (2005)</a>	minimização dos custos totais de geração.	IEEE de 118 barras.	Algoritmo híbrido que emprega o operador de mutação do AG no PSO. Mostrou obter melhores resultados médios e de desvio da função objetivo quando comparado ao PSO clássico.
HPSO <a href="#">AlRashidi e El-Hawary (2007)</a>	minimização dos custos totais de geração, minimização de perdas na transmissão, minimização emissão de poluentes.	IEEE de 30 barras.	Proposta de PSO acoplado ao método de Newton. Não há comparação de resultados.
DEEP <a href="#">(CHUNG et al., 2010)</a>	minimização de perdas na transmissão.	IEEE de 14, 30, 57 e 118 barras.	Junção de DE e EP. Quando comparado ao DE, a proposta DEEP mostrou obter melhores resultados médios.
MOPSO <a href="#">Abido e Ali (2012)</a>	minimização de perdas na transmissão e minimização do desvio da magnitude de tensão.	IEEE de 30 e 118 barras.	Quando comparado a SPEA2 e NSGA-II por meio do valor de hipervolume, mostrou obter melhores resultados.
PSOGSA <a href="#">(RADOSAVLJEVIĆ; ARSIĆ, 2014)</a>	minimização dos custos totais de geração.	IEEE de 30 barras.	Acopla as regras de GSA na equação de movimento de PSO. Com base nos resultados médios PSOGSA se mostrou mais eficiente que PSO e GSA.
HMPSO <a href="#">Srivastava e Singh (2015)</a>	minimização de perdas na transmissão e minimização do desvio da magnitude de tensão.	IEEE de 30 e 75 barras.	Inspirado em AE se apoia na ideia de usar o melhor indivíduo da população no termo de memória da regra de movimento do PSO. Os resultados indicam que o algoritmo proposto obteve melhores resultados quando comparado aos algoritmos: PSO, MDE (SINGH; SRIVASTAVA, 2014), SaDE (HUANG; QIN; SUGANTHAN, 2009), EPSDE (MALLIPEDDI et al., 2011) no Sistema IEEE de 30 barras.

Como visto, foram abordados diversos trabalhos em ordem cronológica nos quais se apresentou os métodos mais comuns para solução de problemas OPF conhecidos na literatura. Foi possível verificar que 84% dos trabalhos usaram como problema a ser resolvido o Sistema IEEE<sup>1</sup> de 30 barras. Por sua vez, o Sistema IEEE de 118 barras foi resolvido em 21% dos casos enquanto o Sistema IEEE de 14 barras foi abordado em 21% dos casos. Como funções objetivo se destacam a minimização dos custos totais e a minimização das perdas de transmissão. O levantamento aqui realizado auxiliou na escolha dos cenários de problemas a serem resolvidos nesta tese, bem como as funções objetivo a

<sup>1</sup> São sistemas de energia, também conhecidos como casos de teste IEEE, disponibilizados pela [University of Washington](#) (Acessado em 07/04/2017)

serem utilizadas. Foi possível observar alguns algoritmos híbridos propostos para solução do problema, entre os quais 83.3% tem como base o algoritmo PSO.

## 2.2 Fluxo de Potência Ótimo com Restrições de Segurança

Como já abordado, o estudo de OPF desempenha um papel importante no sistema de geração e transmissão de energia elétrica, no qual todo o sistema é supervisionado. Porém, uma maior demanda de energia elétrica fez com que o consumidor não dependesse apenas da disponibilidade da eletricidade, mas também que este serviço fosse ofertado de forma confiável, segura, com qualidade de serviço e ininterruptamente. Neste caso, quando o OPF considera que o sistema prevê contingências na ocorrência de falha dos equipamentos (geradores, transformadores, linhas, etc.), o termo usualmente adotado é Fluxo de Potência Ótimo com Restrições de Segurança, comumente referenciado como SCOPF (BHASKAR; MUTHYALA; MAHESWARAPU, 2010).

O artigo de (GAING; CHANG, 2006) propôs um algoritmo genético, *Mixed-Integer Genetic Algorithm* (MIGA), no qual os indivíduos contêm variáveis inteiro-mistas em que foi realizado arredondamento para tratar o problema. O objetivo foi a minimização dos custos totais, garantindo segurança e reduzindo perdas na transmissão, incorporando medidas de contingência no modelo. O método MIGA foi aplicado aos Sistemas IEEE de 26 e 57 barras, nos quais os resultados foram comparados com os obtidos usando programação evolutiva. O algoritmo proposto mostrou melhor desempenho computacional e melhores resultados médios. O artigo também aborda a comparação de resultados OPF com e sem restrições de segurança, no qual é possível notar que, a abordagem SCOPF possui resultados mais elevados que a abordagem OPF clássica, devido o maior número de restrições contidas em SCOPF.

O algoritmo populacional e estocástico *Mean-Variance Mapping Optimization* (MVMO) foi proposto por Pham, Rueda e Erlich (2014), e utilizado para otimizar o Sistema IEEE 41 *Wind Farm Bus-System*. Sua característica mais importante é que ele usa uma função de mapeamento espacial aplicada para a mutação da prole com base na média e variância da população corrente. MVMO opera em uma única solução ao invés de um conjunto de soluções como em muitos algoritmos evolutivos, fazendo o balanceamento médio da população e sua variância com esta solução. Possui uma função de mapeamento que explora o espaço aproveitando assimetria com a capacidade de realizar busca global em torno das melhores soluções encontradas até o momento. O algoritmo *Differential Evolution Algorithm with a Modified Archiving-based Adaptive Tradeoff Model* (ICDE) de Niu et al. (2014) foi proposto para solução dos problemas de SCOPF de uma competição desta área (ERLICH et al., 2014b). ICDE propôs novas estratégias para o operador de mutação de DE e o uso de um arquivo para armazenar os melhores indivíduos das gerações anteriores.

Zhang et al. (2014) propuseram o uso do algoritmo DE canônico na solução de problemas SCOPF cujo objetivo foi a minimização dos custos totais de produção. A modelagem do problema sofreu uma alteração buscando minimizar a violação de restrições. Neste processo uma busca na região crítica factível é realizada. Um método híbrido foi proposto, no qual duas populações independentes são geradas, uma para realizar a busca global a partir do DE e outra para realizar uma busca local, por meio do algoritmo de ponto interior levando em conta apenas a região crítica de violação. Os autores comparam os resultados obtidos entre o método híbrido proposto e o algoritmo DE. A comparação, usando apenas média e desvio padrão do valor ótimo obtido, foi apresentada para os Sistemas IEEE de 14 e 118 barras, nos quais o algoritmo proposto mostrou obter melhores resultados. É interessante observar que o valor obtido na minimização de perdas para o caso 118 foi de 130.961 \$/h, um valor alto comparado aos obtidos em (ERLICH et al., 2014b) para este problema. O artigo apresenta uma abordagem interessante, indicando ser comum minimizar violações das restrições atreladas com uso de penalidades na função objetivo.

Alguns sistemas teste em SCOPF foram abordados em (PHAN; KALAGNANAM, 2014). Com uso de um algoritmo baseado em dualidade Lagrangeana, buscou-se decompor as funções objetivo e restrições para resolver o problema de forma linear. Ocorreram falhas nesta decomposição para os Sistemas IEEE de 30 e 118 barras, inviabilizando assim os resultados desta abordagem. O método proposto obteve êxito nos Sistemas IEEE de 14 e 57 barras. Além de ser uma abordagem mais difícil de se obter sucesso, dado o alto número de restrições do problema, o custo computacional foi elevado. No artigo de Carvalho et al. (2015) o algoritmo *Differential Evolutionary Particle Swarm Optimization* (DEEPSO) de (MIRANDA; ALVES, 2013) foi usado para minimização dos custos totais da geração do Sistema IEEE de 57 barras. O artigo mostrou com uso de técnicas estatísticas a importância de se realizar o ajuste fino de parâmetros em algoritmos evolucionários e que os resultados alcançados na solução do problema se mostram competitivos.

Um novo algoritmo híbrido multiobjetivo baseado em PSO e *Artificial Physics Optimization* (APO), denominado MOHPSO-APO foi proposto para minimizar o custo da operação dos Sistemas IEEE de 30 e 75 barras (TEEPARTHI; KUMAR, 2017). Uma função objetivo inclui além dos custos dos geradores a diesel, o custo dos geradores eólicos. A segunda função objetivo adotada foi a minimização de perdas na transmissão. Em MOHPSO-APO a equação de movimento do PSO é alterada pela utilização do cálculo de massa, que utiliza a informação do melhor e pior indivíduos da geração anterior. Assim o termo de cooperação da equação de movimento é substituído pelo cálculo de massa realizado por APO. O algoritmo usa o operador de dominância do NSGA-II para obter os conjuntos não dominados a cada iteração. Os resultados gráficos (Fronteiras de Pareto) aparentemente mostram que o algoritmo proposto obteve melhores resultados que PSO e APO separadamente. Porém o artigo não adotou nenhuma medida de desempenho ou realizou um número mínimo de execuções para validar as Fronteiras de Pareto obtidas.

## 2.3 Despacho Elétrico em UHE

Como um típico problema não-linear, o Despacho Elétrico em usinas hidrelétricas é considerado de difícil solução. Uma das primeiras menções à solução deste problema foi realizada por [Baldwin, Dale e Dittrich \(1959\)](#). Assim, alguns trabalhos foram considerados para um levantamento do recente estado da arte em relação a este problema. Com utilização de algoritmos genéticos, [França \(2010\)](#) propôs um modelo para despacho ótimo em sistemas hidrotérmicos considerando custos de partida/parada de geradores, por meio de um operador genético. O modelo adota um esquema de decomposição que permite apenas a utilização de variáveis da parte elétrica da formulação, sendo que as variáveis hidráulicas são representadas de forma indireta usando simulação hidráulica (não informada no artigo).

Em seu trabalho, [Banos et al. \(2011\)](#) realizou uma revisão das técnicas até então efetuadas para otimização aplicada à geração de energia renovável e sustentável. Este estudo cita as diversas formas de energia, dentre elas a hidrelétrica. Como solução de despacho ótimo, os artigos por ele visitados apresentam as técnicas: AG e PSO. A primeira conclusão desta revisão é que o número de trabalhos de pesquisa que utilizam métodos de otimização para resolver problemas de energia renováveis tem aumentado. Porém na maioria dos casos o custo computacional é elevado até mesmo utilizando processamento paralelo. [Pezzini, Gomis-Bellmunta e Sudrià-Andreua \(2011\)](#) enunciaram em seu artigo técnicas de otimização para melhorar a eficiência energética em sistemas de energia. As técnicas citadas são: Algoritmos de busca, Algoritmos Evolucionários, *Simulated Annealing*, Busca Tabu, *Ant Colony Optimization*, *Particle Swarm Optimization*, Algoritmos Genéticos, Redes Neurais Artificiais e Técnicas de Programação Evolucionária. Entre elas, AG são recomendados para minimização de perdas e maximização de eficiência e PSO para geração ótima de potência.

No artigo de [Abrao, Wanner e Almeida \(2013\)](#), foi proposto o uso de redes neurais artificiais para modelar a função de produção de um gerador existente em uma UHE. O problema de planejamento de curto prazo, que consistiu em definir o respectivo despacho de cada unidade geradora da UHE por um período específico de tempo, sendo solucionado usando DE e PSO. Contudo, o custo computacional desta abordagem de solução foi relativamente alto, impossibilitando o possível uso em uma planta real. [Marcelino, Wanner e Almeida \(2013\)](#) propuseram um novo modelo matemático para resolver o problema de despacho em UHE usando DE. A estratégia evolutiva DE/best/1/bin se mostrou mais eficiente para resolver a versão mono-objetivo deste problema. Os resultados obtidos mostraram que é possível obter uma economia de água significativa, na casa de bilhões de litros, durante a geração.

Um modelo de otimização para despacho em usinas dispostas em cascata foi proposto por [Guedes et al. \(2015\)](#) e otimizado com uso do algoritmo DE. O modelo proposto evita a natureza combinatória, tornando-se compacto e contínuo, o tornando atrativo para

uso de metaheurísticas. Experimentos de simulação computacional mostram o êxito desta abordagem na geração de energia baseada em 6 usinas operando em modo cascata. [Li e Qiu \(2016\)](#) propuseram a otimização multiobjetivo a longo prazo de um sistema interligado de fonte hidráulica e fotovoltaica. A justificativa principal é a intermitência e a instabilidade existentes na geração fotovoltaica. Para solução, o algoritmo NSGA-II foi utilizado e os resultados indicam que o modelo de compensação de energia na rede entre as duas fontes se torna viável em ambiente simulado.

## 2.4 Sistemas *Microgrids*

*Microgrids* compreendem sistemas de distribuição de baixa tensão com recursos de energia distribuídos (micro turbinas, geradores à combustível, painéis fotovoltaicos, entre outros) juntamente com dispositivos de armazenamento (capacitores de energia e baterias) e cargas flexíveis. Estes sistemas podem ser operados de forma não autônoma, interligados à rede, ou de forma autônoma, se estiverem desligados da rede principal. A operação de *microgrids* na rede pública pode proporcionar benefícios importantes para o desempenho do sistema global, se gerenciado e coordenado de forma eficiente ([HATZIARGYRIOU, 2014](#)).

Um sistema híbrido para geração de energia por meio das fontes: eólica, fotovoltaica e gerador a diesel foi projetado por [Kaviani, Riahy e Kouhsari \(2009\)](#). O foco foi a minimização do custo anual do mesmo ao longo de 20 anos. O problema de otimização estava sujeito à oferta confiável da demanda. Para solução o algoritmo PSO foi usado para resolver o problema de otimização. Os resultados mostraram o impacto das falhas de componentes na confiabilidade e no custo do sistema, o qual necessita de um investimento considerável para sua instalação.

Foi proposto, por [Moghaddam et al. \(2011\)](#), o algoritmo *Adaptive Modified Particle Swarm Optimization* (AMPSO) para a operação ideal de um microgrid autônomo (fonte de energia híbrida micro-turbina, gerador combustível e bateria). O problema foi formulado em uma abordagem multiobjetivo visando minimizar o custo operacional e emissão de poluentes simultaneamente. Para aprimorar o processo de otimização, um algoritmo baseado no mecanismo de busca local caótico foi usado no interior de AMPSO. O algoritmo proposto foi testado em um *microgrid* típico e seu desempenho se mostrou superior quando comparado outros algoritmos evolutivos como AG e PSO.

Um modelo para minimização de custos de um sistema *microgrid* com uso do algoritmo PSO foi proposto por [Mohammadi, Hosseinian e Gharehpetian \(2012\)](#). Uma configuração ótima para o dimensionamento do *microgrid* híbrido foi apresentado como resultado, em que o número de bancos de baterias diminui à medida em que se é necessário utilizar energia da rede pública para manter o sistema. Segundo [Levron, Guerrero e Beck \(2013\)](#) o armazenamento de energia pode melhorar sistemas *microgrids* que incluem fontes

de energia renováveis. Dispositivos de armazenamento combinam a geração elétrica com o consumo, facilitando um equilíbrio suave e robusto de energia dentro do sistema. Desta maneira, em sistemas *microgrid* é possível propor um fluxo de potência ótimo que considere todo o sistema: os limites operativos do dispositivo de armazenamento, de tensão, corrente e potência.

[Borhanazad et al. \(2014\)](#) propuseram em seu trabalho um modelo matemático a fim de minimizar o custo total e as perdas de carga para um sistema microgrid híbrido (geradores eólicos, painéis fotovoltaicos, bateria e gerador a diesel) autônomo. Este modelo utilizou escalarização de funções objetivo e foi solucionado com o algoritmo PSO. O modelo foi testado com dados de vento de três localidades no Irã. Os resultados apresentados mostraram que o modelo pode ser aplicado, a fins de se melhorar o acesso à energia nas zonas remotas iranianas ou em outras localidades que possuam condições climáticas favoráveis.

O aumento do uso das energias renováveis, nas matrizes mundiais de geração, é fortemente retardada pela sua intermitência característica e pela inadequação das redes de eletricidade. Estas questões podem ser discutidas no desenvolvimento de novas tecnologias de armazenamento com maior desempenho, disponibilidade, durabilidade, segurança e custos mais baixos. No artigo de [Barelli, Bidini e Bonucci \(2016\)](#), *microgrids* são caracterizados pela presença de diferentes tecnologias, incluindo plantas renováveis juntamente com a solução de armazenamento em baterias. O foco foi avaliar duas baterias distintas, uma baseada em lítio e outra fabricada com chumbo. Os resultados indicaram a superior qualidade da bateria de lítio nos cenários testados.

Outras tentativas para otimizar HMGS vêm da área de análise de decisão multicritério (MCDA) em combinação com otimização como visto em ([VASILJEVSKA; LOPES; MATOS, 2012](#)), ([KAZMI; HASAN; SHIN, 2015](#)) e ([WIMMLER et al., 2015](#)). Métodos de , especialmente participativos, podem ser utilizados para obter preferências do operador da rede de distribuição em relação aos benefícios potenciais e em estratégias de desenvolvimento ideal para HMGS ([VASILJEVSKA; LOPES; MATOS, 2012](#)). Contudo, apenas alguns estudos no campo da otimização e MCDA focam a utilização de diferentes tecnologias de sistemas de armazenamento em baterias (BESS) e seu impacto no desempenho HMGS.

## 2.5 Considerações Finais

Neste capítulo, foi realizado um levantamento a respeito do estado da arte referente aos problemas OPF e SCOPF. Os artigos discutidos na Seção [2.1.1 não contemplam](#) a modelagem dos problemas apresentados com o tratamento de restrições de segurança. Isto permite, por exemplo, que o sistema de operação não controle falhas, apagões e afins que venham a ocorrer na rede de energia. O modelo que não possui tais restrições pode

ser considerado de maior facilidade para solução, pois permite violação dos limites e não contempla condições de segurança e contingências da rede elétrica. Segundo [Capitanescu \(2016\)](#), o aumento das exigências do setor elétrico em termos de novas opções de software SCOPF e, especialmente, o requisito de operação do sistema de energia para cumprir o critério de segurança de contingências, fazem com que a abordagem OPF clássica se torne obsoleta por possuir usos limitados. A partir desta afirmação, optou-se por utilizar, nesta tese, apenas sistemas testes SCOPF em grandes redes.

Ao realizar um levantamento de técnicas aplicadas à solução de problemas de SCOPF, na Seção 2.2, ficou claro que até o momento nenhum outro trabalho além dos trabalhos de [Pham, Rueda e Erlich \(2014\)](#) e [Niu et al. \(2014\)](#) solucionaram os Sistemas IEEE de 41, 57, 118, 300 barras, com segurança de restrições no despacho reativo e ativo/reativo. Também foi possível observar que todos os trabalhos citados fizeram comparação de resultados observando apenas o valor médio e de desvio. Estas métricas são insuficientes quando se deseja obter significância dos dados observados. Este trabalho propõe a concepção de um algoritmo evolucionário híbrido que se difere dos demais apresentados na revisão da literatura. Este algoritmo será aplicado na solução de problemas que possuem natureza em larga escala e são difíceis de serem resolvidos. Vinculado a isto, um planejamento experimental com significância de dados foi proposto no Capítulo ???. O algoritmo será detalhado no Capítulo 5. Os resultados obtidos a partir do planejamento experimental proposto, foram comparados com os algoritmos estado da arte e são apresentados no Capítulo 6.

Além disto, esta tese aborda o problema de despacho horário em tempo real em uma UHE, o que é pouco difundido na literatura. Esta maneira de tratar o problema possibilita, além de estudos do comportamento de uma usina, informações para decisões de planejamento futuro. Agrega também o provisionamento da operação em tempo real de uma usina otimizando o sistema de geração e economizando insumos, neste caso a água. Neste trabalho é proposto também o aprimoramento do modelo matemático de [Marcelino, Wanner e Almeida \(2013\)](#) e a concepção do modo de “Controle Otimizado” de operação em UHE. Este modo auxilia no entendimento dos operadores do sistema, sobre a existência de uma região de solução factível, em que a vazão turbinada no controle otimizado não se distancia muito da vazão turbinada quando a operação usual do sistema é realizada. Quando utilizado, o conceito de “modo de Controle Otimizado” altera minimamente o despacho em cada unidade, caso a demanda total mude e seja necessário despachar cada unidade geradora novamente, e isto é feito economizando água na geração com a expectativa de um menor desgaste dos equipamentos. Esta abordagem faz uso dos algoritmos descritos pela Seção 3.2.3.

Finalmente, um modelo baseado no trabalho de [Borhanazad et al. \(2014\)](#) adaptado para conexão à rede pública, para otimização de um sistema *microgrid* híbrido é proposto, se diferenciando dos trabalhos relacionados. A necessidade de se estudar novos sistemas

híbridos de fonte renovável energia é emergente. O acoplamento de geradores eólicos, painéis fotovoltaicos e baterias, visando o baixo custo de geração no fluxo de potência ótimo, é um grande desafio na disputa energética. Para tanto, uma investigação da indústria vem ganhando formato na proposição de novos sistemas de armazenamento. Assim, neste trabalho diferentes tecnologias são verificadas com o intuito de identificar qual é a melhor opção a ser instalada no sistema *microgrid* proposto, na cooperação entre geração e armazenagem da eletricidade. Para tomada de decisão, buscando definir qual é a tecnologia mais indicada ao *microgrid* referido, o método descrito na Seção 3.3 será utilizado.

## 3 Fundamentação Teórica

### 3.1 Otimização

Em termos gerais, otimização se refere ao estudo de problemas em que se busca minimizar ou maximizar uma função por meio da escolha sistemática dos valores de variáveis dentro de um conjunto (KONAR, 2005). Normalmente uma função, na qual se busca encontrar seu extremo (máximo ou mínimo), representa alguma causa ou princípio em que é necessário analisar ou construir. A motivação para realização de uma otimização deve ser clara, como a minimização do custo de um sistema ou a maximização da eficiência do mesmo. Para sua efetuação, os valores extremos de uma função (ou aproximações dos mesmos) podem ser obtidos usando algoritmos de otimização, no domínio do problema regido por sua(s) variável (eis) de decisão, respeitando as restrições impostas pelo problema.

No âmbito da engenharia, a otimização pode ser aplicada, por exemplo, quando há necessidade de se encontrar o melhor ajuste possível para os controles de um determinado processo industrial, ou buscar a melhor configuração possível para os processos produtivos na obtenção de um produto. Este capítulo apresenta conceitos matemáticos referentes a otimização mono objetivo, multiobjetivo e a por escalarização dos objetivos.

#### 3.1.1 Otimização Mono-objetivo

Um problema de otimização mono-objetivo pode ser caracterizado quando existe apenas uma função objetivo e deseja-se por padrão realizar sua minimização. Além de minimizar uma determinada função objetivo, a otimização deve também atender as restrições impostas ao problema. Estas podem ser por exemplo, limitações físicas ou tecnológicas. Conceitualmente, uma função de variáveis do tipo escalar tem a forma  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  e um problema de otimização mono-objetivo que busca a minimização de uma função pode ser expresso como:

$$\begin{aligned} \mathbf{x}^* &= \arg \min f(\mathbf{x}), \\ \text{sujeito a : } &\begin{cases} \mathbf{g}_i(\mathbf{x}) \leq 0 & i = 1, \dots, r, \\ \mathbf{h}_j(\mathbf{x}) = 0 & j = 1, \dots, p, \end{cases} \end{aligned} \quad (1)$$

no qual:

- $\mathbf{x}$  é o vetor de variáveis de otimização,  $\mathbf{x}^*$  é o vetor otimizado e  $f(\mathbf{x})$  a função objetivo;
- $\mathbf{g}_i(\mathbf{x}) \leq 0$ ,  $i = 1, \dots, r$  e  $\mathbf{h}_j(\mathbf{x}) = 0$ ,  $j = 1, \dots, p$  são as restrições de desigualdade e igualdade impostas ao problema, respectivamente (TAKAHASHI; CUNHA, 2013).

A primeira linha do problema (1) indica que é necessário encontrar o vetor  $\mathbf{x}^* \in \mathbb{R}^n$  que minimize o valor da função  $f(\mathbf{x})$ . A segunda linha mostra que uma solução para este problema deve satisfazer as restrições impostas a ele.

### 3.1.2 Otimização Multiobjetivo

Um problema multiobjetivo é caracterizado por ter duas ou mais funções objetivo que são geralmente conflitantes. Este tipo de problema não têm uma solução única, mas um conjunto de soluções ótimas denominado soluções Pareto-ótimas ou soluções eficientes. Um problema de otimização multiobjetivo pode ser formulado como:

$$\begin{aligned} \chi^* &= \{\mathbf{x}^* \in \mathbb{R}^n\} \\ \mathbf{x}^* &= \min_{\mathbf{x}} \mathbf{f}(\mathbf{x}) \\ \text{sujeito à: } &\begin{cases} \mathbf{g}_i(\mathbf{x}) \leq 0; & i = 1, 2, \dots, r, \\ \mathbf{h}_j(\mathbf{x}) = 0; & j = 1, 2, \dots, p, \end{cases} \end{aligned} \quad (2)$$

na qual  $\mathbf{x} \in \mathbb{R}^n$  são os vetores das variáveis de decisão que formam o espaço de parâmetros  $\chi$ . Os vetores  $\mathbf{f}(\mathbf{x}) \in \mathbb{R}^m$  pertencem a um espaço chamado de espaço de objetivos, ou seja, a imagem da função  $\mathbf{f}(\cdot)$ . As funções  $\mathbf{g}_i(\mathbf{x})$  e  $\mathbf{h}_j(\mathbf{x})$  são, respectivamente, restrições de desigualdade e igualdade do problema de otimização (TAKAHASHI; CUNHA; FONSECA, 2013). A presença de múltiplos objetivos em um problema desta classe geralmente dá origem a uma família de soluções eficientes,  $\chi^*$ , conhecida como Conjunto Pareto-ótimo (ou conjunto de soluções eficientes).

A imagem deste conjunto, denotada por  $\mathcal{Y}^*$ , é denominada Fronteira Pareto-ótimo ou imagem do conjunto de soluções não-dominadas. Cada componente do vetor de objetivos é pertencente ao conjunto de soluções não dominadas  $\chi^*$ . O problema de otimização multiobjetivo consiste em determinar um conjunto de soluções que satisfaçam as restrições e que minimizem as funções objetivo  $\mathbf{f}(\mathbf{x})$ . O conceito de dominância pode ser definido como: dadas duas soluções,  $\mathbf{x}$  e  $\mathbf{y}$ , diz-se que  $\mathbf{x}$  domina  $\mathbf{y}$  (denotado  $\mathbf{x} \preceq \mathbf{y}$ ) se as seguintes condições são satisfeitas:

1. A solução  $\mathbf{x}$  é pelo menos igual a  $\mathbf{y}$  para todos os objetivos;
2. A solução  $\mathbf{x}$  é superior a  $\mathbf{y}$  para pelo menos um objetivo.

### 3.1.3 Otimização por Escalarização de objetivos

Uma maneira de resolver um determinado problema de natureza multiobjetivo é a escalarização linear dos objetivos. Entre os vários métodos de escalarização está o uso de pesos, que estão associados com a importância de cada objetivo em questão (EHRGOTT, 2006; MIETTINEN; MAKELA, 2002; EICHFELDER, 2008). Neste método, um problema multiobjetivo pode ser transformado em um problema mono-objetivo. Alguns trabalhos com

problemas de aplicação do mundo real usaram com sucesso esta técnica (BORHANAZAD et al., 2014; PEREIRA et al., 2015). A função de aptidão (*fitness*) necessária para encontrar um único ponto na Fronteira de Pareto (COELLO et al., 2007) é dada por:

$$\min = \sum_{i=1}^k w_i f_i(\mathbf{x}),$$

$$\text{com } w_i \geq 0 \text{ e } \sum_{i=1}^k w_i = 1,$$

$$\text{sujeito à: } g_i(\mathbf{x}) \geq 0 \text{ e } h_j(\mathbf{x}) = 0 \text{ para } i, j \in \{1, \dots, m\},$$

nas quais  $k$  é o número de objetivos,  $w_i$  são os pesos associados a cada objetivo,  $x$  é o vetor de variáveis de decisão,  $f_i$  são as funções objetivo. Funções  $g_i(\mathbf{x})$  e  $h_j(\mathbf{x}) = 0$  são restrições de desigualdade e de igualdade, respectivamente.

## 3.2 Algoritmos Evolucionários

Nos últimos 40 anos do século XX, muitos estudos relacionados à proposição e implementação de metaheurísticas baseadas e inspiradas em mecanismos de adaptação e seleção natural foram realizados. Esta área se tornou extensa e rica no âmbito da pesquisa, na grande área da inteligência artificial, ficando conhecida como Algoritmos Evolucionários (AE) (BEYER; SCHWEFEL; WEGENER, 2002). Uma das técnicas de AE que pode ser considerada como a mais difundida na literatura são os AG (GOLDBERG, 1989). AG são métodos computacionais de busca baseados nos mecanismos de evolução e seleção natural. Um conjunto de possíveis soluções (população) evolui de acordo com regras probabilísticas inspiradas por metáforas biológicas: a cada geração, os indivíduos tendem a ser melhores, enquanto o processo de evolução recomeça. AG são caracterizados por operadores de cruzamento, mutação e seleção entre os indivíduos da população. Muitos AE são inspirados nesta mesma técnica ou derivados dela (GOLDBERG, 1989), nas abordagens mono e multiobjetivo. Este trabalho destaca e descreve duas metaheurísticas de cunho multiobjetivo em especial, o *Nondominated Sorting Genetic Algorithm II* (NSGA-II) (DEB et al., 2000) e o *Strength Pareto Evolutionary Algorithm 2* (SPEA2) (ZITZLER; LAUMANN; THIELE, 2001).

Um outro algoritmo que ganhou destaque na década de 90, foi o algoritmo de Evolução Diferencial (DE, do termo em inglês *Differential Evolution*) de Storn e Price (1995). Este método é considerado um AE, uma vez que possui em seu ciclo de execução procedimentos semelhantes aos apresentados no AG, embora seu operador de mutação não seja bio-inspirado. Este algoritmo populacional foi considerado como de caráter geral dada a robustez apresentada em resultados experimentais sobre difíceis funções de *benchmark*

(STORN; PRICE, 1997). Miranda e Fonseca (2002) introduziram ao algoritmo de otimização por Enxame de Partículas (PSO, do termo em inglês *Particle Swarm Optimization*) um operador inspirado em seleção natural gerando então uma nova metaheurística populacional evolutiva denominada algoritmo de Otimização Evolucionário por Enxame de Partículas (EPSO, do termo em inglês *Evolutionary Particle Swarm Optimization*).

Esta seção apresenta uma breve revisão dos algoritmos evolucionários mono-objetivo e multiobjetivo relacionados a este trabalho, que serviram de inspiração para proposição de novos métodos mono-objetivo ou seu uso direto no caso das técnicas multi-objetivo. Os algoritmos mono-objetivo DE e EPSO serão apresentados distintamente nas subseções 3.2.1 e 3.2.2, enquanto os algoritmos multiobjetivo NSGA-II e SPEA2 serão discutidos na subseção 3.2.3.

### 3.2.1 O algoritmo de Evolução Diferencial

Um algoritmo que ganhou destaque na literatura é o algoritmo DE, que foi proposto por Storn e Price (1995) e vem sendo difundido na comunidade científica desde então, por obter sucesso na solução de diversos problemas de cunho geral, dado seu bom desempenho demonstrado nas edições de 1996 e 1997 da *International Contest on Evolutionary Optimization* da *IEEE International Conference on Evolutionary Computation - ICEC* (DAS; SUGANTHAN, 2011). Embora o método de evolução diferencial seja classificado como um algoritmo evolucionário, e se enquadre em um esquema geral de AE, a mutação diferencial não tem inspiração em nenhum processo natural (GUIMARÃES, 2013). O algoritmo DE consiste em gerar aleatoriamente uma população de indivíduos, na qual cada indivíduo representa um ponto de busca no espaço de soluções potenciais de um dado problema.

Em geral, esta população inicial é criada aleatoriamente a partir de uma distribuição de probabilidade uniforme, quando não há nenhum conhecimento sobre o problema. A população inicial sofre modificações, dando lugar a uma nova população de mesmo tamanho, até que o procedimento de otimização seja encerrado, por exemplo, ao se atingir um número máximo de iterações. O algoritmo DE se baseia em seu operador de mutação diferencial, que utiliza a diferença entre pares de vetores. Na sua versão clássica um vetor-diferença é criado a partir da diferença vetorial de dois outros vetores candidatos selecionados aleatoriamente na população. Após isto, ao vetor diferença é somado um terceiro vetor, amostrado aleatoriamente da população, gerando assim uma nova solução. Logo, este processo de mutação pode ser descrito por meio da Equação (3),

$$V_{t,i} = x_{t,r1} + F(x_{t,r2} - x_{t,r3}); \quad r_1 \neq r_2 \neq r_3 \in \{1, \dots, N\}, \quad (3)$$

na qual  $V_{t,i}$  é a  $i$ -ésima solução mutante da população, os parâmetros  $x_{t,r1}$  é denominado vetor base,  $x_{t,r2}$  e  $x_{t,r3}$  são diferentes vetores amostrados aleatoriamente da população.

$F$  é um fator de escala aplicado ao vetor diferença usado para controlar a amplificação da variação diferencial. DE possui um operador de recombinação, que em sua versão clássica é realizada uma recombinação discreta. Os indivíduos da população corrente  $X_t$  são re combinados com os indivíduos da população mutante, gerando a população de soluções teste  $U_t$ . A recombinação é obtida conforme,

$$u_{t,i,j} = \begin{cases} v_{t,i,j}, & \text{se } U_{[0,1]} \leq C_r \vee j = \delta_i \\ x_{t,i,j}, & \text{caso contrário} \end{cases} \quad (4)$$

na qual  $u_{t,i,j}$  representa a dimensão  $j$  do indivíduo  $i$  da população mutante no momento  $t$ .  $C_r \in [0,1]$  é uma probabilidade de cruzamento informada pelo usuário.  $U_{[0,1]}$  representa uma amostragem aleatória de uma variável com distribuição uniforme no intervalo  $[0,1]$  e  $\delta_i$  é uma amostragem aleatória inteira de  $[1, \dots, n]$  na qual  $n$  representa o número de variáveis presentes em cada indivíduo.

Após este procedimento, o valor da função objetivo é avaliado em  $u_{t,i}$ . Cada solução mutante  $u_{t,i}$  é comparada com seu correspondente,  $x_{t,i}$ , na população corrente. Se a solução mutante for melhor que a solução corrente,  $x_{t,i}$ , a solução corrente é eliminada e seu lugar passa a ser ocupado por  $u_{t,i}$ . Caso contrário, a solução mutante é eliminada e a solução corrente sobrevive permanecendo na próxima geração,  $X_{t+1}$ .

A notação usual DE/x/y/z é utilizada neste algoritmo e esta faz menção às estratégias evolutivas utilizadas, como por exemplo, a estratégia inicial proposta por [Storn e Price \(1995\)](#), conforme:

- $x$  especifica o vetor que vai participar do processo de mutação, podendo ser *rand* (um vetor da população escolhido aleatoriamente), ou outros;
- $y$  determina o número de diferenças ponderadas em que o vetor  $x$  será submetido ao processo de mutação, e;
- $z$  determina o tipo de cruzamento (bin: binomial).

A título de exemplo, se a estratégia adotada for DE/*rand*/1/bin, um vetor da última geração é escolhido aleatoriamente e participa do processo de mutação. Neste caso, o vetor *rand* sofrerá uma operação de diferença ponderada usada para a perturbação do vetor mutante e usará cruzamento binomial. Ao longo dos anos, diversas estratégias tem sido propostas para o melhoramento deste algoritmo, como por exemplo: DE/best/1, DE/target-to-best/1, DE/best/2, DE/rand/2, DE/current-to-rand/1 ([PRICE, 1999](#); [PRICE; STORN; LAMPINEN, 2005](#)), DE/current-to-best/1 ([QIN; SUGANTHAN, 2005](#); [HUANG; QIN; SUGANTHAN, 2006](#)), DE/current-to-pbest/1 ([ZHANG; SANDERSON, 2009](#)). O fluxo de execução do algoritmo DE é retratado no pseudocódigo apresentado pelo Algoritmo 1.

**Algoritmo 1:** Pseudocódigo do algoritmo de Evolução Diferencial.Adaptado: [Das e Suganthan \(2011\)](#)


---

```

início
  Passo 1: Iniciar os parâmetros de controle de DE: taxa de perturbação  $F$ , taxa de
    recombinação  $C_r$ , tamanho da população  $NP$  informados pelo usuário.
  Passo 2: Iniciar o contador de gerações  $t = 1$  e inicializar uma população aleatória de  $NP$ 
    indivíduos  $X_t = \{x_{t,i}; i = 1, \dots, N\}$ 
  Passo 3:
  enquanto o critério de parada não é satisfeito faça
    para  $i = 1:NP$  para cada indivíduo sequencialmente faça
      Passo 3.1: Mutação
      Gerar vetor-diferença:  $V_{t,i} = x_{t,r1} + F(x_{t,r2} - x_{t,r3}); r_1, r_2, r_3 \in \{1, \dots, N\}$ 
      Passo 3.2: Cruzamento
       $u_{j,i,j} = v_{t,i,j}$ , IF ( $U_{[0,1]} \leq C_r \vee j = \delta_i$ ) caso contrário  $x_{t,i,j}$ 
      Passo 3.3: Seleção
      se  $f(u_{t,i}) \leq f(x_{t,i})$  então
        |  $x_{t+1,i} = u_{t,i}$ 
      senão
        |  $x_{t+1,i} = x_{t,i}$ 
      fim
    fim
     $t = t + 1$ 
  fim
fim

```

---

## 3.2.2 O algoritmo EPSO

O algoritmo EPSO foi proposto por [Miranda e Fonseca \(2002\)](#). A ideia foi introduzida de forma a concatenar os conceitos de auto adaptação dos AE à função exploratória do conhecido algoritmo PSO que se apoia no comportamento social dos animais, com base no conjunto de soluções representadas como partículas, para explorar o espaço de busca a partir da interação das mesmas. No PSO cada partícula  $X_i$  obedece uma regra de movimento que depende da velocidade. Por sua vez, a velocidade é dependente de três fatores conhecidos como inércia, memória e cooperação, conforme Equações (6) e (5):

$$V_i^{new} = Dec(t)w_{i0}V_i + Rnd_1w_{i1}(b_i - X_i) + Rnd_2w_{i2}(b_g - X_i). \quad (5)$$

$$X_i^{new} = X_i + V_i^{new}, \quad (6)$$

O parâmetro  $V_i^{new}$  caracteriza a atualização das velocidades das partículas que se movem em direção ao ótimo. O primeiro termo da Equação (5) é caracterizado como inércia, e ligado a ele se tem a função  $Dec(t)$  que é responsável por diminuir o peso de inércia durante o ciclo de execução do algoritmo. O termo  $b_i$  representa a memória da partícula, fazendo com que o seu movimento seja atraído para o melhor ponto encontrado pela partícula no ciclo anterior. O último termo é referente à cooperação entre as partículas, ou seja a troca de informações, para que o melhor ponto atual seja encontrado pelo enxame,  $b_g$ , se movendo para esta direção. Os parâmetros  $w_{ik}$  são pesos aplicados a cada fator e  $Rnd_x$  são números gerados aleatoriamente a partir de uma distribuição uniforme.

A ideia por trás do algoritmo EPSO é fornecer capacidade de adaptação ao operador de recombinação. Para alcançar este objetivo, os pesos dos fatores (inércia, memória e cooperação) foram sujeitos à mutação, a fim de tentar obter uma maior aceleração de convergência. Uma vez que a eficiência do processo de evolução é limitada pela influência de valores de pesos na equação de movimento, uma propriedade de auto-adaptação teve que ser adicionada aos parâmetros estratégicos.

Desta forma, o valor inicial especificado para os pesos  $w_{ij}$  perdeu a sua relevância no mecanismo EPSO. O processo de seleção também opera com nível dos valores dos pesos, selecionando aqueles que dão a melhor eficiência na convergência dos algoritmos em direção de busca ao ótimo. No algoritmo EPSO, a partir da posição de uma partícula  $X_i$ , a posição de uma nova partícula  $X_i^{new}$  é obtida pelas Equações (8) e (7), conforme:

$$V_i^{new} = w_{i0}^* V_i + w_{i1}^* (b_i - X_i) + w_{i2}^* P(b_g^* - X_i). \quad (7)$$

$$X_i^{new} = X_i + V_i^{new}, \quad (8)$$

Apesar de usar inteligência de enxame, EPSO segue um esquema evolutivo como qualquer outro AE (MIRANDA; FONSECA, 2002).

### 3.2.3 Algoritmos Evolucionários Multiobjetivo

Estudos relacionados aos AE multiobjetivo datam dos anos 80. O primeiro algoritmo desta classe com base em Fronteira de Pareto foi proposto por Fonseca e Fleming (1993) no início da década de 90, o qual foi denominado como *Multiobjective Genetic Algorithm* (MOGA). Depois disto, alguns outros algoritmos surgiram, os quais são: *Niched Pareto Genetic Algorithm* (NPGA) proposto por Horn e Goldberg (1994), *Nondominated Sorting Genetic Algorithm* (NSGA) proposto por Srinivas e Deb (1994), e sua evolução NSGA-II (DEB et al., 2000). Nesta mesma época também foi proposto o *Strength Pareto Evolutionary Algorithm* (SPEA) (ZITZLER; THIELE, 1998), e sua evolução, o SPEA2 proposto por Zitzler, Laumanns e Thiele (2001).

No contexto dos AE, a abordagem multiobjetivo se difere da mono-objetivo na forma em que se é atribuída a aptidão (*fitness*) às soluções. Para um AE mono-objetivo, a melhor solução é a mais apta. No caso do AE multiobjetivo existe uma diferença entre as soluções dominantes de um conjunto referência. Desta forma, é necessário definir algumas estratégias para calcular a aptidão das soluções e para selecionar aquelas com maior probabilidade de reprodução. Em geral um AE multiobjetivo tem a estrutura apresentada no

## Algoritmo 2.

**Algoritmo 2:** Pseudocódigo de um AE multiobjetivo generalista

---

```

início
  Inicializar a população;
   $P(t=0) = \{p^{(1)} \dots p^{(\mu)}\}$ ;
  Inicializar população do arquivo de estimativas Pareto  $A(t=0) \leftarrow \emptyset$ ;
  enquanto Critério de parada não for satisfeito faça
     $\phi_P(t), \phi_A(t) \leftarrow$  avaliar aptidão  $(P(t), A(t))$ ;
     $A(t+1) \leftarrow$  atualização do arquivo  $(P(t), A(t), \phi_P(t), \phi_A(t))$ ;
     $S(t) \leftarrow$  seleção  $(P(t), A(t), \phi_P(t), \phi_A(t))$ ;
     $R(t) \leftarrow$  recombinação  $(S(t))$ ;
     $Q(t) \leftarrow$  mutação  $(R(t))$ ;
     $P(t+1) \leftarrow$  atualização  $(Q(t), P(t))$ ;
     $t \leftarrow t + 1$ ;
  fim
fim

```

---

## 3.2.3.1 O algoritmo NSGA-II

No fim da década de 80, [Goldberg \(1989\)](#) propôs no seu livro uma inspiração para a construção de um AE multiobjetivo. Posteriormente, o algoritmo *Nondominated Sorting Genetic Algorithm* (NSGA) foi proposto por [Srinivas e Deb \(1994\)](#). A principal característica deste algoritmo é a ordenação por fronteiras não dominadas, que consiste em ordenar os indivíduos da população em termos de fronteiras não dominadas, no espaço de objetivos, e atribuir um valor de aptidão para cada fronteira não dominada.

O NSGA clássico usava função de partilha para degradar os valores de aptidão entre indivíduos de uma mesma fronteira muito próximos entre si. Tal método apresentava alguns problemas práticos, o principal deles era a complexidade computacional da ordenação por fronteiras não dominadas, além de não implementar elitismo ([DEB et al., 2000](#)). Então foi proposta uma nova versão deste algoritmo, o NSGA-II ([DEB et al., 2000](#)). As principais mudanças no NSGA-II são:

- A criação de um algoritmo para ordenação rápida e de menor complexidade computacional do que a ordenação por fronteiras não dominadas original;
- A utilização de elitismo e a eliminação do parâmetro de nicho, por meio do uso de outra estratégia para medida de dispersão denominada distância de multidão. Esta é calculada por meio da distância média das duas soluções adjacentes a cada indivíduo para todos os objetivos.

O NSGA-II realiza a aptidão de indivíduos por meio do procedimento de ordenação de fronteiras conhecido como *fast non-dominated sorting* e atribuição do operador de diversidade *crowding distance*, definindo assim a qualidade das soluções obtidas. Em um problema de minimização bi-objetivo, a primeira etapa realizada pelo operador *fast non-dominated sorting* é realizar a organização das soluções candidatas em fronteiras, nas quais a fronteira mais inferior representa soluções não-dominadas e as superiores são ditas

soluções dominadas em relação à fronteira imediatamente anterior.

Na segunda fase, para se obter uma estimativa da densidade de soluções que estão ao redor de uma solução em particular da população, o cálculo da distância média entre dois pontos com referência a uma determinada solução é realizado observando cada um dos objetivos. Esta distância é uma estimação do perímetro de um cuboide formado usando os vizinhos mais próximos como vértices, caracterizando assim o operador *crowding distance*. Informações detalhadas sobre este algoritmo se encontram em (SRINIVAS; DEB, 1994) e (DEB et al., 2000).

### 3.2.3.2 O algoritmo SPEA2

O *Strength Pareto Evolutionary Algorithm* (SPEA) foi proposto por Zitzler e Thiele (1998) no final da década de 90. Pode-se dizer que o SPEA marca o início da segunda geração de AE multiobjetivo. Este algoritmo foi o primeiro a empregar uma população de arquivo com as melhores soluções. Posteriormente, como ocorrido com o NSGA, foram identificadas algumas limitações e uma versão mais sofisticada foi proposta em seguida, o SPEA2 (ZITZLER; LAUMANN; THIELE, 2001). Este algoritmo se difere pelo fato que a primeira população do arquivo tem sempre tamanho fixo e igual ao tamanho da população inicial, conforme:

- Até o momento, a população do arquivo tinha sempre tamanho menor ou igual à população inicial;
- No SPEA2, a atualização do arquivo consiste em colocar as soluções não dominadas,  $A(t) \cup P(t)$ , na próxima população em arquivo  $A(t + 1)$ ;
- Se o tamanho de  $A(t + 1)$  for menor do que as melhores soluções da população inicial, as melhores soluções de  $A(t) \cup P(t)$ , de acordo com os valores de aptidão, são colocadas na próxima população de arquivo,  $A(t + 1)$ , até que se complete o arquivo;
- Se o tamanho da próxima população em arquivo for maior do que a população inicial, emprega-se uma estratégia para redução do arquivo com uso de um operador de truncamento.

A estratégia de redução de arquivo ocorre quando o tamanho do conjunto de soluções não-dominadas excede o tamanho da população. Desta maneira o operador de truncamento de arquivo remove iterativamente indivíduos. A cada iteração, um indivíduo é escolhido para remoção. O indivíduo que possui a mínima distância para outro indivíduo é escolhido para remoção. Se houverem vários indivíduos com distância mínima, o desempate é realizado considerando as segundas menores distâncias e assim por diante.

A segunda diferença é que o operador de seleção atua somente sobre indivíduos da população de arquivo. Por essa razão, a população em arquivo é preenchida com os melhores indivíduos até ter o tamanho da população inicial, de forma a manter uma ampla

diversidade de opções para o operador de seleção. Informações detalhadas sobre este algoritmo se encontram em (ZITZLER; THIELE, 1998) e (ZITZLER; LAUMANN; THIELE, 2001).

### 3.3 Análise de Decisão Multicritério

A tomada de decisão leva em consideração alguns critérios definidos previamente objetivando alcançar a melhor escolha para ser considerada como solução de um determinado problema. Esta decisão pode ser guiada a partir de um conjunto de alternativas de solução possíveis dado um problema de otimização, quando há uma função objetivo a ser maximizada ou minimizada. Em um problema multiobjetivo ou multicritério, há mais de um objetivo a ser observado e geralmente eles podem ser conflitantes. Tais objetivos estão usualmente associados às possíveis consequências (ou resultados) advindos da escolha de uma alternativa. Desta maneira, esses problemas possuem mais de uma função objetivo a ser atendida em concomitância. Na Análise de Decisão Multicritério (MCDA, do inglês *Multi-Criteria Decision Analysis*), cada objetivo pode ser representado por uma variável, na qual seu desempenho para uma dada alternativa pode ser avaliado. Essa variável pode ser chamada de critério ou atributo, dependendo do método multicritério utilizado (ALMEIDA et al., 2015).

MCDA é considerada uma área da pesquisa operacional que possui modelos que lidam com problemas de decisão envolvendo multicritérios. Em geral, o MCDA pode ser separado em métodos compensatórios clássicos ou teoria da utilidade multiatributo provenientes da academia americana ou métodos de aproximações do *outranking* advindos da escola europeia (GUITOUNI; MARTEL, 1998). Todos os métodos MCDA apresentam seus limites teóricos e pragmáticos sendo geralmente adequados para diferentes problemas de decisão. Os métodos de MCDA podem ser descritos por uma fase de construção (dados de entrada e fase de modelagem - que inclui a interface com os *stakeholders*) e uma fase de exploração (agregação e cálculo que leva a recomendações). O Processo de Hierarquia Analítica (AHP, do inglês *Analytic Hierarchy Process*) foi utilizado nesta tese para a fase de construção e a Técnica de Preferência de Ordem por Semelhança a Solução Ideal (TOPSIS, do inglês *Technique for Order Preference by Similarity to Ideal Solution*) foi considerada como uma abordagem adequada para a fase de exploração e será fundamentada nesta seção. Um levantamento do estado da arte foi realizado por Chai, Liu e Ngai (2013), em que 30 artigos (24.39%) desta sondagem utilizaram AHP e 14.65% fizeram uso de TOPSIS.

Segundo Saaty (1990) o AHP representa uma estrutura não-linear para realizar o pensamento dedutivo e indutivo, considerando vários fatores simultaneamente, permitindo que *trade-offs* cheguem a uma síntese. AHP é uma metodologia conhecida, popular e de fácil entendimento baseada em utilidade multiatributo que faz uso de comparações

pareadas associadas aos julgamentos de especialistas para lidar com a estimação de atributos qualitativos ou intangíveis. É um método compensatório que permite compromissos numéricos entre várias dimensões. O método requer uma hierarquia ou uma estrutura de rede que represente o problema de decisão (SAATY, 1987). Isso é feito simplesmente pela decomposição e estruturação do dado problema de decisão em diferentes níveis dentro de uma hierarquia. No topo dessa hierarquia, permanece o objetivo geral do processo decisório (por exemplo, escolha de um serviço, uma política ou uma tecnologia).

Critérios relacionados ao problema podem ser encontrados sob este objetivo e podem ser ainda mais decompostos. Alternativas concorrentes podem ser encontradas na parte inferior abaixo dos critérios de nível mais baixo (SAATY, 1987), (GOODWIN, 2004). As comparações em pares, baseadas numa escala 1-9 de números absolutos, devem ser realizadas para recolher a importância relativa de cada critério com base nesta estrutura hierárquica. A importância relativa de dois critérios comparados é disposta em uma escala discreta de 1 a 9, conforme ilustrado na Tabela 1.

Tabela 1 – Escala de comparação de pareamento AHP.

1	Mesma importância	Dois critérios contribuem igualmente para os objetivos
3	Um pouco mais importante (moderadamente fraco)	Um critério é ligeiramente favorecido contra o outro
5	Moderadamente mais importante (de essencial importância)	Um critério é moderadamente mais favorecido contra o outro
7	Fortemente mais importante (fortemente importante)	Um critério é fortemente favorecido contra o outro
9	Extremamente mais importante (importância absoluta)	Um critério é favorecido sobre outro com a mais alta ordem possível de afirmação
2, 4, 6, 8	Valores intermediários entre os dois valores de escala adjacentes	Usado para representar compromisso entre as prioridades listadas acima

A quantidade de comparações pareadas,  $n_c$ , é dependente do número de critérios considerados e pode ser calculada por,

$$n_c = \frac{n(n-1)}{2}.$$

AHP requer uma matriz  $M \times N$  na qual  $M$  é o número de alternativas e  $N$  o número de critérios. A matriz é construída por comparações pareadas que fornecem a base para uma matriz quadrada em que  $a_{ij}$  representa as razões de pesos ( $w_i/w_j$ ) para cada objeto/critério  $A_1, \dots, A_n$ . Os elementos  $a_{ij}$  indicam o julgamento do par de critérios ( $C_i, C_j$ ). Todos os outros elementos restantes representam a propriedade recíproca da matriz por meio de  $a_{ij} = 1/a_{ji}$  e  $a_{jj} = 1$  (SAATY, 1987) (PERERA; SUTRISNA, 2010). Portanto a matriz de julgamentos pode ser obtida conforme,

$$A = \begin{matrix} & C_1 & \cdots & C_n \\ A_1 & \left[ \begin{array}{ccc} w_1/w_1 & \cdots & w_1/w_n \\ \vdots & \ddots & \vdots \\ w_n/w_1 & \cdots & w_n/w_n \end{array} \right] & & \end{matrix} . \quad (9)$$

Existem vários métodos de priorização disponíveis na literatura, mas poucos fornecem fatores correspondentes que permitem avaliar a inconsistência dentro dos julgamentos (AGUARON; MORENO-JIMENEZ, 2003). Os métodos mais comuns para cálculo das prioridades são o método clássico de autovetores e o cálculo da média geométrica (GMM, do inglês *Geometrical Mean Method*). Na proposta de Saaty (1990), AHP faz uso do cálculo de autovetores, conforme descrito pela Equação (10),

$$A\omega = \lambda_{max}\omega \sum_{i=1}^n \omega_i = 1, \quad (10)$$

na qual  $A$  é a matriz de compensação pareada positiva de ordem  $n_o$ ,  $\lambda_{max}$  é o maior autovalor presente em  $A$  e  $\omega$  é o vetor de prioridade. De acordo com (AGUARON; MORENO-JIMENEZ, 2003) o vetor de prioridade  $w_{iAHP}$  pode ser calculado para cada linha, usando o conceito de GMM, pelo uso da Equação (11),

$$w_{iAHP} = \sqrt[n_{cr}]{\prod_{j=1}^{n_{cr}} (a_{ij})}. \quad (11)$$

na qual  $n_{cr}$  representa a quantidade de critérios em uma matriz de decisão normalizada conforme descrito em (AGUARON; MORENO-JIMENEZ, 2003). É possível que os julgamentos na matriz de pareamento de comparações sejam totalmente consistentes ou não. A inconsistência é uma consequência da tentativa de derivar uma prioridade por meio da comparação de dois critérios de cada vez. Esses objetos podem estar envolvidos em várias comparações em uma escala não padronizada, nas quais os valores relativos são atribuídos como uma questão de julgamento, podendo ocorrer inconsistência.

Previendo a eventualidade de inconsistência, AHP faz uso de um fator correspondente chamado Índice de Consistência (CI, do termo inglês *Consistency Index*). CI é utilizado para avaliação de inconsistência da matriz de julgamentos, e pode ser obtido pela Equação (12),

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (12)$$

na qual  $n$  é a ordem da matriz e  $\lambda_{max}$  é o maior autovalor da matriz de julgamentos. A matriz de julgamentos pode ser considerada consistente quando  $\lambda_{max} = n$  e CI é zero. A consistência das prioridades pode ser medida por uma razão de consistência (CR, do termo em inglês *Consistency Ratio*) dada pela Equação 13,

$$CR = \frac{CI}{RI(n)}, \quad (13)$$

na qual  $RI$  é o índice de consistência obtido para uma matriz aleatória recíproca, com elementos não negativos. Valores de  $RI$  foram tabelados por Saaty (1987) os quais estão dispostos na Tabela 2.

Tabela 2 – Índices de consistência. Fonte (SAATY, 1987)

Ordem da Matriz( $n$ )	2	3	4	5	6	7	8	9	10
RI	0	0.58	0.9	1.12	1.24	1.32	1.41	1.45	1.49

Uma junção das técnicas AHP e TOPSIS foi realizada neste trabalho. Para isto, os pesos obtidos via AHP foram inseridos no método TOPSIS, que pode ser caracterizado como um método de agregação eficiente e fácil de realizar. Baseia-se na ideia de Hwang e Yoon (1981) de que uma alternativa escolhida deve ter uma distância mínima à solução ideal positiva  $A^*$ , e uma distância máxima à solução ideal negativa  $A^-$ . Para este cálculo é utilizada a distância euclidiana. TOPSIS requer a geração de uma matriz  $R = \{r_{ij}\}$  na qual  $r_{ij}$  é definido na Equação (14) de Zaidan et al. (2015),

$$r_{ij} = \frac{c_{ij}}{\sqrt{\sum_{i=1}^m c_{ij}^2}}, \quad (14)$$

O parâmetro  $c_{ij}$  é um valor que indica a classificação de desempenho de todas as alternativas com relação a cada critério.  $R$  é então multiplicada pela sua priorização associada  $w_{iAHP}$  fornecida pelo AHP para determinar o alongamento do eixo de um valor normalizado  $NV_{ij}$ , conforme observado na Equação (15),

$$NV_{ij} = w_{iAHP} \times r_{ij}, \text{ com } i = 1, 2, \dots, n. \quad (15)$$

Segundo Zaidan et al. (2015), esta nova matriz é usada para determinar a solução ideal  $A^*$  e a solução ideal negativa  $A^-$  vistas nas Equações (16) e (17),

$$A^* = \{v_1^*, v_2^*, \dots, v_n^* \max_i v_{ij}^* \mid j \in J\}, (\min_i v_{ij}^* \mid j \in J^-), \quad (16)$$

$$A^- = \{v_1^-, v_2^-, \dots, v_n^- (\min_i v_{ij}^* \mid j \in J), (\max_i v_{ij}^* \mid j \in J^-)\}, \quad (17)$$

nas quais  $J$  está associada com os critérios positivos e  $J^-$  com os critérios negativos. Então uma medida de separação é realizada calculando a distância  $D_i^*$  para a melhor alternativa  $A_j$  e a distância  $D_i^-$  para a pior alternativa, conforme Equações (18) e (19),

$$D_i^* = \sqrt{\sum_{j=1}^n (v_{ij} - v_i^*)^2} \quad i = 1, 2, \dots, n, \quad (18)$$

$$D_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_i^-)^2} \quad i = 1, 2, \dots, n. \quad (19)$$

Finalmente, o cálculo para obter a proximidade com a solução ideal (CIS, do termo em inglês *Closeness to Ideal Solution*) classificando as alternativas é feita usando a Equação (20):

$$CIS_i = \frac{D_i^-}{D_i^* + D_i^-} \quad i = 1, 2, \dots, n. \quad (20)$$

A melhor solução é apresentada por  $CIS_j^* = 1$  se ( $A_j = A^*$ ) e a pior por  $CIS_j^* = 0$  se ( $A_j = A^-$ ). A classificação é realizada pela ordem decrescente de  $CIS_j$ , onde o valor mais alto representa o melhor desempenho (ZAIDAN et al., 2015). TOPSIS inibe o perigo da inversão de classificação<sup>1</sup> (*rank reverso*) (WANG; LUO, 2009; GARCIA-CASCALES-CASCALES; LAMATA, 2012). Duas alternativas fictícias, incluindo os valores  $min_c$  e  $max_c$ , foram assim introduzidas seguindo as recomendações de (GARCIA-CASCALES-CASCALES; LAMATA, 2012). Esses valores permanecem fixos para que qualquer avaliação em referência a eles não possa mudar. A Figura 5 mostra a representação física de uma solução bidimensional de TOPSIS.

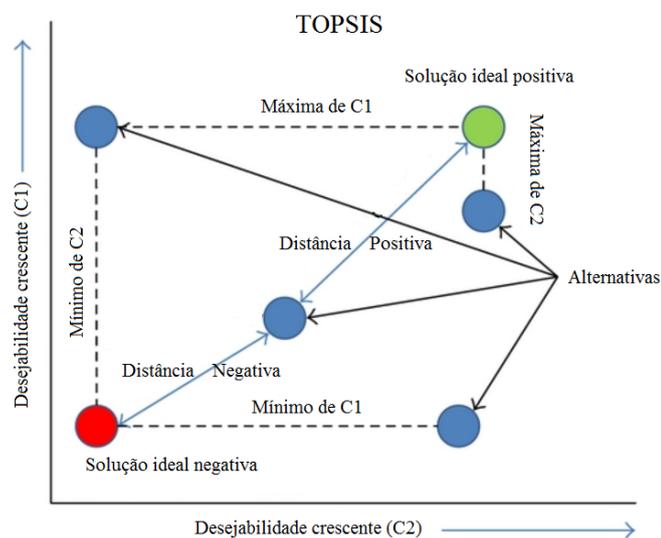


Figura 5 – Representação gráfica do funcionamento TOPSIS em 2D. Adaptado de: (CHAUHAN; VAISH, 2013)

Por fim, o fluxograma presente na Figura 6 apresenta as etapas realizadas no processo de junção dos métodos AHP e TOPSIS adotado.

<sup>1</sup> É uma mudança na ordem de classificação da preferência de alternativas de possíveis decisões.

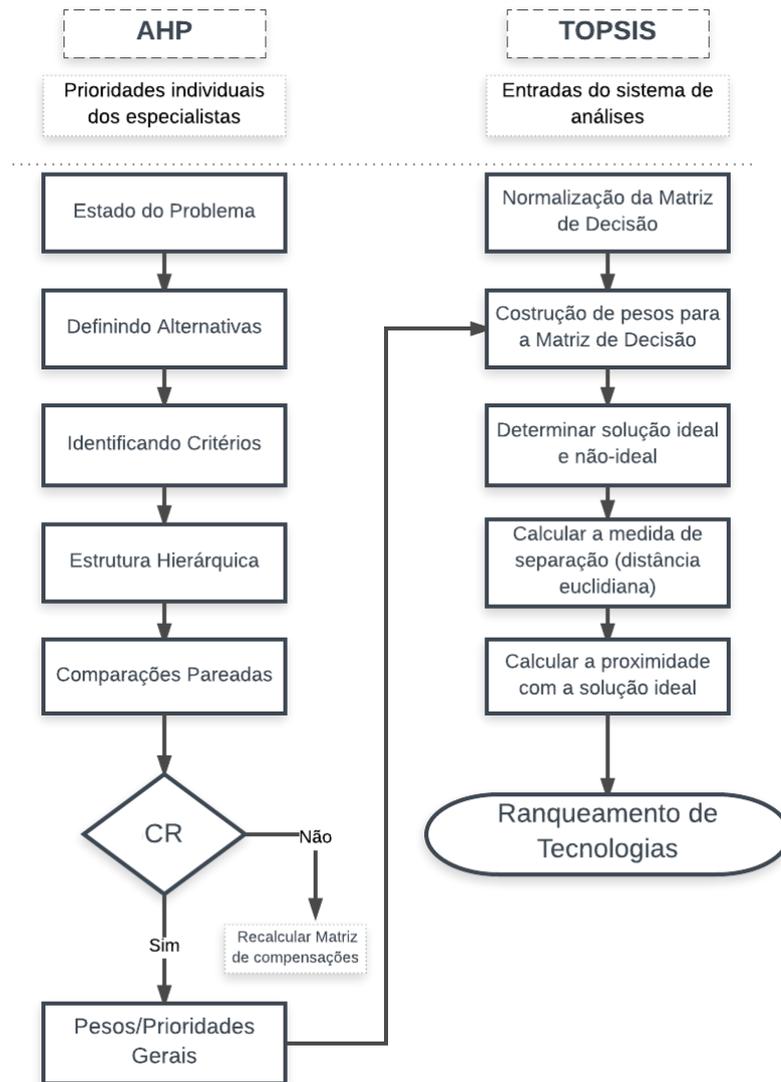


Figura 6 – Fluxograma do modelo MCDA adotado para avaliação de tecnologias.

### 3.4 Considerações Finais

Este capítulo apresentou a fundamentação teórica necessária para estabelecer os conceitos referentes a otimização, bem como três maneiras para seu uso: mono-objetivo, multiobjetivo e por escalarização de objetivos. Expôs conceitos a respeito do paradigma evolucionário referentes aos algoritmos a ele pertencentes, bem como as conhecidas metaheurísticas DE, EPSO na abordagem mono-objetivo que serviram de inspiração para proposta de um novo algoritmo híbrido. Os algoritmos evolutivos multiobjetivo NSGA-II e SPEA2 foram utilizados diretamente para a solução de um problema de despacho elétrico em usinas hidrelétricas conforme os experimentos descritos na Seção 6.1. Finalmente abordou as técnicas de decisão multicritério AHP e TOPSIS que foram utilizadas em conjunto neste trabalho para auxílio a tomada de decisão a respeito de diferentes tecnologias de armazenamento de energia.

## 4 Caracterização do Problema e Estudos de Casos

O fluxo de potência ótimo pode ser caracterizado como um mecanismo capaz de realizar os ajustes das variáveis de controle visando encontrar as condições ótimas para operação da rede de energia elétrica - despacho de potência ativa e reativa, redução na emissão de poluentes, minimização de custos operacionais, diminuição de perdas na transmissão, entre outros - (ABIDO, 2002; FRANK; STEPONAVICE; REBENNACK, 2012a; BISKAS et al., 2005). Este trabalho apresenta três estudos de caso relacionados ao OPF. Em primeiro lugar é discutida a extensão de um modelo despacho de energia elétrica em uma usina hidrelétrica (UHE) e sua otimização com uso de algoritmos evolutivos multiobjetivo, criando assim o conceito de controle conjunto otimizado para UHE. Após isto, o SCOPF em grandes redes elétricas no despacho ativo/reactivo é abordado em diferentes cenários conhecidos como, Sistemas teste do IEEE. Finalmente uma a proposta para aperfeiçoamento de um modelo e de sua otimização para um sistema *microgrid* híbrido (HMGS) é discutido e apresentado.

### 4.1 Formulação Matemática do Despacho em UHE

Uma usina hidrelétrica tem como objetivo produzir eletricidade, por meio da utilização do potencial hidráulico existente em um rio. Uma típica UHE é composta de uma barragem, responsável pela criação do reservatório, retendo a água. A força da gravidade conduz a água até a turbina por meio de um conduto forçado. A água acumula pressão à medida que flui através do conduto forçado. Em seguida, a água escorre pelas grandes pás de uma turbina, que está ligada a um gerador localizado acima dela por um eixo. A Figura 7 é uma representação gráfica de uma UHE.

Uma finalidade deste trabalho é a proposição e o aperfeiçoamento de algoritmos evolutivos para aplicação na área de energia. Como um estudo de caso a ser tratado, se propôs a continuidade do trabalho de (MARCELINO, 2012) cujo objeto era o tratamento do problema do despacho elétrico em uma usina hidrelétrica. Assim, são apresentadas nesta seção, de maneira resumida, a modelagem matemática do problema mono-objetivo e sua expansão para tratamento do problema em uma abordagem multiobjetivo. A modelagem matemática proposta utiliza como objetivo a maximização da produtividade de uma UHE de grande porte. Neste modelo, a produção elétrica em  $MW$  é calculada pela Equação (21),

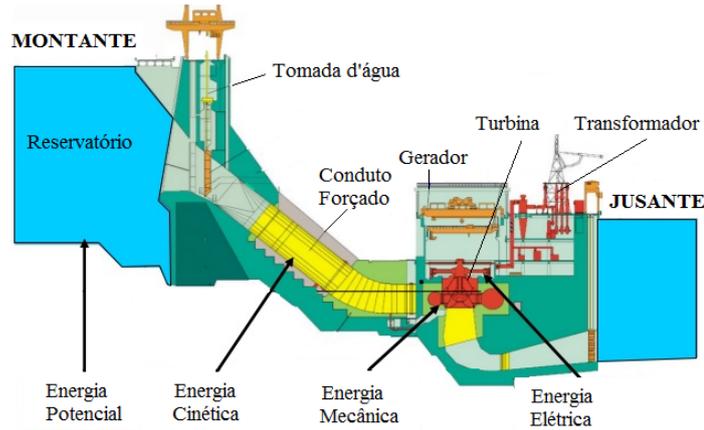


Figura 7 – Exemplo dos principais componentes presentes em uma UHE. A energia potencial da água é transformada em energia cinética, pela força da gravidade presente no conduto forçado. Por sua vez, a energia mecânica pode ser observada pelo movimento giratório da turbina pela água. O gerador então produz energia elétrica que é transformada e posteriormente transmitida por meio das linhas. Adaptado de Tucuri (Acessado em 16/06/2017).

$$ph_{jt} = g\kappa \cdot [\rho_{0j} + \rho_{1j}hl_{jt} + \rho_{2j}q_{jt} + \rho_{3j}hl_{jt}q_{jt} + \rho_{4j}hl_{jt}^2 + \rho_{5j}q_{jt}^2] \cdot [Hb_{jt} - \Delta_{Hjt}] \cdot q_{jt}, \quad (21)$$

na qual,

- $ph_{jt}$  é a potência gerada pela unidade geradora  $j$  no tempo  $t$  em  $MW$ ;
- $g$  é a aceleração da gravidade  $9,8m/s$ ;
- $\kappa = 10^{-3}kg/m$  é uma constante que converte cavalo vapor,  $HP$ , em  $MW$ ;
- $\rho_{0j} \dots \rho_{5j}$  são os coeficientes operativos da unidade geradora que foram obtidos por regressão linear multivariável e estão dispostos na Tabela 3;
- $hl_{jt}$  é a altura de queda líquida na unidade geradora  $j$  no tempo  $t$  em  $m$ ;
- $q_{jt}$  é a vazão turbinada na unidade geradora  $j$  no tempo  $t$  em  $m^3/s$ ;
- $Hb_{jt}$  é a altura de queda bruta na unidade geradora  $j$  no tempo  $t$  em  $m$ , e
- $\Delta_{Hjt}$  são as perdas totais referentes ao atrito nos condutos forçados na unidade geradora  $j$  no tempo  $t$  em  $m$ .

Tabela 3 – Coeficientes Operativos. Fonte: (MARCELINO, 2012)

Coefficiente	$\rho_{0j}$	$\rho_{1j}$	$\rho_{2j}$	$\rho_{3j}$	$\rho_{4j}$	$\rho_{5j}$
Valor	1,4630E+03	1,8076E+02	5,0502E+01	-3,5254E-01	-1,1234E+01	-1,4507E-01

Um modelo multiobjetivo do problema de despacho elétrico é proposto com a adição de um segundo objetivo ao modelo de otimização disposto nesta subseção. A modelagem multiobjetivo proposta é a da maximização da produção de energia elétrica e minimização da distância entre o modo de funcionamento do sistema, comumente chamado de Modo de Controle Conjunto (MCC), que divide igualmente entre os geradores as demanda solicitadas, e Modo de Controle Otimizado (MCO), que aloca para cada gerador uma demanda que utiliza a vazão ótima. A Tabela 4 apresenta resumidamente os parâmetros do modelo.

Tabela 4 – Parâmetros usados no modelo

Parâmetros	Descrição
$ph_{jt}$	é a potência gerada na unidade $j$ no tempo $t$ em $MW$ ;
$q_{jt}$	é a vazão turbinada na unidade $j$ no tempo $t$ em $m^3/s$ ;
$Dm$	é a demanda de energia requerida em $MW$ sujeita a um erro de até $\varepsilon$ ( $1 MW$ );
$Z_{jk}$	é o estado de operação da unidade $j$ no tempo $t$ ;
$q_{cc}$	é a vazão total no MCC em $m^3/s$ ;
$q_{jtmin}; q_{jtmax}$	são a vazão mínima e máxima operativas em $m^3/s$ , e
$ph_{jk}^{min}; ph_{jk}^{max}$	são a potência mínima e máxima operativas em $MW$ .

Logo, o modelo de otimização multiobjetivo que caracteriza MCO é dado por:

$$\left\{ \begin{array}{l} \max F_1(q_{1t}; q_{2t}; \dots; q_{jt}) = \frac{\sum_{j=1}^{J(r)} ph_{jt}}{\sum_{j=1}^{J(r)} q_{jt}} \\ \min F_2(q_{1t}; q_{2t}; \dots; q_{jt}) = \sqrt{\sum_{j=1}^{J(r)} (q_{jt} - q_{cc})^2} \end{array} \right.$$

$$\text{s.a.} \left\{ \begin{array}{l} \sum_{j=1}^{J(r)} ph_{jt} = Dm \\ q_{jtmin} \leq q_{jt} \leq q_{jtmax} \\ ph_{jk}^{min} \sum_{k=1}^{\theta_j} Z_{jk} \leq ph_{jt} \leq ph_{jk}^{max} \sum_{k=1}^{\theta_j} Z_{jk} \\ Z_{jk} \in \{0,1\}, \sum_{k=1}^{\theta_j} Z_{jk} \leq 1 \end{array} \right.$$

A função objetivo  $F_1$  determina o quanto de energia a usina é capaz de produzir com um determinado volume de água. Maximizar a função significa gerar energia utilizando menor vazão de água. O numerador é a função de produção conforme a Equação (21). À medida que o valor cresce a função objetivo aumenta seu valor.

A segunda função objetivo,  $F_2$ , mede a distância entre a vazão de água utilizada em MCC e a vazão de água utilizada no MCO. Esta função é usada pelo fato de que, na prática, a equipe técnica da operação de UHE mantém a cultura e a prática de utilizar o MCC. Esta função mostra que existem pontos de operação MCO que estão mais próximos do MCC, que ainda garantem a maximização da eficiência de produção de energia. A operação em modo MCC minimiza o desgaste dos conjuntos turbina-gerador. Ao otimizar o despacho utilizando

$F_2$  foi observado que não existiu oscilação nas demandas unitárias a cada execução de MCO, garantindo assim a premissa da minimização do desgaste presente em MCC. Além disso, esta abordagem multiobjetivo contribui para uma nova cultura de operação de UHE por parte de sua equipe técnica.

A primeira restrição indica que a potência entregue deve ser aproximadamente igual à demanda solicitada pelo ONS para o despacho elétrico com variação de erro  $\varepsilon = 1MW$ . A segunda restrição informa que a vazão calculada deve respeitar os limites mínimos e máximos de capacidade da unidade geradora. A terceira restrição indica que a potência gerada também deve respeitar os limites mínimos e máximos de capacidade da unidade geradora. A quarta restrição informa que cada unidade geradora possui apenas um estado de operação (ligada ou desligada). Neste modelo optou-se por informar o estado de cada gerador ( $Z$ ) como um parâmetro de entrada, uma vez que a usina estudada usualmente realiza manutenções em seus conjuntos geradores, atendendo assim uma preocupação da gerência de operação.

## 4.2 Formulação Matemática do SCOPF

A representação matemática do problema de despacho de energia tornou-se mais detalhada ao longo dos anos. Em um ambiente competitivo, o problema de despacho de energia ativa pode ser formulado, considerando a representação de corrente alternada das redes de transmissão e ser resolvido usando o modelo OPF. O objetivo do OPF é definir o valor ótimo das variáveis de controle para um cenário da operação, respeitando os limites físicos das variáveis de controle e as equações de fluxo de potência. Normalmente o propósito do problema OPF é minimizar o custo total da produção, que consiste tipicamente em uma função quadrática, mas é comum também minimizar as perdas de potência ativa. Tradicionalmente, OPF é um problema de otimização não-linear inteiro-misto de difícil solução sendo considerado na computação como um problema NP-difícil (GAN; LOW, 2014). Esta formulação não garante que a operação da rede permaneça em um estado de segurança após uma súbita queda ou falha de equipamento. O modelo SCOPF, garante que a energia pode ser transferida com sucesso a partir de geradores para cargas, não apenas sob a topologia de rede esperada, mas também para qualquer contingência prevista.

Incidentes casuais podem ser causados pela perda repentina de partes da rede, tais como geradores, transformadores e/ou linhas de transmissão. Portanto, o problema SCOPF possui um maior número de restrições do que o problema OPF. Neste problema, as variáveis de controle mais comuns são a geração de energia ativa e a magnitude de tensão no REF (barramento de referência) e nos barramentos pelos quais a potência ativa injetada e o módulo de tensão são especificados, as definições de TAP dos transformadores, o estado dos bancos de capacitores/reatores (ligado/desligado). Os limites físicos das variáveis

incluem o fluxo de potência aparente ou a corrente nos circuitos da rede, os limites de potência ativa e reativa dos geradores, a magnitude de tensão nas barras, os limites mínimo e máximo de TAP dos transformadores (alternância de carga, do termo inglês “*On-Load TAP Changer*” - OLTC). O controle de configuração do TAP dos transformadores pode ser tratado a partir de variáveis de valor contínuo ou discreto, enquanto o controle de bancos de capacitores/reatores é tradicionalmente discreto.

Um método utilizado no tratamento das variáveis discretas em OPF é o arredondamento (RINGERTZ, 1988; ADIBI et al., 2003; LIN; HO; LIN, 2004; CAPITANESCU; WEHENKEL, 2010). Inicialmente, o problema é resolvido assumindo que todas as variáveis são contínuas. Na solução obtida, cada variável discreta é arredondada para o valor discreto mais próximo. Este trabalho fez uso do método de arredondamento para o tratamento das variáveis discretas, durante o processo de otimização. A extensão de modelos matemáticos para representar a potência reativa no problema de despacho provou ser uma questão complexa. Tradicionalmente, o despacho de potência reativa é realizado após o despacho de potência ativa e os custos associados aos geradores para a produção de energia reativa são incorporados no custo total da geração de energia (ALMEIDA; SENNA, 2001).

Em SCOPF podem haver modelos de otimização de despacho reativo (ORDP), com o objetivo de por exemplo minimizar perdas totais na geração, e de despacho ativo e reativo (OARDP) visando para minimizar o custo total da produção de energia. Um dos desafios dos mercados de energia é criar mecanismos eficientes para compensar adequadamente geração e transmissão dos equipamentos para fornecer suporte reativo (BHASKAR; MUTHYALA; MAHESWARAPU, 2010; HUANG et al., 2012). Em sistemas de potência em corrente alternada, o controle de tensão é realizado ao gerenciar a produção e a absorção da potência reativa. Este controle tem como objetivo garantir que a magnitude de tensão nas barras da rede elétrica fique dentro dos limites operativos especificados. Baixas magnitudes de tensão provocam nos equipamentos elétricos uma redução de rendimento ou inoperância, enquanto altas magnitudes de tensão podem reduzir a vida útil e causar danos aos equipamentos, o que causaria dificuldades na operação do sistema elétrico de potência (CHUANWEN; BOMPARD, 2005).

Alguns dos problemas associados a OARDP são: a necessidade de estabelecer um nível de suporte reativo que é aceito por todos os equipamentos; as diferenças entre os regimes de reservas de potência reativa e a geração reativa real com a caracterização adequada dos custos; o fato de que a energia reativa deve ser fornecida localmente, o que requer regras adequadas para conter o custo associado a cada gerador (HAO; PAPAEXOPOULOS, 1997; CORSI, 2008). Este trabalho tem como objetivo abordar ORPD e OARDP com duas funções objetivos distintas, para otimização de alguns cenários de teste, na abordagem mono-objetivo com a utilização de um algoritmo evolutivo híbrido proposto no Capítulo 5. No problema ORPD, a função objetivo é dada pela minimização das perdas

totais do sistema, em MW por:

$$\min P_{loss} = \sum_{K=1}^{N_L} G_K [U_i^2 + U_j^2 - 2|U_i||U_j| \cos(\delta_i - \delta_j)], \quad (22)$$

na qual,  $N_L$  é o número total de linhas no sistema;  $G_K$  é a condutância da linha;  $U_i$  e  $U_j$  em kV referem-se às magnitudes do envio e recebimento final das tensões de extremidade das linhas;  $\delta_i$  e  $\delta_j$  são os ângulos (graus) de tensão nos barramentos.

No problema OARDP, a abordagem tem o propósito de minimizar o custo total de produção de energia atendendo as restrições do problema. Neste caso, a função objetivo é dada pela minimização da função de custo do sistema de combustível, que pode ser expressa segundo (ABIDO, 2002), (ALMEIDA; SENNA, 2001), como uma função quadrática da potência ativa e reativa dos geradores (em \$/h), conforme:

$$\min F(P_g) = \sum_{i=1}^{NG} (a_i + b_i P_{gi} + c_i P_{gi}^2), \quad (23)$$

na qual  $F(P_g)$  é o custo total do sistema;  $P_{gi}$  é a potência ativa gerada em cada unidade geradora  $i$  em MW;  $NG$  é o número de geradores;  $a_i$ ,  $b_i$  e  $c_i$  são os coeficientes de custo associados a cada unidade geradora.

Os problemas de despacho elétrico ORDP e OARDP também devem satisfazer as seguintes restrições de igualdade e desigualdade, para garantia da operação em SCOPF:

$$\text{s.a. : } \left\{ \begin{array}{l} P_i = P_{gi} - P_{li} = \sum_{j=1}^{NB} U_i U_j [G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)], \\ \forall_i \in NB, \forall_s \in NS, \\ Q_i = Q_{gi} - Q_{li} = \sum_{j=1}^{NB} U_i U_j [G_{ij} \sin(\delta_i - \delta_j) + B_{ij} \cos(\delta_i - \delta_j)], \\ \forall_i \in NB, \forall_s \in NS, \\ \underline{U}_i \leq U_i \leq \bar{U}_i, \forall_i \in NB, \forall_s \in NS, \\ |S_{ij}| \leq \bar{S}_{ij}, \forall_i \in NC, \forall_s \in NS, \\ |S_{ji}| \leq \bar{S}_{ij}, \forall_i \in NC, \forall_s \in NS, \\ \underline{P}_{gi} \leq P_{gi} \leq \bar{P}_i, \forall_i \in NG, \forall_s \in NS, \\ \underline{Q}_{gi} \leq Q_{gi} \leq \bar{Q}_i, \forall_i \in NG, \forall_s \in NS, \\ \underline{t}_i \leq t_i \leq \bar{t}_i, \forall_i \in NOLTC, t_i \in \forall_s \in NS, \\ 0 \leq q_i \leq 1, \forall_i \in NSHUNT, q_i \in Z, \forall_s \in NS, \end{array} \right. \quad (24)$$

nas quais  $P_{gi}$  (MW) é a geração de energia ativa,  $Q_{gi}$  (MVar) é a geração de energia reativa,  $P_l$  (MW) é a carga de energia ativa,  $Q_l$  (MVar) é a carga de energia reativa,  $U$  (kV) é a magnitude da tensão,  $\delta$  (graus) é o ângulo de tensão,  $S_{ij}$  (MVA) é a injeção de fluxo de potência aparente no final de envio do circuito de barramentos de conexão  $i$  para o barramento  $j$  considerando que  $S_{ij}$  (MVA) é a injeção de fluxo de potência aparente no final

de recebimento do mesmo circuito,  $t$  é a posição do TAP em alternância de carga  $OLTC$ ,  $q$  é uma variável binária que representa o estado dos bancos de capacitores/reatores.

Os fatores  $a$  (\$/h),  $b$  (\$/ MWh) e  $US c$  (\$/MWh<sup>2</sup>) são os coeficientes de custo de produção,  $NG$  é o número de geradores,  $NB$  é o número de barramentos,  $NC$  é o número de circuitos da rede,  $NOLTC$  é o número de alternância de cargas dos transformadores,  $NSHUNT$  é o número de bancos de capacitores/reatores e  $NS$  é o número de cenários que representam estados de contingência.

### 4.3 Cenários de estudo em SCOPF

Este trabalho apresenta 4 conhecidos Sistemas IEEE de barras como estudos de caso. O Sistema 41 aborda um caso de ORPD em usina eólica, enquanto os Sistemas IEEE de 57, 118 e 300 barras contemplam tanto a abordagem em ORPD quanto OARPD em grandes redes de energia. Nestes problemas de otimização podem ser distinguidos três tipos de variáveis conforme seu papel no processo de otimização. Estas são: variáveis de controle, de estado e parâmetros. As variáveis podem ser definidas de acordo com:

- Controle: potência ativa da barra; amplitude de tensão na barra; estado de TAP dos transformadores; estado de comutação dos capacitores; controles de eletrônica de potência e posição de fase dos TAP;
- Estado: amplitude de tensão (carga da barra), ângulos de tensão da carga e da barra, fluxo de potência da rede, potência ativa de saída da barra, potência reativa de saída e de tensão na barra, e;
- Parâmetros: da linha, da topologia de rede e dos geradores.

A modelagem do problema SCOPF discutido neste trabalho é considerada como caixa-preta, pois foi adotado o modelo disponibilizado por (ERLICH et al., 2014b), que é um arquivo criptografado via software MATLAB. O uso de um modelo caixa preta permite que o desenvolvedor de algoritmos não tenha acesso a algumas particularidades da modelagem, assim tornando inviáveis possíveis alterações no modelo, que venham trazer vantagem insidiosa de sua proposta frente as demais. Este modelo foi utilizado em uma competição (ERLICH et al., 2014b), cujo objetivo foi identificar novas metaheurísticas capazes de resolver problemas SCOPF de forma eficiente.

Os Sistemas IEEE de 57, 118 e 300 barras na abordagem ORPD têm como finalidade, minimizar as perdas totais do sistema. Na abordagem de solução em OARPD o objetivo é a minimização do custo total de combustível. Em ambos casos, a otimização deve ao mesmo tempo cumprir as restrições (associadas ao equilíbrio nodal da potência, as tensões nodais, fluxos de potência permitidas em cada ramo da rede e capacidade de potência reativa do gerador) para o estado normal da rede (não-contingência) e as N-1 condições de contingência selecionadas.

### 4.3.1 Sistema IEEE 41 - WPP-Offshore

Uma versão do Sistema IEEE 41 foi considerada como estudo de caso de um problema ORPD em Usina Eólica, que tem seus geradores instalados no mar (*WPP-Offshore*, do termo em inglês, “*Wind Power Plants*”). A geração eólica pode ser representada, de maneira simplista pela Figura 8.

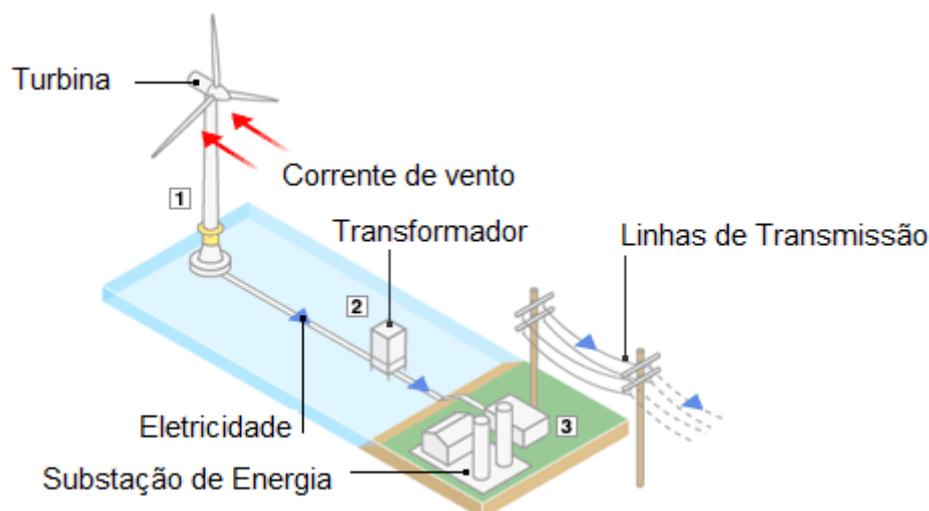


Figura 8 – Representação de uma Usina Eólica - *Offshore*. A velocidade do vento proporciona a rotação da turbina por meio de suas pás. O gerador converte a energia cinética em energia elétrica, que é então, transmitida por um cabo submarino até o transformador onde a energia elétrica é convertida para transmissão. Adaptado de [Marcelino et al. \(2016\)](#).

Basicamente a produção de energia eólica se dá por três etapas, conforme descrito a seguir:

- Unidades Geradoras: compostas pela turbina de vento (pás), e uma caixa fechada contém o gerador que utiliza campos magnéticos para converter a energia de rotação em eletricidade;
- Transformador: converte a energia para distribuição e a envia para subestação;
- Linhas de transmissão que conduzem a energia para os consumidores.

A Figura 9 apresenta o esquema elétrico do Sistema 41. Como pode ser visto nos detalhes, dois fatores  $X_{sh1}$  e  $X_{sh2}$ , podem ser continuamente ajustados. O capacitor  $C_1$  é responsável por fornecer apoio a potência reativa auxiliar. A carga  $L1$  presente no esquema elétrico indica a potência ativa gerada pela WPP. O modo de controle do sistema considera que a WPP tem a tarefa de fornecer a potência reativa necessária ( $Q_{ref}$ ) até atingir o poder de acoplamento comum ( $Q_{PCC}$ ). O esquema mostrado na Tabela 5 caracteriza o Sistema de 41 barramentos.

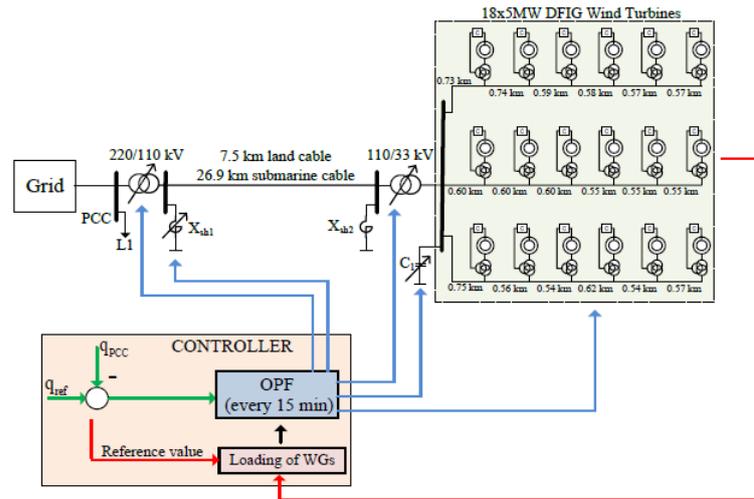


Figura 9 – Esquema elétrico de um típico sistema de controle WPP-Offshore.

Extraído de: (ERLICH et al., 2014b)

Sistema IEEE 41 - WPP			
Composição do Sistema de Testes	Geradores	18	
	Cabo submarino	1	
	Transformadores	T1 ( <i>Stepwise</i> )	2
		T2 (Tap fixo)	18
Composição do problema de otimização	Variáveis Contínuas	18	
	Variáveis Otimização	Variáveis Discretas	1
		Variáveis contínuas e de <i>Stepwise</i>	1
Restrições		123	

Tabela 5 – Sistema IEEE 41 - WPP

#### 4.3.2 Sistema IEEE de 57 barras

O Sistema IEEE de 57 barras compreende uma rede em que 57 pontos de medição são controlados. Estes pontos de medição são os barramentos de tensão existentes na rede. Este sistema possui 25 variáveis de otimização em ORPD, compreendendo 7 variáveis contínuas associadas a *set-points* de tensão do gerador, 15 variáveis discretas associadas a posições de torneira de transformador em carga ajustáveis por etapas e 3 variáveis binárias associadas a dispositivos de compensação de *shunt* comutáveis.

Além do cenário de operação esperado, foram considerados dois cenários de contingência (critério N-1) correspondentes à interrupção dos ramos 8 e 50. O número de restrições é 178 para condições não contingenciais e 177 para cada condição N-1. Por outro lado, o número de variáveis de otimização na OARPD é de 31 em que as 13 variáveis contínuas correspondem à produção de energia ativa dos geradores. O Quadro 4 apresenta sucintamente as características desta rede, enquanto a Figura 10 mostra o diagrama unifilar do sistema.

		Sistema IEEE de 57 barras	ORDP	OARDP	
Composição do Sistema de testes	Geradores		7	7	
	Carga		42	42	
	Linhas		63	63	
	Transformadores	Stepwise		15	15
		Fixos		2	2
	Condutores de Compensação		3	3	
Composição do problema de otimização	Variáveis contínuas	Variáveis	7	13	
		Variáveis de otimização discretas	15	15	
	Variáveis Binárias	Variáveis	3	3	
		Restrições	178 (de condição de não contingência) + 177 (de N-1 condições)		
	Contingências consideradas (N-1 condições)		Interrupções 8 e 50		

Quadro 4 – Características do Sistema IEEE de 57 barras

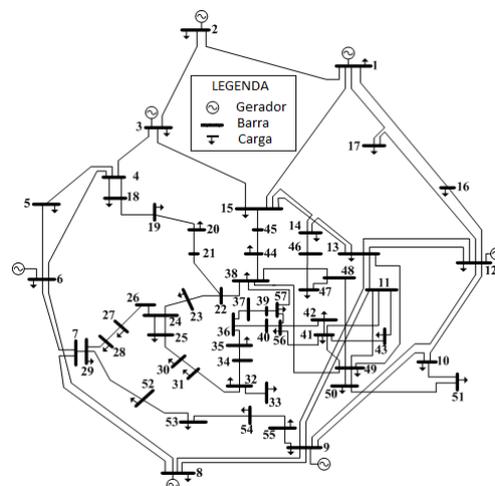


Figura 10 – Diagrama unifilar do Sistema IEEE de 57 barras

### 4.3.3 Sistema IEEE de 118 barras

O Sistema IEEE de 118 barras compreende uma rede em que 118 pontos de medição são controlados. Estes pontos de medição são os barramentos de tensão existentes na rede. O Sistema IEEE de 118 barras possui 77 variáveis de otimização em ORPD, com 54 variáveis contínuas associadas aos pontos de tensão de barramento do gerador, 9 variáveis discretas associadas a posições de torneira de transformador em carga ajustáveis por etapas e 14 variáveis binárias associadas a dispositivos de compensação de *shunt* comutáveis. Os cenários de contingência considerados resultam de interrupções nos ramos 21, 50, 16 e 48. O número de restrições é 492 para condições não contingenciais e 491 para cada condição N-1. A diferença entre o ORPD e o OARPD é o número adicional de variáveis de controle (total de 53) que representam a produção de energia ativa dos geradores. O Quadro 5 apresenta as características desta rede, enquanto a Figura 11 mostra o diagrama unifilar do sistema.

		Sistema IEEE de 118 barras	ORPD	OARPD	
Composição do Sistema de testes	Geradores		54	54	
	Carga		99	99	
	Linhas		177	177	
	Transformadores	Stepwise		9	9
		Fixos		0	0
	Condutores de Compensação		3	3	
Composição do problema de otimização	Variáveis contínuas		54	107	
	Variáveis de otimização	Variáveis discretas		9	9
		Variáveis Binárias		14	14
	Restrições		492 (de condição de não contingência) + 491 (de N-1 condições)		
	Contingências consideradas (N-1 condições)		Interrupções 20, 16, 50 e 48		

Quadro 5 – Características do Sistema IEEE de 118 barras.

### 4.3.4 Sistema IEEE de 300 barras

O Sistema IEEE de 300 barras compreende uma rede em que 300 pontos de medição são controlados. Estes pontos de medição são os barramentos de tensão existentes na rede. O Sistema IEEE de 300 barras possui 145 variáveis em ORPD, compreendendo 69 variáveis contínuas associadas aos pontos de tensão de barramento do gerador, 62 variáveis discretas associadas a transformadores em carga ajustáveis por etapas e 14 variáveis binárias associadas a dispositivos de compensação de derivação comutáveis. Três cenários

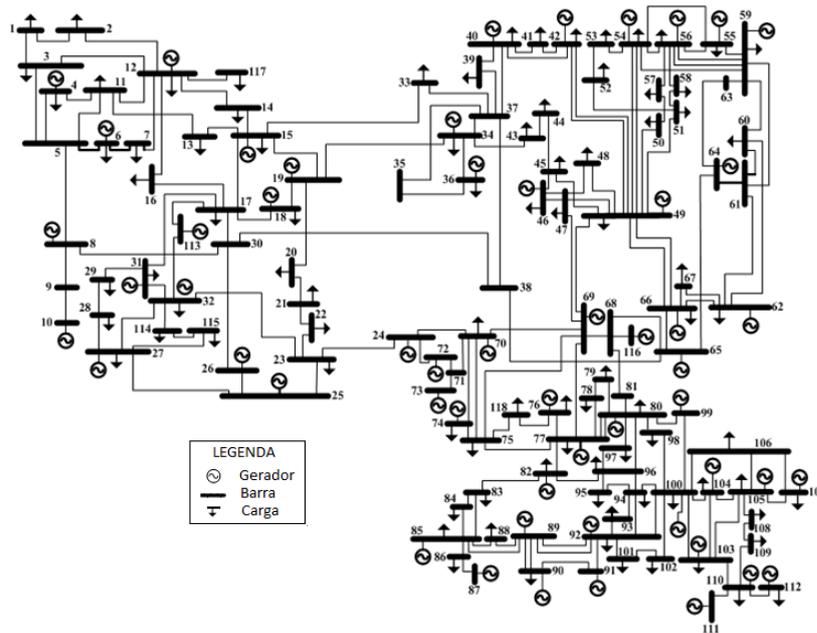


Figura 11 – Diagrama unifilar do Sistema IEEE de 118 barras.

de contingência foram considerados como resultado de falhas nos ramos 187, 176 e 213. O número de restrições é de 651 para condições de não contingência e de 950 para cada condição de N-1. O número total de variáveis de controle no problema OARPD é 213. O Quadro 6 apresenta as características desta rede, enquanto a Figura 12 mostra o diagrama unifilar do sistema.

		Sistema IEEE de 300 barras	ORDP	OARPD	
Composição do Sistema de testes	Geradores		69	69	
	Carga		201	201	
	Linhas		304	304	
	Transformadores	Stepwise		62	62
		Fixos		45	45
	Condutores de Compensação		14	14	
Composição do problema de otimização	Variáveis contínuas		69	137	
	Variáveis de otimização	Variáveis discretas		62	62
		Variáveis Binárias		14	14
	Restrições		651 (de condição de não contingência) + 950 (de N-1 condições)		
	Contingências consideradas (N-1 condições)		Interrupções 187, 176 e 213		

Quadro 6 – Características do Sistema IEEE de 300 barras

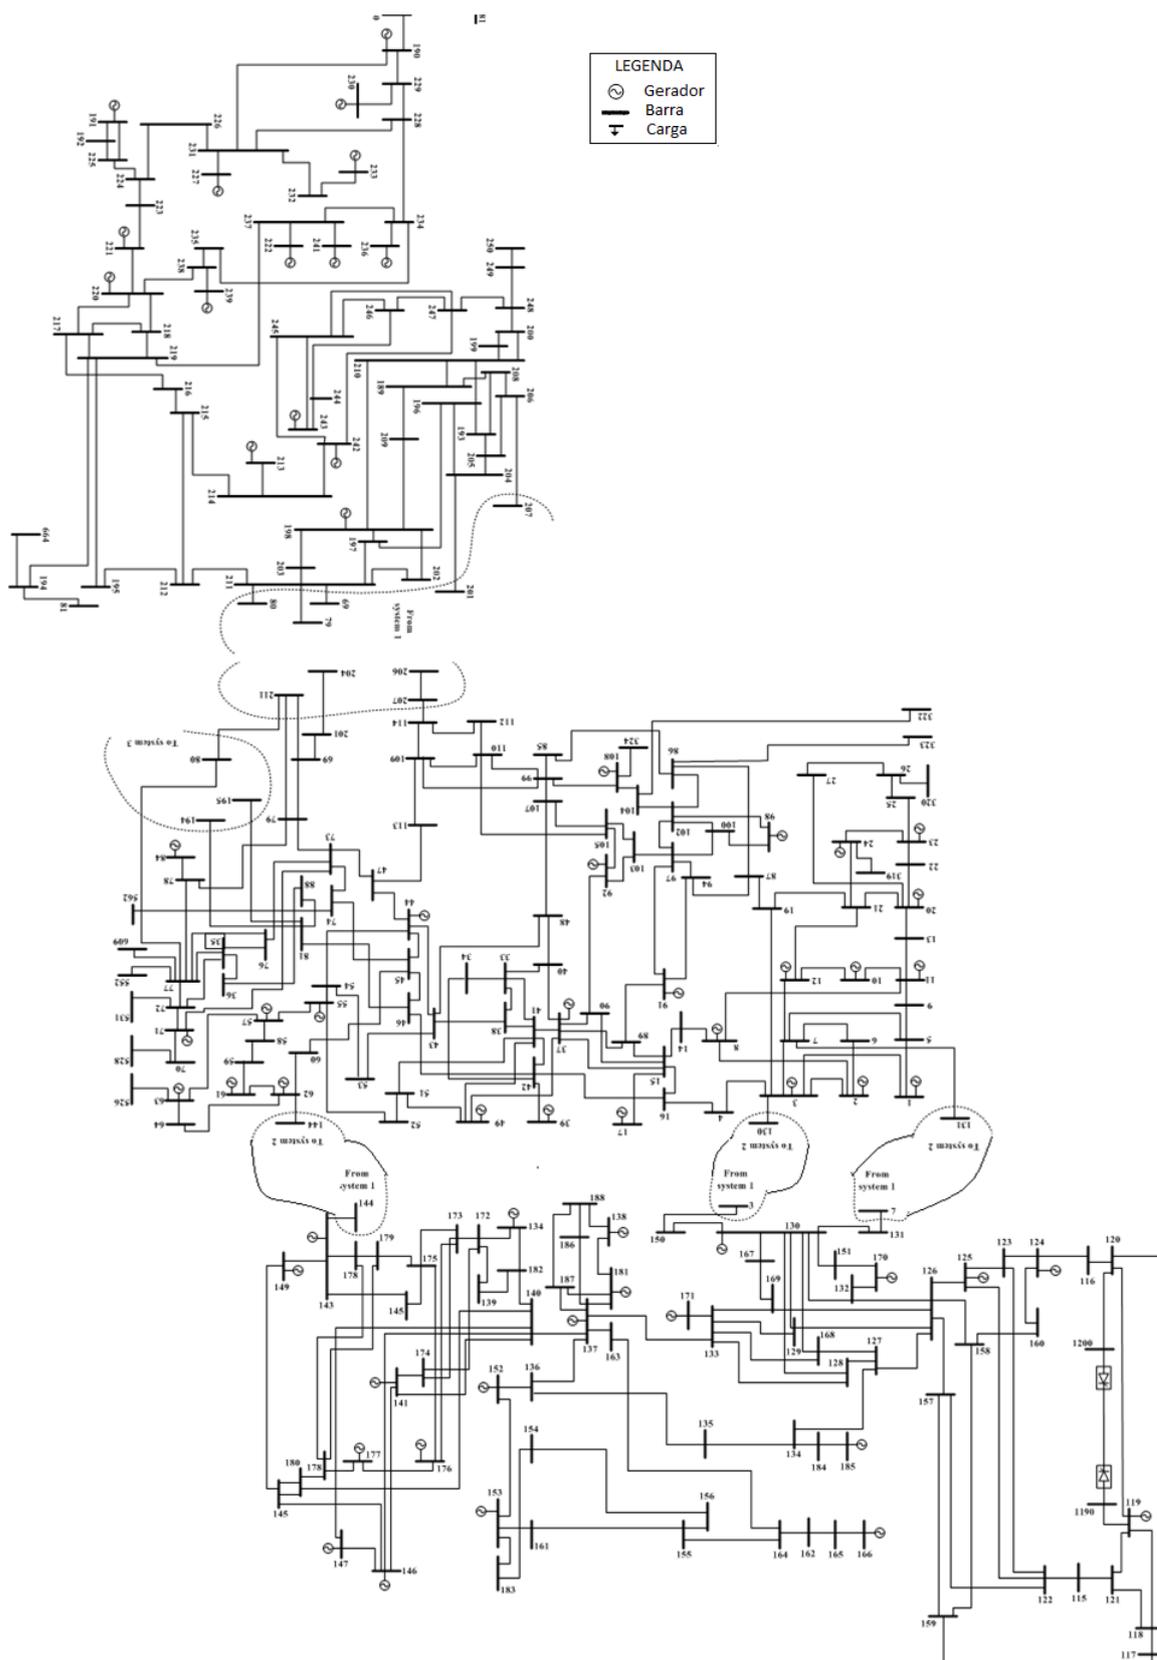


Figura 12 – Diagrama unifilar do Sistema IEEE de 300 barras

## 4.4 Sistema *Microgrid* híbrido

O aumento do mercado de flutuação de recursos de energia renováveis descentralizados, como a fotovoltaica e a energia eólica, representa um desafio para a estabilidade da rede no mundo. Os sistemas de *microgrids* híbridos (HMGS) são vistos como uma possibilidade de integrar tais fontes de eletricidade distribuídas numa rede eléctrica local. Podem ser descritos como agrupamentos de pequenos geradores, cargas, sistemas de resposta e de armazenamento de energia em bateria (BESS, do termo inglês *Battery Energy Storage Systems*) conectados por meio de uma rede eléctrica local, controlada por um sistema de gestão de energia para otimizar os fluxos de energia. A interconexão e coordenação de múltiplos HMGS pode ser alcançada dentro de uma grade de distribuição inteligente (FARHANGI, 2010).

Uma grande questão desses sistemas é garantir, a cada momento, um equilíbrio entre geração e carga para manter os níveis de frequência e tensão. BESS representam assim um fator importante para HMGS, pelo fato de responderem dentro de segundos para efetuar carga e descarga de energia. Existem várias tecnologias BESS disponíveis, cada uma com diferentes vantagens e desvantagens adequadas para este fim. Um esquema simplificado de um HMGS é mostrado na Figura 13.

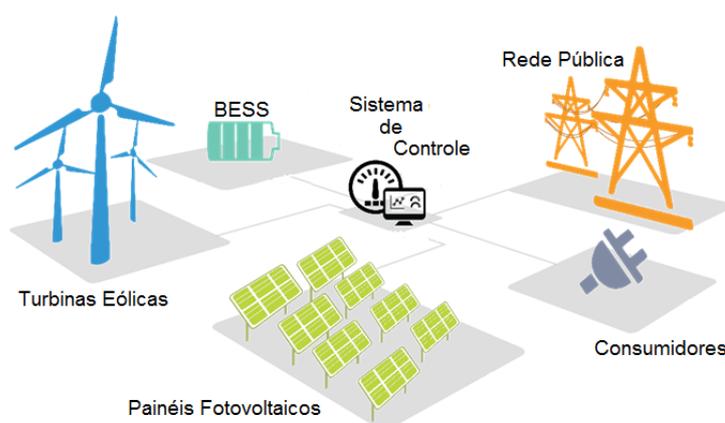


Figura 13 – Configuração simplificada de um HMGS incluindo BESS.

A literatura destaca três questões sobre HMGS: 1) como minimizar o custo de eletricidade (COE) por unidade de eletricidade gerada; 2) como minimizar a Probabilidade de Perda de Carga (LPSP) ou avarias; 3) como maximizar a proporção de energia gerada pela fonte de energia renovável (RS-factor) (LEVRON; GUERRERO; BECK, 2013; BARELLI; BIDINI; BONUCCI, 2016; BORHANAZAD et al., 2014).

### 4.4.1 Um estudo de caso na Alemanha

Uma região genérica no sul da Alemanha foi usada como uma localidade hipotética para o estudo de caso deste trabalho. As séries anuais sazonais para uma típica carga

padrão de casas, radiação solar (SODA, 2016), velocidade do vento por hora e temperatura ambiente (DWD, 2016) servem como entradas do modelo. As diferentes séries de dados para o período de um ano estão dispostas na Figura 14.

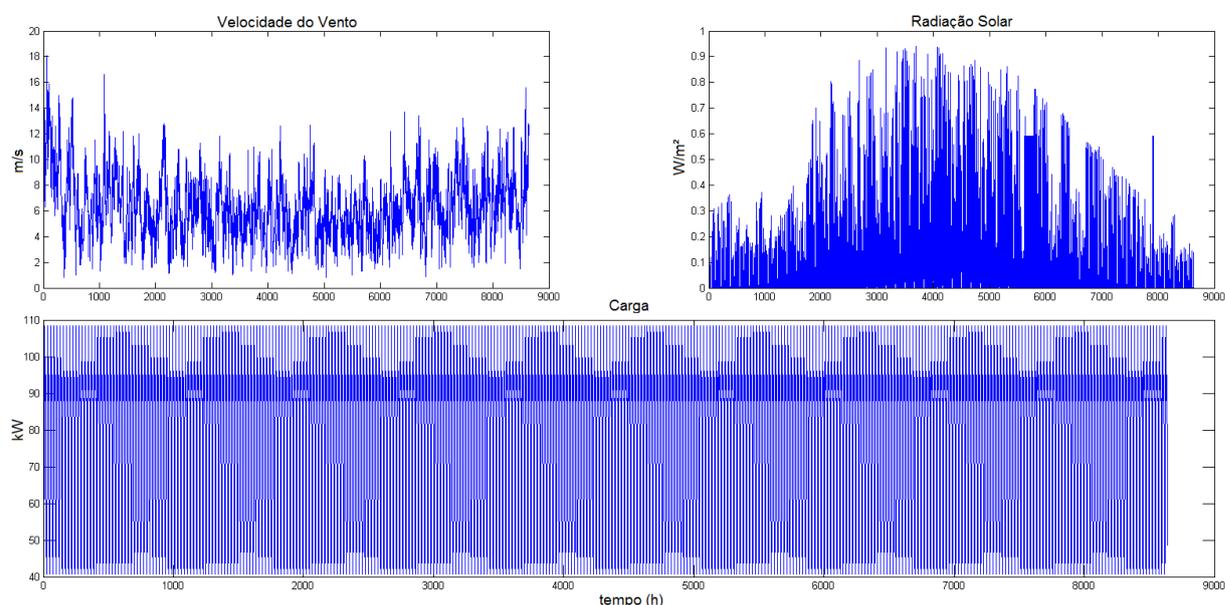


Figura 14 – Série de dados que representa as entradas para o modelo HMGS. A velocidade média anual do vento está na faixa de  $[1,6]$   $m/s$ . A radiação solar presente nesta área é baixa e está em torno de  $[0,1]$   $W/m^2$ . A demanda de carga foi gerada com dados de 24 horas para 100 casas e replicadas para um ano.

Um cenário de teste com um número máximo de 100 residências familiares foi usado na simulação. O modelo HMGS inclui os seguintes parâmetros econômicos e características gerais dos componentes:

- Inversor: eficiência = 96%, tempo de vida = 15 anos e custo inicial = 771.6\$/kW;
- PV: Eficiência do regulador fotovoltaico = 95 %; tempo de vida = 24 anos; potência nominal = 7.3 kW; Custo inicial = 1800 \$/kW,
- Turbina Eólica: velocidade nominal = 12 m/s, potência nominal = 30kW, tempo de vida = 24 anos, custo inicial = 2869.2 \$/kW, área varrida = 113.1 m, 95%, corte = 20 m/s e corte em = 3 m/s;
- Parâmetros econômicos: taxa de desconto = 6%, taxa de inflação = 1,4%, custo operacional = 20% e tempo de vida do projeto = 24 anos;
- Eletricidade da rede = valor da eletricidade na rede pública - 0.34\$/kWh.

Os valores tecno-econômicos e as curvas de desempenho para pequenas turbinas eólicas foram extraídos de (GAMPE, 2013). Os custos do inversor dependem da escala e são baseados em (BAUMANN et al., 2016), os demais valores foram retirados de (BORHANAZAD et al., 2014). A Tabela 6 dá uma breve visão geral das principais características tecno-econômicas do BESS, extraídos de uma base de dados com informações sobre 14

diferentes tecnologias BESS (BAUMANN et al., 2016; STENZEL; BAUMANN; FLEER, 2014). Neste trabalho cinco sistemas distintos foram considerados: *Lithium Iron phosphate* (LFP), *Lithium Nickel Cobalt Aluminum Oxide* (NCA), *valve regulated lead acid batteries* (VRLA), *Sodium Nickel Chloride* (NaNiCl) e *Sodium Sulfur* (NaS).

Tabela 6 – Dados de entrada tecno-econômicos para o BESS dentro do HMGS considerado valores de custo médio.

Fator	Unidade	VRLA	LFP	NCA	NaNiCl	NaS
Custo	\$/kWh	276.432	370.644	255.0	264.36	361.2
Ciclos	-	1400	5000	3000	3000	3250
Eficiência	%	77	92	92	86	85.5
Tempo de vida	anos	18	10	10	14	13.5
BoP	\$/kW	374	374	374	374	374
Outros custos	\$/kW	328	328	328	328	328

Os custos de investimento do BESS incluem as células em \$/kWh, e o Balanço da Planta<sup>1</sup> (BoP) \$/kW (inclui dispositivos auxiliares, comunicações, equipamentos de controle). Outros custos estão relacionados com a instalação, licenciamento e comissionamento do BESS.

#### 4.4.2 Modelo matemático de HMGS

Alguns modelos que incluem a produção de eletricidade para fontes renováveis dentro do HMGS estão disponíveis na literatura (LEVRON; GUERRERO; BECK, 2013; FARHANGI, 2010; BARELLI; BIDINI; BONUCCI, 2016; BORHANAZAD et al., 2014). Nesta seção é apresentado o modelo matemático, baseado no trabalho de Borhanazad et al. (2014), proposto para o HMGS que inclui a conexão do mesmo a rede pública, diferenciando-se da abordagem de HMGS autônomo. A Tabela 7 descreve os principais parâmetros do modelo.

Tabela 7 – Parâmetros utilizados no modelo.

Parâmetro	Descrição
$COE$	custos totais de eletricidade em \$/kWh
$CRF$	índice relativo ao custo geral dos equipamentos
$LPSP$	Probabilidade de Perda de Carga em (%)
$Total_{costs}$	custos totais do sistema HMGS em \$
$P_{load}$	consumo de energia em kW
$P_{pv}$	potência gerada pelo PV em kW
$P_{wind}$	potência gerada pelo gerador eólico em kW
$P_{soc_{min}}$	compensação mínima realizada pela bateria em kW
$P_{grid}$	potência adquirida da rede pública em kW

<sup>1</sup> refere-se ao equipamento de apoio e componentes auxiliares que são necessários para fazer uma usina de energia ou sistema de energia operar.

O intuito do modelo proposto é minimizar o custo total da produção de eletricidade (COE) e a probabilidade de perdas de energia (LPSP) de forma a garantir a produção de energia renovável em sua maximização. Segundo (KAABECHE; BELHAMEL; IBTIOUEN, 2011; BORHANAZAD et al., 2014), COE pode ser obtido em termos de \$/kWh, pela Equação (25),

$$COE = \frac{C_{total}}{\sum_{h=1}^{h=8760} P_{load}(h)} \times CRF, \quad (25)$$

em que  $C_{total}$  são os custos de instalação, manutenção, operação e substituição de componentes do HMGS. A geração de energia elétrica ao longo do tempo (8640 horas = 1 ano - 24 horas  $\times$  30 dias  $\times$  12 meses) é obtida por  $P_{load}$  e CFR representa o valor presente de todos os componentes igualmente distribuídos sobre o tempo de vida do projeto (também chamado método de anuidade) (KAABECHE; BELHAMEL; IBTIOUEN, 2011; BORHANAZAD et al., 2014).

$C_{total}$  é composto por um somatório: do custo inicial do sistema  $ICS$  (obras civis, instalação e conexões), de custos  $PW_p$ , que é caracterizado como um custo periódico (manutenção dos painéis PV, manutenção do gerador eólico, outros) e  $PW_{np}$  caracterizado como um custo não periódico (custo de substituição de bateria, equipamentos, entre outros) (KAABECHE; BELHAMEL; IBTIOUEN, 2011).

Um novo fator, o custo de degradação  $c_d$  (KEMPTIN; TOMIC, 2005), foi introduzido para fornecer um cenário mais realista para calcular o COE. Este custo considera a degradação da bateria em termos do ciclo de vida disponível  $L_c$  e a capacidade de armazenamento de energia em BESS,  $E_s$ , a uma determinada profundidade de descarga (DoD) relacionada com os custos totais das células de bateria  $c_{bat}$ , como indicado na Equação (26),

$$c_d = \frac{c_{bat}}{L_c E_s DoD}. \quad (26)$$

Logo, a nova equação para COE é dada pela Equação (27)

$$COE = \frac{ICS + PW_p + PW_{np} + \sum_{h=1}^{h=8760} c_d}{\sum_{h=1}^{h=8760} P_{load}(h)} \times CRF. \quad (27)$$

Técnicas estatísticas e abordagens de simulação cronológica podem ser usadas para calcular a probabilidade de perdas no suprimento de energia. O cálculo de LPSP é expresso pela Equação (28),

$$LPSP(\%) = \frac{\sum P_{load} - P_{pv} + P_{wind} + P_{dch} + P_{grid}}{\sum P_{load}}, \quad (28)$$

na qual  $P_{load}$  é o consumo de energia horária,  $P_{pv}$  e  $P_{wind}$  são a energia gerada por PV e pelo gerador eólico. O  $P_{dch}$  é a energia descarregada da bateria,  $P_{grid}$  é a energia recebida

pela rede pública e  $P_s$  é o excedente de energia gerado. O percentual de energia renovável, *RS-factor*, é calculado por,

$$RS\text{-factor}(\%) = \frac{\sum P_{pv} + P_{wind} + P_{dch} - P_s}{\sum P_{load}}. \quad (29)$$

De acordo com [Borhanazad et al. \(2014\)](#) em sistemas de geração híbrida COE e LPSP poder obter o mesmo conceito de importância na busca pela operação ótima. Portanto, o modelo de otimização para despacho da energia em HMGS foi realizado a partir da escalarização linear dos objetivos COE e LPSP usando a abordagem discutida na Seção 3.1.3 deste trabalho. A fim de equilibrar os dois objetivos, os pesos foram ajustados igualmente para o valor de 0.5 proporcionando a escalarização de COE e LPSP. Na função de avaliação que possui a uma penalidade associada ao percentual de energia renovável do sistema (*RS-factor*). O modelo de simulação inicial desenvolvido por [Borhanazad et al. \(2014\)](#) foi implementado em MATLAB (disponível em ([BORHANAZAD, 2016](#))). O fluxograma contido na Figura 15 apresenta visualmente o modelo de simulação utilizado neste trabalho.

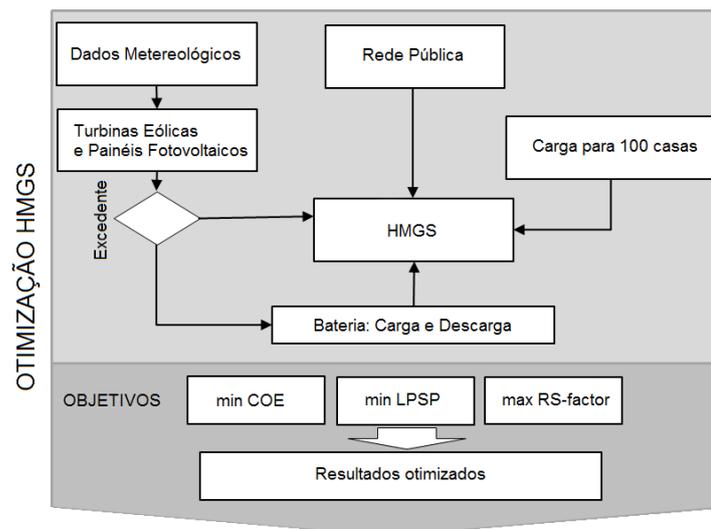


Figura 15 – Visão geral do modelo simplificado para otimização HMGS.

## 4.5 Considerações Finais

Este capítulo caracterizou o fluxo de potência ótimo e descreveu alguns estudos de casos que são abordados nesta tese. A formulação matemática do despacho elétrico em usinas hidrelétricas foi discutida na Seção 4.1. O modelo matemático a respeito do fluxo de potência ótimo com restrições de segurança, bem como os cenários de teste, foram descritos na Seção 4.2. O aperfeiçoamento de um modelo *microgrid* foi proposto na Seção 4.4. Para solução dos problemas apresentados novos algoritmos evolucionários foram propostos e descritos no Capítulo 5.

# 5 Proposição e desenvolvimento de novos Algoritmos Evolucionários

Este Capítulo aborda os fundamentos do algoritmo C-DEEPSO, que integra os conceitos presentes em métodos populacionais e evolutivos. Após isto, é descrita uma proposta de operador de busca local, denominado *Spiral Local Search* (SLS), que acoplado ao algoritmo proposto gera uma nova versão híbrida nominada hC-DEEPSO.

## 5.1 Algoritmo C-DEEPSO

O algoritmo *Canonical Differential Evolutionary Particle Swarm Optimization* (C-DEEPSO) é uma metaheurística que incorpora características distintas de Computação Evolutiva (EC), Otimização por Enxame de Partículas (PSO) e Evolução Diferencial (DE). Este algoritmo, que pode ser visto como um aperfeiçoamento em relação ao EPSO de [Miranda e Fonseca \(2002\)](#) e DEEPSO de [Miranda e Alves \(2013\)](#), corresponde a um algoritmo evolutivo com as regras de recombinação emprestados de PSO, ou um método de otimização de enxame com os operadores de seleção e de adaptação originários do DE.

Como grande parte das metaheurísticas populacionais, C-DEEPSO emprega o uso dos operadores de mutação, recombinação e seleção para gerar novas soluções (ou partículas). Isto é feito de modo que a população é melhorada gradualmente, por meio da aptidão das melhores soluções em cada geração, até que um determinado critério de parada seja atingido. A geração de novas soluções em C-DEEPSO é baseada em operações de recombinação sucessivas aplicadas em soluções atuais e salvas em arquivo, da mesma forma que em DEEPSO. Cada partícula  $X_t$  obedece a uma regra de movimento que depende da velocidade. Por sua vez, a velocidade é dependente de três fatores conhecidos como inércia, memória e comunicação. Assim, em DEEPSO, a recombinação de soluções é obtida por meio da regra de movimento apresentada nas Equações (30) e (31) conforme descrito por [Miranda e Alves \(2013\)](#):

$$V_t = w_I^* \times V_{t-1} + w_M^* \times (X_r - X_{t-1}) + w_C^* \times C \times (X_{gb}^* - X_{t-1}), \quad (30)$$

$$X_t = X_{t-1} + V_t. \quad (31)$$

O termo  $X_r$  representa uma partícula diferente de  $X_{t-1}$  e pode ser obtido, conforme descrição de [Miranda e Alves \(2013\)](#), em acordo às opções:

- $S_g$ : amostrado a partir de todas as partículas da geração atual;

- $P_B$ : amostrado da população em memória “B” das melhores partículas do passado (gerações anteriores);
- $S_g-rnd$ : extraído como uma recombinação uniforme de partículas da geração atual, e;
- $P_B-rnd$ : extraído como uma recombinação uniforme da memória “B”.

O Quadro 7 descreve os termos da equação de movimento apresentada.

Termo	Descrição
$t$	é a solução corrente
$X_{t-1}$	é a solução corrente
$X_{gb}$	é a melhor solução encontrada na geração anterior
$V_t$	é a velocidade da partícula
“*”	indica que o parâmetro é submetido ao processo de mutação
$C$	é uma matriz diagonal de variáveis aleatórias amostrada a cada iteração com probabilidade $P$ de comunicação

Quadro 7 – Descrição dos termos da equação de movimento

Ao avaliar o modelo de algoritmo DEEPSO apresentado, é possível notar que tal algoritmo é melhor descrito como um método de otimização por enxame de partículas com propriedade de seleção e auto-adaptação. Esta afirmação se dá pelo fato de que em DEEPSO não há uma inspiração fortemente ligada ao algoritmo DE clássico, no que tange a pesquisa realizada no espaço de busca realizado pelo seu operador de mutação, como se pode comprovar por:

*“O mecanismo de busca do algoritmo de Evolução Diferencial utiliza vetores-diferença criados a partir de pares de vetores da própria população. **Dois** indivíduos são selecionados aleatoriamente da população corrente, criando-se um **vetor-diferença**, que por sua vez é **somado** a um **terceiro** indivíduo, também selecionado aleatoriamente, produzindo uma **nova solução** mutante” (GUIMARÃES, 2013).*

Por uma questão de clareza, o operador de mutação do DE canônico observado nos trabalhos de Price (1999) e Price, Storn e Lampinen (2005), DE/rand/1, é apresentado na Equação (32):

$$V_{t,i} = x_{t,r_1^i} + F(x_{t,r_2^i} - x_{t,r_3^i}); r_1^i, r_2^i, r_3^i \in \{1, \dots, N\}, r_1^i \neq r_2^i \neq r_3^i, \quad (32)$$

na qual os parâmetros  $x_{t,r_1^i}$ ,  $x_{t,r_2^i}$  e  $x_{t,r_3^i}$  são vetores obtidos na população e  $F$  é um número, que geralmente pertence ao intervalo  $[0,2]$ , usado para controlar a amplificação de variação diferencial. Comparando-se o operador de mutação DE dado pela Equação (32) e a equação de movimento de DEEPSO dada pela Equação (30), é possível notar que três vetores são utilizados no processo de mutação. Ao visualizar a regra de movimento de DEEPSO, apenas dois vetores, representados por  $X_r$  e  $X_{t-1}$ , são utilizados no processo. Por outro lado, C-DEEPSO é inspirado no operador de mutação original do DE canônico, tal como descrito pela Equação (32).

Em relação ao algoritmo DEEPSO, a característica distintiva de C-DEEPSO consiste na utilização de uma melhoria na assimilação da paisagem de otimização. Da mesma forma que alguns algoritmos evolutivos gerais, esta assimilação pode ser grosseiramente obtida comparando soluções diferentes, isto é, calculando macro-gradientes. Para utilizar a informação recolhida por parte da população em toda a busca, C-DEEPSO depende de uma memória coletiva, em vez de múltiplas e independentes memórias que englobam a experiência de busca de cada partícula. A Figura 16 é uma representação em 2D da equação de movimento, com foco nas diferentes interações entre soluções em cada termo (inércia, cooperação e assimilação).

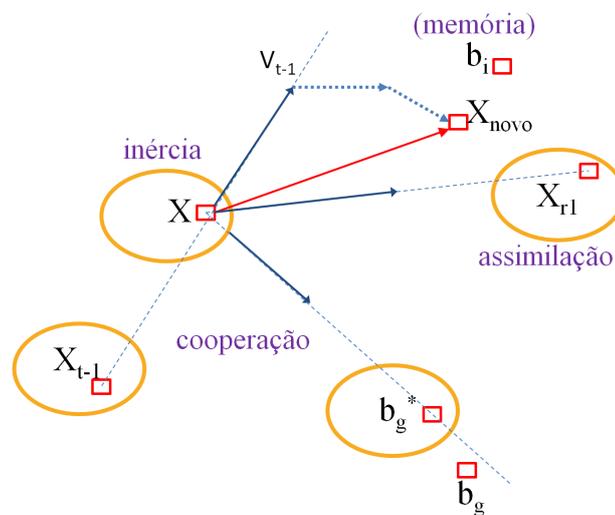


Figura 16 – Ilustração da equação de movimento para C-DEEPSO, tendo como atrator o termo de assimilação em que no PSO é utilizado o termo de memória.

No entanto, em vez de um termo de memória, como no PSO clássico, um termo mais geral, chamado termo de *assimilação*, é usado. Este termo é sensível ao macro-gradiente, que leva a melhorias na solução candidata. O C-DEEPSO confia em uma memória coletiva em vez de memórias múltiplas e independentes que abrange a experiência de busca de cada solução. O mecanismo de memória, chamado *Memória B*, inclui não apenas a posição do indivíduo, mas também a sua aptidão. Uma nova maneira de gerar  $X_r$  é proposta com o objetivo de assegurar uma maior assimilação do espaço de busca. A nova estratégia  $S_g P_b$ -*rnd* é proposta. Nesta, é realizada a combinação das estratégias  $S_g$ -*rnd* e  $P_b$ -*rnd* na qual uma recombinação uniforme a partir de diferentes soluções é utilizada para gerar  $X_r$ . Visando obter as informações recolhidas pela população em toda a pesquisa, o C-DEEPSO propõe uma reformulação na *Regra do Movimento* para incluir um novo atrator obtido pelo operador de mutação do algoritmo DE canônico. Nesse caso, a regra de movimento em C-DEEPSO é descrita por,

$$V_t = w_I^* V_{t-1} + w_A^* (X_{st} - X_{t-1}) + w_C^* C(X_{gb}^* - X_{t-1}). \quad (33)$$

Neste trabalho, a estratégia evolutiva,  $st$ , adotada é a *current-to-best* (QIN; SUGANTHAN, 2005; HUANG; QIN; SUGANTHAN, 2006), que pode ser expressa por,

$$X_{st} = X_r + F(X_{best} - X_r) + F(X_{r1} - X_{r2}). \quad (34)$$

Nas Equações (33) e (34),  $t$  representa a geração atual,  $X_{t-1}$  indica a posição atual ou solução corrente. Além disso,  $X_{gb}$  é a melhor solução encontrada na população,  $V$  é a velocidade da solução.  $C$  representa uma matriz diagonal,  $n \times n$  que é amostrada a cada iteração. A matriz  $C$  binária é obtida por meio da seguinte regra: dada a geração de  $N$  números aleatórios no intervalo  $[0,1]$  para cada dimensão presente em cada solução, o número gerado é comparado a taxa de comunicação  $P$ , informada pelo usuário. Se  $rand() > P$  então o elemento  $C_{ij}$  da matriz  $C$  é preenchida com 0, caso contrário  $C_{ij}$  recebe 1. Isto significa que, para cada dimensão no espaço de busca e em cada interação, existe uma probabilidade  $P$  de que uma solução não receba (use) a informação disponível na melhor localização do enxame,  $X_{gb}$ . Assim as soluções somente recebem a influência de componentes de inércia e assimilação ou, na linguagem EA, o operador de recombinação descarta a informação contida em  $X_{gb}$  como contribuinte para essa dimensão específica. As variáveis  $w_I$ ,  $w_A$  e  $w_C$  são pesos aplicados sobre os termos de inércia, assimilação e comunicação, respectivamente.  $X_{r1}$  e  $X_{r2}$  são soluções aleatoriamente amostradas.

Após o cálculo de  $X_{st}$ , a solução obtida é avaliada. Se o valor de aptidão presente em  $X_{st}$  for maior que o apresentado por  $X_r$ , então  $X_{st}$  recebe o valor de  $X_r$ . O expoente \* indica que o parâmetro correspondente sofre evolução sob um processo de mutação. Tipicamente, a mutação de um peso genérico  $w$  de um indivíduo segue uma regra aditiva simples como descrito pela Equação (35),

$$w^* = w + \tau \times N(0,1), \quad (35)$$

na qual  $\tau$  é a taxa de mutação que deve ser definida pelo usuário e  $N(0,1)$  é um número amostrado a partir de uma distribuição gaussiana padrão.

Observe que o peso mutado não deve se tornar negativo ou maior que 1. Além disso, não só os pesos apresentados na Equação (33) são mutados, mas também  $X_{gb}$ . Esta posição é ligeiramente atraída ao se mover no espaço de busca usando uma distribuição gaussiana. Isto é realizado visando prevenir a população de ficar presa em uma dada região, que é especialmente evidente nos casos em que o termo de cooperação se torna mais dominante do que os outros termos. A mutação de  $X_{gb}$ <sup>1</sup>, que é feita para cada solução, é realizada de acordo com a Equação (36),

$$X_{gb}^* = X_{gb}[1 + \tau \times N(0,1)]. \quad (36)$$

<sup>1</sup> Quando as variáveis são inteiras, essa mutação também é aplicada, e feito o arredondamento do valor da variável.

Como o algoritmo DEEPSO proposto por [Miranda e Alves \(2013\)](#) utiliza apenas dois vetores no processo de mutação, o mesmo não abrange o uso das estratégias evolucionárias propostas no DE, como por exemplo: “*best/1/bin*” ou “*current-to-best/1/bin*”, entre outras. Uma vez que em C-DEEPSO é introduzido um terceiro vetor no processo de mutação, se observa a herança vinda do DE de todas as possibilidades que permitem escolher este terceiro vetor, da forma mais apropriada a cada caso. Agora, portanto, passa a fazer sentido, no C-DEEPSO, usar a mesma notação que identifica os diferentes tipos do DE canônico.

O algoritmo C-DEEPSO permite uma combinação eficiente dos algoritmos DE e PSO, pois emprega as regras de mutação presentes no DE e a inspiração/recombinação presentes no PSO. C-DEEPSO pode então ser visto como um algoritmo evolutivo, baseado no operador de mutação do algoritmo DE, que mantém as regras de recombinação emprestadas do algoritmo PSO. O Algoritmo 3 mostra o pseudo-código do C-DEEPSO.

---

**Algoritmo 3:** Pseudocódigo do algoritmo C-DEEPSO.
 

---

```

início
  Passo 1: Iniciar os parâmetros de controle de C-DEEPSO - Tamanho da população  $NP$ ,
  Taxa de Mutação  $\tau$ , Taxa de Comunicação  $P$ , Tamanho da Memória  $MB$ , Número limite
  de gerações que podem efetuar busca local,  $N_{gl}$ , dada uma taxa  $\gamma$  de ocorrência e
  Dimensão do problema ( $D$ )
  Passo 2: Iniciar o contador de gerações  $t = 1$  e iniciar aleatoriamente a população de  $NP$ 
  partículas, conforme  $P_t = \{X_{1,t}, \dots, X_{NP,t}\}$  com  $\vec{X}_{i,t} = [x_{1,i,t}, x_{2,i,t}, x_{3,i,t}, \dots, x_{D,i,t}]$ 
  em que cada partícula está distribuída uniformemente no intervalo  $[X_{min}, X_{max}]$ , no qual
   $X_{min} = \{x_{1,min}, x_{2,min}, \dots, x_{D,min}\}$  e  $X_{max} = \{x_{1,max}, x_{2,max}, \dots, x_{D,max}\}$  com
   $i = [1, 2, \dots, NP]$ 
  Passo 3: Avaliar a população corrente,  $P_t$ 
  Passo 4: Atualizar a melhor solução obtida até o momento,  $X_{bg}$ 
  enquanto o critério de parada não é satisfeito faça
    para cada partícula  $i$  pertencente a população  $P_t$  faça
      Calcular  $X_r$  usando a estratégia,  $S_g P_B - rnd$ ;
      Mutar os parâmetros estratégicos  $w_I, w_A, w_C$  usando a Equação (35);
      Mutar  $X_{gb}^*$  usando a Equação (36);
      Aplicar regra de movimento à partícula corrente  $X_t$  a Equação (33);
      Avaliar a partícula corrente  $X_t$ ;
      Selecionar a partícula com melhor aptidão para fazer parte da próxima população
      ( $NP + 1$ ). *Usando por exemplo Torneio Estocástico;
    fim
    Atualizar o melhor indivíduo  $X_{bg}$  e a memória  $MB$ ;
    Executar Algoritmo 4 - caso use busca local;
     $t = t + 1$ 
  fim
fim
  
```

---

## 5.2 Proposta de operador para Busca Local

Devido à alta dimensionalidade dos problemas SCOPF, o algoritmo evolutivo proposto pode se beneficiar da inclusão de um operador de busca local. O operador de busca local proposto é inspirado no *Spiral Optimization Algorithm* (SOA) de [Tamura e Yasuda](#)

(2011a), Tamura e Yasuda (2011b). SOA baseia-se na busca multiponto de  $n$  dimensões aplicada à solução de problemas que têm características contínuas, com base numa analogia aos fenômenos naturais da forma espiral.

A ideia básica é explorar o espaço de busca usando a forma espiral logarítmica, que pode ser observada na natureza, como em conchas, algumas flores, formação de ciclones e até galáxias (BENASLA; BELMADANI; RAHLI, 2014). O modelo de trajetória espiral logarítmica, centrado em  $x^* \in \mathbb{R}^n$ , começando com um ponto arbitrário, é dado por:

$$x^{(k+1)} = rM(\theta) \cdot x^{(k)} - (rM(\theta) - I) \cdot x^*, \tag{37}$$

na qual o ângulo de rotação  $\theta$ , pertence ao intervalo  $[0, 2\pi]$ , em torno da origem para cada ponto  $k$ . O raio,  $r$ , é a distância entre o ponto e a origem em cada  $k$ , pertencendo ao intervalo  $[0,1]$ ,  $M(\theta)$  é a matriz de rotação e  $I_n$  é a matriz identidade  $n$ -dimensional. Como exemplo, a matriz de rotação, em um caso 2D, é definida como:

$$M(\theta) = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix}. \tag{38}$$

A Figura 17 mostra a trajetória de 100 pontos, usando a Equação (37) e os parâmetros na Tabela 8, começando em  $x_0 = (10 \ 10)$ .

Tabela 8 – Parâmetros usados para gerar a trajetória espiral em 2D

(esquerda)	$r = 0.95$	$\theta = \pi/4$
(direita)	$r = 0.90$	$\theta = \pi/4$

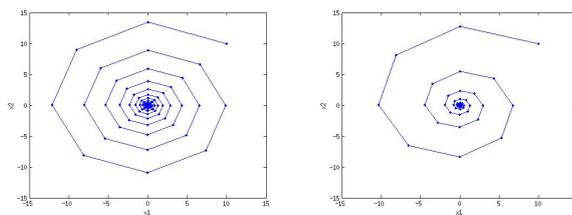


Figura 17 – Exemplos de trajetórias espirais logarítmicas usando a Equação(37). Diferentes valores de taxa de convergência  $r$  produzem comportamentos de forma espiral distintos. No gráfico à esquerda pode ser vista uma trajetória usando  $r = 0.95$ ;  $\theta = \pi/4$ , enquanto à direita é percebida uma trajetória usando  $r = 0.90$ ;  $\theta = \pi/4$ .

Uma rotação geral no espaço  $n$ -dimensional pode ser vista como a rotação de um eixo  $i$  em direção a um eixo  $j$ . O plano descrito pelos eixos  $i$  e  $j$  é o plano de rotação e a matriz geral para responsável pela rotação principal,  $M_{i,j}^{(n)}(\theta_{i,j})$  é obtida por:



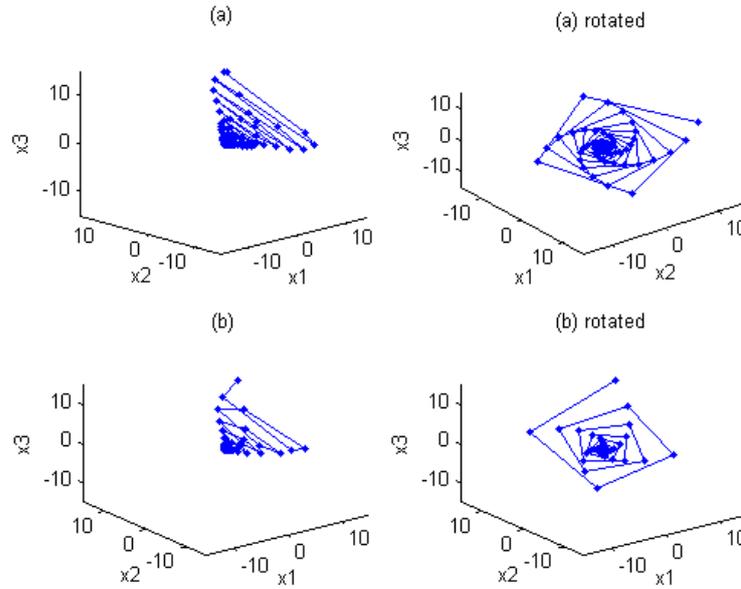


Figura 18 – Exemplos de trajetórias espirais logarítmicas usando a Equação (41). Valores diferentes da taxa de convergência  $r$  produzem comportamentos de forma espiral distintos. (a) representa a trajetória espiral usando  $r = 0,95$ ;  $\theta = \pi/4$  e (b) mostra a trajetória espiral usando  $r = 0,90$ ;  $\theta = \pi/4$ . A coluna do lado direito mostra uma versão rotacionada da espiral correspondente.

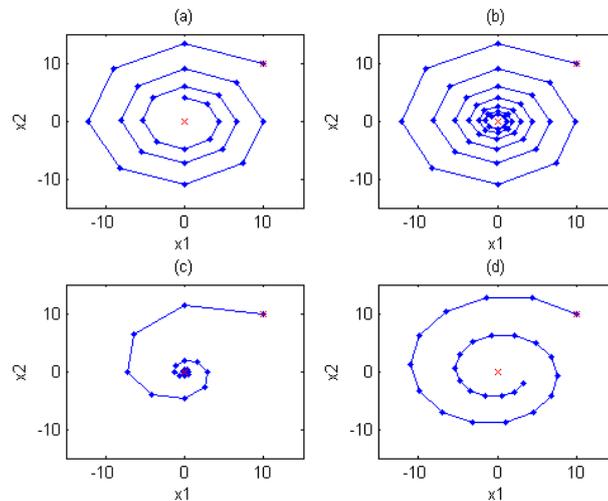


Figura 19 – Exemplos de trajetórias espirais logarítmicas usando a Equação (41). Valores diferentes da taxa de convergência  $r$  produzem comportamentos de forma espiral distintos. (a) trajetória usando  $r = 0.95$ ,  $\theta = \pi/4$  e  $popsize = 25$ , (b)  $r = 0.95$ ,  $\theta = \pi/4$  e  $popsize = 50$ , (c)  $r = 0.80$ ,  $\theta = \pi/4$ ,  $popsize = 25$  e (d)  $r = 0.95$ ,  $\theta = \pi/7$  e  $popsize = 25$ .

Para usar os conceitos de espirais logarítmicas observados em SOA, como um operador de busca local dentro do algoritmo C-DEEPSO, algumas definições e premissas devem ser observadas e realizadas:

- Dada uma taxa de ocorrência ( $\gamma$ ), o operador de busca local será executado a cada

- geração, até atingir o número máximo de gerações especificado em  $N_{gl}$ ;
- O raio e o ângulo são escolhidos aleatoriamente. O número de pontos gerados está diretamente relacionado com os parâmetros de inicialização usados no SOA. Por conveniência, o número de pontos gerados é o mesmo que a população iniciada em C-DEEPSO;
  - O ponto central da espiral logarítmica é  $X_{best}$  porque a ideia principal do operador de busca local é ampliar a pesquisa em torno de uma região promissora do espaço de busca;
  - Uma espiral logarítmica inversa aditiva é introduzida com base na informação contida em  $X_{best}$ , com o intuito de intensificar a exploração de possíveis soluções próximas a  $X_{best}$ ;

Nesta nova abordagem, uma amostra de soluções totalmente aleatória de espirais logarítmicas é gerada, permitindo nomear este novo operador de busca local como *Spiral Local Search* (SLS). Para fins de ilustração de uma espiral e sua inversa aditiva usando o operador SLS, a Figura 20 mostra uma espiral e sua inversa aditiva vista do ponto central (0,0,0).

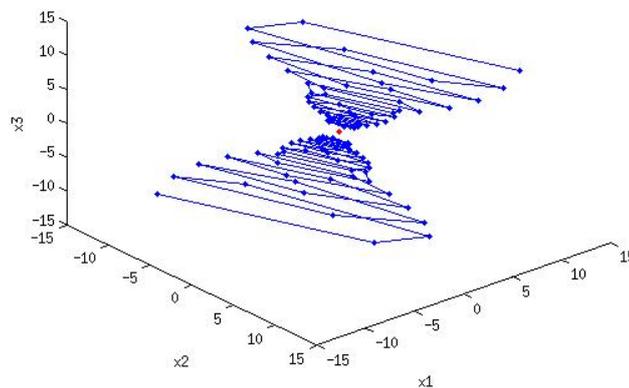


Figura 20 – Um exemplo de uma espiral inversa aditiva, em um espaço tridimensional, vista do ponto central (0,0,0).

O procedimento do operador SLS corresponde à geração de amostras em espiral a partir de  $X_{best}$ . Uma população amostrada pela espiral obtida é avaliada na função objetivo original e a solução que tem o menor valor de função objetivo é chamada de  $X_{SLS}$ . O operador SLS é elitista, o que significa que a pior solução,  $X_{pior}$ , na população atual de C-DEEPSO, é substituído por  $X_{SLS}$ .

O operador de busca local proposto pretende ajudar o algoritmo C-DEEPSO a encontrar um ótimo local. Não somente a pressão de seleção usual direciona C-DEEPSO para focar mais e mais em regiões melhores já descobertas, mas também realiza uma busca em maior profundidade. Como resultado, a diversidade populacional diminui e a convergência prematura pode ocorrer. Embora a convergência prematura não seja causada pela perda de diversidade, acredita-se que a manutenção de um certo grau de diversidade

ajuda a evitar o aprisionamento em soluções não ótimas. Tendo isso em mente, propõe-se um mecanismo de diversidade simples inspirado no trabalho de [Ursem \(2002\)](#).

Este mecanismo de diversidade usa a informação de uma distância entre a melhor solução,  $X_{best}$  para cada solução presente na população, visando alternar *exploitation*<sup>2</sup> e *exploration*<sup>3</sup>. Assim, a distância para um ponto médio,  $\bar{X}_d$ , entre as soluções presentes na população e  $X_{best}$ , é obtida na Equação (42):

$$\bar{X}_d = \frac{1}{NP} \sum_{i=1}^{NP} \sqrt{\sum_{j=1}^D (X_{(ij)} - X_{best})^2}, \quad (42)$$

em que  $NP$  é o tamanho da população e  $D$  é a dimensão do problema. São geradas novas soluções  $X_{d+} = X_{t(i)} + \bar{X}_d$  e  $X_{d-} = X_{t(i)} - \bar{X}_d$  e são, então, avaliados na função objetivo original. As melhores  $NP$  soluções são então selecionadas para a próxima geração. O Algoritmo 4 apresenta o pseudocódigo do procedimento de busca local, SLS, e o mecanismo de diversidade proposto neste trabalho.

---

#### Algoritmo 4: Pseudocódigo *Spiral Local Search* (SLS)

---

```

se  $rand() > \gamma$  então
  se  $(t \leq N_{gl})$  então
    Passo 1: Inicializar a quantidade de  $m$  pontos de busca como  $m = \#NP$ , gerar um
    valor aleatório para  $\theta$  no intervalo  $[0, 2\pi]$ , gerar um valor aleatório para  $r$  no intervalo
     $[0, 1]$  para  $rM^{(n)}(\theta)$ ;
    Passo 2: Gerar  $m$  soluções (uma amostra de população espiral e sua inversa) a partir
    de  $X_{best}$  usando a Equação (41);
    Passo 3: Avaliar a população  $m$ ;
    Passo 4: Substituir na  $NP$ :  $X_{SLS}$  por  $X_{pior}$ ;
  senão
    para cada solução  $i$  pertencente a população  $NP$  faça
      Calcular  $X_d$  usando a Equação (??) para cada dimensão;
      Gerar  $X_{d+} = X_{(i)} + X_d$  e  $X_{d-} = X_{(i)} - X_d$ ;
      Avaliar populações  $X_{d+}$  e  $X_{d-}$ ;
      Ordenar  $X_{d+}$ ,  $X_{d-}$  e  $NP$ ;
      Criar nova população  $\#NP$  a partir do melhores indivíduos do passo anterior;
    fim
  fim
fim

```

---

De acordo com [Krasnogor e Smith \(2005\)](#), está bem estabelecido que os AE puros não são bem adequados para refinamento de espaços combinatórios complexos e que a

<sup>2</sup> Termo em inglês que consiste em sondar uma região limitada (mas promissora) do espaço de busca com a esperança de melhorar uma solução promissora  $S$  que se tem à mão. Esta operação equivale então a intensificar (refinar) a busca na vizinhança de  $S$ . Ao fazer isso, estará sendo feita, de fato, uma busca local.

<sup>3</sup> Termo em inglês que consiste em sondar uma porção muito maior do espaço de busca com a esperança de encontrar outras soluções promissoras que ainda precisam ser refinadas. Esta operação equivale, então, a diversificar a busca, visando evitar ficar preso em um ótimo local. Ao fazer isso, estará sendo realizado uma busca global.

hibridização com outras técnicas pode prover significativamente a eficiência da busca. Dessa forma, o algoritmo proposto une os conceitos de otimização evolutiva e métodos heurísticos, com a intenção de ser uma boa abordagem para resolver problemas relacionados ao fluxo de potência ótimo. Assim, o novo algoritmo híbrido proposto neste trabalho é agora denominado de *Hybrid Canonical Differential Evolutionary Particle Swarm Optimization* (hC-DEESPO).

### 5.3 Testes preliminares para validação do hC-DEESPO

Para validar um método é necessário submetê-lo a testes de desempenho. Esta seção vai apresentar alguns experimentos, com uso de uma conhecida função de *benchmark*, para verificar o comportamento dos algoritmos C-DEESPO e hC-DEESPO. Funções de *benchmark* possuem propriedades que as tornam verdadeiramente úteis, no que tange oferecer uma imparcialidade em conjuntos de testes. Quando o número de variáveis de decisão (isto é, a dimensão do problema) aumenta, o espaço de busca também aumenta. Para problemas não-lineares, esta dimensionalidade pode ser uma barreira significativa para quase todos os algoritmos de otimização (JAMIL; YANG, 2013).

A modalidade de uma função está relacionada com o número de pontos (máximos e mínimos) presentes em sua paisagem, o que induz uma tendência para que o algoritmo fique preso em um deles durante um processo de busca. Isto ocasiona um impacto negativo sobre o processo de busca, fazendo com que ele caminhe para regiões afastadas das verdadeiras soluções ótimas. Uma função que possui mais de um valor ótimo local é chamada de multimodal. A separabilidade é uma propriedade que também pode implicar em dificuldade para um problema de otimização. A função determinada separável pode ser escrita como uma soma de outras funções sub-objetivo com apenas uma variável de decisão. Quando estas variáveis de decisão são inter-relacionadas, a função é chamada não-separável (LOCATELLI, 2003).

A função de Rosenbrock foi escolhida para realizar a validação preliminar dos resultados obtidos pelos algoritmos propostos neste trabalho. A Equação (43) apresenta a função de Rosenbrock, que apenas com  $D = 2$  é unimodal, neste caso  $D$  caracteriza a dimensão do espaço,

$$f(x) = \sum_{i=1}^{D-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]. \quad (43)$$

Esta função é considerada, pela comunidade, uma função de difícil otimização. Em duas dimensões, o seu mínimo se encontra dentro de uma longa e estreita parabólica em forma de vale plano. Encontrar o vale é trivial, no entanto, convergir para o mínimo global é difícil. Rosenbrock é não-convexa, o que pode ser comprovado pelo comportamento

presente em sua curva de nível, como pode ser visto na Figura 21. O ponto [1,1] é o ótimo global do problema e está representado por um ponto no gráfico à direita.

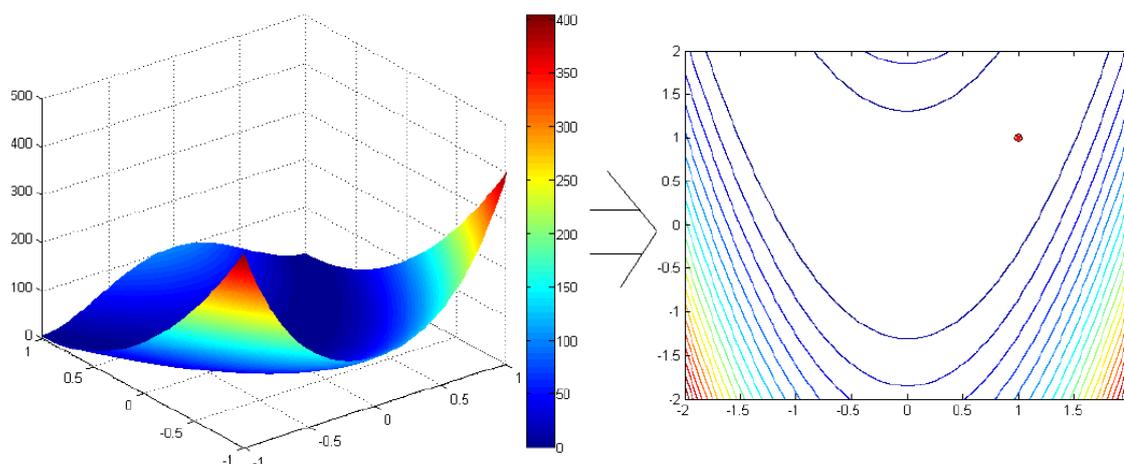


Figura 21 – Representação gráfica da Função de Rosenbrock - 2D

A Figura 22 retrata a busca ao ótimo realizada por um algoritmo evolutivo. Nesta demonstração o algoritmo gera 30 indivíduos no espaço de busca, representados pelos quadrados. A primeira ampliação realizada na imagem, após N gerações, mostra a nova população. A segunda ampliação ilustra a distância entre os indivíduos da população atual e a próxima geração. Ao final, os pontos presentes na ultima geração mostrada na figura são relativamente próximos ao ponto X.

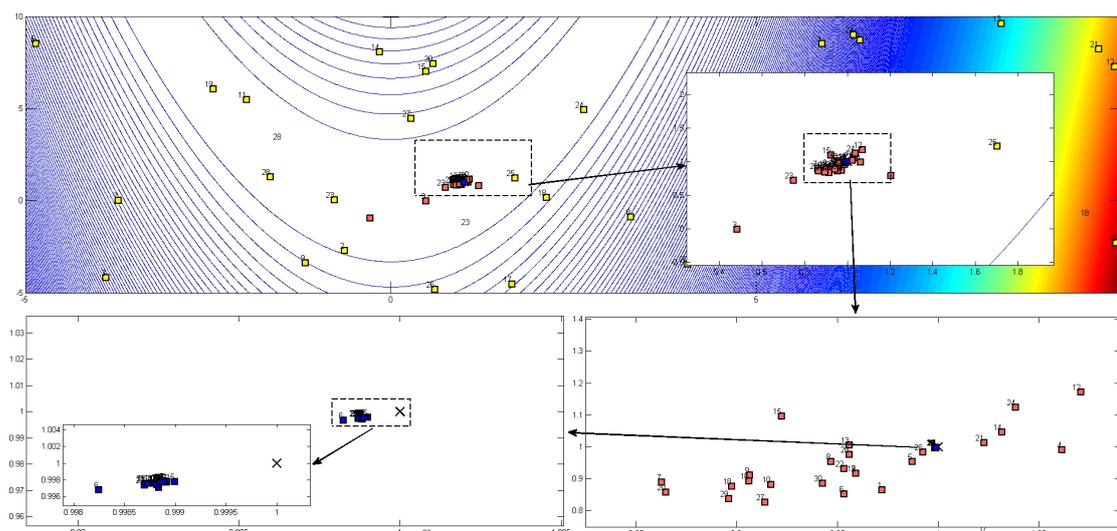


Figura 22 – Exemplo de convergência - Função de Rosenbrock - 2D

Um teste preliminar variando as dimensões do problema em 30, 50 e 100 foi realizado. Uma comparação de desempenho foi obtida com os resultados dispostos em (PANT et al.,

2011). Para se manter a justiça no teste, os algoritmos EPSO, DEEPSO, C-DEEPSO e hC-DEEPSO utilizaram os mesmos parâmetros descritos no trabalho de Pant et al. (2011), que propôs uma junção simples entre os algoritmos DE e PSO, denominado como DE-PSO.

Os parâmetros são: dimensão (30, 50 e 100) e tamanho da população (30, 50 e 100 indivíduos). Foi mantido fixo o número máximo de avaliações de função em 100.000. Em C-DEEPSO e hC-DEEPSO se mantiveram as taxas empíricas de mutação e comunicação  $[\tau, P] = [0.5, 0.9]$ . O hC-DEEPSO utilizou taxa  $\gamma = 0.5$  e  $N_{gl} = 10$ . Cada algoritmo foi executado 30 vezes. As medidas comparativas de média e desvio padrão não são as melhores abordagens de avaliação em um planejamento de experimentos adequado, porém diversos trabalhos na literatura utilizam estas métricas. A Tabela 10 apresenta os resultados de cada algoritmo na função de Rosenbrock.

Tabela 10 – Comparativo dos resultados da otimização - media ( $M$ ) e desvio ( $D$ )

$f$	D	PSO	DE	DE-PSO	EPSO	DEEPSO	C-DEEPSO	hC-DEEPSO
		(M)/(D)	(M)/(D)	(M)/(D)	(M)/(D)	(M)/(D)	(M)/(D)	(M)/(D)
Eq.(43)	30	81.273	31.1369	24.202	20.3765	19.4198	19.0847	17.2111
		41.218	17.1211	12.3086	1.4823	2.5076	2.3503	1.9076
	50	174.222	50.3377	44.741	40.4248	41.1863	39.8960	38.9081
		113.635	16.8557	1.402	2.0347	2.5789	2.3512	2.5446
	100	250.681	91.237	91.024	91.1405	92.1401	91.9330	89.6036
		24.643	3.82465	3.4001	2.3205	2.5339	1.9048	1.9072

Como já dito, analisar apenas média e desvio não traz garantias de significância. Assim, um T-test (MONTGOMERY, 2012) pode ser executado para comparar mais efetivamente os resultados obtidos, uma vez que as amostras são aproximadamente normais. Tal teste pode ser usado para comparar resultados de amostras de população em rodadas de teste "dois a dois". A hipótese nula adotada neste trabalho é a igualdade das médias, portanto o experimento é projetado para detectar se essa hipótese é rejeitada ou não usando um valor de significância  $\alpha = 5\%$ . Se a hipótese nula for rejeitada, uma comparação pode ser feita para determinar qual é o melhor algoritmo.

A Tabela 11 apresenta os resultados do T-test. Para o número de graus de liberdade, o valor tabelado para um alfa de  $\alpha = 5\%$  para realização do T-test é de 2.0. A rejeição se dá caso o valor do teste for superior ao valor tabelado. Uma vez que o P-Valor calculado obteve um resultado inferior a 0.05, a hipótese nula de igualdade das médias é rejeitada, com nível de 5% de significância, em que hC-DEEPSO possui valor médio menor que os demais algoritmos testados. Isso significa que em uma comparação estatística o algoritmo hC-DEEPSO possui resultados mais eficientes para solução do problema frente aos demais.

Tabela 11 – Comparando resultados com T-test - Função de Rosenbrock

Função de Rosenbrock				
<b>Rosenbrock 30D</b>	<b>T-test</b>	<b>P-Value</b>	<b>Ação</b>	<b>Vencedor</b>
hC-DEEPSO x C-DEEPSO	3.4374	5.87E-04	reject	hC-DEEPSO
hC-DEEPSO x DEEPSO	6.0607	1.35E-09	reject	hC-DEEPSO
hC-DEEPSO x EPSO	7.2657	1.78E-03	reject	hC-DEEPSO
hC-DEEPSO x DE-PSO	3.6708	2.40E-04	reject	hC-DEEPSO
hC-DEEPSO x DE	4.8954	9.80E-07	reject	hC-DEEPSO
hC-DEEPSO x PSO	8.8090	2.07E-12	reject	hC-DEEPSO
<b>Rosenbrock 50D</b>	<b>T-test</b>	<b>P-Value</b>	<b>Ação</b>	<b>Vencedor</b>
hC-DEEPSO x C-DEEPSO	3.1946	2.23E-03	reject	hC-DEEPSO
hC-DEEPSO x DEEPSO	5.0379	4.60E-06	reject	hC-DEEPSO
hC-DEEPSO x EPSO	4.3008	6.36E-05	reject	hC-DEEPSO
hC-DEEPSO x DE-PSO	13.0948	0.00E+00	reject	hC-DEEPSO
hC-DEEPSO x DE	4.0597	1.40E-04	reject	hC-DEEPSO
hC-DEEPSO x PSO	6.6772	8.86E-09	reject	hC-DEEPSO
<b>Rosenbrock 100D</b>	<b>T-test</b>	<b>P-Value</b>	<b>Ação</b>	<b>Vencedor</b>
hC-DEEPSO x C-DEEPSO	5.4312	1.06E-06	reject	hC-DEEPSO
hC-DEEPSO x DEEPSO	4.9797	5.69E-06	reject	hC-DEEPSO
hC-DEEPSO x EPSO	3.4049	1.18E-03	reject	hC-DEEPSO
hC-DEEPSO x DE-PSO	2.4570	1.60E-02	reject	hC-DEEPSO
hC-DEEPSO x DE	2.5144	1.46E-02	reject	hC-DEEPSO
hC-DEEPSO x PSO	36.3524	0.00E+00	reject	hC-DEEPSO

Para avaliar o comportamento dos algoritmos C-DEEPSO e hC-DEEPSO aplicados à solução de problemas SCOPF, um experimento foi realizado com o Sistema 57 de barras. Os parâmetros de inicialização dos algoritmos foram os mesmos, conforme: NP = 60; MB = 6;  $\gamma = 0.5$ ;  $N_{gl} = 20$ ; Mutaç o = 0.6; Comunicaç o = 0.2; M ximo de avaliaç es =  $5 \times 10^3$ . Cada algoritmo foi executado 31 vezes. A Figura 23 apresenta o gr fico de converg ncia m dia dos resultados obtidos pelos algoritmos DEEPSO, C-DEEPSO e hC-DEEPSO no decorrer das  $5 \times 10^3$  avaliaç es de funç o.

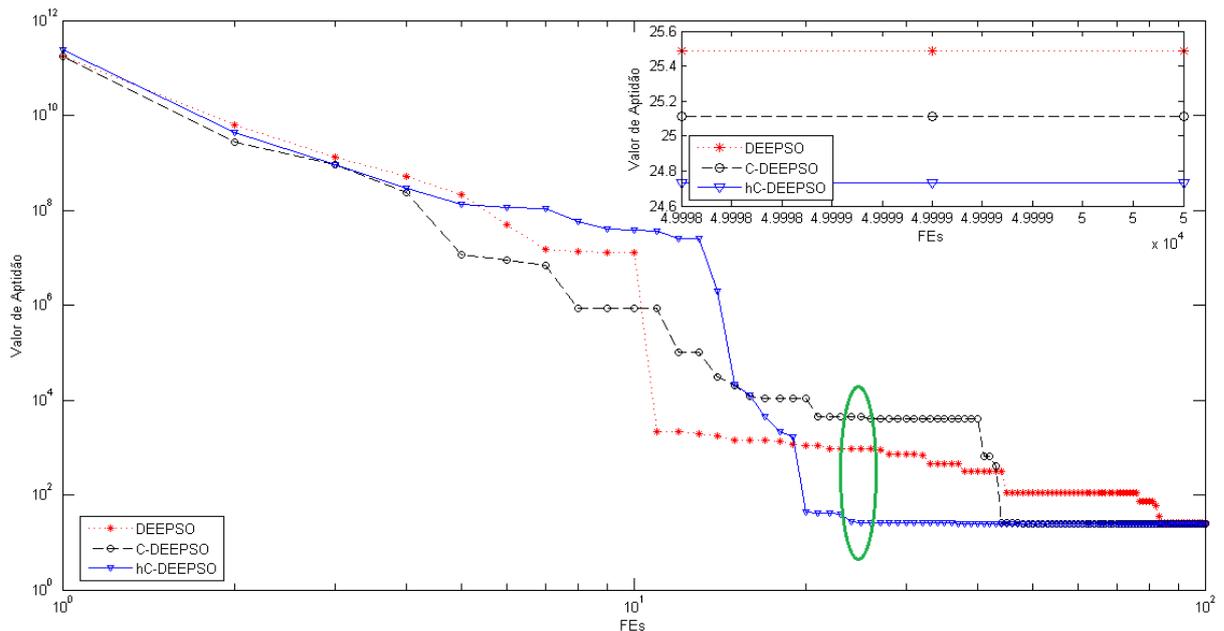


Figura 23 – Curva de converg ncia m dia - Sistema 57 barras/ ORDP

O comportamento apresentado no gráfico de convergência média da Figura 23 indica que o algoritmo hC-DEESPO converge antes dos demais seguido do algoritmo C-DEEPSO. A área circulada pretende mostrar os valores otimizados que cada algoritmo obteve naquela avaliação de função. O valor encontrado por hC-DEEPSO foi de 25.91 MW, enquanto os valores de C-DEEPSO e DEEPSO foram, respectivamente, 4456 MW e 927.6 MW. Isto mostra visualmente que o uso do operador de busca local proposto, SLS, permite que hC-CDEEPSO convirja mais rapidamente na solução deste problema específico frente aos demais. O resultado final encontrado por cada algoritmo foi avaliado com uso de técnicas estatísticas. Em primeiro plano, gráficos de caixa foram gerados e estão presentes na Figura 24. Esta medida não-paramétrica auxilia na análise de amostras de resultados e como pode ser visto, a caixa apresentada pelo algoritmo hC-DEEPSO é mais estreita em relação aos demais algoritmos.

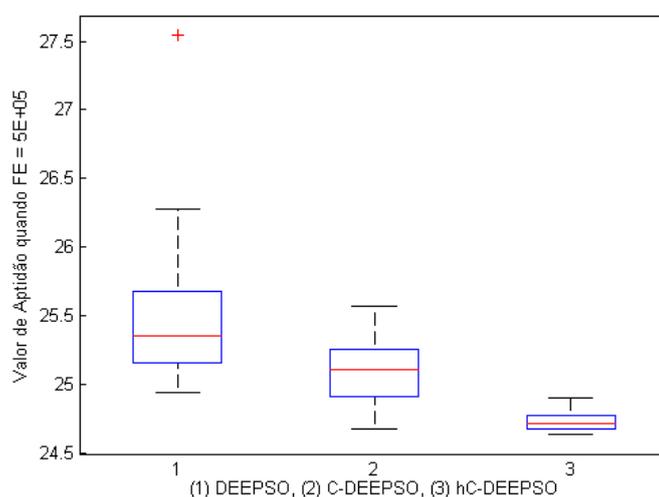


Figura 24 – Gráficos de Caixa - Sistema 57 barras/ ORDP

O algoritmo hC-DEEPSO não apresenta pontos extremos como é o caso do algoritmo DEEPSO. Para uma melhor análise de resultados, um teste ANOVA foi realizado e com uso dos resíduos deste teste foi possível verificar, via Teste de Tukey, diferenças entre as médias dos resultados apresentados pelos algoritmos testados. O P-valor calculado para um nível de significância de 5% foi de  $6.19E-13$ , indicando a rejeição da hipótese de igualdade das médias. A Figura 25 apresenta o resultado do teste de Tukey realizado.

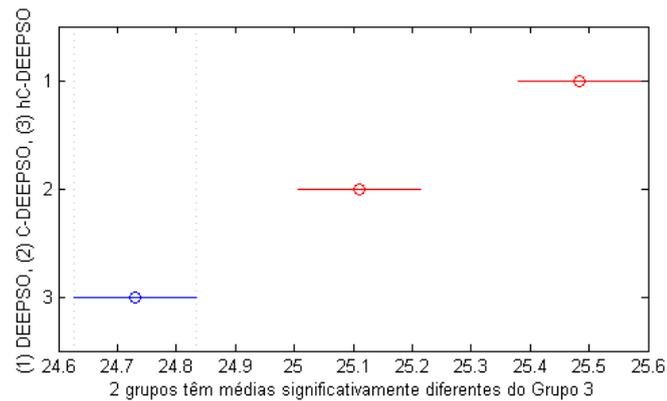


Figura 25 – Resultado do Teste de Tukey - Sistema 57 barras/ ORDP

O resultado indica com 95% de confiança que existem diferenças médias entre os três algoritmos observados. O hC-DEEPSO apresenta menor valor médio em relação a C-DEEPSO e DEEPSO, e por consequência C-DEEPSO indica um melhor resultado médio que DEEPSO. Este experimento mostra que o uso da busca local proposta é relevante para resolver o problema em questão. A motivação em se fazer uma busca local é realizar uma amostragem mais refinada do espaço de busca, explorando alguns vizinhos do melhor ponto até o momento ( $X_{best}$ ). Esta ação se faz importante, principalmente, em um contexto de problemas de larga escala, como os de despacho elétrico em abordagem SCOPF, no qual essa amostragem do espaço de busca é intrinsecamente difícil.

A busca local proposta (SLS), partindo de um ponto de origem ( $X_{best}$ ) e um ponto de destino, gera uma amostragem de pontos em cima de uma espiral ligando estes pontos e, em uma tentativa de intensificar a busca, gera pontos também em cima da espiral ligando  $X_{best}$  e o oposto do ponto de destino. Ao usar como ponto de destino (ou ponto central) o segundo melhor indivíduo ou o centroide dos pontos da população, esta amostra de pontos gerada não se mostrou tão diversa em relação ao ponto de origem,  $X_{best}$ . Isto se deve ao fato de que o segundo melhor e/ou centroide estão relativamente próximos da solução  $X_{best}$ . Assim, visando verificar a exploração do espaço de busca, escolhemos como destino um ponto totalmente aleatório. O resultado desta abordagem mostrou que a utilização de um ponto aleatorizado não se mostrou eficiente.

Desta maneira, ao usar como destino a origem do sistema cartesiano conforme é realizado no primeiro passo do algoritmo SOA, os resultados se mostraram significativamente melhores que as demais abordagens. A escolha se deve também ao fato de que a expressão matemática para se gerar a amostra de pontos em espiral fica mais simplificada. Os resultados dos testes preliminares para os Sistemas de 57 barras em modo ORDP/OARDP e o Sistema de 118 barras em modo ORDP estão dispostos nas Tabelas 12 e 13.

Tabela 12 – Valores médios e de desvio padrão para diferentes centros para geração de amostras espirais logarítmicas.

IEEE de 57 barras		ORDP	
Destino	Média	Desvio	
Origem	<b>24.7286</b>	<b>0.1064</b>	
Segundo Melhor	24.7812	0.0801	
Centroide	24.8134	0.1542	
Aleatório	25.4202	0.5725	
IEEE de 57 barras		OARDP	
Destino	Média	Desvio	
Origem	<b>41691.4193</b>	<b>2.804</b>	
Segundo Melhor	41697.58	1.499	
Centroide	41698.67	3.866	
Aleatório	41697.69	11.75	
IEEE de 118 barras		ORDP	
Destino	Média	Desvio	
Origem	<b>117.9541</b>	<b>0.3048</b>	
Segundo Melhor	124.3415	3.3563	
Centroide	124.7636	2.9123	
Aleatório	119.7117	2.8148	

Tabela 13 – Comparação de resultados usando T-test em uma avaliação *post hoc*.

Verificação				
<b>57 - ORPD</b>	<b>T-test</b>	<b>P-Valor</b>	<b>Ação</b>	<b>Vencedor</b>
Origem x Segundo	2.1488	0.0316	rejeitar	Origem
Origem x Centroide	2.1219	0.0332	rejeitar	Origem
Origem x Aleatório	6.6110	3.81E-11	rejeitar	Origem
<b>57 - OARDP</b>	<b>T-test</b>	<b>P-Valor</b>	<b>Ação</b>	<b>Vencedor</b>
Origem x Segundo	8.9796	00E+00	rejeitar	Origem
Origem x Centroide	7.2489	4.20E-13	rejeitar	Origem
Origem x Aleatório	2.4142	0.0157	rejeitar	Origem
<b>118 - ORPD</b>	<b>T-test</b>	<b>P-Valor</b>	<b>Ação</b>	<b>Vencedor</b>
Origem x Segundo	10.5501	00E+00	rejeitar	Origem
Origem x Centroide	12.9477	00E+00	rejeitar	Origem
Origem x Aleatório	3.4563	5.47E-04	rejeitar	Origem

Os resultados indicam com significância de 5% que a melhor estratégia para destino das amostras espirais é caminhar em direção à origem do plano cartesiano do sistema, conforme resultados mostrados na Tabela 13. Logo, os experimentos computacionais para solução dos problemas SCOPF em grandes redes de energia usaram SLS partindo do melhor indivíduo corrente  $X_{best}$  em direção à origem do plano cartesiano do sistema.

## 5.4 Considerações Finais

Este capítulo apresentou a proposta de novos algoritmos evolutivos. Uma validação foi realizada com o emprego de um problema de *benchmark* bastante difundido na comunidade. Os resultados experimentais mostraram que C-DEEPSO e hC-DEEPSO obtiveram soluções de melhor qualidade na resolução do problema em questão. O Sistema de 57 barras foi utilizado como problema teste inicial na abordagem ORPD na qual os algoritmos DEEPSO, C-DEEPSO e hC-DEEPSO foram avaliados. Os resultados preliminares indicaram com significância estatística que hC-DEEPSO é uma melhor abordagem para solução de problemas SCOPF na rede de larga escala testada. Uma análise de sensibilidade foi realizada a fim de se discutir qual melhor centro para geração de amostras espirais. Os testes realizados mostraram com significância estatística que caminhar em direção à origem do plano cartesiano do sistema é a melhor abordagem para solução de problemas de natureza SCOPF estudados neste trabalho. Isto é um indicativo preliminar que os algoritmos propostos possuem potencial para solução de problemas de natureza multimodal.

## 6 Experimentos e Resultados

Este Capítulo apresenta os experimentos realizados com uso dos algoritmos propostos C-DEEPSO e hC-DEEPSO na solução dos problemas referentes ao despacho elétrico no fluxo ótimo de potência.

### 6.1 Problema de Despacho Elétrico em UHE

Para validar o modelo multiobjetivo apresentado na Seção 4.1, três experimentos são propostos. O primeiro tem como objetivo analisar os resultados obtidos por DE/best/1/bin e C-DEEPSO na abordagem mono-objetivo presente em [Marcelino, Wanner e Almeida \(2013\)](#). Além disso, os experimentos podem verificar se as soluções da abordagem mono-objetivo foram encontradas na abordagem multiobjetivo, alcançadas com os algoritmos NSGA-II e SPEA2, no experimento 2. O terceiro experimento contempla a comparação de desempenho entre os algoritmos NSGA-II e SPEA2 na solução de um caso teste. Para isto, a demanda de  $320MW$  foi definida, uma vez que esta é uma demanda típica da UHE estudada e modelada. A queda líquida  $Hb$ , do reservatório, foi definida em  $54m$ . Os AE mono-objetivo e multiobjetivo usaram os parâmetros de inicialização definidos empiricamente contidos na Tabela 14.

Tabela 14 – Parâmetros de inicialização dos algoritmos mono e multiobjetivo

Parâmetros	Mono	Multi
Tamanho da População	10	50
Gerações	50	50
Mutação	0.5	0.02
Cruzamento/Comunicação	0.75	0.8

No primeiro experimento o algoritmo C-DEEPSO foi utilizado para otimização do despacho elétrico em UHE, no qual a primeira função objetivo é a produtividade (que deve ser maximizada). Este experimento visa realizar a comparação dos resultados obtidos por C-DEEPSO com os alcançados pelo algoritmo DE/best/1/bin. Ambos os algoritmos foram executados 30 vezes. Este número baseia-se no interesse prático, uma vez que a aproximação normal será satisfatória, independentemente da forma da população, se  $n \geq 30$ . O teorema do limite central funciona se uma distribuição populacional não é muito diferente da normal se  $N < 30$  ([MONTGOMERY; RUNGER; HUBELE, 2004](#)). Um gráfico *boxplot* foi gerado e é apresentado na Figura 26.

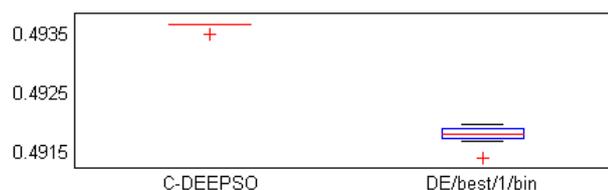


Figura 26 – *Boxplot* comparativo entre os algoritmos C-DEEPSO e DE/best/1/bin.

Cada algoritmo apresentou um ponto fora de cada série de dados estudada. C-DEEPSO não demonstra haver diversidade de resultados, enquanto DE/best/1/bin apresenta uma formação de caixa. Como visto na Seção 1.6.1, caso não ocorra sobreposição de dados pode-se constatar que as séries de dados possuem diferenças, assim pode-se afirmar que existem diferenças entre as séries de dados dos algoritmos C-DEEPSO e DE/best/1/bin.

### 6.1.1 Mono-objetivo vs. Multiobjetivo

Uma das finalidades da abordagem multiobjetivo realizado neste trabalho foi verificar se a solução mono-objetivo apresentada em (MARCELINO; WANNER; ALMEIDA, 2013) e a solução obtida por C-DEEPSO são encontradas na abordagem multiobjetivo. A Figura 27 mostra o ponto representado pela esfera que é a melhor solução do DE/best/1/bin, um triângulo que representa a solução de C-DEEPSO e a Fronteira de Pareto obtida pelos algoritmos NSGA-II e SPEA2. É percebido que caso um operador de dominância seja utilizado, o ponto referente ao DE/best/1/bin deve ser dominado. A Fronteira de Pareto apresenta diversas soluções em que o MCO economiza água em relação ao MCC, sem que as restrições sejam violadas. Os pontos do conjunto de solução do NSGA-II e SPEA2 escolhidos para comparação foram os melhores pontos que caracterizam a maior eficiência produtiva na maior distância ao MCC.

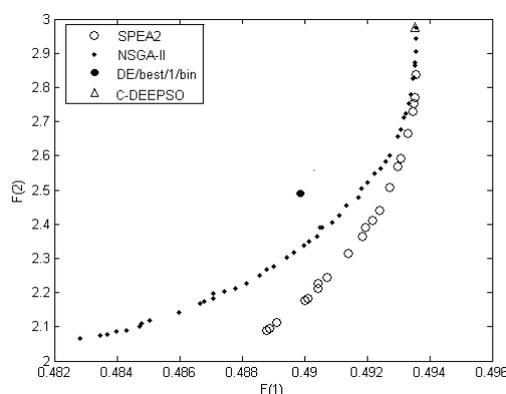


Figura 27 – Fronteira de Pareto para demanda de energia de 320MW.

Os resultados de simulação referentes aos pontos das soluções DE/best/1/bin, NSGA-II e SPEA2 são mostrados na Tabela 15.

Tabela 15 – Relatório geral referente à demanda de 320MW

<b>Algoritmo Mono-objetivo: DE/best/1/bin</b>			
<b>TOTAL</b>	320.353 MW	Vazão Total em MCO: <b>651.422</b> $m^3/s$	Vazão Total em MCC: 655.05 $m^3/s$
<b>DIFERENÇA</b>	+0.35 MW	<b>3.63</b> $m^3/s$	Índice de Produtividade: 0.4917
<b>Algoritmo Mono-objetivo: C-DEEPSO</b>			
<b>TOTAL</b>	320.380 MW	Vazão Total em MCO: <b>648.961</b> $m^3/s$	Vazão Total em MCC: 655.05 $m^3/s$
<b>DIFERENÇA</b>	+0,38 MW	<b>6.09</b> $m^3/s$	Índice de Produtividade: 0.4936
<b>Algoritmo Multiobjetivo: SPEA2</b>			
<b>TOTAL</b>	320.467 MW	Vazão Total em MCO: <b>648.903</b> $m^3/s$	Vazão Total em MCC: 655.05 $m^3/s$
<b>DIFERENÇA</b>	+0.46 MW	<b>6.14</b> $m^3/s$	Índice de Produtividade: 0.4936
<b>Algoritmo Multiobjetivo: NSGA-II</b>			
<b>TOTAL</b>	320.452 MW	Vazão Total em MCO: <b>649.390</b> $m^3/s$	Vazão Total em MCC: 655.05 $m^3/s$
<b>DIFERENÇA</b>	+0.45 MW	<b>5.66</b> $m^3/s$	Índice de Produtividade: 0.4930

Operando em MCC, a demanda de 320MW seria dividida igualmente pelo número de máquinas. Em uma UHE que possui seis conjuntos geradores, cada gerador receberia um *set-point* igual a 53.33MW. Isto corresponderia a uma vazão total de 655.05 $m^3/s$ . Neste contexto, o índice de produtividade em MCC seria igual a 0.4800. O índice de produtividade encontrado pelo algoritmo DE/best/1/bin na abordagem mono-objetivo foi de 0.4917. O índice obtido equivale a uma economia em vazão turbinada de 2.54 $m^3/s$  em relação ao MCC. O índice de produtividade encontrado pelo algoritmo C-DEEPSO na abordagem mono-objetivo foi de 0.4936. O índice obtido equivale a uma economia em vazão turbinada de 6.09 $m^3/s$  em relação ao MCC. Já o ponto de solução escolhido, obtido via algoritmo SPEA2, retrata uma economia de 6.14 $m^3/s$ . A economia via solução do NSGA-II foi de 5.66 $m^3/s$  neste experimento isolado.

Esta economia obtida em MCO equivale mensalmente a 9.4 milhões de  $m^3$  (via DE/best /1/bin), 15,7 milhões de  $m^3$  (via C-DEEPSO), 14.4 milhões de  $m^3$  (via NSGA-II) e 15.7 milhões de  $m^3$  (via SPEA2). Devido a estocasticidade presente nos algoritmos o valor exato referente a potência gerada e vazão consumida dificilmente é o mesmo. A solução obtida por C-DEEPSO está presente na Fronteira de Pareto, representado pelo símbolo triângulo, no qual indica o mesmo índice de produtividade que o apresentado pelo ponto escolhido do algoritmo SPEA2. De acordo com (CARNEIRO; CHAVES, 2008), o consumo mensal residencial de uma cidade com 300.000 habitantes, em média, é de 1.1 milhões de  $m^3$ . A cidade de Belo Horizonte é a sexta maior cidade brasileira, possuindo uma população de aproximadamente 2.4 milhões de habitantes. Numa simples analogia, 15.7 milhões de  $m^3$  seria uma quantidade suficiente para abastecimento da cidade de Belo Horizonte no período aproximado de 2 meses. Vale ressaltar que em MCO, as unidades geradoras atingem o máximo de sua capacidade de rendimento de 93%.

### 6.1.2 Apuração de desempenho dos algoritmos multiobjetivo

Neste experimento, os algoritmos NSGA-II e SPEA2 foram executados 30 vezes. Uma Fronteira de Pareto combinada foi posteriormente gerada, por meio do operador de dominância. A Figura 28 apresenta o resultado desta combinação.

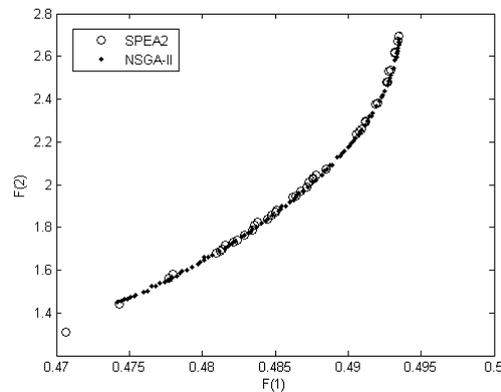


Figura 28 – Comparação entre Fronteiras de Pareto combinadas.

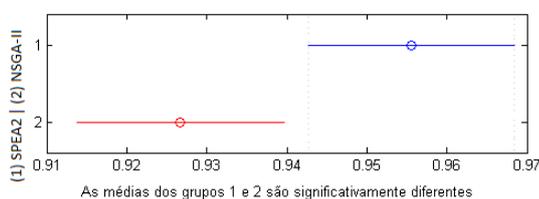
Embora os pontos de solução de ambos os algoritmos estejam praticamente sobrepostos, apenas visualmente não é possível identificar se existem diferenças entre os resultados obtidos pelos algoritmos. Este gráfico fornece ao tomador de decisões um conjunto de *set points* válidos para o planejamento da operação. É visível que entre o MCC e o MCO existem  $n$  soluções viáveis para o despacho elétrico. Desta maneira, a Fronteira de Pareto tem um papel importante no âmbito operacional, no qual a equipe técnica de operação visualiza que a nova forma de se despachar energia não está distante de sua forma usual. Assim, mostra-se que MCO é um tipo de controle que pode ser utilizado sem prejudicar as boas práticas operacionais atuais, fazendo com que a equipe técnica aceite de maneira mais amigável uma possível mudança do sistema.

O experimento aqui realizado utilizou uma solução da Fronteira de Pareto de cada um dos algoritmos testados. Esta escolha foi tomada por critérios *a posteriori*, com base no conhecimento adquirido sobre o problema. Esta é uma das maneiras de se escolher, mas necessariamente não é a mais indicada. Para verificar se existem diferenças significativas entre a solução apresentada pelos algoritmos NSGA-II e SPEA2, um teste de análise de variância foi realizado. Para tanto, foi necessário utilizar uma métrica conhecida como *S-metric* para cada uma das 30 execuções de cada um dos algoritmos. A *S-metric* é uma medida de qualidade comumente aceita para aproximações de Fronteira de Pareto (ZITZLER; LAUMANN; THIELE, 2001). Esta métrica calcula a área de hipervolume de uma região multidimensional delimitada por um ponto de referência, calculando assim a extensão de área da região a qual a solução domina. A Tabela 16 mostra os resultados da ANOVA realizada indicando que a hipótese de igualdade de *S-metric* é rejeitada com 95% de significância, dado que o P-valor calculado é igual a 0.0008.

Tabela 16 – Resultado da Análise de Variância - *S-metric*

Fonte	ANOVA				
	SS	dF	MS	F	Prob>F
Tratamentos	8.1496	1	8.14963	12.48	<b>0.0008</b>
Erro	37.8698	58	0.65293		
Total	46.0194	59			

Isto mostra que os algoritmos NSGA-II e SPEA2, neste problema, apresentam diferenças em suas soluções. Como indicado pelo teste de ANOVA, existe uma diferença entre as médias testadas, porém ANOVA não informa onde está a diferença. Para tentar identificar tal diferença, um teste de Tukey foi realizado. A Figura 29 apresenta o resultado gráfico do teste de comparações múltiplas.

Figura 29 – Teste de Tukey - *S-metric* de NSGA-II e SPEA2.

O teste indica que o valor médio de *S-metric* no algoritmo SPEA2 é maior que o mesmo valor obtido no NSGA-II. Logo, é conclusivo que para este problema, o algoritmo SPEA2 apresenta maior eficiência dos resultados frente ao algoritmo NSGA-II. Este trabalho apresentou uma abordagem multiobjetivo para resolver o problema de despacho elétrico em UHE usando os algoritmos NSGA-II e SPEA2. Os resultados dos experimentos de simulação mostram que é possível identificar pontos próximos a MCC que apresentam alta eficiência produtiva. Em um experimento, um ponto selecionado na Fronteira de Pareto com demanda de potência de  $320MW$  mostrou um índice de produtividade 0.4936.

Este ponto é muito semelhante, em ambas as funções objetivos, com resultados encontrados em abordagens mono-objetivo anteriores. Os resultados indicam uma economia de 15.7 milhões de  $m^3$ , na produção de energia usando o algoritmo SPEA2. Com uso de inferência estatística, foi possível verificar que SPEA2 mostrou melhores resultados que o algoritmo NSGA-II na solução deste problema. Por fim, é importante mencionar que a abordagem MCO pode ser facilmente adaptada para ser utilizada em outros tipos de plantas, semelhantes à UHE estudo de caso aqui discutido, pois esta é uma abordagem generalista.

## 6.2 Problemas SCOPF - Experimentos e resultados

### 6.2.1 Sistema IEEE 41 - minimização de perdas em WPP

O algoritmo C-DEEPSO foi testado no sistema disposto da WPP descrita na Seção 4.3.1. Os experimentos foram realizados a fim de se destacar a relevância do problema de

controle da potência reativa, que são definidos pelas mudanças graduais de  $q_{ref}$  no período de 1 dia (24 horas). A variabilidade do período mencionado é definida por intervalos de 15 minutos, que caracterizam 96 cenários, para os quais o problema de ORDOP deve ser resolvido. A Figura 30 é um exemplo do comportamento característico da potência de saída em um WPP.

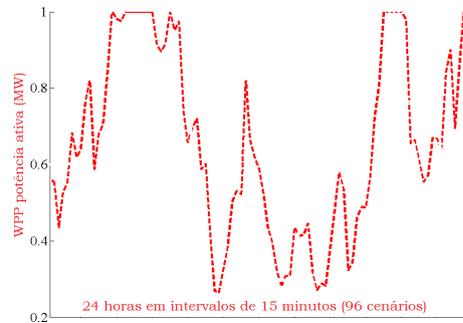


Figura 30 – Perfil de potência - saída da WPP) (ERLICH et al., 2014b).

Ao operar em condições ideais, para garantir a disponibilidade do sistema, a normal aquisição de dados e para atender continuamente  $q_{ref}$ , uma estratégia de controle é necessária. O planejamento experimental foi realizado para verificar se o algoritmo C-DEEPSO corresponde às premissas de controle para o tratamento de OPF na WPP. O algoritmo foi executado 31 vezes para cada cenário, usando um Intel Xeon 2,4 Ghz e 12 GB de RAM no MATLAB. Existem muitos estudos abordando o ajuste fino de parâmetros em algoritmos evolutivos. Sabe-se que tal procedimento pode garantir um melhor desempenho do algoritmo. No entanto, o ajuste fino dos parâmetros para C-DEEPSO está fora do escopo dos experimentos realizados neste problema. Dito isto, os parâmetros foram definidos empiricamente durante as experiências, resultando nos valores mostrados na Tabela 17.

Tabela 17 – Definição de parâmetros de inicialização de C-DEEPSO.

Máx. Aval. de Função	Tamanho da População	Tamanho da Memória	Com. $P$	Mut. $\tau$
10000	30	6	0.5	0.9

Para validar a eficiência da solução C-DEEPSO para o problema, os resultados obtidos são comparados com os resultados dos algoritmos DEEPSO e MVMO, que foram extraídos do banco de dados uma competição (ERLICH et al., 2014b). Os demais algoritmos participantes, não foram considerados na comparação, porque violaram as restrições do problema. De acordo com as premissas impostas pela competição, cada algoritmo deve ser executado por 31 vezes. O gráfico comparativo do resultado médio obtido por cada algoritmo é mostrado na Figura 31. A Figura 32 mostra uma expansão desse gráfico na faixa dos cenários 14-31.

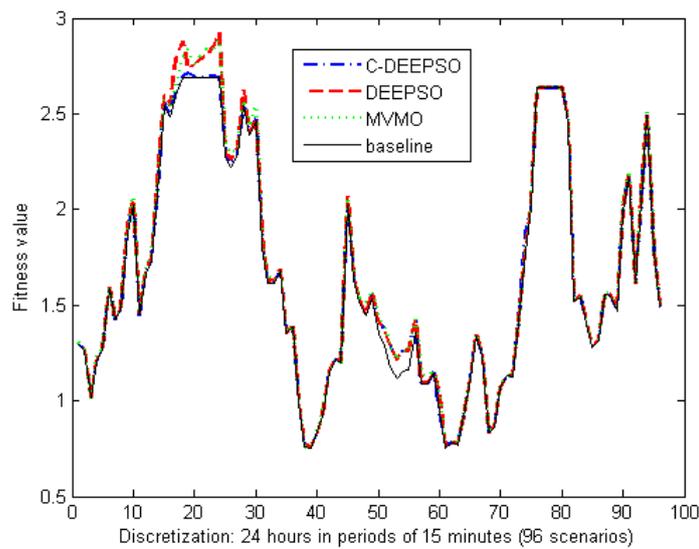


Figura 31 – Potência de saída gerada pela WPP (resultado médio) - uma comparação entre os algoritmos C-DEEPSO, MVMO e DEEPSO.

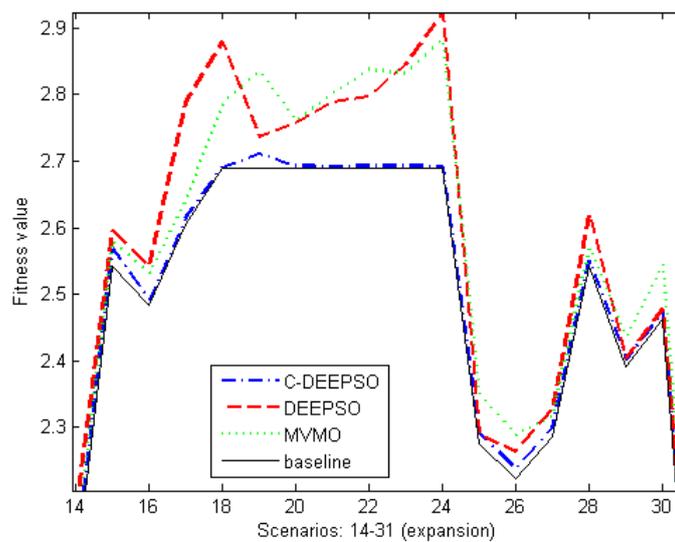


Figura 32 – Expansão (cenários 14-31).

Pode-se verificar que, nesse intervalo, C-DEEPSO apresenta um desempenho melhor quando comparado aos outros algoritmos. As Tabelas 18 e 19 fornecem outra maneira de verificar os resultados dos algoritmos em cada um dos 96 cenários de testes experimentais. Nestas tabelas, são listados os valores de média e desvio padrão para cada algoritmo. Os resultados indicam que, em termos de média e desvio, C-DEEPSO apresenta melhores resultados em 97% dos cenários experimentais. No entanto, uma análise baseada apenas na média e desvio não representa uma boa abordagem para comparação. Apesar do fato de que os valores médios e de desvio padrão obtidos por C-DEEPSO são menores que os de DEEPSO e MVMO, não é possível determinar se essas diferenças são estatisticamente significativas.

Tabela 18 – Resultados dos algoritmos C-DEEPSO, DEEPSO e MVMO

Sc	ALGORITMOS					
	C-DEEPSO		DEEPSO		MVMO	
	Média	Desvio	Média	Desvio	Média	Desvio
1	<b>1.296709</b>	<b>0.0011</b>	1.300416	0.006464	1.299471	0.002149
2	<b>1.2674</b>	<b>0.001079</b>	1.27365	0.006849	1.270922	0.002452
3	<b>1.013952</b>	<b>0.000889</b>	1.018528	0.009137	1.017974	0.00618
4	<b>1.206103</b>	<b>0.001241</b>	1.210449	0.006677	1.214193	0.012536
5	<b>1.274215</b>	<b>0.001054</b>	1.277351	0.004858	1.277518	0.00302
6	<b>1.58931</b>	<b>0.001891</b>	1.590727	0.002382	1.595016	0.002961
7	<b>1.427447</b>	<b>0.001014</b>	1.430635	0.003885	1.431654	0.003422
8	<b>1.486853</b>	<b>0.001425</b>	1.490068	0.002738	1.491214	0.001765
9	<b>1.890275</b>	<b>0.004331</b>	1.920608	0.025138	1.912675	0.017726
10	<b>2.036265</b>	<b>0.006961</b>	2.059875	0.021007	2.068124	0.024814
11	<b>1.448917</b>	<b>0.001581</b>	1.460489	0.019159	1.466775	0.028831
12	<b>1.676151</b>	<b>0.003887</b>	1.687921	0.00919	1.696736	0.020164
13	<b>1.740549</b>	<b>0.004298</b>	1.75454	0.009227	1.765304	0.019683
14	<b>2.105806</b>	<b>0.007327</b>	2.138487	0.02316	2.131292	0.015799
15	<b>2.553849</b>	<b>0.007303</b>	2.576392	0.015664	2.583475	0.017772
16	<b>2.492254</b>	<b>0.00333</b>	2.52295	0.022583	2.526806	0.015743
17	<b>2.622195</b>	<b>0.011828</b>	2.763067	0.063241	2.752978	0.049748
18	<b>2.698968</b>	<b>0.01222</b>	2.837714	0.049846	2.832812	0.065309
19	<b>2.701435</b>	<b>0.012939</b>	2.838913	0.054696	2.832115	0.05962
20	<b>2.703978</b>	<b>0.014009</b>	2.829544	0.062866	2.836847	0.037857
21	<b>2.7048</b>	<b>0.013638</b>	2.826354	0.054087	2.824264	0.052248
22	<b>2.701397</b>	<b>0.011375</b>	2.840033	0.041991	2.8105	0.043337
23	<b>2.702657</b>	<b>0.011834</b>	2.84924	0.052075	2.813017	0.060382
24	<b>2.698104</b>	<b>0.010336</b>	2.824618	0.060398	2.830624	0.038445
25	<b>2.291002</b>	<b>0.004759</b>	2.320457	0.026687	2.328435	0.025966
26	<b>2.238042</b>	<b>0.006057</b>	2.279125	0.018528	2.273852	0.022695
27	<b>2.301127</b>	<b>0.007693</b>	2.332162	0.019854	2.326763	0.016357
28	<b>2.554652</b>	<b>0.008919</b>	2.584022	0.024599	2.588382	0.025195
29	<b>2.404226</b>	<b>0.004125</b>	2.434756	0.025572	2.435477	0.016747
30	<b>2.472276</b>	<b>0.002946</b>	2.504222	0.019501	2.510542	0.021636
31	<b>1.818557</b>	<b>0.004294</b>	1.837128	0.013342	1.845527	0.031906
32	<b>1.619751</b>	<b>0.003618</b>	1.632586	0.012615	1.638392	0.024243
33	<b>1.61713</b>	<b>0.000828</b>	1.620574	0.005501	1.621487	0.002227
34	<b>1.686769</b>	<b>0.000694</b>	1.688831	0.003948	1.690077	0.002368
35	<b>1.356638</b>	<b>0.001714</b>	1.35859	0.003192	1.359256	0.00347
36	<b>1.393209</b>	<b>0.001513</b>	1.396066	0.003154	1.397859	0.003853
37	<b>0.984658</b>	<b>0.000513</b>	0.989143	0.008027	0.986252	0.002255
38	<b>0.759614</b>	<b>0.00117</b>	0.765184	0.015427	0.761642	0.002352
39	<b>0.75597</b>	<b>0.001058</b>	0.760265	0.012586	0.757799	0.003082
40	<b>0.838926</b>	<b>0.000668</b>	0.840169	0.007057	0.84189	0.005286
41	<b>0.924513</b>	<b>0.000716</b>	0.927213	0.007331	0.92718	0.003881
42	<b>1.153131</b>	<b>0.001052</b>	1.155496	0.005161	1.155485	0.002304
43	<b>1.217101</b>	<b>0.001165</b>	1.220947	0.006493	1.221542	0.004354
44	<b>1.196428</b>	<b>0.001065</b>	1.201751	0.009862	1.199745	0.002207
45	<b>2.033573</b>	<b>0.004264</b>	2.06253	0.018563	2.07081	0.025702
46	<b>1.633785</b>	<b>0.002592</b>	1.644981	0.009954	1.655683	0.025572
47	<b>1.524769</b>	<b>0.001657</b>	1.535093	0.010909	1.552997	0.033933
48	<b>1.449359</b>	<b>0.0015</b>	1.464665	0.021088	1.466773	0.021983

Tabela 19 – Resultados dos algoritmos C-DEEPSO, DEEPSO and MVMO

Sc	ALGORITMOS					
	C-DEEPSO		DEEPSO		MVMO	
	Média	Desvio	Média	Desvio	Média	Desvio
49	<b>1.554853</b>	<b>0.000269</b>	1.573228	0.014294	1.593472	0.038212
50	<b>1.419097</b>	<b>0.000124</b>	1.42171	0.004049	1.429751	0.015539
51	<b>1.372646</b>	<b>0.000169</b>	1.37299	0.000638	1.379473	0.009745
52	1.280405	4.42E-05	<b>1.280345</b>	<b>3.92E-05</b>	1.280361	5.04E-05
53	<b>1.21604</b>	<b>4.49E-05</b>	1.216045	5.26E-05	1.216075	7.43E-05
54	1.257865	1.97E-05	<b>1.257835</b>	<b>2.25E-05</b>	1.257843	2.72E-05
55	1.261093	3.11E-05	<b>1.261064</b>	<b>4.58E-05</b>	<b>1.261064</b>	<b>4.53E-05</b>
56	<b>1.425905</b>	<b>0.000193</b>	1.427878	0.002874	1.435186	0.016387
57	<b>1.090003</b>	<b>0.000897</b>	1.100627	0.019237	6.477143	29.84215
58	<b>1.091811</b>	<b>0.000938</b>	1.107108	0.024072	1.12865	0.037902
59	<b>1.149323</b>	<b>0.000986</b>	1.162567	0.025166	1.18516	0.032974
60	<b>0.942244</b>	<b>0.001247</b>	0.967602	0.041148	485.9867	2700.31
61	<b>0.759047</b>	<b>0.000937</b>	0.768336	0.019544	0.764196	0.009798
62	<b>0.78431</b>	<b>0.017395</b>	0.785943	0.010336	0.788255	0.01326
63	<b>0.7726</b>	<b>0.00102</b>	0.781982	0.018497	0.779951	0.012635
64	<b>0.919392</b>	<b>0.00066</b>	0.924948	0.016801	0.923803	0.0095
65	<b>1.11818</b>	<b>0.000359</b>	1.12153	0.004301	1.12021	0.002402
66	<b>1.342056</b>	<b>0.001249</b>	1.344351	0.002214	1.344502	0.001449
67	<b>1.236404</b>	<b>0.001176</b>	1.23958	0.004837	1.239307	0.001269
68	<b>0.83218</b>	<b>0.000808</b>	0.838725	0.014454	0.834139	0.003636
69	<b>0.864326</b>	<b>0.000728</b>	0.868957	0.010561	0.865998	0.002148
70	<b>1.074571</b>	<b>0.000791</b>	1.076649	0.004521	1.075708	0.001544
71	<b>1.132337</b>	<b>0.000823</b>	1.13391	0.003072	1.134448	0.004129
72	<b>1.130509</b>	<b>0.00048</b>	1.132922	0.003447	1.132384	0.002756
73	<b>1.421856</b>	<b>0.001654</b>	1.424401	0.00346	1.42228	0.002085
74	<b>1.783861</b>	<b>0.017107</b>	1.789148	0.02496	1.783307	0.003791
75	<b>2.020105</b>	<b>0.02545</b>	75.50458	409.1587	2.022251	0.002981
76	<b>55954.25</b>	<b>273071.8</b>	1269600	5761404	2.637258	3.74E-08
77	<b>147776.7</b>	<b>416206.1</b>	923281.7	5118422	2.637258	2.50E-08
78	<b>148703.8</b>	<b>488445.5</b>	646388.5	3598924	7085.962	39438.28
79	<b>2.637259</b>	<b>4.08E-07</b>	20074.95	111757.9	2.637258	3.01E-08
80	<b>2.637258</b>	<b>1.83E-07</b>	2.637258	7.48E-08	2.637258	3.01E-08
81	<b>2.463194</b>	<b>0.004594</b>	2.47379	0.03726	2.463748	0.006993
82	<b>1.520329</b>	<b>0.001776</b>	1.522664	0.003022	1.524768	0.00223
83	<b>1.544186</b>	<b>0.001679</b>	1.546459	0.002979	1.549251	0.001964
84	<b>1.407015</b>	<b>0.00195</b>	1.409471	0.002567	1.409581	0.001261
85	<b>1.279572</b>	<b>0.001034</b>	1.282229	0.003461	1.281927	0.001248
86	<b>1.320585</b>	<b>0.001055</b>	1.323782	0.003268	1.322905	0.00182
87	<b>1.558975</b>	<b>0.001598</b>	1.560763	0.002548	1.563525	0.00138
88	<b>1.552458</b>	<b>0.001414</b>	1.554608	0.002166	1.557436	0.002001
89	<b>1.472436</b>	<b>0.00126</b>	1.47573	0.003377	1.476867	0.001657
90	<b>2.007656</b>	<b>0.001314</b>	2.011905	0.006837	2.022072	0.006272
91	<b>2.181026</b>	<b>0.000514</b>	2.192417	0.012609	2.198064	0.005255
92	<b>1.615984</b>	<b>0.001982</b>	1.617162	0.002416	1.622292	0.003239
93	<b>2.056128</b>	<b>0.001679</b>	2.064203	0.010235	2.071865	0.00516
94	<b>2.492259</b>	<b>0.004349</b>	2.516119	0.023582	2.512312	0.007086
95	<b>1.782919</b>	<b>0.001653</b>	1.784854	0.003648	1.79233	0.005024
96	<b>1.49785</b>	<b>0.001625</b>	1.500072	0.002245	1.502958	0.002782

Um teste de ANOVA foi realizado para cada caso obtendo-se o P-Valor de cada um dos 96 experimentos. O nível de significância adotado para verificar se existem diferenças estatísticas entre os algoritmos C-DEEPSO, DEEPSO e MVMO foi definido como 5%. Considerando cada cenário, se o P-valor na ANOVA for menor que 0.05, então é possível dizer que há evidência estatística suficiente para rejeitar  $H_0$ , significando que há uma diferença estatística entre as médias. Caso contrário, a diferença significativa não pode ser rejeitada. Embora a ANOVA possa determinar se há diferenças significativas entre as médias de três ou mais amostras, ela não tem uma indicação de qual grupo é diferente. Uma técnica de comparação emparelhada simples, conhecida como Teste de Tukey ou Diferença Honestamente Significativa (HSD), pode ser usada para identificar médias que são diferentes de outras (ABDI; WILLIAM, 2010).

As Tabelas 20 e 21 mostram os resultados de P-Valor obtidos para cada cenário usando ANOVA e uma classificação dada a partir do resultado informado pelo teste de Tukey, quando necessário. Os resultados mostram que em 17 dos 96 cenários, ou em 17,7% dos casos, uma vez que o P-Valor é maior que 0.05, pode-se dizer que os algoritmos têm o mesmo desempenho para resolver o problema. Entretanto, em 79 dos 96 cenários, ou em 82,3% dos cenários, a ANOVA foi capaz de identificar que existem diferenças estatísticas entre as médias dos algoritmos. Nesses casos, o teste de Tukey foi realizado para classificar os algoritmos de forma a *post hoc*. Os resultados que não indicaram diferença estatística entre as médias estão sinalizados nas referidas tabelas como (-).

Como resultado final, após a aplicação da ANOVA e Teste de Tukey, em 60.4% dos cenários C-DEEPSO foi classificado na primeira posição quando comparado a DEEPSO e MVMO. Em 18.8% dos cenários, C-DEEPSO se manteve na primeira posição com outro algoritmo. Em 3.1% dos cenários, C-DEEPSO é classificado na terceira posição, sendo pior do que os outros algoritmos. Vale ressaltar que, em 79.2% dos cenários, C-DEEPSO obteve desempenho melhor ou igual ao algoritmo de estado da arte MVMO. Pode-se verificar que C-DEEPSO é um algoritmo competitivo, capaz de realizar um controle ótimo da operação de um WPP do despacho diário, minimizando as perdas de transmissão e assegurando o ajuste de todas as variáveis para atender aos requisitos de potência reativa no ponto de acoplamento comum (PCC, do termo inglês *Point of Common Coupling*).

Tabela 20 – Resultados da ANOVA e do Teste de Tukey.

Sc	P-value	CLASSIFICAÇÃO		
		1º	2º	3º
1	1.20E-03	C-DEEPSO	DEEPSO; MVMO	-
2	5.93E-07	C-DEEPSO	DEEPSO	-
3	1.11E-02	C-DEEPSO	DEEPSO; MVMO	-
4	1.00E-04	C-DEEPSO	DEEPSO	-
5	2.00E-04	C-DEEPSO	DEEPSO; MVMO	-
6	2.15E-14	C-DEEPSO; DEEPSO	MVMO	-
7	1.06E-06	C-DEEPSO	DEEPSO; MVMO	-
8	1.36E-12	C-DEEPSO	DEEPSO; MVMO	-
9	4.88E-09	C-DEEPSO	DEEPSO; MVMO	-
10	8.54E-09	C-DEEPSO	DEEPSO; MVMO	-
11	2.60E-03	C-DEEPSO; DEEPSO	MVMO	-
12	8.60E-08	C-DEEPSO	DEEPSO	MVMO
13	1.70E-10	C-DEEPSO	DEEPSO	MVMO
14	2.16E-11	C-DEEPSO	DEEPSO; MVMO	-
15	2.88E-12	C-DEEPSO	DEEPSO; MVMO	-
16	6.49E-14	C-DEEPSO	DEEPSO; MVMO	-
17	9.87E-22	C-DEEPSO	DEEPSO; MVMO	-
18	3.07E-21	C-DEEPSO	DEEPSO; MVMO	-
19	3.50E-21	C-DEEPSO	DEEPSO; MVMO	-
20	1.28E-22	C-DEEPSO	DEEPSO; MVMO	-
21	3.12E-20	C-DEEPSO	DEEPSO; MVMO	-
22	1.95E-27	C-DEEPSO	MVMO	DEEPSO
23	3.19E-21	C-DEEPSO	MVMO	DEEPSO
24	1.57E-23	C-DEEPSO	DEEPSO; MVMO	-
25	1.52E-09	C-DEEPSO	DEEPSO; MVMO	-
26	1.02E-15	C-DEEPSO	DEEPSO; MVMO	-
27	4.39E-12	C-DEEPSO	DEEPSO; MVMO	-
28	5.32E-09	C-DEEPSO	DEEPSO; MVMO	-
29	5.38E-11	C-DEEPSO	DEEPSO; MVMO	-
30	2.05E-14	C-DEEPSO	DEEPSO; MVMO	-
31	3.26E-06	C-DEEPSO	DEEPSO; MVMO	-
32	4.77E-05	C-DEEPSO	DEEPSO; MVMO	-
33	6.49E-06	C-DEEPSO	DEEPSO; MVMO	-
34	2.44E-05	C-DEEPSO	DEEPSO; MVMO	-
35	1.70E-03	C-DEEPSO	DEEPSO. MVMO	-
36	1.42E-07	C-DEEPSO	DEEPSO	MVMO
37	1.60E-03	C-DEEPSO; MVMO	DEEPSO	-
38	<b>0.0539*</b>	-	-	-
39	<b>0.0832*</b>	-	-	-
40	<b>0.0773*</b>	-	-	-
41	<b>0.0543*</b>	-	-	-
42	7.20E-03	C-DEEPSO	DEEPSO; MVMO	-
43	4.00E-04	C-DEEPSO	DEEPSO; MVMO	-
44	2.30E-03	C-DEEPSO	DEEPSO; MVMO	-
45	6.59E-12	C-DEEPSO	DEEPSO; MVMO	-
46	3.04E-06	C-DEEPSO	DEEPSO	MVMO
47	2.57E-06	C-DEEPSO; DEEPSO	MVMO	-
48	3.00E-04	C-DEEPSO	DEEPSO; MVMO	-

Tabela 21 – Resultado da ANOVA e do Teste de Tukey.

Sc	P-value	CLASSIFICAÇÃO		
		1º	2º	3º
49	3.63E-08	C-DEEPSO	DEEPSO	MVMO
50	4.84E-05	C-DEEPSO; DEEPSO	MVMO	-
51	3.69E-06	C-DEEPSO; DEEPSO	MVMO	-
52	2.96E-06	DEEPSO; MVMO	C-DEEPSO	-
53	<b>0.0543*</b>	-	-	-
54	5.02E-06	DEEPSO; MVMO	C-DEEPSO	-
55	7.20E-03	DEEPSO; MVMO	C-DEEPSO	-
56	6.00E-04	C-DEEPSO; DEEPSO	MVMO	-
57	<b>0.3689*</b>	-	-	-
58	1.32E-06	C-DEEPSO; DEEPSO	MVMO	-
59	3.20E-07	C-DEEPSO; DEEPSO	MVMO	-
60	<b>0.3719*</b>	-	-	-
61	1.79E-03	C-DEEPSO; MVMO	DEEPSO	-
62	<b>0.5379*</b>	-	-	-
63	1.36E-02	C-DEEPSO; MVMO	DEEPSO	-
64	<b>0.1229*</b>	-	-	-
65	5.98E-05	C-DEEPSO	DEEPSO; MVMO	-
66	4.89E-08	C-DEEPSO	DEEPSO; MVMO	-
67	5.70E-05	C-DEEPSO	DEEPSO; MVMO	-
68	1.13E-02	C-DEEPSO; MVMO	DEEPSO	-
69	1.53E-02	C-DEEPSO; MVMO	DEEPSO	-
70	1.66E-02	C-DEEPSO; MVMO	DEEPSO	-
71	1.94E-02	C-DEEPSO; DEEPSO	MVMO	-
72	9.00E-04	C-DEEPSO	DEEPSO; MVMO	-
73	3.00E-04	C-DEEPSO; MVMO	DEEPSO	-
74	<b>0.3578*</b>	-	-	-
75	<b>0.3721*</b>	-	-	-
76	<b>0.2426*</b>	-	-	-
77	<b>0.5235*</b>	-	-	-
78	<b>0.5544*</b>	-	-	-
79	<b>0.3719*</b>	-	-	-
80	<b>0.7213*</b>	-	-	-
81	<b>0.1093*</b>	-	-	-
82	8.56E-10	C-DEEPSO	DEEPSO	MVMO
83	8.35E-13	C-DEEPSO	DEEPSO	MVMO
84	8.83E-07	C-DEEPSO	DEEPSO; MVMO	-
85	7.61E-06	C-DEEPSO	DEEPSO; MVMO	-
86	6.33E-70	C-DEEPSO	DEEPSO; MVMO	-
87	3.40E-14	C-DEEPSO	DEEPSO	MVMO
88	3.56E-16	C-DEEPSO	DEEPSO	MVMO
89	4.82E-11	C-DEEPSO	DEEPSO; MVMO	-
90	6.21E-17	C-DEEPSO	DEEPSO	MVMO
91	1.44E-12	C-DEEPSO	DEEPSO	MVMO
92	1.15E-15	C-DEEPSO; DEEPSO	MVMO	-
93	8.16E-14	C-DEEPSO	DEEPSO	MVMO
94	3.32E-09	C-DEEPSO	DEEPSO; MVMO	-
95	1.86E-16	C-DEEPSO; DEEPSO	MVMO	-
96	4.75E-13	C-DEEPSO	DEEPSO	MVMO

## 6.2.2 Sistemas IEEE de 57, 118 e 300 barras

Para avaliar o desempenho do algoritmo hC-DEEPSO na solução de problemas SCOPF, foram realizados dois experimentos. O primeiro executou um ajuste fino de parâmetros para o algoritmo hC-DEEPSO, com relação às taxas de mutação e comunicação utilizadas por ele. O segundo experimento consistiu em comparar os resultados obtidos pelo hC-DEEPSO, nos melhores parâmetros encontrados pelo ajuste realizado, com três algoritmos disponíveis na literatura: DEEPSO, ICDE e MVMO que segundo (ERLICH et al., 2014b) foram executados em seus melhores parâmetros.

### 6.2.2.1 Ajuste de Parâmetros Estratégicos

A Metodologia de Superfície de Resposta foi escolhida como a configuração experimental para realizar o ajuste fino dos parâmetros. Esta metodologia é uma coleção de técnicas matemáticas e estatísticas que são úteis para modelagem e análise em aplicações em que a variável de saída é influenciada por muitas variáveis e o objetivo é otimizar essa variável de saída (MONTGOMERY, 2012). Usando um planejamento específico de experimentos, o objetivo foi otimizar a resposta (variável de saída) do algoritmo hC-DEEPSO que, neste trabalho, é influenciado por duas variáveis de entrada que foram tratadas: a taxa de mutação e a probabilidade de comunicação.

Fazendo algumas mudanças na taxa de mutação e na probabilidade de comunicação, é possível identificar as mudanças correspondentes na resposta de saída. Nesse caso, cada resposta de saída corresponde a cada função objetivo em relação à minimização das perdas totais do sistema e ao custo total de produção. Cada função objetivo  $f$  então é uma função dos níveis de mutação ( $\tau$ ) e comunicação ( $P$ ). A resposta esperada pela função  $f(\tau, P)$  pode ser representada graficamente por uma função tridimensional do espaço e é chamada de superfície de resposta. O objetivo é encontrar os melhores valores de parâmetros,  $\tau$  e  $P$ , que minimizam cada função objetivo, em cada sistema de teste. O algoritmo hC-DEEPSO foi aplicado para resolver os problemas SCOPF descritos na Seção 4.3. Em cada um dos casos de teste de ORDP e OARDP, os Sistemas IEEE de 57, 118 e 300 barras foram executados 31 vezes. Este número de execuções foi definido para comparar os resultados de hC-DEEPSO com os obtidos pelos algoritmos DEEPSO, ICDE e MVMO que estão disponíveis em (ERLICH et al., 2014a), (PES, 2014).

Para construir um modelo de aproximação que captura a interação entre essas variáveis de entrada,  $\tau$  e  $P$ , é necessário um experimento fatorial (MONTGOMERY, 2012). Em palavras simples, em um experimento fatorial as variáveis de entrada são variadas ao mesmo tempo em vez de uma por vez. Os limites inferior e superior para as taxas de mutação e comunicação foram empiricamente ajustados para [0,2, 0,9]. Cada variável de entrada é definida somente nos limites de nível superior e inferior em cada discretização da faixa predefinida, com variação de 0.1. No total, hC-DEEPSO foi executado 1984 vezes para

cada sistema de teste (84 combinações  $\times$  31 execuções). Usando os valores da variável de entrada e o valor correspondente para cada função objetivo e cenário de teste no SCOPF, um modelo de segunda ordem para a superfície de resposta pode ser ajustado. Todas as execuções foram executadas em um Cluster Cent-OS composto por 32 núcleos Intel Xeon E5-1650 3.5GHz e 32GB de memória RAM. O critério de parada estabelecido foi o número máximo de avaliações de função, critério este definido nas regras da competição cujos algoritmos DEEPSO e ICDE participaram em 2014 (veja (PES, 2014)). Os demais parâmetros de inicialização foram escolhidos empiricamente e são mostrados na Tabela 22.

Tabela 22 – Parâmetros de inicialização do algoritmo hC-DEEPSO

Parâmetros	Sistemas IEEE de barras					
	57 <sub>1</sub>	57 <sub>2</sub>	118 <sub>1</sub>	118 <sub>2</sub>	300 <sub>1</sub>	300 <sub>2</sub>
$NP$	60	80	80	140	150	200
$MB$	6	8	8	14	15	20
$N_{gl}$	10	10	10	10	10	10
$\gamma$	0.5	0.5	0.5	0.5	0.5	0.5
Máx.Aval.	$5 \times 10^3$		$1 \times 10^5$		$3 \times 10^5$	

A Figura 33 mostra as superfícies de resposta, e suas correspondentes curvas de nível, obtidas usando os valores médios e de melhor solução encontrados no problema ORDP - Sistema IEEE de 57 barras. Pode-se observar que o melhor conjunto de parâmetros obtidos para a mutação e comunicação foi  $[\tau, P] = [0.6, 0.2]$  com um resultado médio de perdas de potência ativa totais igual a  $24.7286MW$ . Além disso, usando a superfície de resposta gerada por meio das melhores soluções encontradas, o conjunto de parâmetros  $[\tau, P] = [0.4, 0.3]$  se mostrou melhor, resultando em uma perda de potência total de  $24.606MW$ .

Da mesma forma, hC-DEEPSO foi usado para resolver problemas OARDP, cujo objetivo é minimizar o custo total da produção de energia. A Figura 34 mostra as superfícies de resposta e suas correspondentes curvas de nível obtidas usando os valores médios e melhor solução encontrados no problema OARDP para Sistema IEEE de 57 barras. Pode-se observar que o melhor conjunto de parâmetros obtidos para a mutação e comunicação foi  $[\tau, P] = [0.9, 0.7]$  com um valor médio do custo total de produção de energia igual a  $41691.50$   $\$/h$ . Observando a superfície gerada por meio das melhores soluções encontradas, o conjunto de parâmetros  $[\tau, P] = [0.3, 0.3]$  se mostrou melhor, resultando em um custo total de produção de energia de  $41686.9$   $\$/h$ .

A metodologia foi aplicada aos Sistemas IEEE de 118 e 300 barras, no problema ORDP. Em ambos sistemas, as superfícies de resposta e os gráficos de curva de nível correspondentes foram gerados usando os valores médios e as melhores soluções obtidas. A Figura 35 mostra os resultados do ORPD no Sistema IEEE de 118 barras. A melhor configuração foi  $[\tau, P] = [0.9, 0.4]$  para um resultado médio de  $117.9MW$  em relação ao total de perdas de energia e, ao usar as melhores soluções,  $[\tau, P] = [0.6, 0.4]$ , o resultado para o total de perdas de potência ativa foi igual a  $117.4MW$ . O conjunto de parâmetros utilizado para OARDP no Sistema IEEE de 118 barras foi  $[\tau, P] = [0.7, 0.2]$  resultando em

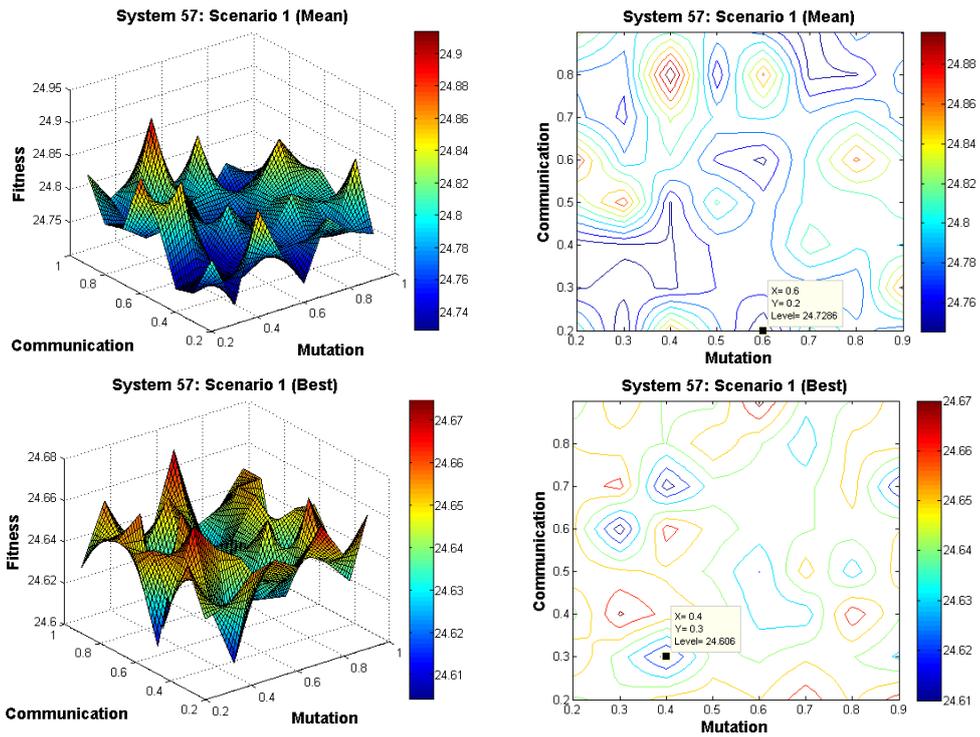


Figura 33 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 57 barras no problema ORPD.

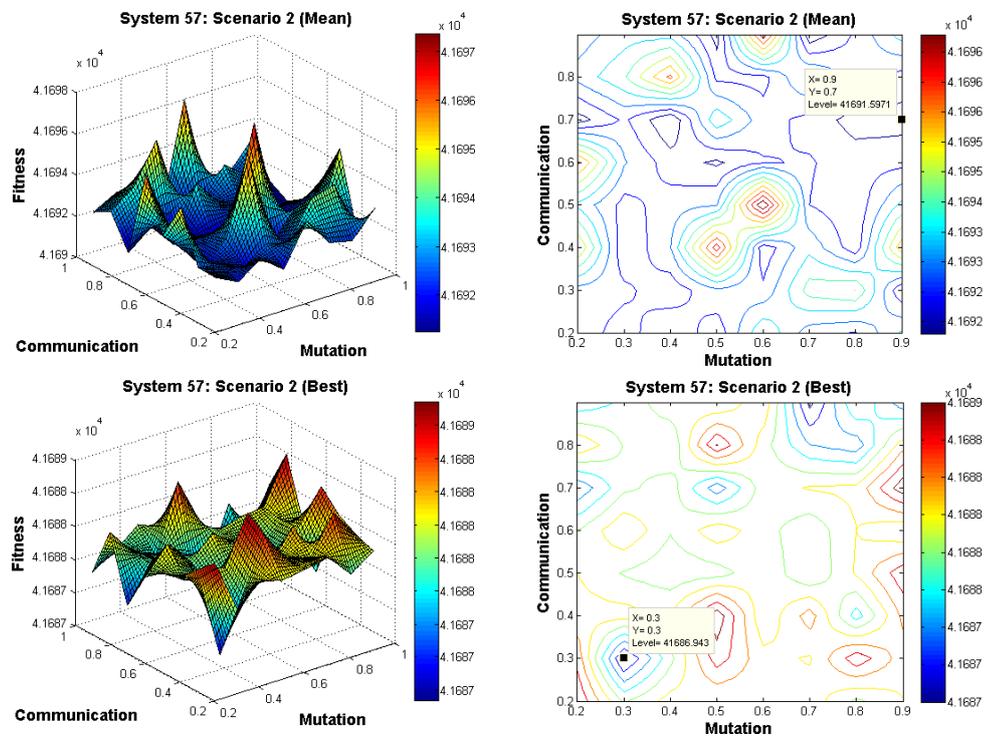


Figura 34 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 57 barras no problema OARPD.

135560.03 \$/h para o custo total da produção de energia.

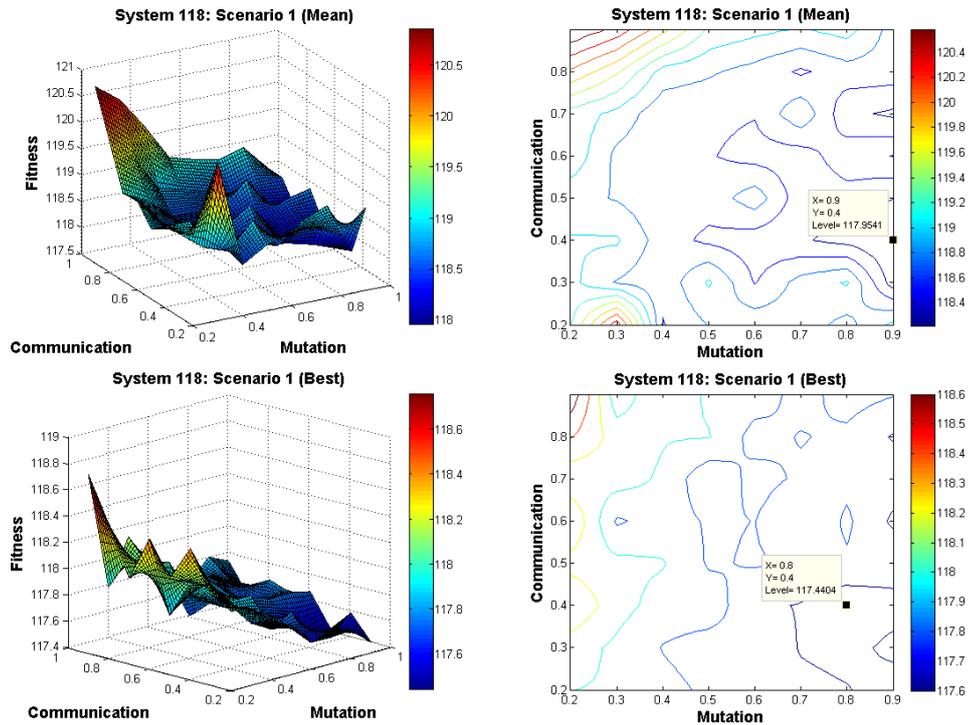


Figura 35 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 118 barras no problema ORPD

A Figura 36 mostra as superfícies de resposta e suas correspondentes curvas de nível, obtidas usando os valores médios e melhor solução encontrados no problema ORDP - Sistema IEEE de 300 barras. Pode-se observar que o melhor conjunto de parâmetros obtidos para mutação e comunicação foi  $[\tau, P] = [0.8, 0.3]$  com um valor médio de perda de potência ativa igual a 394.048 MW. Além disso, usando a superfície de resposta gerada observando as melhores soluções obtidas, o melhor conjunto de parâmetros foi  $[\tau, P] = [0.9, 0.6]$ , resultando em uma perda de potência ativa de 387.09 MW. O conjunto de parâmetros utilizado para OARDP no Sistema IEEE de 300 barras foi  $[\tau, P] = [0.7, 0.2]$  resultando em 722160.00 \$/h do custo total de produção de energia.

#### 6.2.2.2 Análise de Desempenho

Depois de obter a melhor configuração de parâmetros,  $\tau$  e  $P$ , para hC-DEEPSO, na solução dos problemas ORDP e OARDP nos sistemas de teste considerados, foi realizada uma análise de desempenho, comparando os resultados obtidos, com resultados de outros algoritmos estado da arte na solução destes problemas. Para esta tarefa, três diferentes algoritmos, DEEPSO, ICDE e MVMO, fizeram parte desta comparação. Estes algoritmos solucionaram os problemas SCOPF tratados neste trabalho e seus resultados foram extraí-

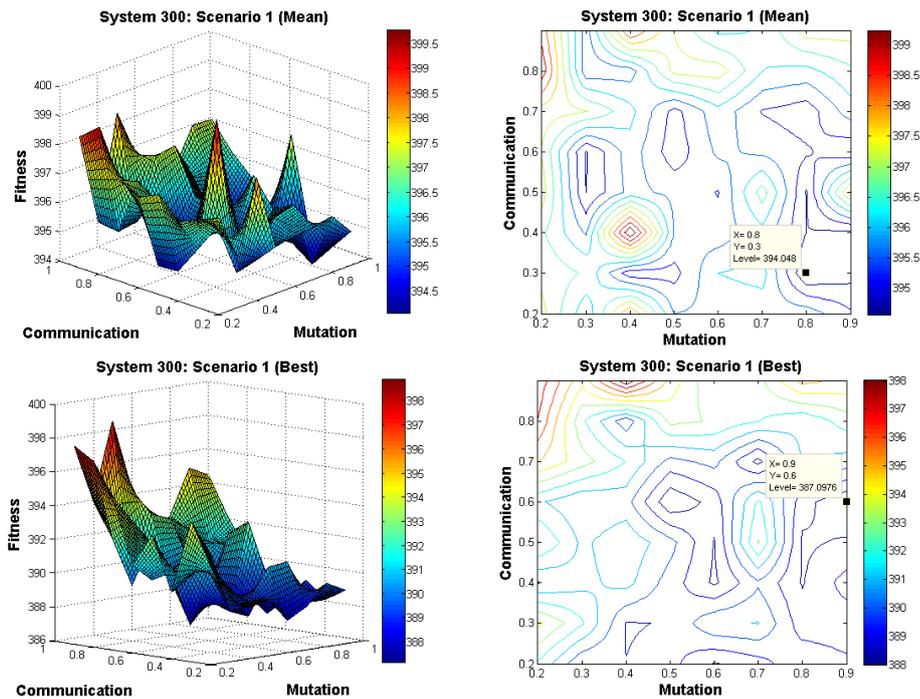


Figura 36 – Superfícies de resposta, e seus correspondentes gráficos de curva de nível, obtidos usando os valores médios e melhor solução para o Sistema IEEE de 300 barras no problema ORPD.

dos de *Competition on Application of Modern Heuristic optimization algorithms for solving optimal power flow problems* (ERLICH et al., 2014b).

A competição representa uma iniciativa para o desenvolvimento de novas propostas para otimização do fluxo de potência, fornecendo alguma análise comparativa, no campo da otimização heurística. Embora MVMO não fosse um algoritmo participante, foi utilizado para produzir resultados de referência para comparações. Vale a pena notar que a DEEPSO foi o vencedor desta competição. Os demais algoritmos participantes desta competição não foram considerados na comparação, pois eles violaram as restrições do problema ao utilizarem mecanismos para o tratamento de variáveis inteira e binárias. Todos os algoritmos trataram as restrições do problema via penalidade na função de avaliação adotada no arquivo criptado.

A Tabela 23 mostra os resultados dos três algoritmos usados para resolver problemas de SCOPF (ERLICH et al., 2014b) incluindo os resultados obtidos por hC-DEEPSO. Os valores médios e o desvio padrão, para todas as execuções, são mostrados e, sendo um problema de minimização, valores médios inferiores são preferíveis aos superiores. Os melhores valores de média e desvio padrão são marcados em negrito. Em uma análise simplista, hC-DEEPSO apresenta melhores resultados do que os algoritmos DEEPSO e ICDE, quando comparados em termos de valores médios em todos os três cenários de teste para o problema ORDP.

Tabela 23 – Valores médios e de desvio padrão para hC-DEEPSO, DEEPSO, ICDE e MVMO (os três últimos extraídos de (ERLICH et al., 2014b)) em problemas de ORPD e OARDP usando os três cenários de teste.

Algoritmo	ORDP		OARDP	
	Média	Desvio	Média	Desvio
IEEE de 57 barras				
hC-DEEPSO	<b>24.7286</b>	<b>0.1064</b>	<b>41692.4521</b>	<b>2.804</b>
DEEPSO	25.5725	0.4125	41697.58	7.9393
ICDE	25.0414	0.42956	41739.81	27.6884
MVMO	24.8172	0.12504	41707.6893	10.5581
IEEE de 118 barras				
hC-DEEPSO	<b>117.9541</b>	<b>0.3048</b>	135560.03	320
DEEPSO	119.2799	1.7131	135890.716	221.991
ICDE	128.3549	2.4535	154234.873	12324.2502
MVMO	117.862	0.42379	<b>135050.21</b>	<b>27.5014</b>
IEEE de 300 barras				
hC-DEEPSO	<b>394.0480</b>	<b>3.8037</b>	<b>722160.00</b>	<b>533.3307</b>
DEEPSO	414.6239	42.0460	724041.13	2669.9100
ICDE	8669.8730	15255.7100	740013.64	6205.4528
MVMO	394.1294	8.2219	722323.24	869.3588

O mesmo pode ser visto para o problema OARDP, exceto o Sistema IEEE de 118 barras. Neste caso, MVMO possui um melhor resultado médio quando comparado com hC-DEEPSO. Uma comparação feita exclusivamente com valores de média e desvio padrão não diz nada sobre a significância estatística desses resultados. Para avaliar os resultados com significância, é necessário realizar uma inferência estatística sobre a diferença entre cada par de valores médios. Um T-test (MONTGOMERY, 2012) pode ser executado para comparar mais efetivamente os resultados obtidos.

Este teste pode ser usado quando se deseja comparar resultados de amostras de população numa base "dois a dois". A hipótese nula adotada neste trabalho é a igualdade das médias, portanto o experimento é projetado para detectar se essa hipótese é rejeitada ou não usando um valor de significância  $\alpha = 5\%$ . Se a hipótese nula for rejeitada, uma comparação *post hoc* pode ser feita para determinar qual é o melhor algoritmo. As Tabelas 24 e 25 mostram os resultados do T-test e os resultados após a comparação *post hoc* para problemas ORDP e OARDP, respectivamente. Valores em branco significam que a comparação *post hoc* não é capaz de detectar qualquer diferença estatística entre os algoritmos.

Analisando os resultados do problema ORDP, o T-test indicou que, com 95% de confiança, o hC-DEEPSO apresenta melhores resultados em comparação com DEEPSO, ICDE e MVMO no Sistema IEEE de 57 barras. Para o Sistema IEEE de 118 barras e os cenários do Sistema IEEE de 300 barras, o hC-DEEPSO é melhor que o DEEPSO e o ICDE. No entanto, o teste estatístico não foi capaz de detectar qualquer diferença entre hC-DEEPSO e MVMO.

Verificando os resultados do problema OARDP, o T-test indicou que, com 95% de confiança, o hC-DEEPSO apresenta melhores resultados em comparação com DEEPSO, ICDE e MVMO no Sistema IEEE de 57 barras. Para o Sistema IEEE de 118 barras e os

Tabela 24 – Comparação de resultados usando T-test em uma avaliação *post hoc* nos problemas ORDP.

ORDP				
IEEE de 57 barras	T-test	P-value	Ação	Vencedor
hC-DEEPSO x DEEPSO	11.0296	4.44E-16	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	3.9354	2.18E-04	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	3.0046	3.87E-04	rejeitar	hC-DEEPSO
IEEE de 118 barras	T-test	P-value	Ação	Vencedor
hC-DEEPSO x DEEPSO	4.2424	2.77E-05	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	23.4226	00E+00	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	0.9823	0.329	não rejeitar	-
IEEE de 300 barras	T-test	P-value	Ação	Vencedor
hC-DEEPSO x DEEPSO	2.7136	8.67E-03	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	3.0204	3.70E-03	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	0.0500	0.960	não rejeitar	-

Tabela 25 – Comparação de resultados usando T-test em uma avaliação *post hoc* nos problemas OARDP.

OARDP				
IEEE de 57 barras	T-test	P-Valor	Ação	Vencedor
hC-DEEPSO x DEEPSO	3.3909	1.23E-03	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	9.4746	1.58E-13	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	7.7661	1.22E-10	rejeitar	hC-DEEPSO
IEEE de 118 barras	T-test	P-Valor	Ação	Vencedor
hC-DEEPSO x DEEPSO	8.2927	1.55E-11	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	8.4339	8.94E-12	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	8.8379	1.85E-12	rejeitar	MVMO
IEEE de 300 barras	T-test	P-Value	Ação	Vencedor
hC-DEEPSO x DEEPSO	3.8469	2.92E-04	rejeitar	hC-DEEPSO
hC-DEEPSO x ICDE	15.9601	00E+00	rejeitar	hC-DEEPSO
hC-DEEPSO x MVMO	0.8911	0.3764	não rejeitar	-

cenários do Sistema IEEE de 300 barras, o hC-DEEPSO é melhor que o DEEPSO e o ICDE. No entanto, MVMO é melhor do que hC-DEEPSO no Sistema IEEE de 118 barras entretanto o teste estatístico não é capaz de detectar qualquer diferença entre hC-DEEPSO e MVMO no Sistema IEEE de 300 barras.

### 6.3 Otimização em um Sistema *Microgrid* Híbrido

O objetivo da otimização nos HMGS é reduzir COE e LPSP, ajustando a produção de energia horária da rede pública e BESS em termos de carga, PV e geração de energia eólica. Além disso, busca-se encontrar a composição ótima em termos de capacidade instalada de componentes no HMGS. Um experimento foi realizado com o uso de uma bateria genérica (eficiência = 85%, tempo de vida = 12 anos, custo inicial da célula = 280 \$/kWh, potência nominal = 200 kWh) para verificar o desempenho dos algoritmos C-DEEPSO e PSO. Cada vetor solução possui 4 dimensões com limites inferior e superior de potência nominal do PV igual à, [10, 150] kW; Autonomia [1,3], número de turbinas eólicas [1,10], número de casas[1,100]. Os parâmetros empíricos de inicialização de cada algoritmo são dados na Tabela 26. Demais parâmetros utilizados foram: tamanho da população (NP = 50), gerações

( $t = 30$ ) e dimensões ( $D = 4$ ) e são utilizados os mesmos em ambos os algoritmos.

Tabela 26 – Parâmetros de inicialização dos algoritmos.

	$c1$	$c2$	$w_{pso}$	$\tau$	$P$	$F$	$MB$
PSO	[0,2]	[0,2]	[0,1]	-	-	-	-
C-DEEPSO	-	-	-	0.9	0.5	[0,2]	10%

Os algoritmos PSO e C-DEEPSO foram executados por 30 vezes. O resultado médio de COE e os respectivos desvios obtidos pelos algoritmos C-DEEPSO e PSO foram (0.3303, 0.0053)  $\$/kWh$  e (0.3572, 0.0741)  $\$/kWh$ , respectivamente. Foi realizado um T-test para avaliar se haviam diferenças estatísticas entre os algoritmos PSO e C-DEEPSO com  $\alpha = 5\%$  de significância.

A resposta do teste a partir do P-Valor calculado de 0.04843, indica que o T-test rejeita a hipótese nula com 95% de confiança. C-DEEPSO apresenta melhores valores médios, conforme indicado pelo teste realizado. Para legitimar visualmente esse resultado, a Figura 37 mostra um histograma do teste de permutação descrito em (MARCELINO; WANNER; ALMEIDA, 2014). Esse teste confirma que o valor médio representado pela diferença média (“ponto negro”) está fora do limiar de confiança testado, indicando que os conjuntos de dados são diferentes. Assim, o algoritmo C-DEEPSO pode ser considerado como uma melhor abordagem para resolver o problema relacionado ao modelo HMGS, pois apresenta menor média de resultados quando comparado ao algoritmo PSO.

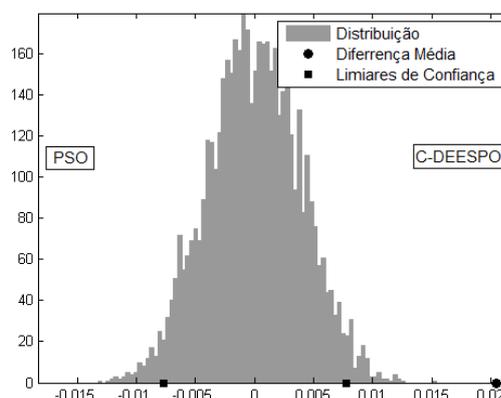


Figura 37 – Histograma do Teste de Permutação em que os algoritmos PSO e C-DEEPSO são comparados. O resultado indica com 95% de confiança que existem diferenças entre as médias apresentadas pelos algoritmos, já que o ponto observado está fora dos limiaries de confiança.

### 6.3.1 Uma análise de solução obtida via C-DEEPSO

A partir da solução obtida via C-DEEPSO com uso da bateria genérica, discutida na Seção 6.3, uma análise do comportamento do HMGS foi realizada. A geração de energia

produzida nos períodos de verão e inverno, podem ser observadas pela visualização dos gráficos presentes nas Figuras ?? e ??, respectivamente. Estes gráficos fornecem uma visão geral da operação HMGS como resultado da otimização C-DEEPSO. Pode ser observado como o BESS é carregado e descarregado pelo menos uma vez durante o período de teste representado.

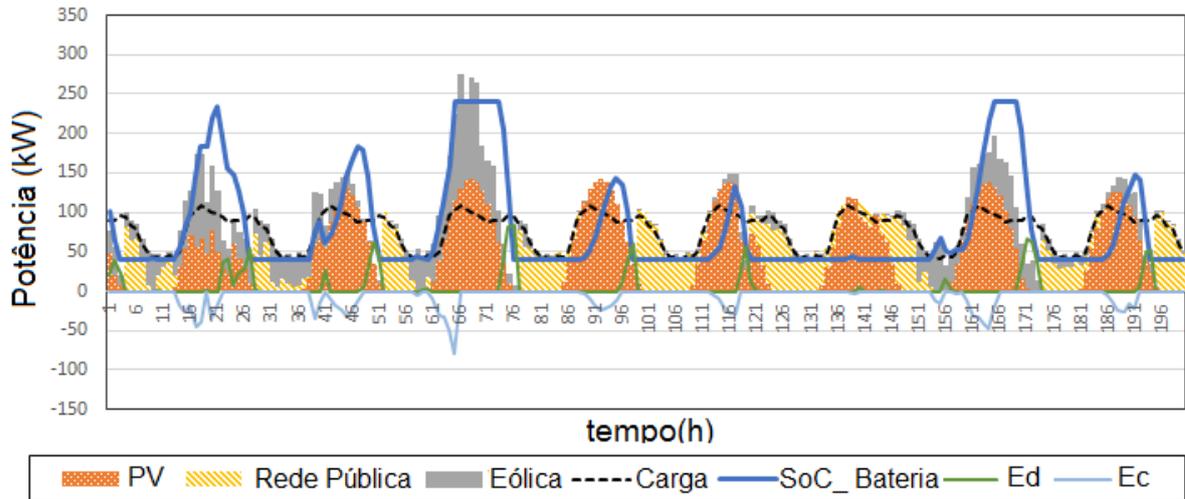


Figura 38 – Exemplo da operação do sistema para o verão - Dados de entrada: vento, radiação solar e carga.

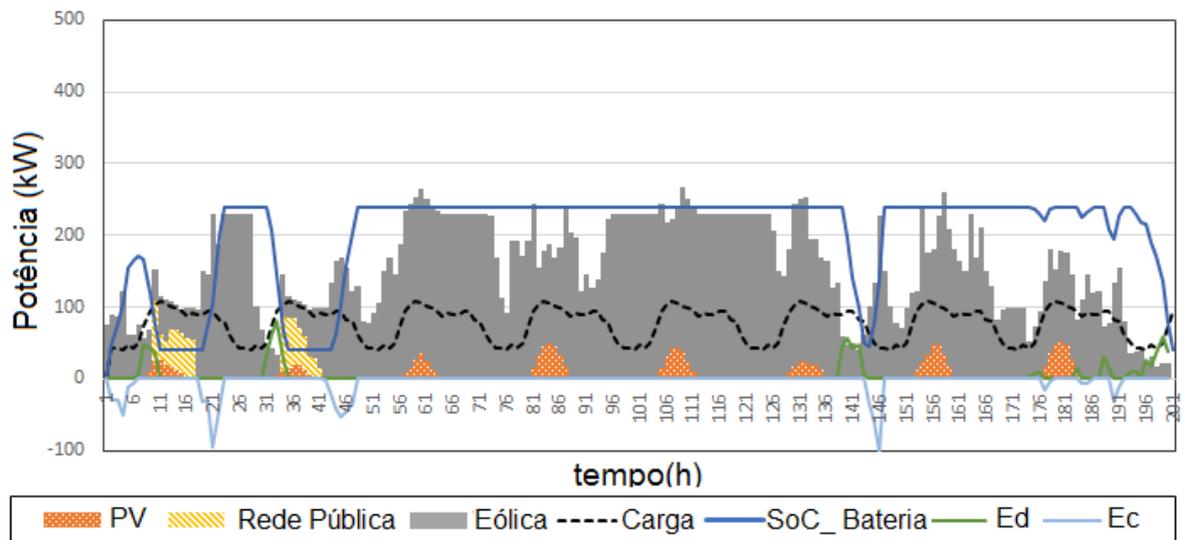


Figura 39 – Exemplo da operação do sistema para o inverno - Dados de entrada: vento, radiação solar e carga.

O HMGS consome energia elétrica da rede pública quando não há energia disponível em PV, Eólica ou BESS. É possível ser verificado que a contribuição do PV ultrapassa a carga no verão. O mesmo acontece com a energia eólica no inverno, onde as velocidades

do vento podem se tornar muito altas. Isto leva a uma situação inversa em relação ao fornecimento de energia eólica e PV. A partir desta situação resulta um claro aumento do excedente de RES no período do inverno. A geração total de energia anual resultantes fornecidas por PV, Eólica, BESS, energia excedente e a obtida via rede pública ao longo de um ano estão ilustradas na Figura 40.

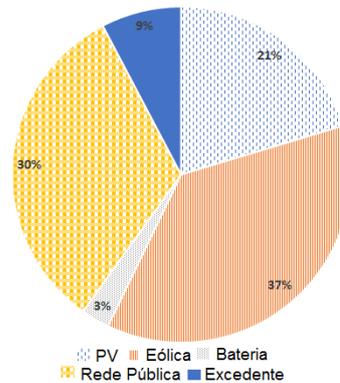


Figura 40 – Parcela anual total de geração: eólica, radiação solar, excedente e rede pública.

O HMGS pode ser operado ao menor custo de 0.33 \$/kWh de forma que 61% da energia demandada é fornecida por fontes renováveis, incluindo a participação de 3% do BESS. É, contudo, necessário utilizar a rede pública que contribui com uma quota de energia de 30% para assegurar um abastecimento de eletricidade seguro para a comunidade. O excedente de 9% indica a quantidade de energia renovável que não pode ser utilizada na rede. Geralmente, a ocorrência de excedente é gerada quando as fontes renováveis já estão atendendo a demanda e o BESS estar totalmente carregado. Um próximo passo na melhoria do modelo HMGS apresentado é, portanto, incluir uma forma de realizar a compensação de energia entre o HMGS e o provedor da rede pública. Os resultados do sistema otimizado para PV, Eólica, rede pública e excedente da geração produzida/alcançada por C-DEEPSO são mostrados nas Figuras 41 e 42.

Os gráficos de PV e Eólica na Figura 41 (a,b) apresentam uma curva de tendência obtida pelo cálculo da média móvel para uma semana que ajudam a análise visual. Como esperado, há uma maior produção de energia solar no período de verão, com um máximo de 140 kW e uma taxa de geração mais alta de energia eólica no outono/inverno (capacidade máxima de turbinas instaladas com 240 kW). A dispersão da geração eólica é maior devido às correntes de ar que podem ter ocorrido durante o ano na região estudada.

A eletricidade a partir da rede pública só é utilizada no modelo HMGS quando a demanda não pode ser atendida por fontes renováveis e armazenamento de bateria como ilustrado na Figura 42(c) (média flutuante entre 20 a 60 kW). O excesso de energia está representado na Figura 42(d). Em relação à energia gerada por fontes renováveis (e não utilizada), pode-se considerar que o sistema HMGS obteve uma baixa taxa de ocorrência de excedente.

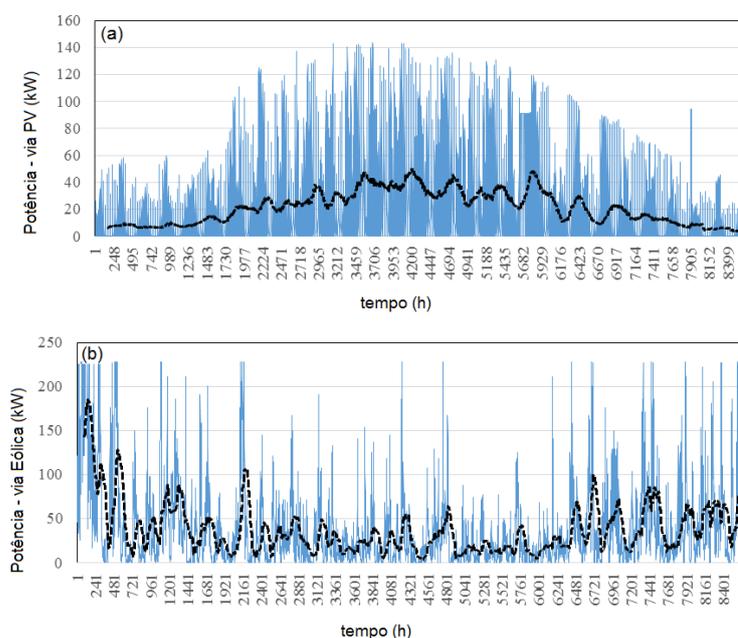


Figura 41 – Geração de eletricidade por hora (h)/ano para o modelo HMGS via otimização realizada pelo algoritmo C-DEEPSO.

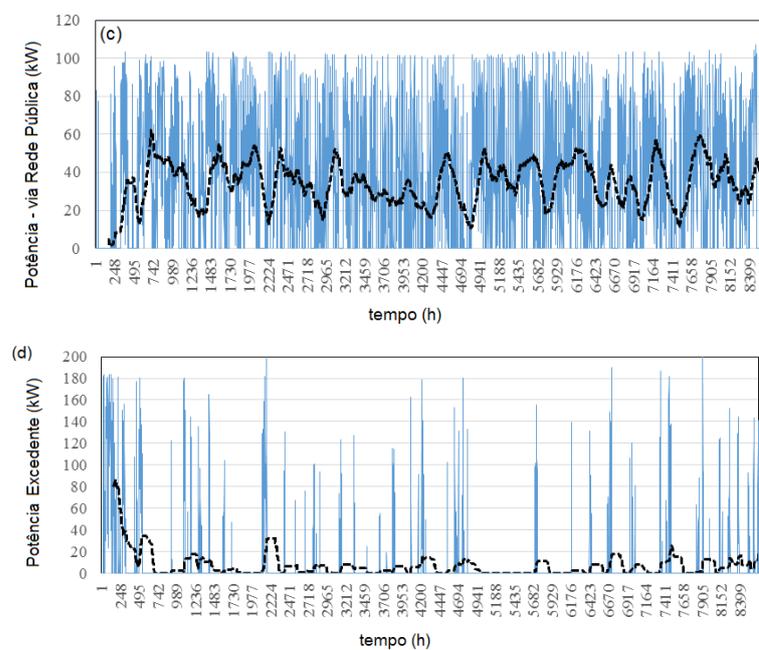


Figura 42 – Geração de eletricidade por hora (h)/ano para o modelo HMGS via otimização realizada pelo algoritmo C-DEEPSO.

### 6.3.2 Avaliação BESS com uso de AHP+TOPSIS

O algoritmo C-DEEPSO foi executado 30 vezes usando os parâmetros de inicialização já apresentados pela Tabela 26 para otimizar o HMGS com diferentes baterias. A Tabela 27 mostra os valores médios calculados e seus desvios para RS-factor e COE para cada bateria testada. O LPSP permaneceu muito baixo para todas as tecnologias de bateria, conforme descrito na Tabela 27.

Tabela 27 – Resultados de otimização obtido para cada BESS

	COE (\$/kWh)	LPSP (%)	RS-factor (%)
VRLA	(0.3139, 0.0029)	(0.0247, 0.0007)	(0.6297, 0.0081)
LFP	(0.3070, 0.0027)	(0.0255, 0.0014)	(0.6343, 0.0130)
NCA	(0.3139, 0.0031)	(0.0247, 0.0013)	(0.6332, 0.0147)
NaNiCl	(0.3066, 0.0014)	(0.0256, 0.0009)	(0.6321, 0.0108)
NaS	(0.3125, 0.0018)	(0.0253, 0.0007)	(0.6318, 0.0129)

Os resultados do processo de otimização foram utilizados como entrada para a MCDA. Para realização da tomada de decisão, 5 especialistas da área foram consultados. O grupo de especialistas foi formado por 3 profissionais acadêmicos (de 2 distintos centros de pesquisa alemães) e 2 especialistas de uma empresa prestadora de consultoria em energia e serviços públicos. O questionamento para MCDA foi realizado de forma exploratória para os três critérios alcançados por C-DEEPSO. Um arquivo automatizado contendo as regras de AHP foi gerado em Excel-VBA utilizando uma verificação de consistência baseada em CR e foi distribuído entre 5 especialistas em HMGS.

Foi realizado o contato com cada especialista, explicando o funcionamento do sistema e o porque da escolha dos critérios estabelecidos para otimização HMGS. Os contatos foram realizados por telefone, bem como correio eletrônico e dois presencialmente. As preferências em relação ao COE, LPSP e RS-Factor dos especialistas em HMGS são mostradas nos gráficos da Figura 43.

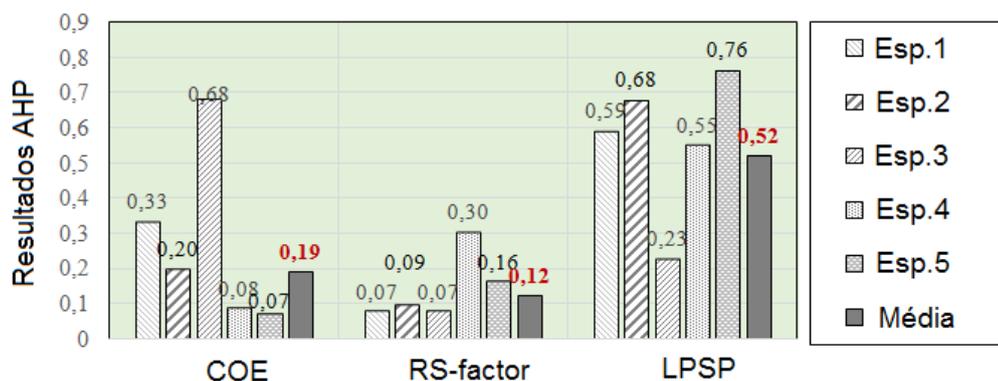


Figura 43 – Obtenção de pesos individuais e médios a partir dos especialistas em HMGS.

Pode ser visto que LPSP foi considerado como o critério mais importante para a operação de HMGS, seguido pelo COE. Os resultados da AHP mostram um quadro diverso em relação às prioridades das partes interessadas. Isto indica que não há consenso sobre qual critério é mais importante frente a outro. Os especialistas tiveram dificuldades para atribuir pesos a LPSP pelo fato de pensarem que o sistema seria altamente dependente do tipo de usuário final (por exemplo, apenas uma família ou uma linha de produção sensível a flutuações na fonte de alimentação). As prioridades mostram que um baixo LPSP desempenha um papel superior para a maioria dos especialistas em relação ao COE e RS-Factor. Uma exceção é o especialista no. 3 que mostrou uma forte preferência em relação ao baixo COE. Os resultados de AHP foram finalmente utilizados como entrada para TOPSIS em combinação com os resultados vindos de C-DEEPSO para fornecer uma classificação de BESS sobre HMGS para apoio à decisão. O ranqueamento e a classificação das baterias para todos os interessados em média são dadas pela Figura 44.

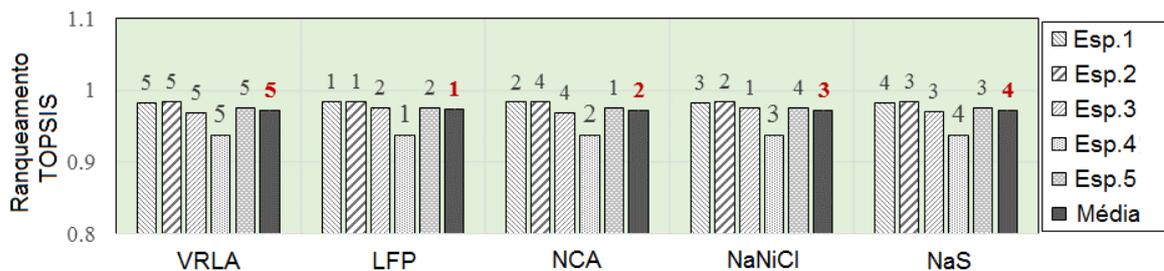


Figura 44 – Resultados de TOPSIS a partir de C-DEEPSO e AHP.

Pode-se verificar que LFP foi classificada em primeiro lugar. Isto pode ser explicado pelo baixo custo e propriedades técnicas favoráveis deste tipo de bateria. NCA, um tipo de bateria que também é à base de lítio, é em média, a segunda melhor opção. NaNiCl e NaS estão classificados no terceiro e quarto lugar, enquanto VRLA está em último. A classificação dos especialistas individualmente indica resultados diferentes. Isto pode ser visto por exemplo, especialmente sob a ótica do especialista no.3. Tal opinião favorece baterias NaNiCl que em média foram classificadas em terceiro, mas por ele em primeiro lugar. As baterias VRLA, que têm baixo custo no primeiro vislumbre, são classificadas em último lugar em todos os casos devido à baixa vida útil dos ciclos, levando a alto custo por ciclo conduzindo a uma baixa eficiência, comparativamente.

## 6.4 Considerações Finais

Este Capítulo apresentou algoritmos evolucionários para aplicação em diferentes problemas. Uma finalidade foi a geração de energia elétrica com base no conceito de eficiência energética e sustentabilidade. Os experimentos realizados no que tange ao despacho elétrico de uma UHE indicaram uma considerável economia projetada de recursos

hídricos com uso da solução mono-objetivo do C-DEEPSO, que se compara à solução obtida pelo SPEA2.

A minimização das perdas na transmissão em uma WPP foi realizada por C-DEEPSO de maneira a garantir o controle eficiente da planta. A realização da operação de grandes redes é uma tarefa de alta dificuldade. O algoritmo hC-DEEPSO, além prover a garantia de operação em redes larga escala, sem violar restrições, se mostrou competitivo quando comparado a outras metaheurísticas. Por fim, um HMGS conectado à rede pública, foi proposto realizando o despacho elétrico com uso de C-DEEPSO para otimizar a rede. Resultados condizentes com a realidade do mercado foram encontrados para custo de kWh. Um método para tomada de decisão foi utilizado para classificar diferentes BESS, os quais a melhor alternativa para atender ao sistema *microgrid* foi a bateria LFP.

O controle da geração e transmissão de energia é uma área que precisa de atenção e novas tecnologias, no Brasil e no mundo. Embora 75.5% da energia elétrica gerada em nosso país seja proveniente de recursos renováveis, apenas um percentual muito baixo desta geração é de fonte eólica e/ou solar. O Brasil possui sazonalidade ideal para estas fontes, porém elas ainda são pouco difundidas. C-DEEPSO e hC-DEEPSO se mostraram metaheurísticas aptas para o tratamento dos problemas apontados neste trabalho.

## 7 Conclusão

Este trabalho propôs e aperfeiçoou um AE para sua aplicação na solução de problemas de fluxo de potência ótimo. Uma revisão da literatura e um levantamento do atual estado da arte, relacionados à solução de problemas desta natureza, foram realizados. Uma metaheurística recente, denominada DEEPSO, foi estudada e identificou-se uma oportunidade para o aperfeiçoamento desta técnica. O novo algoritmo resultante foi então denominado de C-DEEPSO, contemplando de modo abrangente o conceito de hibridização, no qual ao fim duas novas versões foram propostas C-DEEPSO e hC-DEEPSO, sendo que o segundo é acoplado a um novo operador de busca local. Os estudos de caso, referentes ao problema de fluxo de potência ótimo no despacho elétrico foram apresentados em diferentes abordagens de geração de energia. Os experimentos e resultados relativos às soluções de otimização obtidas tanto via de C-DEEPSO quanto hC-DEEPSO foram abordados.

O algoritmo hC-DEEPSO, por sua vez, foi comparado a algumas técnicas presentes na literatura mostrando obter melhores valores médios frente a elas, na solução de um conhecido problema de *benchmark*. Quando comparado à metaheurística DEEPSO, as versões C-DEEPSO e hC-DEEPSO se mostraram competitivas (como mostrado pelo método de inferência estatística realizado e discutido naquele capítulo). Após apresentar bom desempenho nos experimentos preliminares, as propostas de AE feitas neste trabalho foram utilizadas para resolver problemas de larga escala no fluxo ótimo de potência.

Três estudos de caso na área de energia elétrica fizeram parte dos estudos de casos deste projeto. No problema do Despacho Elétrico em UHE, o modelo matemático de (MARCELINO; WANNER; ALMEIDA, 2013) foi ampliado e o transformando em um problema do tipo multiobjetivo. Um experimento usando C-DEEPSO foi realizado a fim de se comparar o resultado obtido com o do algoritmo DE/best/1/bin, no qual o algoritmo proposto se mostrou uma melhor alternativa para solução deste problema. De forma a obter conjuntos de soluções, na abordagem multiobjetivo, foram utilizados dois algoritmos bastante difundidos na literatura, o algoritmo NSGA-II e o algoritmo SPEA2.

Os experimentos, por meio do método de inferência estatística proposto, indicaram que o algoritmo SPEA2 possui maior eficiência frente ao algoritmo NSGA-II, para o problema em questão. A economia prevista ao usar a solução encontrada na Fronteira Pareto-Ótimo via SPEA2 (obtida também por C-DEEPSO) é capaz de abastecer uma cidade do tamanho de Belo Horizonte pelo período de 2 meses. Esta economia é equivalente a 15.7 milhões de  $m^3$  de água mensais na geração de energia. A abordagem multiobjetivo também colabora para a aceitação da equipe operacional de uma UHE ao uso do MCO.

O problema, conhecido como SCOPF na geração de energia eólica, pode ser

expresso como, por exemplo a minimização do custo operacional de uma usina eólica ou a minimização de perdas de energia durante a transmissão da mesma. A fim de se estudar fontes limpas e renováveis de energia elétrica, uma vez que o sistema hídrico no Brasil não tem conseguido manter a demanda interna do país sozinho, a energia eólica se torna uma fonte viável dada a sazonalidade proeminente em nosso país. Apesar do grande progresso neste setor, considerando a geração de energia *off-shore* e *on-shore*, é necessário garantir uma utilização otimizada do potencial eólico. A obtenção de solução em SCOPF na minimização das perdas de potência ativa durante sua transmissão, em parques eólicos foi realizada usando o algoritmo C-DEEPSO no Sistema IEEE 41. Os resultados obtidos foram comparados com os resultados dos algoritmos DEEPSO e MVMO, que são estado da arte na solução deste problema. Os resultados indicam que o algoritmo proposto é eficiente e competitivo. Os resultados experimentais também mostraram que C-DEEPSO obteve soluções consistentes, quando comparado aos algoritmos de referência em 79,2% dos cenários de teste com 95% de confiança.

A estrutura competitiva dos modernos sistemas de energia exige uma utilização rentável dos recursos disponíveis. Seguindo isto, novas técnicas já foram desenvolvidas para otimização da operação em redes de larga escala. Neste trabalho, um novo algoritmo híbrido chamado hC-DEEPSO, correspondente ao C-DEEPSO acoplado a um operador de busca local, SLS, e um mecanismo de diversidade simples, foi introduzido e aplicado para resolver problemas SCOPF. Devido a um grande número de restrições e contingências em problemas SCOPF, a solução matemática para esses problemas pode se tornar de difícil solução. Portanto, hC-DEEPSO foi uma hipótese relevante testada neste trabalho de pesquisa como um método de bom desempenho e adequado para ser usado em problemas desta natureza.

O operador de busca local proposto, a fim de realizar uma investigação aprofundada a partir da melhor solução presente na população, garantiu a hC-DEEPSO um melhor desempenho que a versão DEEPSO original. SLS gerou amostras de espirais logarítmicas ao redor do melhor indivíduo, permitindo equilíbrio entre *exploration* e *exploitation* na busca de melhores soluções. hC-DEEPSO foi testado frente a três algoritmos da literatura, DEEPSO, ICDE e MVMO, para resolver problemas de fluxo de potência ótimo com restrições de segurança, do despacho reativo e ativo/reativo usando três sistemas de teste. Os Sistemas IEEE de 57, 118 e 300 barras foram escolhidos.

Resultados experimentais mostraram que hC-DEEPSO obteve soluções competitivas com os algoritmos presentes na literatura, sendo capaz de enfrentar grandes problemas de larga escala de difícil solução. Os resultados para o Sistema IEEE de 57 barras mostraram que, com 95% de confiança, hC-DEEPSO se mostrou comprovadamente melhor que os algoritmos ICDE, DEEPSO e MVMO nos problemas de ORDP e OARDP. Nos resultados obtidos nos problemas ORDP, para os Sistemas IEEE de 118 e 300 barras, hC-DEEPSO

obteve melhores resultados que DEEPSO e ICDE. Contudo, o teste estatístico não detectou qualquer diferença entre hC-DEEPSO e MVMO em ambos os cenários.

Nos resultados dos problemas OARDP, para os Sistemas IEEE de 118 e 300 barras, hC-DEEPSO se mostrou melhor do que os algoritmos DEEPSO e ICDE. No entanto, MVMO se mostrou melhor que hC-DEEPSO no Sistema IEEE de 118 barras e o teste estatístico não foi capaz de detectar qualquer diferença entre hC-DEEPSO e MVMO no Sistema IEEE de 300 barras. A conclusão geral após os experimentos é que a nova metaheurística hC-DEEPSO se destaca como um promissor algoritmo de otimização híbrido evolutivo com bom potencial para resolução de problemas SCOPF com resultados comparáveis a de outros algoritmos estado da arte.

Este trabalho também abordou um sistema *microgrid* híbrido na geração de energia elétrica. O modelo HMGS inicial, proposto por [Borhanazad et al. \(2014\)](#), serviu de ponto de partida. Novos dados tecno-econômicos, cinco tecnologias de armazenamento de energia (LFP, NCA, NaS, VRLA e NaNiCl) e séries temporais de uma região alemã foram utilizados. Uma comparação entre PSO e C-DEEPSO foi realizada. A resposta do teste estatístico, mostrou que a hipótese nula foi rejeitada com 95% de confiança. C-DEEPSO pôde assim ser considerado como a melhor abordagem para resolver os problemas relacionados a este caso HMGS. Posteriormente cada BESS foi testado via C-DEEPSO em relação ao seu desempenho em três diferentes critérios no modelo HMGS: COE, LPSP e RS-factor.

Resultados de otimização para cada bateria foram suficientes para fornecer um primeiro auxílio indicativo para decisão da escolha mais adequada de BESS para HMGS, com base nos pesos definidos por 5 especialistas. Os resultados das comparações pareadas mostram uma definição diversa sobre a importância de cada critério para cada especialista, especialmente em relação ao RS-Factor e ao COE, e em um caso para LPSP. Isto mostra para futuros trabalhos a necessidade de participação de um número maior de especialistas para permitir uma melhor compreensão para tomada de decisão da escolha de BESS mais apropriado para HMGS similares ao proposto.

Mesmo assim, a agregação de resultados de C-DEEPSO em combinação com AHP no TOPSIS forneceu uma primeira classificação final indicativa de BESS adequado para aumentar o desempenho no HMGS. O ranqueamento definiu como tecnologia de armazenamento adequado ao sistema: 1ª posição - LFP, na 2ª posição NCA, em terceiro lugar NaNiCl, estando em 4ª posição NaS e como última opção VRLA. As diferentes ponderações indicados por cada especialista forneceram um quadro bastante diverso em relação aos escores obtidos. Esta variedade mostra que a escolha de uma tecnologia de bateria adequada é altamente dependente das noções sobre propriedades HMGS que cada especialista possui.

O objetivo geral de contribuir para eficiência energética e o uso sustentável da energia elétrica foi alcançado, no tratamento dos problemas específicos contidos neste

trabalho, considerando o que foi apresentado no Capítulo 4 e a relevância dos resultados mostrados no Capítulo 6. Os seguintes objetivos específicos foram também obtidos:

- Um novo algoritmo evolucionário híbrido foi desenvolvido e testado conforme descrito no Capítulo 5. Os resultados dos problemas elétricos solucionados por C-DEEPSO foram apresentados e discutidos nas seções 6.1 e 6.3. Os resultados referentes ao fluxo de potência com restrições de segurança foram apresentados na Seção 6.2, nos quais o algoritmo C-DEEPSO foi usado no Sistema IEEE 41, enquanto os Sistemas IEEE de 57, 118 e 300 barras foram solucionados usando hC-DEEPSO.
- A concepção do novo operador de busca local *Spiral Local Search*, presente na Seção 5.2, foi realizada e implementada. Quando acoplada a C-DEEPSO, SLS, implementou uma hibridização original com C-DEEPSO, originando o método hC-DEEPSO. A operação de busca deste algoritmo híbrido aprimorou a pesquisa no espaço e os resultados obtidos por hC-DEEPSO competem com os encontrados no estado da arte para os problemas em SCOPF, como discutido na Seção 6.2.2.
- Foi realizada uma extensão de um modelo que caracteriza o problema do despacho elétrico em UHE, conforme discutido na Seção 4.1 e os resultados apresentados na Seção 6.1. A abordagem adotada, além de colaborar com a economia de água na geração de energia, promovendo a eficiência energética e a sustentabilidade, facilita o uso do MCO por parte da equipe operacional;
- Um sistema microgrid híbrido foi aperfeiçoado na Seção 4.4. Os resultados obtidos indicam que com o uso do algoritmo C-DEEPSO é possível se obter um custo final comparável ao da rede pública. É relevante observar que a bateria LFP foi considerada, a partir da ponderação de critérios realizada por especialistas, como o sistema BESS a ser usado no cenário de testes, conforme discutido na Seção 6.3.

## 7.1 Trabalhos Futuros

Como trabalhos futuros, sugere-se dar continuidade nesta pesquisa nas seguintes direções:

- Propor e substituir no atual processo de mutação, para o caso das variáveis de decisão apresentarem características inteiro-mistas, um operador que leve em consideração o fato de existirem variáveis inteiras, evitando assim o uso de arredondamento;
- Realizar ajuste de parâmetros das taxas referentes ao operador SLS, bem como o tamanho da população utilizada em hC-DEEPSO, uma vez que este parâmetro é diretamente ligado à operação de busca local proposta;
- Propor e implementar um algoritmo multiobjetivo baseado em hC-DEEPSO, com inspiração no mecanismos de dominâncias presentes no NSGA-II ou SPEA2, uma vez que o algoritmo hC-DEEPSO já possui uma memória arquivada e;

- Aprimorar o modelo de HMGS incluindo a compensação de energia com a rede pública e a otimização para obtenção do tamanho adequado de BESS.

## 7.2 Considerações Finais

Como contribuição científica, esta tese mostrou que um algoritmo híbrido formado por meio de técnicas já conhecidas se apresentou eficiente e competitivo na solução de problemas de fluxo de potência já conhecidos. Contribui também no que tange ao uso de abordagem multiobjetivo para solução de problemas da área de engenharia elétrica. Como fruto da pesquisa realizada nesta tese, os seguintes trabalhos foram publicados:

- **MARCELINO, C.**; WANNER, E.; ALMEIDA, P. An evolutionary approach to improve efficiency for solving the electric dispatch problem. **Proc.: IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)**, pp.: 1-8, 2014;
- **MARCELINO, C.**; CARVALHO, L.; ALMEIDA, P.; WANNER, E.; MIRANDA V. Application of Evolutionary Multiobjective Algorithms for Solving the Problem of Energy Dispatch in Hydroelectric Power Plants. **Springer. In: Lecture Notes in Computer Science, V. 9019, pp.: 403-417**, 2015;
- **MARCELINO, C.**; ALMEIDA, P.; WANNER, E.; CARVALHO, L.; MIRANDA, V. Fundamentals of the C-DEEPSO Algorithm and its Application to the Reactive Power Optimization of Wind Farms. **In: IEEE Congress on Evolutionary Computation (CEC)**, pp.:1547-1554, 2016;

Submetidos:

- **MARCELINO, C.**; BAUMANN, M.; ALMEIDA, P.; WANNER, E.; WEIL, M. Um novo modelo para otimização de microgrids híbridos usando algoritmos evolutivos. **IEEE Latin America Transactions** - aceito 2017.
- **MARCELINO, C.**; BAUMANN, M.; WEIL, M.; ALMEIDA, P.; WANNER, E.; CARVALHO, L.; MIRANDA, V. Solving Security Constrained Optimal Power Flow problems: a hybrid evolutionary approach. **IEEE Transactions on Evolutionary Computation**, 2017;

Em processo de finalização:

- **MARCELINO, C.**; BAUMANN, M.; CARVALHO, L., CHIBELES-MARTINS, N.; WANNER, E.; ALMEIDA, P.; WEIL, M. Battery storage for hybrid micro grid systems: optimization and decision making analysis - a ser submetido na: **IEEE Transactions on Smart Grid**.

Outros trabalhos ligados indiretamente a esta tese foram publicados em conjunto aos grupos de pesquisa parceiros:

- FERREIRA, L.; **MARCELINO, C.**; ALMEIDA, P. ; WANNER, E. A computational approach to the Electric Dispatch problem: comparative case study between the Differential

- Evolutionary, Genetic and Clonal Algorithms. **In: 17th Encontro Nacional de Modelagem Computacional**, 2014;
- **MARCELINO, C.**; ALMEIDA, P.; WANNER, E.; CARVALHO, L.; MIRANDA, V. Aplicação da metaheurística DEEPSO a problemas de otimização global em larga escala. **In: Anais do Simpósio Brasileiro de Pesquisa Operacional**, pp.: 1756-1765, 2015;
  - CARVALHO, L.; LOUREIRO, F.; SUMALLI, J.; KEKO, H.; MIRANDA, V.; **MARCELINO, C.**; WANNER, E. Statistical Tuning of DEEPSO Soft Constraints in the Security Constrained Optimal Power Flow Problem. **In: IEEE Intelligent Systems Applications to Power Systems**, pp.:1-8, 2015;
  - BRAGA, L.; **MARCELINO, C.**; MILANES, A.; ALMEIDA, P. Successful Parallel Implementation of NSGA-II on GPU for the Energy Dispatch Problem on Hydroelectric Power Plants. **In: IEEE World Conference on Computational Intelligence**, 2016.
  - BAUMANN, M.; **MARCELINO, C.**, PETERS, J.; WEIL, M.; ALMEIDA, P.; WANNER, E. Environmental impacts of different battery technologies in renewable hybrid microgrid systems. **In: IEEE International Conference on Innovative Smart Grid Technologies (ISGT)** - aceito 2017.

# Referências

ABDI, H.; WILLIAM, L. **Tukey's Honestly significant Difference (HSD) Test**. [S.l.], 2010. Citado 2 vezes nas páginas 12 e 86.

ABIDO, M. Optimal power flow using particle swarm optimization. **Electrical Power and Energy Systems - ELSEVIER**, 24:563-571, 2002. Citado 5 vezes nas páginas 8, 15, 17, 41 e 46.

ABIDO, M. Environmental/economic power dispatch using multiobjective evolutionary algorithm. **IEEE Transactions on Power Systems**, vol 18, no.4, pp.: 1529-1537, 2003. Citado na página 17.

ABIDO, M.; ALI, N. Multi-objective Optimal Power Flow Using Differential Evolution. **Arabian Journal for Science and Engineering**, vol. 37, no. 4, pp.: 991-1005, 2012. Citado 2 vezes nas páginas 17 e 18.

ABRAO, P. L.; WANNER, E.; ALMEIDA, P. A novel movable partitions approach with neural networks and evolutionary algorithms for solving the hydroelectric unit commitment problem. **Proceeding of the 15h annual conference on GECCO**, pages 1205-1212, 2013. Citado na página 21.

ADIBI, M. et al. Optimal transformer TAP selection using Modified Barrier-augmented Lagrangian method. **IEEE Transaction on Power Systems**, Vol 18, no. 1, 251-257, 2003. Citado na página 45.

AGUARON, J.; MORENO-JIMENEZ, J. M. The geometric consistency index: Approximated thresholds. **Eur. J. Oper. Res.**, vol. 147, pp. 137-145, May, 2003. Citado na página 37.

ALLAOUA, B.; LAOUFI, A. Collective Intelligence for optimal Power Flow Solution Using Ant Colony Optimization. **Leonardo Electronic Journal of Practices and Technologies**, vol. 13, pp.: 88-105, 2008. Citado na página 17.

ALMEIDA, A. et al. **Multicriteria and Multiobjective Models for Risk, Reliability and Maintenance Decision Analysis**. [S.l.]: International Series in Operations Research & Management Science Volume 231, 2015. Citado na página 35.

ALMEIDA, K.; SENNA, F. Optimal Active-Reactive Power Dispatch Under Competition via Bilevel Programming. **IEEE Transactions on Power Systems**. V. 26. pp: 2345-2354, 2001. Citado 2 vezes nas páginas 45 e 46.

ALRASHIDI, M.; EL-HAWARY, M. E. Hybrid Particle Swarm Optimization Approach for Solving the Discrete OPF Problem Considering the Valve Loading Effects. **IEEE Transaction on Power Systems**, vol 22, no. 4, 2030-2038, 2007. Citado na página 18.

ARCE, A.; OHISHII, T.; SOARES, S. Optimal Dispatch of Generating Units of the Itaipu Hydroelectric Plant. **IEEE Transactions on power Systems**, Vol. 17 N.1, 2002. Citado na página 14.

BALDWIN, C. J.; DALE, K. M.; DITTRICH, R. F. A Study of the Economic Shutdown of Generating Units in Daily Dispatch. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems ( Volume: 78, Issue: 4, Dec.)**, 1959. Citado na página 21.

BANOS, R. et al. Optimization methods applied to renewable and sustainable energy: A review. **ELSEVIER, In: Renewable and Sustainable Energy Reviews**, v. 15, p. 1753 – 1766, 2011. Citado na página 21.

BARELLI, L.; BIDINI, G.; BONUCCI, F. A micro-grid operation analysis for cost-effective battery energy storage and RES plants integration. **Energy**, vol.113, pp.: 831-844, 2016. Citado 3 vezes nas páginas 23, 54 e 56.

BAUMANN, M. et al. CO2 footprint and life cycle costs of electrochemical energy storage for stationary grid applications. **Energy Technology**, no. Submitted, 2016. Citado 2 vezes nas páginas 55 e 56.

BENASLA, L.; BELMADANI, A.; RAHLI, M. Spiral Optimization Algorithm for solving Combined Economic and Emission Dispatch. **Electrical Power and Energy Systems**, vol. 62, pp.: 163-174, 2014. Citado na página 64.

BEYER, H.-G.; SCHWEFEL, H.-P.; WEGENER, I. How to analyse evolutionary algorithms. **Theoretical Computer Science. ELSEVIER**, v. 287, p. 101–130, 2002. Citado 3 vezes nas páginas 1, 2 e 28.

BHASKAR, M.; MUTHYALA, S.; MAHESWARAPU, S. Security Constraint Optimal Power Flow (SCOPF) - a comprehensive Suvery. **International Journal of Computer Applications**, vol. 2, n.6, pp.:42-52, 2010. Citado 4 vezes nas páginas 14, 15, 19 e 45.

BHUIYAN, A. G. et al. InGaN Solar Cells: Present State of the Art and Important Challenges. **IEEE Journal of Photovoltaics**, Vol. 2, Issue: 3, pp: 276-293, 2002. Citado na página 7.

BISKAS, P. et al. Comparasion of two metaheuristics with mathematical programmin methods for the solution of OPF. **Proc: in 13th International conference on Intelligent Systems Application to Power Systems**, vol.1, pp.: 16-24, 2005. Citado 2 vezes nas páginas 15 e 41.

BORHANAZAD, H. **Techno-Economic Analysis of Hybrid Renewable energy System with PSO**. 2016. Disponível em: <<https://de.mathworks.com/matlabcentral/fileexchange/54205-techno-economic-analysis-of-hybrid-renewable-energy-system-with-pso>. Acesadoem13deMaiode2017>. Citado na página 58.

BORHANAZAD, H. et al. Optimization of micro-grid system using MOPSO. **Renewable energy**, Vol. 71, pp. 295-306, 2014. Citado 9 vezes nas páginas 23, 24, 28, 54, 55, 56, 57, 58 e 105.

CAPITANESCU, F. Critical review of recent advances and further developments needed in AC optimal power flow. **Electric Power Systems Research** 136:57-68, 2016. Citado na página 24.

CAPITANESCU, F.; WEHENKEL, L. Sensitivity-based aapproaches for handling discrete variables in Optimal Power Flow computations. **IEEE Transactions on Power Systems**, Vol 25, no. 4, 1780-1789, 2010. Citado na página 45.

- CARNEIRO, G.; CHAVES, J. Estudo piloto para estabelecimento da vazão de conforto para consumo residencial de água na cidade de Ponta Grossa. **Anais do Encontro de Engenharia e Tecnologia em campos gerais.**, 2008. Citado na página 79.
- CARPETIER, J. Contribution to the economic dispatch problem. **Bull. Soc. Fr. Electri. vol. 8, no. 3, pp.: 431-447**, 1962. Citado na página 15.
- CARVALHO, A.; BRAGA, A. P.; LUDERMIR, T. **Computação Evolutiva**. [S.l.]: Sistemas Inteligentes: Fundamentos e aplicações. Capítulo de Livro., 2003. Citado na página 1.
- CARVALHO, E.; SANTOS, A.; MA, T. Reduced gradient method combined with augmented Lagrangian and barrier for the optimal power flow problem. **Applied Mathematics and Computation, vol 200, pp.: 529-536**, 2004. Citado na página 15.
- CARVALHO, L. et al. Statistical Tuning of DEEPSO Soft Constraints in the Security Constrained Optimal Power Flow Problem. **Proc: in 18th International Conference on Intelligent System Application to Power Systems, vol.1. pp: 1-7**, 2015. Citado na página 20.
- CHAI, J.; LIU, J.; NGAI, E. Application of decision-making techniques in supplier selection: A systematic review of literature. **Expert Systems with Applications, 40:3872-3885**, 2013. Citado na página 35.
- CHAUHAN, A.; VAISH, R. Fluid Selection of Organic Rankine Cycle Using Decision Making Approach. **Journal of Computational Engineering Volume 2013, Article ID 105825, pp.: 1-10**, 2013. Citado 2 vezes nas páginas ix e 39.
- CHUANWEN, J.; BOMPARD, E. A hybrid method of chaotic particle swarm optimizations and linear interior for reactive power optimisation. **Mathematics and Computers in Simulation, vol. 68, no.1, pp.: 57-65**, 2005. Citado na página 45.
- CHUNG, C. Y. et al. Hybrid algorithm of Differential evolution and evolutionary programming for optimal reactive power flow. **IET Generation, Transmission & Distribution, vol.4, no.1, pp: 84-93**, 2010. Citado na página 18.
- COELHO, D. et al. A Multiobjective Evolutionary Algorithm for the 2D Guillotine Strip Packing Problem. **Proc in: IEEE CEC. DOI: 10.1109/CEC.2012.6256469.**, 2013. Nenhuma citação no texto.
- COELLO, C. et al. **Evolutionary Algorithms for Solving Multi-Objective problems**. [S.l.]: 2th Edition, 2007. Citado na página 28.
- CORSI, S. Recognition and pricing of the generators contribution to the network voltage support in a market environment. In: **In Proc: IEEE Power & Energy Society General Meeting. V.1. pp: 1-9**. [S.l.: s.n.], 2008. Citado na página 45.
- DAS, S.; SUGANTHAN, P. Differential Evolution: a survey of the State-of-the-Art. **IEEE Transactions on Evolutionary Computation. pp: 4-31**, 2011. Citado 3 vezes nas páginas xiv, 29 e 31.
- DEB, K. et al. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA II. In **M. S. et al. (Ed.), Parallel Problem Solving from Nature PPSN VI, Berlin, pp. 849-858. Springer**, 2000. Citado 4 vezes nas páginas 28, 32, 33 e 34.

DIAS, W.; WANNER, E.; CARDOSO, R. A multiobjective optimization approach for combating *Aedes aegypti* using chemical and biological alternated step-size control. **Mathematical Biosciences**. Accepted, doi: 10.1016/j.mbs.2015.08.019, 2015. Nenhuma citação no texto.

DIXIT, S.; SRIVASTAVA, L.; AGNIHOTRI, G. Minimization of Power Loss and Voltage Deviation by SVC Placement Using GA. **International Journal of Control and Automation**, Vol.7, No.6, pp.95-108, 2014. Citado na página 17.

DWD. **Deutscher Wetterdienst: Wetter und Klima aus einer Hand**. [S.l.], 2016. Citado na página 55.

EHRGOTT, M. A discussion of scalarization technics for multiple objective interger programming. **Annals of Operations Research**, vol. 147, pp: 343-460, 2006. Citado na página 27.

EICHFELDER, G. **Adaptative Scalarization Methods in a Multiobjective Optimization**. [S.l.]: 1th edition, 2008. Citado na página 27.

ELA, A.; ABIDO, M.; SPEA, A. Optimal power flow using differential evolution algorithm. **Electric Power System Research**, vol 80, pp.: 878-885, 2010. Citado na página 17.

ELLABBAN, O.; ABU-RUB, H.; BLAABJERG, F. Renewable energy resources: Current status, future prospects and their enabling technology. **Renewable and Sustainable Energy Reviews**, vol. 39, pp: 748-764, 2014. Citado 2 vezes nas páginas ix e 6.

EPE. **Balanço Energético Nacional: ano base 2015**. [S.l.], 2016. Citado 3 vezes nas páginas ix, 4 e 5.

ERLICH, I. et al. 2014 OPF problems: About the competition and its continuity. In: **Disponível em: <https://www.uni-due.de/ieee-wgmho/competition2014>**. Acessado em 12/04/2017. [S.l.: s.n.], 2014. Citado na página 89.

ERLICH, I. et al. Competition on application of modern heuristic optimization algorithms for solving optimal power flow problems. In: **Technical report, Working Group on Modern Heuristic Optimization, Intelligent Systems Subcommittee Power System Analysis, Computing, and Economic Committee, (February)**. [S.l.: s.n.], 2014. Citado 10 vezes nas páginas x, xii, 19, 20, 47, 49, 82, 89, 93 e 94.

ESMIN, A.; LAMBERT-TORRES, G.; ZAMBRONI, A. A Hybrid Algorithm Swarm Optimization Applied to Loss power Minimization. **IEEE Transaction on Power Systems**, vol 20, no. 2, 859-866, 2005. Citado na página 18.

FARHANGI, H. The path of the smart grid. **IEEE Power Energy Mag.**, vol. 8, no. 1, pp. 1828, 2010. Citado 2 vezes nas páginas 54 e 56.

FONSECA, C. M.; FLEMING, P. Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization. In **S. Forrest (Ed.), Proceedings of the Fifth International Conference on Genetic Algorithms, San Mateo, California**, pp. 416-423. Morgan Kaufmann, 1993. Citado na página 32.

FRANÇA, T. Um modelo de unit commitment para sistemas hidrotérmicos resolvido por método Híbrido baseado em Algoritmos Genéticos e Métodos de Pontos Interiores. **Anais de Congresso, In: XVIII Congresso Brasileiro de Automática**, p. 1–8, 2010. Citado na página 21.

FRANK, S.; STEPONAVICE, I.; REBENNACK, S. Optimal Power Flow: A Bibliographic Survey (I) - Formulations and deterministic methods. **Energy Systems, Springer, vol .3, pp.:221-258**, 2012. Citado 4 vezes nas páginas 8, 15, 16 e 41.

FRANK, S.; STEPONAVICE, I.; REBENNACK, S. Optimal power flow: a bibliographic survey II: Non-deterministic an Hybrid methods. **Energy Systems, Springer, vol 3, pp.:259-289**, 2012. Citado 2 vezes nas páginas 16 e 18.

GAING, Z.; CHANG, R. Security-Constrained Optimal Power Flow by Mixed-Integer Genetic Algorithm with Arithmetic Operators. **Proc: in IEEE Power Engineering Society General Meeting, vol.1, pp.: 1-8**, 2006. Citado na página 19.

GAMPE, D. Kleinwindkraftanlagen Hintergrundinformationen und Handlungsempfehlungen fur die Landwirtschaft. **Centrales Agrar, Straubing**, 2013. Citado na página 55.

GAN, L.; LOW, S. H. Optimal power flow in direct current networks. **IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 29, NO. 6, NOVEMBER 2014, pp.: 2892-2904**, 2014. Citado na página 44.

GARCIA-CASCALES-CASCALES, M. S.; LAMATA, M. T. On rank reversal and TOPSIS method. **Math. Comput. Model., vol. 56, no. 5-6, pp. 123-132, Sep**, 2012. Citado na página 39.

GASPAR-CUNHA, A.; TAKAHASHI, R.; ANTUNES, C. **Manual de computação evolutiva e metaheurística**. [S.l.]: Impresso pela Universidade de Coimbra, 1 Ed., 2013. Citado na página 1.

GEORGESCU, M. et al. Smart electrical energy storage system for small power wind turbines. In: **In Proc in: 12th International Conference on Optimization of Electrical and Electronic Equipment, OPTIM, pp: 1192-1197**. [S.l.: s.n.], 2010. Citado na página 8.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. [S.l.]: Addison-Wesley, 1989. Citado 3 vezes nas páginas 3, 28 e 33.

GOODWIN, P. **Decision analysis for management judgment**. [S.l.]: 3rd ed. Hoboken, 2004. Citado na página 36.

GUEDES, L. et al. A continuous compact model for cascaded hydro-power generation and preventive maintenance scheduling. **Electrical Power and Energy Systems 73, 702-710**, 2015. Citado na página 21.

GUIMARÃES, F. **Manual de computação evolutiva e metaheurística**. [S.l.]: Capítulo 7: Evolução Diferencial. pp: 141:160, 2013. Citado 2 vezes nas páginas 29 e 60.

QUITOUNI, A.; MARTEL, J.-M. Tentative guidelines to help choosing an appropriate MCDA method. **European Journal of Operational Research 109: 501-521**, 1998. Citado na página 35.

- HAO, S.; PAPALEXOPOULOS, A. Reactive power pricing and management. **IEEE Transactions on Power Systems**, V.12. pp: 95-104, 1997. Citado na página 45.
- HATZIARGYRIOU, N. **Microgrids: architectures and control**. [S.l.]: Wiley, IEEE Press, 2014. Citado 2 vezes nas páginas 14 e 22.
- HORN, N. N. J.; GOLDBERG, D. E. A niched pareto genetic algorithm for multiobjective optimization. In **Proceedings of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Computation, Volume 1, Piscataway, NJ**, pp. 82-87. **IEEE Press.**, 1994. Citado na página 32.
- HUANG, C. et al. Comparative study of evolutionary computation methods for active-reactive power dispatch. **IET Generation, Transmission & Distribution**, vol.6, no.7, pp: 636-645, 2012. Citado na página 45.
- HUANG, H.; QIN, A.; SUGANTHAN, P. Self-adaptative differential evolution algorithm for constrained real-parameter optimization. **Proc.: in IEEE Congress on Evolutionary Computation**, vol 1, pp.:17-24, 2006. Citado 2 vezes nas páginas 30 e 62.
- HUANG, V.; QIN, A.; SUGANTHAN, P. Differential evolution algorithm with strategy adaptation for global numerical optimization. **IEEE Transactions on Evolutionary Computation**, v. 13, p. 398 – 417, 2009. Citado na página 18.
- HUANG, X.; HAOZHONG, C.; L., H. Optimal reactive power flow incorporating static voltage stability based on multi-objective adaptative immune algorithm. **Energy Conversion and Management**, vol 49, pp.: 1175-1181, 2008. Citado na página 17.
- HWANG, C. L.; YOON, K. Multiple attribute decision making: methods and applications; a state-of-the-art-survey. **Berlin: Springer**, 1981. Citado na página 38.
- JABR, R.; PAL, B. Intermittent wind generation in optimal power flow dispatching. **IET Generation, Transmission & Distribution**, vol.3, no.1, pp: 66-74, 2009. Citado na página 7.
- JAMIL, M.; YANG, X.-S. A literature survey of benchmark functions for global optimisation problems. **International Journal of Mathematical Modelling and Numerical Optimisation**, 4(2):150-194, 2013. Citado na página 69.
- J.J.LIANG et al. Elite Multi-Group Differential Evolution. **WCCI 2012 IEEE World Congress on Computational Intelligence**, 2012. Citado na página 17.
- KAABECHE, A.; BELHAMEL, M.; IBTIOUEN, R. Techno-economic valuation and optimization of integrated photovoltaic/Wind energy conversion system. **Solar Energy**, 85(10):2407-2420, 2011. Citado na página 57.
- KANG, Q. et al. Swarm Intelligence Approaches to Optimal Power Flow Problem With Distributed Generator Failures in Power Networks. **IEEE Transactions on Automation Science and Engineering**, vol. 10, pp.: 343-353, 2013. Citado na página 17.
- KAVIANI, A.; RIAHY, G.; KOUHSARI, S. Optimal design of a reliable hydrogen-based stand-alone wind/PV generating system, considering component outages. **Renewable Energy** 34, 2380-390, 2009. Citado na página 22.

- KAZMI, S. A.; HASAN, S. F.; SHIN, D.-R. Multi criteria decision analysis for optimum DG placement in smart grids. **Proc.in:IEEE ISGT**, pp:1-5, 2015. Citado na página 23.
- KEMPTIN, W.; TOMIC, J. Vehicle-to-grid power fundamentals: calculating capacity and net revenue. **Journal of power Sources**, v. 144, pp: 268-279, 2005. Citado na página 57.
- KONAR, A. Computational Intelligence: Principles, Techniques and Applications. **Calcutta: Springer**, 2005. Citado 2 vezes nas páginas 2 e 26.
- KOZA, J. **Genetic Programming: on the Programming of Computers by Means of Natural Selection**. [S.l.]: A Bradford Book, 1998. Citado na página 3.
- KRASNOGOR, N.; SMITH, J. A tutorial for competent memetic algorithms: Model, taxonomy and design issues. **IEEE Transactions on Evolutionary Computation**, V.9, N.5, pp: 474-488, 2005. Citado 2 vezes nas páginas 10 e 68.
- LAI, L. et al. Improved genetic algorithm for optimal power flow under both normal and contingent operation states. **Electrical Power and Energy Systemns**, vol.19, pp.: 287-291, 1997. Citado na página 17.
- LEVRON, Y.; GUERRERO, J. M.; BECK, Y. Optimal Power Flow in Microgrids With Energy Storage. **IEEE Trans. Power Syst.**, vol. 28, no. 3, pp. 3226-3234, Aug, 2013. Citado 3 vezes nas páginas 22, 54 e 56.
- LI, F.-F.; QIU, J. Multiobjective optimization for integrated hydrophotovoltaic power system. **Applied Energy**, 167, 377-384, 2016. Citado na página 22.
- LI, X. et al. Benchmark functions for the CEC 2013 special session and competition on large-scale global optimization. **Technical report, IEEE CEC**, 2013. Citado na página 1.
- LIMA, F. et al. Phasemethods Placement in Large-Scale Systems via Mixed Interger Linear Programming. **IEEE Transactions on Power Systems**, vol. 18, n.3, pp.: 1029-1034, 2003. Citado na página 15.
- LIN, S.; HO, Y.; LIN, C. An ordinal optimization Theory-based algorithm for Solving the Pptimal Power Flow problem with discrete control variables. **IEEE Transaction on Power Systems**, Vol 19, no. 1, 276-286, 2004. Citado na página 45.
- LOBATO, E. et al. An LP-Based Optimal Power Flow for Transmission Losses and Generator Reactive margins Minimization. **Proc: in IEEE Porto Power tech Conference**, 2001. Citado na página 15.
- LOCATELLI, M. A note on the griewank test function. **Journal of global optimization**, 25(2):169-174, 2003. Citado na página 69.
- MALLIPEDDI, R. et al. Differential evolution algorithm with ensemble of parameters and mutation strategies. **Applied Soft Computing**, p. 1679 –1696, 2011. Citado na página 18.
- MARCELINO, C. **Otimização de um Sistema de Controle Conjunto de Geração de Energia Hidrelétrica com o emprego de Inteligência Computacional**. Dissertação (Mestrado) — CEFET-MG, 2012. Citado 4 vezes nas páginas xii, 7, 41 e 42.
- MARCELINO, C. et al. Fundamentals of the C-DEEPSO Algorithm and its Application to the Reactive Power Optimization of Wind Farms. **Proc: in IEEE Congress on Evolutionary Computation**, vol. 1, pp.:, 2016. Citado 2 vezes nas páginas ix e 48.

- MARCELINO, C.; WANNER, E.; ALMEIDA, P. A novel mathematical modeling approach to the electric dispatch problem: Case study using differential evolution algorithms. **Proceedings of conference: IEEE Congress on Evolutionary Computation (CEC)**, pages **400-407**, 2013. Citado 6 vezes nas páginas [7](#), [21](#), [24](#), [77](#), [78](#) e [103](#).
- MARCELINO, C.; WANNER, E.; ALMEIDA, P. An evolutionary approach to improve efficiency for solving the electric dispatch problem. **Proc.: IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)**, pp.: **1-8**, 2014. Citado na página [96](#).
- MIETTINEN, K.; MAKELA, M. On scalarizing functions in a multiobjective optimization. **OR Spectrum**, v. **24**, pp: **193-213**, 2002. Citado na página [27](#).
- MIRANDA, V.; ALVES, R. Differential evolutionary particle swarm optimization (DEEPSO): a successful hybrid. In **Proc: 11th Brazilian Congress on Computational Intelligence (BRICS-CCI)**. pp **368-374**, 2013. Citado 3 vezes nas páginas [20](#), [59](#) e [63](#).
- MIRANDA, V.; FONSECA, N. Epso - best-of-two-worlds metaheuristics applied to power system problems. **Proc: of WCCI/CEC - World Conf. on Computational Intelligence. Honolulu (Hawaii), USA, June**, 2002. Citado 4 vezes nas páginas [29](#), [31](#), [32](#) e [59](#).
- MOGHADDAM, A. et al. Multi-objective operation management of a renewable MG (micro-grid) with back-up micro-turbine/fuel cell/battery hybrid power source. **Energy vol.36**, pp.: **6490-6507**, 2011. Citado na página [22](#).
- MOHAMMADI, M.; HOSSEINIAN, S.; GHAREHPETIAN, G. Optimization of hybrid solar energy sources/wind turbine systems integrated to utility grids as microgrid (MG) under pool/bilateral/hybrid electricity market using PSO. **Solar Energy**, vol. **86**, pp.: **112-125**, 2012. Citado na página [22](#).
- MONTGOMERY, D. **Design and analysis of Experiments**. [S.l.]: 8th edition, 2012. Citado 5 vezes nas páginas [10](#), [11](#), [71](#), [89](#) e [94](#).
- MONTGOMERY, D.; RUNGER, G.; HUBELE, N. **Estatística aplicada à Engenharia**. [S.l.]: 2a Edição, 2004. Citado na página [77](#).
- NIU, M. et al. **Differential Evolution Algorithm with a Modified Archiving-based Adaptive Tradeoff Model for Optimal Power Flow**. [S.l.], 2014. Citado 2 vezes nas páginas [19](#) e [24](#).
- OCDE. 2017. Disponível em: [<http://www.oecd.org/fr/>](http://www.oecd.org/fr/). Citado na página [4](#).
- PANDYA, K.; JOSHI, S. A Survey of Optimal Power Flow methods. **Journal of Theoretical and Applied Information Technology**, pp.:**450-458**, 2008. Citado na página [16](#).
- PANT, M. et al. Hybrid Differential Evolution - Particle Swarm Optimization algorithm for Solving Global Optimization Problems. **Proc: In 3Th International Conference on Digital Information Management**. pp:**18-24**, 2011. Citado na página [71](#).
- PEREIRA, V. et al. Comparasion of Single and Multi-objective Evolutionary Algorithm for Robust Link-State Routig. **Lecture Notes on Computer Science, Part II, vol 9019**, pp: **573-587**, 2015. Citado na página [28](#).

PERERA, N.; SUTRISNA, M. The Use of Analytic Hierarchy Process (AHP) in the Analysis of Delay Claims in Construction Projects in the UAE. **Built Hum. Environ. Rev.**, vol. **Volume 3**, no. **Special Issue 1**, pp. **29-48**, 2010. Citado na página **36**.

PES, I. **2014 OPF problems (Competition and Panel)**. 2014. Disponível em: <<http://sites.ieee.org/psace-mho/panels-and-competitions-2014-opf-problems/>>. Citado 2 vezes nas páginas **89** e **90**.

PEZZINI, P.; GOMIS-BELLMUNTA, O.; SUDRIÀ-ANDREUA, A. Optimization techniques to improve energy efficiency in power systems. **ELSEVIER In: Renewable and Sustainable Energy Reviews**, v. 15, p. 2028 – 2041, 2011. Citado na página **21**.

PHAM, H.; RUEDA, J.; ERLICH, I. Online Optimal control of Reactive sources in Wind Power Plants. **IEEE Transactions on Sustainable Energy**, vol. **5**, no. **2**, pp.:**608-616**, 2014. Citado 2 vezes nas páginas **19** e **24**.

PHAN, D.; KALAGNANAM, J. Some Efficient Optimization Methods for Solving the Security-Constrained Optimal Power Flow Problem. **IEEE Trans. Power Syst.**, vol. **29**, no. **3**, pp. **863-872**, 2014. Citado na página **20**.

PRICE, K. An introduction to differential evolution. **In: New ideas in Optimization**, D. Corne, M. Dorigo, and V. Glover, Eds. London, U.K.: McGraw-Hill, 1999, pp. **79-108**, 1999. Citado 2 vezes nas páginas **30** e **60**.

PRICE, K.; STORN, R.; LAMPINEN, J. Differential Evolution- A Practical Approach to Global Optimization. **Berlin, Germany: Springer**, 2005. Citado 2 vezes nas páginas **30** e **60**.

QIN, A.; SUGANTHAN, P. Self-adaptive differential evolution algorithm for numerical optimization. **Proc: in IEEE Congress on Evolutionary Computation**, vol. **2**, pp.: **1785-1791**, 2005. Citado 2 vezes nas páginas **30** e **62**.

RADOSAVLJEVIĆ, J.; ARSIĆ, N. Optimal Power Flow Using Hybrid PSO-GSA Algorithm. **Proc: in 55th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON)**, 2014. Citado na página **18**.

RADOSAVLJEVIĆ, J. et al. Optimal Power Flow Using a Hybrid Optimization Algorithm of Particle Swarm Optimization and Gravitational Search Algorithm. **Electric Power Components and Systems**, **00(00):1-13**, 2015. Citado na página **17**.

RECHENBERG, I. **Evolutionstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution**. [S.l.]: Stuttgart: Fromman-Holzboog, 1973. Citado na página **3**.

RINGERTZ, U. T. On Methods for discrete structural optimization. **Engineering Optimization**, vol. **13**, no. **1**, pp.: **47-64**, 1988. Citado na página **45**.

SAATY, R. W. The analytic hierarchy process-what it is and how it is used. **Math. Model.**, vol. **9**, no. **35**, pp. **161-176**, 1987. Citado 3 vezes nas páginas **xii**, **36** e **38**.

SAATY, T. L. The analytic hierarchy process: planning, priority setting, resource allocation. **PA: RWS Publications**, 1990. Citado 2 vezes nas páginas **35** e **37**.

SHAHEEN, A.; EL-SEHIEMY, R.; FARRAG, S. Solving multi-objective optimal power flow problem via forced initialised differential evolution algorithm. **IET Generation, Transmission & Distribution**, vol.10, Iss..7, pp: 1634-1647, 2016. Citado na página 17.

SINGH, H.; SRIVASTAVA, L. Modified differential evolution algorithm for multi-objective var management. **International Journal on Electrical Power Energy Systems**, vol. 55, pp.: 731-740, 2014. Citado na página 18.

SODA. **Time Series of Solar Radiation Data - for Free**, 2016. [S.I.], 2016. Citado na página 55.

SRINIVAS, N.; DEB, K. Multiobjective optimization using nondominated sorting in genetic algorithms. **IEEE Transactions on Evolutionary Computation** 2(3), 221-248, 1994. Citado 3 vezes nas páginas 32, 33 e 34.

SRIVASTAVA, L.; SINGH, H. Hybrid multi-swarm particle swarm optimisation based multi-objective reactive power dispatch. **IET Generation, Transmission & Distribution**, vol.9, no.8, pp: 727-739, 2015. Citado na página 18.

STENZEL, P.; BAUMANN, M.; FLEER, J. Database development and evaluation for techno-economic assessments of electrochemical energy storage systems. **Proc. in: ENERGYCON**, pp.: 1334-1342, 2014. Citado na página 56.

STORN, R.; PRICE, K. Differential evolution: a simple and efficient adaptative scheme for global optimization over continuous spaces. **Technical report TR-95-012, International Computer Science Institute, Berkley**, 1995. Citado 3 vezes nas páginas 28, 29 e 30.

STORN, R.; PRICE, K. Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. **Journal of Global Optimization**, v. 11, 1997. Citado na página 29.

SUBBARAJ, P.; RAJNARAYANAN, P. Optimal reactive power dispatch using self adaptative real coded genetic algorithm. **Electric Power Systems Research**, vol 79, pp.: 374-381, 2009. Citado na página 17.

SUHARTO, M. N. et al. Optimal Power Flow Solution Using Evolutionary Computation Techniques. **Proc. in: IEEE Region 10 Conference TENCN**, v.1. pp.: 1-8, 2011. Citado na página 17.

TAKAHASHI, R.; CUNHA, G. **Manual de computação evolutiva e metaheurística**. [S.I.]: Capítulo 1: Introdução. pp:1:21, 2013. Citado na página 26.

TAKAHASHI, R.; CUNHA, G.; FONSECA, C. M. **Manual de computação evolutiva e metaheurística**. [S.I.]: Capítulo 17: Algoritmos Evolutivos Multi-objectivo. pp: 357-375, 2013. Citado na página 27.

TAMURA, K.; YASUDA, K. Primary study of spiral dynamic inspired optimization. **IEEJ Transactions on Electrical and Electronic Engineering**, vol.6, no. S1, pp.: S98-S100, 2011. Citado na página 64.

TAMURA, K.; YASUDA, K. Spiral dynamics inspired optimization. **Journal Advanced Computational Intelligence and Intelligence Informatics**, vol. 15, no 8, pp.: 1116-1122, 2011. Citado 2 vezes nas páginas 64 e 65.

- TEEPARTHI, K.; KUMAR, D. M. Multi-objective hybrid PSO-APO algorithm based security constrained optimal power flow with wind and thermal generators. **Engineering Science and Technology, an International Journal**, accepted March, pp.: 2-16, 2017. Citado na página 20.
- TODOROVSKI, M.; RAJICIC, D. An Initialization Procedure in Solving optimal Power Flow by Genetic Algorithm. **IEEE Transactions on Power Systems**, vol 21, no.2, pp.: 480-487, 2006. Citado na página 17.
- TONG, X.; LIN, M. Semismooth Newton-Type Algorithms for Solving Optimal Power Flow Problems. **Proc: in IEEE PES Transmission and Distribution Conference**, vol 1, pp.: 1-7, 2005. Citado na página 15.
- TUCURI. **Unisna Hidreletrica de Tucuri**. Acessado em 16/06/2017. Disponível em: <[http://cidadedetucurui.com/inicio/usina\\_hidreletrica\\_tucurui/USINA\\_HIDRELETRICA\\_TUCURUI.htm](http://cidadedetucurui.com/inicio/usina_hidreletrica_tucurui/USINA_HIDRELETRICA_TUCURUI.htm)>. Citado 2 vezes nas páginas ix e 42.
- UNIVERSITY OF WASHINGTON. Acessado em 07/04/2017. Disponível em: <<https://www2.ee.washington.edu/research/pstca/>>. Citado na página 18.
- URSEM, R. Diversity-Guided Evolutionary Algorithms. **LNCS 2439, Springer**, pp.: 462-471, 2002. Citado na página 68.
- VASILJEVSKA, J.; LOPES, J.; MATOS, M. Evaluating the impacts of the multi-microgrid concept using multicriteria decision aid. **Electric Power System Research**, pp: 44-51, 2012. Citado na página 23.
- VENKATESH, P.; GNADASS, R.; PADHY, N. Comparasion and application of evolutionary technics to combined economic emissssion dispatch with line flow constraints. **IEEE Transaction on Power Systems**, vol 18, no. 2, 688-697, 2003. Citado na página 17.
- WANG, Y.-M.; LUO, Y. On rank reversal in decision analysis. **Math. Comput. Model.**, vol. 49, no. 56, pp. 1221-1229, Mar., 2009. Citado na página 39.
- WIMMLER, C. et al. Multi-criteria decision support methods for renewable energy systems on islands. **Journal Clean Energy Technol.**, vol. 3, pp. 185-195, 2015. Citado na página 23.
- YAN, W.; LU, S.; YU, D. C. A Novel Optimal Reactive Power Dispatch Method Based on an Improved Hybrid Evolutionary Programming Technique. **IEEE Transaction on Power Systems**, vol 19, no. 2, 913-918, 2004. Citado na página 17.
- YAN, W. et al. A New Optimal Reactive Power Flow Model in Retangular Form and its Solution by Predictor Correrctor Primal Dual Interior Point Method. **IEEE Transactions on Power Systems**, vol 21, no.1, pp.: 61-67, 2008. Citado na página 15.
- YURYEVICH, J.; WONG, K. P. Evolutionary Programming Based Optimal Power Flow Algorithm. **IEEE Transaction on Power Systems**, vol 14, no. 4, 1245-1250, 1999. Citado na página 17.
- Z Aidan, A. et al. Evaluation and selection of open-source EMR software packages based on integrated AHP and TOPSIS. **J. Biomed. Inform.**, vol. 53, pp. 390-404, Feb., 2015. Citado 2 vezes nas páginas 38 e 39.

ZHANG, J.; SANDERSON, A. JADE: Adaptative Differential Evolution with optional external archive. **IEEE Transactions on Evolutionary Computation**, vol. 13, no.5, pp. 945-958, 2009. Citado na página 30.

ZHANG, R. et al. Hybrid computation of corrective security-constrained optimal power flow problems. **IET Gener. Transm. Distrib.**, Vol. 8, Iss. 6, pp. 995-1006, 2014. Citado na página 20.

ZITZLER, E.; LAUMANNNS, L.; THIELE, M. SPEA2: Improving the strength pareto evolutionary algorithm. **TIK-Report 103, May**, 2001. Citado 5 vezes nas páginas 28, 32, 34, 35 e 80.

ZITZLER, E.; THIELE, L. An Evolutionary Algorithm for Multiobjective Optimization: The Strength Pareto Approach. **Technical report: 43, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH), Zurich, Switzerland.**, 1998. Citado 3 vezes nas páginas 32, 34 e 35.