

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Estudo Multicritério do Problema de Despacho Econômico e Ambiental sob Condições de Incerteza

Miguel Monteiro Costa

Área de Concentração: Sistemas de Computação e Te-
lecomunicações

Linha de Pesquisa: Otimização

Orientador: Prof. Dr. Lucas de Souza Batista

Belo Horizonte, MG

2019

| | |
|-----------------|---|
| C837e | <p>Costa, Miguel Monteiro. Estudo multicritério do problema de despacho econômico e ambiental sob condições de incerteza [recurso eletrônico] / Miguel Monteiro Costa. - 2019. 1 recurso online (x, 52 f. : il., color.) : pdf. Orientador: Lucas de Souza Batista.</p> <p>Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.</p> <p>Bibliografia: f. 49-52. Exigências do sistema: Adobe Acrobat Reader.</p> <p>1. Engenharia elétrica - Teses. 2. Incerteza - Teses. 3. Otimização multiobjetivo - Teses. 4. Processo decisório - Teses. I. Batista, Lucas de Souza. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.</p> |
| CDU: 621.3(043) | |

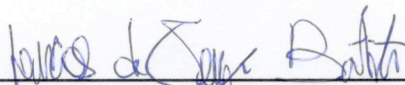
"Estudo Multicritério do Problema de Despacho Econômico e Ambiental Sob Condições de Incerteza"

Miguel Monteiro Costa

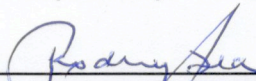
Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 09 de julho de 2019.

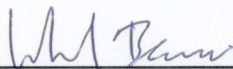
Por:



Prof. Dr. Lucas de Souza Batista
DEE (UFMG) - Orientador



Prof. Dr. Rodney Rezende Saldanha
DEE (UFMG)



Prof. Dr. Michel Bessani
DEE (UFMG)

Agradecimentos

Agradeço primeiramente a Deus pela vida, pela saúde, pelas oportunidades, por tudo.

Agradeço ao meu orientador, professor Lucas de Souza Batista, pelos enriquecedores ensinamentos durante esta pesquisa.

A todos os professores do Programa de Pós-Graduação em Engenharia Elétrica da UFMG pelo excelente trabalho que realizam.

À Universidade Federal de Ouro Preto, por me conceder condições para a realização deste curso.

À minha namorada, Ana Luisa Soares, e à minha família pelo apoio incondicional.

Aos meus amigos Paulo César Ferreira Freitas e Thiago Martins Firmo, pelo apoio e por importantes dicas durante esta trajetória.

Resumo

Com a crescente preocupação com a degradação ambiental, um planejamento de sistemas de geração de energia que visa minimizar apenas o custo de geração não representa uma abordagem adequada para esta tarefa. Nesse sentido, no problema de Despacho Econômico e Ambiental estudado visa-se minimizar dois objetivos conflitantes: custo de geração e emissão de poluentes em sistemas termoelétricos de geração de energia elétrica. No contexto deste problema, poucos trabalhos na literatura incorporam o tratamento de incertezas. Desta forma, este trabalho estuda o problema considerando incertezas na estimação de seus objetivos a partir do emprego de parâmetros nebulosos. É proposta uma otimização robusta, na qual investiga-se soluções ótimas para o pior cenário de incertezas. Uma variação do algoritmo MOEA/D é empregada frente à modelagem proposta. Além disso, dado um conjunto de soluções promissoras obtido para este problema, é também proposta uma análise multicritério destas soluções, onde emprega-se métodos de auxílio à tomada de decisão, de modo a se definir uma ação final de maneira mais adequada. Essa metodologia é aplicada a dois sistemas termoelétricos de geração, resultando em contribuições para a literatura no estudo de problemas com incertezas e no processo de tomada de decisão assistido.

Palavras-Chaves: Despacho Econômico e Ambiental, Otimização Multiobjetivo, Incertezas, MOEA/D Robusto, Tomada de Decisão.

Abstract

With the growing concern about environmental degradation, planning power generation systems that aims to minimize only the generation cost is not an appropriate approach to this task. In this sense, the problem of Environmental Economic Dispatch studied in this work aims to minimize two conflicting objectives: generation cost and emission of pollutants in thermoelectric generation systems. In the context of this problem, few researches in the literature incorporate inherent uncertainties. In this way, this work studies the problem considering uncertainties in the estimation of its objectives by the use of fuzzy parameters. Robust optimization is proposed, in which optimal solutions are investigated for the worst case minimization. A variation of the MOEA/D algorithm is employed in the proposed modeling. In addition, given a set of promising solutions obtained for this problem, a multicriteria analysis of these solutions is also proposed, whereby decision support methods are used, in order to define a final action in a more adequate way. This methodology is applied to two thermoelectric generation systems, resulting in contributions to the literature in the study of problems with uncertainties and in the process of decision making aid.

Keywords: Environmental Economic Dispatch, Multi-objective Optimization, Uncertainties, Robust MOEA/D, Decision Making.

Lista de ilustrações

| | |
|--|----|
| Figura 1 – Matriz elétrica brasileira, referente a 2017. | 1 |
| Figura 2 – Estrutura de uma usina termoelétrica convencional. | 13 |
| Figura 3 – Função de custo de uma unidade termoelétrica com e sem o efeito do ponto de válvula. | 20 |
| Figura 4 – Função de pertinência de um número nebuloso. | 22 |
| Figura 5 – Método α -cut. | 22 |
| Figura 6 – MOEA/D Robusto. | 27 |
| Figura 7 – Estrutura hierárquica genérica adotada no AHP. | 30 |
| Figura 8 – Hipervolume de um conjunto de soluções. | 37 |
| Figura 9 – <i>Box plot</i> dos resultados obtidos para o sistema com 6 usinas. | 38 |
| Figura 10 – <i>Box plot</i> dos resultados obtidos para o sistema com 10 usinas. | 38 |
| Figura 11 – Fronteiras obtidas para diferentes níveis de incerteza para o sistema de 6 usinas. | 39 |
| Figura 12 – Fronteiras obtidas para diferentes níveis de incerteza para o sistema de 10 usinas. | 40 |
| Figura 13 – Soluções não dominadas robustas para o sistema com 6 usinas. A solução representada por 'x' corresponde à solução indicada pelas três estratégias de suporte à tomada de decisão. | 44 |
| Figura 14 – Soluções não dominadas robustas para o sistema com 10 usinas. A solução numerada por 1 foi a selecionada na Tomada de Decisão Fuzzy e a solução 2 foi a obtida nos processos de Tomada de Decisão Multicritério <i>Fuzzy</i> e Tomada de Decisão Multicritério via AHP e TOPSIS. | 46 |

Lista de tabelas

| | |
|--|----|
| Tabela 3 – Diferenças entre os ambientes de contratação regulada e de contratação livre. | 12 |
| Tabela 4 – Classificação dos combustíveis segundo seu estado físico. | 15 |
| Tabela 5 – Escala Fundamental de Comparações. | 30 |
| Tabela 6 – Valores de RI em função da ordem da matriz. | 31 |
| Tabela 7 – Parâmetros para o sistema com 6 unidades geradoras | 34 |
| Tabela 8 – Parâmetros para o sistema com 10 unidades geradoras - Parte 1 | 35 |
| Tabela 9 – Parâmetros para o sistema com 10 unidades geradoras - Parte 2 | 35 |
| Tabela 10 – Julgamentos entre os critérios. | 43 |
| Tabela 11 – Soluções não dominadas robustas para o sistema com 6 usinas. | 43 |
| Tabela 12 – Soluções não dominadas robustas para o sistema com 10 usinas - Parte 1. | 45 |
| Tabela 13 – Soluções não dominadas robustas para o sistema com 10 usinas - Parte 2. | 45 |

Lista de símbolos

| | |
|---|--|
| f_i | i -ésima função objetivo |
| x | vetor de variáveis de decisão |
| n_f | número de funções objetivo |
| n_v | número de variáveis de decisão |
| n_s | número de soluções não dominadas |
| $\Omega \subset \mathbb{R}^{n_v}$ | espaço de decisão viável |
| $g_i(x)$ | i -ésima restrição de desigualdade |
| n_g | número de restrições de desigualdade |
| $h_i(x)$ | i -ésima restrição de igualdade |
| n_h | número de restrições de igualdade |
| $F(P)$ | custo total de geração |
| n_u | número de usinas termoelétricas |
| P_i | potência ativa produzida pela i -ésima usina |
| a_i, b_i, c_i, d_i, e_i | parâmetros da função de custo de geração da i -ésima usina |
| P_i^{min} | valor mínimo de potência ativa produzida pela i -ésima usina |
| P_i^{max} | valor máximo de potência ativa produzida pela i -ésima usina |
| $E(P)$ | emissão total de poluentes |
| $\alpha_i, \beta_i, \gamma_i, \xi_i, \varphi_i$ | parâmetros da função de emissão de poluentes da i -ésima usina |
| P_d | potência total demandada |
| P_{loss} | perdas de potência ativa nas linhas da rede |
| \tilde{a} | número <i>fuzzy</i> |
| $a_0, \underline{a}, \bar{a}$ | valor modal e limitantes inferior e superior de um número <i>fuzzy</i> , respectivamente |
| $\mu_{\tilde{a}}$ | função de pertinência de um número <i>fuzzy</i> |
| \tilde{z} | coeficientes difusos |
| g | função de escalarização |
| g^{te} | função de escalarização de Tchebycheff |
| $\lambda \in \Lambda$ | vetor de peso no MOEA/D |
| z | ponto de referência no MOEA/D |
| X | população de soluções |
| $B(i)$ | i -ésima vizinhança de soluções |

| | |
|-----------------|---|
| N | número de soluções |
| T | número de vetores de peso em uma vizinhança |
| Π | população de perturbações |
| δ | probabilidade de selecionar soluções dentro da vizinhança |
| n_r | número máximo de soluções substituídas |
| \bar{y} | vetor de variáveis de decisão |
| y | vetor de variáveis de decisão |
| F_{cross} | Parâmetro de controle do método <i>Differential Evolution</i> |
| CR | Parâmetro de controle do método <i>Differential Evolution</i> |
| $rand$ | número aleatório de domínio $[0, 1]$ |
| η | índice de distribuição |
| L_k | limite inferior da k -ésima variável de decisão |
| U_k | limite superior da k -ésima variável de decisão |
| λ_{max} | máximo autovalor |
| n | ordem da matriz de comparações |
| D | matriz de decisão |
| n_o | número de critérios |
| R | matriz de decisão normalizada |
| w_j | ponderação do j -ésimo critério |
| V | matriz de decisão normalizada ponderada |
| J' | conjunto de critérios de benefício |
| J'' | conjunto de critérios de custo |
| S_{i+} | distância Euclidiana e relação à PIS |
| S_{i-} | distância Euclidiana e relação à NIS |
| v_{j+} | j -ésima cordenada da PIS |
| v_{j-} | j -ésima cordenada da NIS |
| y_r | ponto de referência no <i>Hypervolume</i> |
| f_i^{max} | máximo valor da i -ésima função objetivo |
| Λ_{HV} | medida de Lebesgue |
| s_i | i -ésima solução do conjunto de soluções S |
| h_i | hipercubo definido por s_i e y_r |
| μ_{norm} | função de pertinência normalizada |

Lista de abreviaturas

| | |
|---------|--|
| UHE | Usina Hidrelétrica |
| UTE | Usina Termoelétrica |
| EPE | Empresa de Pesquisa Energética |
| SIN | Sistema Interligado Nacional |
| ONS | Operador Nacional do Sistema Elétrico |
| ANEEL | Agência Nacional de Energia Elétrica |
| CCEE | Câmara de Comercialização de Energia Elétrica |
| PLD | Preço de Liquidação das Diferenças |
| ACR | Ambiente de Contratação Regulada |
| ACL | Ambiente de Contratação Livre |
| DE | Despacho Econômico |
| DEA | Despacho Econômico e Ambiental |
| PSO | <i>Particle Swarm Optimization</i> |
| SPEA | <i>Strength Pareto Evolutionary Algorithm</i> |
| NSGA-II | <i>Nondominated Sorting Genetic Algorithm-II</i> |
| MCI | Motor de Combustão Interna |
| S | Conjunto Pareto-ótimo |
| PF | Fronteira Pareto-ótima |
| MOEA/D | <i>Multiobjective Evolutionary Algorithm Based on Decomposition</i> |
| AHP | <i>Analytic Hierarchy Process</i> |
| CI | Índice de Consistência |
| RI | Índice Aleatório |
| CR | Razão de Consistência |
| TOPSIS | <i>Technique for Order of Preference by Similarity to Ideal Solution</i> |
| PIS | Solução Ideal Positiva |
| NIS | Solução Ideal Negativa |
| CC | Coefficiente de Aproximação |
| HV | <i>Hypervolume</i> |

Sumário

| | | |
|----------|--|-----------|
| 1 | INTRODUÇÃO | 1 |
| 1.1 | Apresentação | 1 |
| 1.2 | Motivação e Justificativa | 2 |
| 1.3 | Objetivos | 3 |
| 1.3.1 | Objetivos Específicos | 3 |
| 1.4 | Contribuições | 4 |
| 1.5 | Revisão Bibliográfica | 4 |
| 1.6 | Estrutura do Trabalho | 8 |
| 2 | AUTARQUIAS BRASILEIRAS E GERAÇÃO TERMOELÉTRICA | 9 |
| 2.1 | O Mercado de Energia Brasileiro | 9 |
| 2.2 | Geração Termoelétrica | 12 |
| 2.2.1 | Usina Termoelétrica | 13 |
| 2.2.2 | Motor de Combustão Interna | 14 |
| 2.2.3 | Recursos Energéticos | 14 |
| 2.2.4 | Impactos Ambientais da Geração Termoelétrica | 15 |
| 2.3 | Conclusões | 16 |
| 3 | ABORDAGEM PROPOSTA | 18 |
| 3.1 | Problema de Otimização Multiobjetivo | 18 |
| 3.2 | O Problema de Despacho Econômico e Ambiental | 19 |
| 3.2.1 | Custo de Geração | 19 |
| 3.2.2 | Emissão de Poluentes | 20 |
| 3.2.3 | Restrições | 20 |
| 3.3 | Despacho Econômico e Ambiental na Presença de Incertezas | 21 |
| 3.3.1 | Números <i>Fuzzy</i> | 21 |
| 3.3.2 | Método α -cut | 22 |
| 3.3.3 | O Problema de Otimização Robusta para o DEA | 23 |
| 3.4 | MOEA/D Robusto | 23 |
| 3.5 | Estratégia de Suporte à Tomada de Decisão | 28 |
| 3.5.1 | <i>Analytic Hierarchy Process</i> - AHP | 29 |
| 3.5.2 | TOPSIS | 31 |
| 3.6 | Conclusões | 33 |
| 4 | RESULTADOS | 34 |
| 4.1 | Estudos de Caso | 34 |

| | | |
|-----|---|----|
| 4.2 | Ajuste de Parâmetros | 36 |
| 4.3 | Análise do Impacto do Domínio de Incertezas | 38 |
| 4.4 | Tomada de Decisão | 41 |
| 4.5 | Conclusões | 46 |
| 5 | CONCLUSÕES | 47 |
| 5.1 | Considerações Finais | 47 |
| 5.2 | Propostas de Trabalhos Futuros | 48 |
| 5.3 | Publicações Decorrentes desta Pesquisa | 48 |
| | REFERÊNCIAS | 49 |

1 Introdução

1.1 Apresentação

A energia elétrica já há muito é considerada um fator essencial à vida. Neste sentido, a busca por confiabilidade (disponibilidade) na produção e fornecimento de energia é cada vez mais exigida (ANEEL, 2018).

A utilização de usinas hidroelétricas (UHEs), predominante no Brasil, tem a vantagem da não necessidade de um combustível fóssil para a produção da energia, como ocorre nas usinas termoeletricas (UTEs), embora apresentem um maior custo de instalação. No entanto, UHEs estão sujeitas a sazonalidades climáticas e dependência de afluentes, o que justifica o uso de UTEs de forma complementar, visando aumentar a confiabilidade, no que diz respeito à geração do sistema elétrico (Oliveira, 2015). A Figura 1 apresenta a matriz elétrica brasileira, referente ao ano de 2017, onde a geração a partir de usinas termoeletricas correspondeu a 25,3% (biomassa, carvão, petróleo e derivados e gás natural).




Figura 1 – Matriz elétrica brasileira, referente a 2017.

Fonte: (EPE, 2018)

Sistemas termoeletricos eficientes de geração de energia elétrica devem atender à demanda ao menor custo de geração possível. Este custo está associado principalmente ao consumo de combustível, necessário a estas usinas. Essa eficiência pode ser obtida através do despacho econômico (DE), que consiste na alocação da potência ativa a ser gerada entre as usinas, de modo a minimizar este custo, sujeito a restrições operacionais e de carga (Panta; Premrudeepreechacharn, 2007).

1.2 Motivação e Justificativa

Como é grande a preocupação com as emissões de poluentes provenientes de usinas que utilizam combustíveis fósseis, o despacho que visa minimizar apenas o custo total de geração não é uma opção tão adequada ao problema (Azevedo, 2015).

Com o objetivo de se obter uma menor emissão de poluentes na geração a partir de UTEs, segundo (Abido, 2003; Cai et al., 2007) pode-se adotar medidas como o emprego de combustíveis menos poluidores, a instalação de equipamentos de limpeza pós-combustão, substituição de equipamentos envelhecidos, ou a realização de um despacho que já incorpore esta questão ambiental. As três primeiras opções envolvem gastos consideráveis, podendo ser adotadas em um planejamento à longo prazo (Abido, 2003). Em função disso, a incorporação do fator emissão de poluentes no planejamento do despacho de potência torna-se uma medida atraente à curto prazo.

Nesse contexto, a operação de sistemas de geração a partir de usinas térmicas tem lidado com o problema de despacho econômico e ambiental (DEA). Neste cenário, visa-se minimizar simultaneamente dois objetivos conflitantes: o custo total de geração e a emissão de poluentes.

Na literatura especializada, diversos autores têm abordado esse problema de otimização por meio de métodos baseados em inteligência computacional, como algoritmos evolutivos e algoritmos baseados em enxames. Uma vez que estes métodos evoluem as características de uma população de soluções candidatas durante o processo de busca, várias soluções promissoras podem ser encontradas a cada execução, o que representa uma das principais características destes métodos (Qu et al., 2018). Em relação aos modelos propostos para o problema de DEA, observa-se modelos comumente determinísticos, que possuem deficiências em representar o ambiente prático que, por sua vez, é geralmente impreciso e dinâmico.

Dentre os trabalhos presentes na literatura, poucos modelam incertezas inerentes ao problema. Estas incertezas estão tipicamente presentes na demanda, na precificação dos combustíveis ou, de maneira mais geral, nas funções objetivo do problema. Neste sentido, em (Jin et al., 2015), propõe-se uma penalização nas duas funções objetivo (custo de geração e emissão de poluentes) devido à incertezas no valor de demanda. Esta, por sua vez, é proveniente de uma metodologia de previsão cujo valor estimado é somado a um erro aleatório.

O emprego de conceitos da teoria de conjuntos *fuzzy* também é uma alternativa para a incorporação de incertezas (Zhang et al., 2005), (Bedrinana et al., 2007), (Salhi; Naimi; Bouktir, 2013), (Mousa, 2014). No trabalho presente em (Salhi; Naimi; Bouktir, 2013), os autores associam a cada função objetivo uma função de pertinência, definida

pelos valores mínimo desejável e máximo aceitável destes objetivos, de modo a considerar as incertezas. Já em (Zhang et al., 2005) e (Mousa, 2014), os parâmetros das funções objetivo são assumidos como números *fuzzy*.

O uso de parâmetros estocásticos também está presente em (King; Rughooputh; Deb, 2005), onde a geração de cada usina, as perdas de potência ativa no sistema de transmissão e os parâmetros das funções de custo de geração e emissão de poluentes são tomados como estocásticos, em que se assume normalidade na distribuição de probabilidade destes valores. Já em (Assis et al., 2018), embora os autores empreguem parâmetros determinísticos, é adicionada uma variável de incerteza a cada variável de decisão, definida dentro de um domínio específico. Neste cenário, os autores realizam uma otimização robusta, visando otimizar os objetivos no espaço de incerteza.

Com base nos trabalhos destacados anteriormente, pesquisas envolvendo a incorporação de incertezas no problema de DEA, visando desenvolver modelos que melhor representem o ambiente prático deste problema, são bem vindas na literatura especializada. Além disso, dada a característica multiobjetivo do problema e a consequente obtenção de um conjunto de soluções promissoras, outra carência observada ocorre na definição da ação (i.e., solução) final a ser implementada. A seguir são apresentados os objetivos e as contribuições desta pesquisa.

1.3 Objetivos

O principal objetivo deste trabalho é o estudo do problema de despacho econômico e ambiental considerando incertezas na estimação de seus objetivos (custo de geração e emissão de poluentes), onde visa-se a realização de uma otimização robusta, com o intuito de se identificar as melhores soluções viáveis considerando-se o pior cenário de incertezas, cenário este pertinente no setor elétrico, caracterizado por consideráveis oscilações de mercado e discussões envolvendo as melhores formas, econômicas e ambientais, de se produzir energia.

1.3.1 Objetivos Específicos

Visando-se atingir o objetivo principal, foram definidos os seguintes objetivos específicos:

- Investigação e simulações de uma modelagem determinística do problema de DEA, visando um melhor entendimento deste, de suas limitações e possíveis melhorias.
- Definição de um modelo de otimização a partir de parâmetros incertos do problema, de modo a incorporar incertezas em suas funções objetivo.

- Proposição de uma ferramenta de otimização robusta para este problema, visando uma otimização de pior caso.
- Definição de critérios adicionais de desempenho que possibilitem uma análise multicritério do problema, para assim, a partir de métodos de auxílio à tomada de decisão, indicar uma solução adequada ao problema de despacho econômico e ambiental, dadas as preferências do projetista, i.e., tomador de decisão.

1.4 Contribuições

Acredita-se que os pontos a seguir são contribuições desta dissertação:

- Desenvolvimento de uma nova modelagem para o problema de DEA visando a incorporação de incertezas, onde os parâmetros das funções de custo e emissão de poluentes deste problema são tratados como valores incertos, que apresentam uma faixa de variação, de modo a incorporar incertezas inerentes a estes objetivos, modelando de maneira mais próxima o ambiente prático.
- Investigação do impacto do domínio de incertezas no processo de solução do DEA.
- Proposição de uma ferramenta para a análise multicritério das soluções promissoras obtidas, a qual sustenta o processo de tomada de decisão. Como critérios adotados, são considerados os dois objetivos do problema, além do total de perdas de potência ativa na rede de transmissão e o valor médio do percentual de utilização das unidades geradoras.

1.5 Revisão Bibliográfica

O problema de despacho econômico e ambiental, DEA, tem chamado a atenção de pesquisadores nas últimas décadas, devido a crescente preocupação com a degradação ambiental, consequente da operação de usinas geradoras. Este problema, de forma geral, visa a minimização de dois objetivos conflitantes: o custo de geração e a emissão de poluentes. Trata-se, basicamente, de uma generalização do clássico problema de despacho econômico, DE, que, de maneira geral, visa atender a uma demanda ao menor custo de geração possível, sujeito a restrições operacionais e de carga (Panta; Premrudeepreechacharn, 2007).

As primeiras pesquisas dedicadas ao problema de DEA datam da década de 1990. Esses trabalhos frequentemente empregavam métodos convencionais de otimização, como os de programação linear (Talaq; El-Hawary; El-Hawary, 1994), (Farag; Al-Baiyat; Cheng,

1995), onde o objetivo ambiental era comumente modelado junto às restrições do problema. Ainda neste período, foram empregados alguns métodos não lineares, como o método do Lagrangiano Aumentado (Gjengedal; Johansen; Hansen, 1992), Iteração Lambda (Hu; Wee, 1994) e Algoritmo Genético (Song et al., 1997), em que a função objetivo era dada por uma soma ponderada entre os objetivos econômico e ambiental.

Métodos exatos de otimização se tornam menos eficazes frente ao problema de DEA quando este cresce em complexidade, o que tem levado muitos pesquisadores a empregar métodos baseados em inteligência artificial, especialmente algoritmos evolutivos e métodos baseados em enxame (Qu et al., 2018), sendo estes métodos os mais utilizados nos trabalhos aqui destacados.

O emprego de uma soma ponderada entre os objetivos também está presente em pesquisas mais recentes, como em (Azevedo, 2015), (Singh; Dhillon, 2016), (Hussien; Kamel; Ebeed, 2017) e (Chansareewittaya; Soponronnarit; Boonyanant, 2018). Nesses trabalhos, as emissões são modeladas como um custo ambiental o qual é somado ao custo de geração, de forma ponderada. Em (Singh; Dhillon, 2016), são utilizados multiplicadores de Lagrange e fatores de penalidade para incorporar as restrições junto à função objetivo, obtendo assim, um problema de otimização irrestrito. As demais pesquisas citadas empregam metaheurísticas, tais como *Particle Swarm Optimization* e *Differential Evolution* (Azevedo, 2015), (Hussien; Kamel; Ebeed, 2017), (Chansareewittaya; Soponronnarit; Boonyanant, 2018).

Uma abordagem muito adotada para o problema de DEA consiste na definição de um problema multiobjetivo não linear restrito, modelagem esta impulsionada pelo surgimento/aperfeiçoamento, num período mais recente, de diversos algoritmos para problemas de otimização multiobjetivo.

Na literatura, várias pesquisas estudam a otimização simultânea dos dois objetivos: custo de geração e emissão de poluentes. Nesse contexto, em (Abido, 2003) é empregado o algoritmo *Strength Pareto Evolutionary Algorithm* (SPEA). O algoritmo *Nondominated Sorting Genetic Algorithm-II* (NSGA-II) é empregado tanto em (King; Rughooputh; Deb, 2005) quanto em (Assis et al., 2018). Já a metaheurística PSO é empregada em (Zhang et al., 2010) e (Bilil; Ellaia; Maaroufi, 2012). Esta metaheurística também é citada em (Gong; Zhang; Qi, 2010), onde é desenvolvido um algoritmo híbrido multiobjetivo composto pelos métodos PSO e *Differential Evolution*. Um algoritmo híbrido também é empregado em (Mousa, 2014), definido a partir das metaheurísticas *Ant Colony* e *Genetic Algorithm*.

Além da minimização do custo de geração e da emissão de poluentes, a minimização das perdas de potência ativa na rede de transmissão é também assumida como um objetivo em alguns trabalhos. Diante deste problema com três objetivos conflitantes, em (Amorim

et al., 2009) os autores propõem um algoritmo evolucionário multiobjetivo que explora um mecanismo de preservação da diversidade para evitar a convergência prematura e torná-lo capaz de encontrar um conjunto de soluções de compromisso diversificado. Em (Shayeghi; Ghasemi, 2014), utiliza-se um algoritmo *Bee Colony*, que usa um mecanismo de busca local para aprimorar a busca por soluções. Diferentemente destes dois trabalhos, a pesquisa presente em (Pal; Kumar, 2013) apresenta uma versão linear para o problema, com a utilização de aproximações por Série de Taylor e incertezas nos dados disponíveis.

Ainda na abordagem com três objetivos para o problema de despacho, a pesquisa presente em (Salhi; Naimi; Bouktir, 2013) considera, além dos objetivos relacionados ao custo operacional e à emissão de poluentes, a minimização dos desvios de tensão nas barras da rede, usando a teoria de conjuntos fuzzy para modelar incertezas nas funções objetivo. O trabalho presente em (Aichen; Weiguo; Wenhuan, 2014), além de considerar as funções de custo operacional e emissão de poluentes, modela como terceiro objetivo o tempo de resposta das usinas frente ao comando de despacho, ou seja, o tempo mínimo de ajuste de carga. Ambos os trabalhos empregam métodos baseados na metaheurística PSO.

Na literatura especializada, alguns trabalhos tratam o problema de DEA considerando incertezas inerentes a este problema. Neste sentido, a pesquisa presente em (King; Rughooputh; Deb, 2005) apresenta uma abordagem onde os objetivos do problema são definidos por um valor esperado somado a um desvio-padrão esperado. Nesta modelagem, os valores de potência ativa gerados, as perdas nas linhas de transmissão, bem como os coeficientes das funções objetivo consistem em valores estocásticos, onde assume-se uma distribuição normal destes valores.

O uso de conceitos da teoria de conjuntos *fuzzy* também é uma alternativa para a incorporação de incertezas ao problema de DEA. Em (Zhang et al., 2005) aborda-se o problema considerando-se incertezas nos parâmetros das funções de custo e emissão de poluentes, onde estes parâmetros são assumidos como números *fuzzy*. É realizada uma soma ponderada dos objetivos, onde são empregados um método de ponderação baseado em um ponto ideal e um algoritmo evolucionário híbrido, que engloba técnicas quasi-simplex e um método de ranqueamento de números fuzzy. O uso de números *fuzzy* como parâmetros das funções objetivo também é abordado em (Mousa, 2014). Nesta pesquisa, os autores empregam o método α -cut para ponderar o nível de incerteza associado a estes parâmetros.

Ainda empregando-se lógica *fuzzy*, em (Salhi; Naimi; Bouktir, 2013) é associada, a cada função objetivo, uma função de pertinência definida a partir dos valores mínimo desejável e máximo aceitável de cada objetivo. O operador max-min é usado para maximizar o grau de satisfação de todas as funções de pertinência, porém, a modelagem final

mono-objetivo obtida inviabiliza, assim como em (Zhang et al., 2005), a análise de um conjunto de soluções potenciais para o problema.

Em (Jin et al., 2015), propõe-se uma penalização nas duas funções objetivo (custo de geração e emissão de poluentes) devido a incertezas no valor de demanda, as quais são relacionadas à superestimação ou subestimação desta. Esta demanda, por sua vez, é proveniente de uma metodologia de previsão cujo valor estimado é somado a um erro aleatório. Também é definida uma probabilidade de falta (contingência) de alguma usina. Esta formulação é tratada por um algoritmo baseado na metaheurística PSO.

Já em (Assis et al., 2018), propõe-se um modelo de otimização robusta no qual é adicionada uma variável de incerteza a cada variável de decisão, definida dentro de um domínio específico. Também é realizada a estimação do cenário de pior caso, ou seja, é feita a otimização dos objetivos diante do cenário de incerteza que mais os deteriora. Frente a este problema, é aplicado um algoritmo para otimização robusta baseado no NSGA-II.

Conforme trabalhos revisados, observa-se que poucos deles apresentam um estudo visando indicar, a partir do conjunto de soluções estimadas, a solução mais adequada ao problema. Um método de auxílio à tomada de decisão baseado em conceitos da teoria de conjuntos *fuzzy* é empregado nos trabalhos presentes em (Abido, 2003), (Amorim et al., 2009) e (Shayeghi; Ghasemi, 2014), que define um ranqueamento das soluções com base nos valores dos objetivos. Adicionalmente, em (Aichen; Weigu; Wenhuan, 2014) é empregado um método de tomada de decisão multiatributo, que a partir dos valores dos objetivos e de um ponto de referência, calcula coeficientes de ponderação e assim ordena as soluções. Nota-se, entretanto, que critérios adicionais relacionados ao DEA não são considerados durante a decisão, o que limita o processo de definição da solução final e possivelmente sua qualidade.

De forma geral, os trabalhos discutidos anteriormente contribuem com a literatura em diversos aspectos, porém, apresentam limitações quanto a modelagem do problema, análise dos cenários de incerteza e a proposição de uma ferramenta integrada para otimização multiobjetivo e auxílio à tomada de decisão.

Com o intuito de minimizar as limitações destacadas, propõe-se uma modelagem para o problema de DEA na qual os parâmetros das funções objetivo deixam de ser valores escalares e passam a ser definidos dentro de um domínio de incertezas. A partir desta modelagem, realiza-se uma análise do impacto do domínio de incertezas nas soluções do DEA, visando qualificar e quantificar o efeito dessa variabilidade nas soluções do problema. Finalmente, investiga-se soluções eficientes que minimizem o pior caso dos cenários de incerteza. Após a obtenção desse conjunto de soluções de compromisso, emprega-se uma ferramenta de auxílio à tomada de decisão, juntamente com uma análise multicritério, de

modo a se definir uma solução final de maneira mais adequada, de acordo com as preferências do projetista. Nessa ferramenta de suporte à decisão são considerados critérios adicionais, tais como as perdas de potência ativa na rede de transmissão e o valor médio do percentual de utilização das unidades geradoras (razão entre a potência utilizada e a capacidade da unidade).

1.6 Estrutura do Trabalho

Os assuntos discutidos nesta pesquisa estão organizados conforme mostrado a seguir.

Capítulo 2 - Autarquias Brasileiras e Geração Termoelétrica: Visando a contextualização do problema estudado, este capítulo discorre sobre o mercado de energia brasileiro e também sobre os principais aspectos relacionados à geração de energia elétrica a partir de UTEs. São apresentados as diferentes classificações deste tipo de usina, aspectos construtivos, com destaque para o Motor de Combustão Interna, recursos energéticos, além dos impactos ambientais provocados por este tipo de geração.

Capítulo 3 - Abordagem Proposta: Este capítulo apresenta o problema de DEA e sua modelagem na presença de incertezas, bem como as metodologias empregadas em sua resolução. Dentre estas, estão presentes o algoritmo dedicado a este tipo de problema, o MOEA/D Robusto, e a estratégia proposta para a tomada de decisão, que engloba uma análise multicritério e o uso de métodos de auxílio à tomada de decisão.

Capítulo 4 - Resultados: Como forma de ilustrar e validar a metodologia proposta, a mesma é aplicada a dois sistemas termoelétricos de geração. O capítulo inicialmente apresenta um estudo voltado para o ajuste de alguns parâmetros, posteriormente realiza uma análise do impacto do domínio de incertezas e, por fim, aplica uma análise multicritério para a indicação da solução mais adequada (tomada de decisão).

Capítulo 5 - Conclusões: Nesse capítulo são ressaltados os resultados obtidos para os cenários avaliados, bem como a relevância da metodologia geral apresentada. Perspectivas para a continuação da pesquisa deste trabalho também são discutidas.

2 Autarquias Brasileiras e Geração Termoelétrica

2.1 O Mercado de Energia Brasileiro

O setor elétrico brasileiro possui um modelo de operação diferenciado em relação ao restante do mundo. No país, há um enorme potencial energético a ser explorado, principalmente no que diz respeito às fontes renováveis, o que implica em constantes inovações tecnológicas e regulatórias (CCEE, 2018).

De maneira geral, o Sistema Interligado Nacional (SIN) consiste em um sistema hidro-termo-eólico de grande porte. Sua capacidade instalada é composta, principalmente, por usinas hidrelétricas distribuídas em dezesseis bacias hidrográficas nas diferentes regiões do país. Nos últimos anos, observou-se um crescimento na instalação de usinas eólicas, principalmente nas regiões Nordeste e Sul, sendo este tipo de geração importante no atendimento ao mercado.

Já as usinas térmicas se apresentam, de maneira geral, próximas aos principais centros de carga, e desempenham papel estratégico relevante pois contribuem para a segurança do SIN. Essas usinas são despachadas em função de condições hidrológicas e de carga, permitindo a gestão dos estoques de água armazenada nos reservatórios das usinas hidrelétricas, complementando a geração hidrelétrica em períodos de estiagem e em horários de pico.

Conforme (CCEE, 2018), o sistema é atualmente dividido em quatro submercados: Sul, Sudeste/Centro-Oeste, Nordeste e Norte. Cada um deles concentra regiões do país onde a energia circula livremente, sendo os limites entre estes submercados determinados por restrições elétricas no fluxo de energia entre as diversas regiões do país. No mercado brasileiro de energia elétrica, estão presentes três agentes fundamentais, discutidos a seguir.

Agência Nacional de Energia Elétrica (ANEEL): A ANEEL consiste em uma autarquia em regime especial vinculada ao Ministério de Minas e Energia, criada em 1997 para regular o setor elétrico brasileiro. Suas principais atribuições são (ANEEL, 2018):

- Regular as operações de geração, transmissão, distribuição e comercialização de energia elétrica;
- Fiscalizar, diretamente ou mediante convênios com órgãos estaduais, as concessões,

as permissões e os serviços de energia elétrica;

- Implementar as políticas e diretrizes do governo federal relativas à exploração da energia elétrica e ao aproveitamento dos potenciais hidráulicos;
- Estabelecer tarifas;
- Tratar as divergências, na esfera administrativa, entre os agentes e entre esses agentes e os consumidores; e
- Promover as atividades de concessão, permissão e autorização de empreendimentos e serviços de energia elétrica, por delegação do Governo Federal.

Operador Nacional do Sistema Elétrico (ONS): Criado em 1998 como pessoa jurídica de direito privado, sob a forma de associação civil sem fins lucrativos, o ONS é o órgão responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no SIN e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (ANEEL). A atuação do ONS tem como objetivos (ONS, 2018):

- Promover a otimização da operação do sistema eletroenergético, visando o menor custo para o sistema, observados os padrões técnicos e os critérios de confiabilidade estabelecidos pela Aneel;
- Garantir que todos os agentes do setor elétrico tenham acesso à rede de transmissão de forma não discriminatória; e
- Contribuir para que a expansão do SIN se faça ao menor custo e vise as melhores condições operacionais futuras.

Câmara de Comercialização de Energia Elétrica (CCEE): É a instituição responsável por viabilizar a comercialização de energia elétrica no Brasil.

Constituída em 2004 como associação civil sem fins lucrativos, a CCEE consiste em uma estrutura que envolve aspectos regulatórios, operacionais e tecnológicos, de modo a viabilizar as operações de compra e venda de energia em todo o Sistema Interligado Nacional. Além de viabilizar as atividades de comercialização, a CCEE tem o papel de fomentar discussões voltadas ao aprimoramento do mercado, promovendo fóruns com as demais instituições do setor elétrico, os agentes e suas associações representativas (CCEE, 2018).

A CCEE atua desde a medição da energia gerada e efetivamente consumida até a liquidação financeira dos contratos de compra e de venda no mercado de curto prazo.

Neste último, ela é a responsável pelo cálculo e divulgação do Preço de Liquidação das Diferenças (PLD), utilizado para definir valores nas operações de compra e venda de energia. O PLD é divulgado semanalmente para cada patamar de carga e submercado.

No processo de liquidação financeira, após a contabilização dos volumes de energia negociados pelos agentes e apuradas as diferenças entre os montantes contratados e os efetivamente gerados/consumidos, realiza-se este processo para efetivar o acerto de contas entre os agente credores e os devedores. Além disso, a CCEE também promove os leilões de energia, sob delegação da Aneel. Outras principais atribuições da instituição são:

- Implantar e divulgar regras e procedimentos de comercialização;
- Fazer a gestão de contratos do Ambiente de Contratação Regulada (ACR) e do Ambiente de Contratação Livre (ACL);
- Manter o registro de dados de energia gerada e de energia consumida;
- Apurar infrações que sejam cometidas pelos agentes do mercado e calcular penalidades;
- Servir como fórum para a discussão de ideias e políticas para o desenvolvimento do mercado, fazendo a interlocução entre os agentes do setor com as instâncias de formulação de políticas e de regulação.

Nas relações comerciais no atual modelo, uma vez que um agente de mercado (distribuidor, gerador, comercializador, consumidor livre ou especial) se torne membro do SIN, pode negociar energia com qualquer outro agente, independentemente das restrições físicas de geração e transmissão. Estas relações se estabelecem em duas esferas: no Ambiente de Contratação Regulada (ACR) e no Ambiente de Contratação Livre (ACL).

No ACR, a compra e venda de energia é formalizada por meio de contratos celebrados entre os geradores e os distribuidores, que participam dos leilões de compra e venda de energia. Esses contratos possuem regulação específica para aspectos como preço da energia, submercado de registro do contrato e vigência de suprimento, não passíveis de alterações bilaterais pelos agentes. Já no ACL, os geradores, comercializadores, importadores e exportadores de energia e consumidores livres e especiais têm liberdade para negociar e estabelecer em contratos os volumes de compra e venda de energia e seus respectivos preços. Todos os contratos firmados nos ambientes livre e regulado são registrados na CCEE, e servem de base para a contabilização e liquidação das diferenças no mercado de curto prazo. A Tabela 3 apresenta as principais diferenças entre estes dois ambientes.

Tabela 3 – Diferenças entre os ambientes de contratação regulada e de contratação livre.

| | Ambiente Livre | Ambiente Regulado |
|-------------------------|--|--|
| Participantes | Geradoras, comercializadoras, consumidores livres e especiais. | Geradoras, distribuidoras e comercializadoras. As comercializadoras podem negociar energia somente nos leilões de energia existente. |
| Contratação | Livre negociação entre os compradores e vendedores. | Realizada por meio de leilões de energia promovidos pela CCEE, sob delegação da Aneel. |
| Tipo de Contrato | Acordo livremente estabelecido entre as partes. | Regulado pela Aneel. |
| Preço | Acordado entre comprador e vendedor. | Estabelecido no leilão. |

Fonte: (CCEE, 2018).

2.2 Geração Termoelétrica

Na produção de energia a partir de centrais termoelétricas, estão presentes a conversão de energia térmica em energia mecânica e a conversão desta em energia elétrica. Basicamente, a conversão de energia térmica em energia mecânica ocorre a partir da expansão de um fluido, que realiza trabalho em turbinas térmicas. Este trabalho consiste em uma energia mecânica que é aplicada ao eixo de um gerador elétrico acoplado à turbina térmica, produzindo, assim, a eletricidade.

Segundo (Reis, 2011), as centrais térmicas são classificadas de acordo com o método de combustão utilizado:

- Combustão externa: o combustível não entra em contato com o fluido de trabalho. Este processo é muito empregado em usinas a vapor, onde o combustível aquece o fluido de trabalho (em geral água) presente em uma caldeira até gerar vapor que, ao se expandir em uma turbina, produzirá trabalho mecânico;
- Combustão interna: a combustão ocorre sobre uma mistura de ar e combustível, onde o fluido de trabalho consiste no conjunto de produtos da combustão. Este processo é usado principalmente em turbinas a gás e nas máquinas térmicas a pistão (motores a diesel, por exemplo).

Centrais termoelétricas também podem ser classificadas segundo outros critérios (Lora; Nascimento, 2004) como produto principal, tipos de combustível, máquina térmica e caldeira, potência instalada, característica da carga e natureza do combustível.

Na classificação de usinas térmicas com base em seu produto principal, distingue-se dois tipos de usinas: as que apresentam como único produto a eletricidade (centrais termoelétricas de geração) e as que geram simultaneamente eletricidade e calor, destacando-se a maior eficiência destas últimas.

A seguir são discutidas outras características gerais de uma usina termoelétrica, bem como aspectos relacionados ao maquinário empregado, tipos de combustíveis e impactos ambientais.

2.2.1 Usina Termoelétrica

A Figura 2 apresenta as principais partes constituintes de uma usina termoelétrica convencional que utiliza-se da queima de combustível (Oliveira, 2015).




Figura 2 – Estrutura de uma usina termoelétrica convencional.

Fonte: (Oliveira, 2015)

1. Caldeira: Local onde ocorre a queima do combustível e a transformação da água contida no duto em vapor, à alta temperatura e pressão, em torno de 540 °C e 170 bar;
2. Local de entrada de combustível;
3. Turbina a vapor: Produz o movimento de rotação (energia mecânica) devido à incidência do vapor em suas pás;
4. Gerador: Tem seu eixo conectado ao eixo da turbina, convertendo, assim, a energia mecânica de rotação em energia elétrica;
5. Transformadores elevadores: Recebem a energia elétrica produzida e eleva seus níveis de tensão para que seja transmitida;
6. Rede elétrica: Responsável por transmitir a energia elétrica produzida até subestações ou centros consumidores;

7. Condensador: Compartimento que recebe o vapor condensado após passar pela turbina e o reencaminha para a caldeira, iniciando novamente o ciclo;
8. Bomba de refrigeração: Responsável por proporcionar a circulação da água de refrigeração entre o condensador e a fonte fria (rio, mar, ou torre de refrigeração);
9. Equipamento para a redução de emissões: Responsável pela filtragem dos gases provenientes da queima de combustível, que posteriormente são tratados e emitidos ao ambiente;
10. Chaminé: Responsável pela dispersão dos gases;
11. Torre de refrigeração: Responsável por resfriar a água do circuito de refrigeração.

2.2.2 Motor de Combustão Interna

Esta seção é dedicada ao Motor de Combustão Interna (MCI), que tem papel de destaque na produção de energia elétrica a partir de UTEs. Este motor representa a tecnologia mais difundida dentre as máquinas térmicas, devido à sua simplicidade, robustez e alta relação potência/peso (Azevedo, 2015).

Além da geração de energia, o MCI é também empregado na propulsão de sistemas móveis, produção de petróleo e gás, compressão, exploração de pedreiras e na indústria de reciclagem. Sua ampla utilização se justifica por operar com uma variedade de combustíveis, uma ampla gama de velocidades e com cargas variáveis (Deligiannis; Manesis, 2006).

Os MCIs apresentam outras características como grande eficiência térmica, quase que independente da faixa de operação (nível de carga, por exemplo) e são menos sensíveis às condições ambientais como outros motores térmicos (turbinas a gás, por exemplo) (Azevedo, 2015).

Adicionalmente, destaca-se que UTEs que operam a partir de motores a diesel apresentam uma modularidade que possibilita um curto tempo de montagem em um mínimo espaço para construção, além de ótima flexibilização de carga. Também se faz presente uma rápida entrada em operação, após instalação, e flexibilidade para entrar e sair de operação ao longo do dia. A aplicação de MCIs engloba desde a geração de poucos kW até centenas de MW, para fins de geração isolada, interligada ou como geradores de suporte à falta de energia.

2.2.3 Recursos Energéticos

Na geração de energia a partir de usinas termoelétricas, o termo recurso energético está diretamente relacionado ao termo combustível, o qual é definido como uma substância

que ao se combinar quimicamente com um composto oxidante gera uma reação exotérmica, liberando elevadas quantidades de calor (Lora; Nascimento, 2004).

Uma classificação dos combustíveis com base no estado físico é apresentado na Tabela 4.

Tabela 4 – Classificação dos combustíveis segundo seu estado físico.

| Estado Físico | Combustível |
|----------------------|--------------------------|
| Sólido | Carvão mineral |
| | Carvão vegetal |
| | Xisto |
| | Turfa |
| | Lenha |
| | Resíduos Agroindustriais |
| Líquido | Gasolina |
| | Querosene |
| | Diesel |
| | Óleos Combustíveis |
| Gasoso | Gás Natural |
| | Glp |
| | Biogás |

Fonte: (Lora; Nascimento, 2004).

Ainda como recursos energéticos, cabe mencionar também o aproveitamento da energia geotérmica (energia obtida a partir do calor proveniente do interior da Terra), a energia solar, que diferentemente do emprego de painéis fotovoltaicos, pode ser usada como fonte direta de calor para uma usina termoeletrica (centrais termossolares) e ainda os elementos radioativos como urânio, tório e plutônio, empregados em usinas termoeletricas (Reis, 2011).

Dentre os combustíveis até aqui mencionados, o gás natural é o mais nobre, sendo também o mais caro, o que justifica seu emprego somente em sistemas de conversão de alta eficiência, tais como o ciclo combinado e os sistemas de cogeração. Do ponto de vista ambiental, a única preocupação está relacionada às emissões de óxidos de nitrogênio (Lora; Nascimento, 2004). Já a utilização do carvão mineral requer um pré-tratamento caro e complexo (pulverização). Este combustível é tipicamente empregado em centrais termoeletricas de ciclo a vapor, e caracteriza-se por severas emissões de óxidos de enxofre e de nitrogênio e particulados, o que exige a instalação associada de sistemas de limpeza de gases.

2.2.4 Impactos Ambientais da Geração Termoeletrica

Por operarem a partir da queima de combustíveis, em sua maioria derivados de petróleo ou carvão mineral, as usinas termoeletricas acarretam em diversos impactos ne-

gativos ao meio ambiente. Os efluentes deste tipo de usina são classificados basicamente em aéreos (que apresentam maior potencial poluidor), líquidos e sólidos (Reis, 2011), e são brevemente discutidos nesta seção.

Efluentes aéreos: A geração de energia elétrica a partir de centrais termoelétricas consiste na segunda maior produtora de gases-estufa (principalmente CO_2), ficando atrás apenas do setor de transportes. Quando em excesso na atmosfera, o dióxido de carbono (CO_2) é o principal causador do efeito estufa, que provoca o aquecimento global do planeta. O excesso deste efluente também pode causar dificuldades respiratórias, principalmente em crianças e idosos.

Ainda a respeito de efluentes aéreos, destaca-se a emissão de óxidos de enxofre (SO), resultantes da presença de enxofre no combustível. Este efluente é responsável por problemas respiratórios na população que vive em torno de usinas que não controlam suas emissões. Dependendo de sua concentração na atmosfera, pode possibilitar o surgimento de chuva ácida e outros efeitos ambientais, a consideráveis distâncias do local de dispersão.

Durante o processo de combustão, também são produzidos óxidos de nitrogênio (NO_x), que em elevadas concentrações provoca o agravamento de enfermidades pulmonares, cardiovasculares e renais, bem como a redução no crescimento de plantas e a queda prematura de folhas. A queima incompleta do combustível, por sua vez, produz hidrocarbonetos, que podem resultar em compostos oxidantes. Outro efluente aéreo consiste no material particulado arrastado pelo fluxo de gases, que afeta o meio ambiente pelos efeitos decorrentes de sua deposição nos bens e imóveis, nos sistemas respiratórios de pessoas e animais, na ação sobre a visibilidade atmosférica, dentre outros.

Efluentes líquidos: Os efluentes líquidos produzidos por usinas termoelétricas podem afetar física e/ou quimicamente o solo e as águas superficiais e subterrâneas. Parte destes poluentes são devidos ao uso de produtos químicos no tratamento de água para a produção de vapor e na limpeza de equipamentos de queima e de produção de vapor. Produtos químicos também são misturados à água para reduzir a formação de incrustações em caldeiras a vapor. Há ainda a elevação de temperatura da água da bacia fluvial usada no sistema de refrigeração, em usinas que empregam este tipo de estrutura no sistema de arrefecimento.

Efluentes sólidos: Esses efluentes consistem basicamente em cinzas e poeiras consequentes da operação da usina, que podem afetar física e/ou quimicamente o ambiente.

2.3 Conclusões

Conforme visto neste capítulo, a baixa complexidade estrutural de uma usina termoelétrica e sua flexibilidade relacionada ao local de instalação, montagem e variados tipos

de combustíveis, justificam o fato deste tipo de usina apresentar um menor custo de implantação (se comparado a usinas hidroelétricas, por exemplo). Por outro lado, observa-se os acentuados impactos ambientais provenientes de UTEs, o que motiva a consideração deste fator na etapa de planejamento da geração.

3 Abordagem Proposta

Neste capítulo são apresentadas as metodologias propostas para a resolução do problema de Despacho Econômico e Ambiental na presença de incertezas. Inicialmente apresenta-se o problema de DEA (Seção 3.2) bem como sua modelagem incorporando-se incertezas (Seção 3.3). A Seção 3.4 apresenta o algoritmo dedicado à solução deste problema e, por fim, a estratégia de auxílio à tomada de decisão aqui empregada é apresentada na Seção 3.5.

3.1 Problema de Otimização Multiobjetivo

Um problema de otimização multiobjetivo pode ser definido como (Miettinen, 1999):

$$\min_x f(x) = [f_1(x), \dots, f_{n_f}(x)]^T \quad (3.1)$$

sujeito a: $x \in \Omega$

em que $x = (x_1, \dots, x_{n_v})^T$ é uma solução candidata, $f(\cdot) : \mathbb{R}^{n_v} \mapsto \mathbb{R}^{n_f}$ representa n_f funções objetivo conflitantes e $\Omega \subset \mathbb{R}^{n_v}$ é o espaço de decisão viável, tal que $\Omega = \{x \in \mathbb{R}^{n_v} \mid g_i(x) \leq 0, h_j(x) = 0; \forall i = 1, \dots, n_g, j = 1, \dots, n_h\}$, em que $f(\Omega)$ define o conjunto objetivo alcançável, $g(\cdot) : \mathbb{R}^{n_v} \mapsto \mathbb{R}^{n_g}$ representa n_g restrições de desigualdade e $h(\cdot) : \mathbb{R}^{n_v} \mapsto \mathbb{R}^{n_h}$ representa n_h restrições de igualdade.

Uma solução viável $x \in \Omega$ domina outro ponto $x' \in \Omega$ (representado como $f(x) \prec f(x')$) se, e somente se, $f_k(x) \leq f_k(x')$ para todo $k \in 1, \dots, n_f$ e $\exists k$ tal que $f_k(x) < f_k(x')$. Assim sendo, uma solução $x^* \in \Omega$ é *Pareto-ótima* para (3.1) se não existe nenhuma outra solução $x \in \Omega$ tal que $f(x) \prec f(x^*)$, e o conjunto de todas as soluções Pareto-ótimas é chamado *conjunto Pareto-ótimo*, i.é.,

$$S = \{x^* \in \Omega \mid \nexists x \in \Omega : f(x) \prec f(x^*)\} \quad (3.2)$$

A imagem deste conjunto, $f(S)$ é nomeada *fronteira Pareto-ótima*,

$$PF = \{f(x^*) \mid x^* \in S\} \quad (3.3)$$

Em outras palavras, neste tipo de problema não se encontra apenas uma, mas sim um conjunto de soluções ditas não dominadas.

3.2 O Problema de Despacho Econômico e Ambiental

A abordagem mais comumente empregada para este problema consiste na minimização simultânea de dois objetivos (funções objetivo) conflitantes: o custo de geração e a emissão de poluentes. Estes objetivos são estimados em função da potência produzida em cada usina. Baseando-se na operação dessas usinas em diferentes condições de carga, são estimadas as curvas de custo *versus* potência produzida e as emissões *versus* potência produzida. A partir desses dados e de métodos matemáticos de aproximação, são obtidos os parâmetros das funções que modelam estes objetivos, conforme realizado em (Moraes, 2017).

3.2.1 Custo de Geração

O custo de geração em sistemas termoeletricos é devido às atividades de operação, manutenção e principalmente consumo de combustível (Ghasemi, 2013), (Morsali et al., 2014). Este objetivo pode ser modelado da seguinte forma:

$$\text{Minimizar } F(P) = \sum_{i=1}^{n_u} a_i + b_i P_i + c_i P_i^2 \quad (3.4)$$

em que $F(P)$ refere-se ao custo de geração dado em função da potência ativa gerada em cada usina, n_u refere-se ao número de usinas termoeletricas do sistema, a_i , b_i e c_i são os coeficientes da função de custo de geração da i -ésima termoeletrica e P_i é a potência ativa gerada pela i -ésima termoeletrica.

Alguns modelos consideram o efeito de ponto de válvula na função de custo de cada usina. O mesmo é causado devido a realização do controle de temperatura interna da caldeira e da turbina, uma vez que, no momento em que a válvula é aberta, há perda de temperatura/vapor que, conseqüentemente, afeta o consumo de combustível. Este incremento momentâneo no custo de geração eleva o grau de não linearidade da função, podendo ser expresso como uma função periódica adicionada à função quadrática do custo de geração, conforme mostrado em (3.5):

$$\text{Minimizar } F(P) = \sum_{i=1}^{n_u} a_i + b_i P_i + c_i P_i^2 + |d_i \text{sen}(e_i (P_i^{\text{min}} - P_i))| \quad (3.5)$$

em que P_i^{min} consiste no valor mínimo de potência ativa a ser produzida pela i -ésima termoeletrica e d_i e e_i são os coeficientes que representam o efeito do ponto de válvula para a i -ésima termoeletrica.

A Figura 3 apresenta a função de custo de geração na presença e ausência do efeito do ponto de válvula.

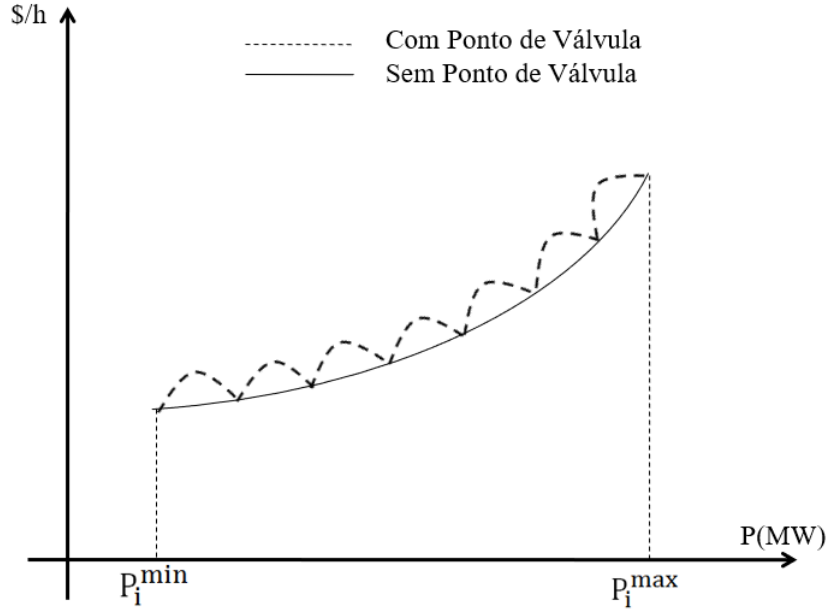


Figura 3 – Função de custo de uma unidade termoeletrica com e sem o efeito do ponto de válvula.

Fonte: Adaptado de (Oliveira, 2015).

3.2.2 Emissão de Poluentes

A função que modela a emissão de poluentes pode ser definida da seguinte maneira:

$$\text{Minimizar } E(P) = \sum_{i=1}^{n_u} \alpha_i + \beta_i P_i + \gamma_i P_i^2 + \xi_i \exp(\varphi_i P_i) \quad (3.6)$$

em que $E(P)$ refere-se à emissão de poluentes dada em função da potência ativa gerada em cada usina, e α_i , β_i , γ_i , ξ_i e φ_i são os coeficientes da função de emissão de poluentes da i -ésima usina termoeletrica.

3.2.3 Restrições

As restrições comumente empregadas no problema de DEA, e também assumidas neste trabalho, são:

- Restrição do balanço de potência ativa: A potência ativa total produzida deve se equivaler a soma da potência ativa demandada com as perdas de potência ativa nas linhas da rede, conforme (3.7):

$$\sum_{i=1}^{n_u} P_i - P_d - P_{loss} = 0 \quad (3.7)$$

em que P_d é a potência ativa total demandada e P_{loss} consiste no total de perdas de potência ativa nas linhas da rede.

- Restrição de limites operacionais: Representam as restrições de operação das usinas. Estas limitações estão associadas à relação entre o combustível utilizado e as limitações da caldeira e da turbina:

$$P_i^{min} \leq P_i \leq P_i^{max}, \forall i = 1, \dots, n_u \quad (3.8)$$

em que P_i^{max} consiste no valor máximo de potência ativa capaz de ser produzida pela i -ésima termoelétrica.

3.3 Despacho Econômico e Ambiental na Presença de Incertezas

Esta pesquisa tem como principal objetivo o estudo do DEA considerando incertezas na estimação de seus objetivos (custo de geração e emissão de poluentes). Assim sendo, visa-se um tratamento robusto do problema, com o intuito de se identificar as melhores soluções viáveis considerando-se o pior cenário de incertezas, cenário este pertinente no setor elétrico, caracterizado por consideráveis oscilações de mercado e discussões envolvendo as melhores formas, econômicas e ambientais, de se produzir energia.

Esta incorporação de incertezas é realizada através do emprego de parâmetros *fuzzy* (difusos) nas funções objetivo. Nesta abordagem, os parâmetros destas funções deixam de ser constantes, passando a assumir um domínio. Este conceito é apresentado nas seções seguintes, bem como os demais conceitos necessários à abordagem do problema de DEA incorporando incertezas.

3.3.1 Números *Fuzzy*

Um número *fuzzy* (nebuloso) (Jang; Sun; Mizutani, 1997) tem como objetivo modelar um pensamento impreciso, subjetivo, como expressões da forma “quase 20” ou “próximo de 50”. Um número nebuloso \tilde{a} possui notação do tipo:

$$\tilde{a} = [\underline{a}, a_0, \bar{a}] \quad (3.9)$$

em que a_0 corresponde ao valor modal, e \underline{a} e \bar{a} correspondem aos limitantes mínimo e máximo do espalhamento, respectivamente.

À cada número nebuloso é associada uma função de pertinência, $\mu_{\tilde{a}}(x)$, $0 \leq \mu_{\tilde{a}}(x) \leq 1$, que quantifica o grau de pertinência (similaridade) de x , contido em um domínio X , ao conjunto nebuloso \tilde{a} . Os tipos mais comuns de funções de pertinência são triangular, trapezoidal, Gaussiana, sigmoideal, dentre outras. A Figura 4 apresenta uma função de pertinência triangular associada a um número nebuloso.




Figura 4 – Função de pertinência de um número nebuloso.
 Fonte: Adaptado de (Mousa, 2014).

Um número *fuzzy* pode ser obtido a partir de um valor escalar e do valor de incerteza/imprecisão associada a ele (Mousa, 2014). Como exemplo, assumindo-se o valor de determinado parâmetro como igual a 150 e uma incerteza a ele associada de valor 2.5%, tem-se como valor modal $a_0 = 150$, limitante inferior correspondente a $\underline{a} = 146.25$ e limitante superior $\bar{a} = 153.75$.

3.3.2 Método α -cut

Dada uma função de pertinência associada a um número fuzzy, é possível ponderar o espalhamento (variação) deste em torno de seu valor modal pelo emprego do método α -cut. Um conjunto α -cut de números *fuzzy* é definido como um conjunto para o qual os valores das funções de pertinência destes números são iguais ou superiores ao nível $\alpha \in [0, 1]$ (Mousa, 2014). Dessa forma, valores de x , contidos em um domínio X , passam a ter valor de pertinência igual a zero se $\mu_{\bar{a}}(x) \leq \alpha$, definindo-se um novo domínio $X' = \{x \mid \mu_{\bar{a}}(x) \geq \alpha\}$. A Figura 5 ilustra este conceito.




Figura 5 – Método α -cut.
 Fonte: Adaptado de (Mousa, 2014).

3.3.3 O Problema de Otimização Robusta para o DEA

Com base nas definições anteriores, os parâmetros difusos empregados nas funções objetivo do problema de DEA são tratados como variáveis de otimização no problema de otimização robusta proposto. A otimização deste problema é realizada por meio de duas etapas consecutivas: primeiro, tem-se a maximização das funções objetivo em relação a estes parâmetros difusos, com o intuito de se estimar o pior cenário de incerteza; feito isso, tem-se a minimização destas funções em relação às variáveis de decisão originais do problema. O problema geral é apresentado a seguir:

$$\min_P \max_{\tilde{z}} F(P, \tilde{z}) = \sum_{i=1}^{n_u} \tilde{a}_i + \tilde{b}_i P_i + \tilde{c}_i P_i^2 + |\tilde{d}_i \text{sen}(\tilde{e}_i (P_i^{\min} - P_i))| \quad (3.10)$$

$$\min_P \max_{\tilde{z}} E(P, \tilde{z}) = \sum_{i=1}^{n_u} \tilde{\alpha}_i + \tilde{\beta}_i P_i + \tilde{\gamma}_i P_i^2 + \tilde{\xi}_i \exp(\tilde{\varphi}_i P_i) \quad (3.11)$$

em que \tilde{z} refere-se aos coeficientes difusos: \tilde{a}_i , \tilde{b}_i , \tilde{c}_i , \tilde{d}_i e \tilde{e}_i são os coeficientes difusos da função de custo de geração e $\tilde{\alpha}_i$, $\tilde{\beta}_i$, $\tilde{\gamma}_i$, $\tilde{\xi}_i$, e $\tilde{\varphi}_i$ são os coeficientes difusos da função de emissão de poluentes da i -ésima termoelétrica.

O problema de minimização de pior caso (*minimax*) para o problema de DEA descrito por (3.10) e (3.11) continua sujeito às restrições descritas por (3.7) e (3.8). Na seção seguinte é apresentado o algoritmo empregado na resolução deste problema.

Cabe mencionar que diferentes funções densidade de probabilidade podem ser consideradas para modelar as incertezas de cada uma das usinas, devido às diferentes características destas, como tipo de combustível, tempo de vida útil do maquinário, tecnologia empregada, dentre outras. Além disso, pode-se realizar um estudo de pior caso, caso médio ou outro que considere a influência destas incertezas.

3.4 MOEA/D Robusto

O algoritmo de otimização empregado, denominado MOEA/D Robusto, baseia-se no *Multiobjective Evolutionary Algorithm Based on Decomposition* (MOEA/D) (Zhang; Li, 2007). O MOEA/D realiza a decomposição de um problema de otimização multi-objetivo em um conjunto de problemas escalares (mono-objetivo), que são otimizados simultaneamente. Esses subproblemas definem estruturas de vizinhança, em que cada problema escalar é relacionado a um vetor de ponderação. Basicamente, em cada iteração do MOEA/D é gerada uma nova solução em cada vizinhança, e a partir deste conjunto de soluções obtido é realizada a atualização das estruturas de vizinhança e da população de soluções.

Como função de escalarização, geralmente nomeada por g , podem ser empregadas Soma Ponderada, Tchebycheff, ou ainda *Penalty-based Boundary Intersection* (PBI) (Zhang; Li, 2007). Nesta pesquisa, emprega-se o método de Tchebycheff, definido da seguinte maneira:

$$\min g^{te}(x \mid \lambda, z^*) = \max_{1 \leq i \leq n_f} \{\lambda_i |f_i(x) - z_i|\} \quad (3.12)$$

em que $z = (z_1, \dots, z_{n_f})$ é um ponto de referência, i.e., $z_i = \min f_i(x)$, $\lambda = \{\lambda_1, \dots, \lambda_{n_f}\}$ é um vetor de peso, e n_f é o número de funções objetivo.

O MOEA/D Robusto empregado neste trabalho é basicamente o algoritmo proposto em (Meneghini; Guimarães; Gaspar-Cunha, 2016). Este algoritmo tem como principal característica a presença de duas populações: $X = \{x^1, \dots, x^N\}$ correspondente à população de soluções candidatas e $\Pi = \{\pi^1, \dots, \pi^N\}$ correspondente à população de vetores de incerteza (ou população de perturbações). Para cada solução candidata x^i é definido um vetor de incerteza π^i . A cada iteração do método, a população X evolui visando a minimização da função g , mantendo-se fixos os valores de perturbações presentes em Π . Por outro lado, esta última tem sua evolução visando a maximização de g , mantendo-se fixos os valores presentes em X . A implementação deste algoritmo, adaptada de (Meneghini; Guimarães; Gaspar-Cunha, 2016), é apresentada a seguir:

A) Inicialização

1. Crie uma população vazia EP , a qual armazena as estimativas da fronteira Pareto;
2. Gere uma população inicial $X = \{x^1, \dots, x^N\}$, com N indivíduos;
3. Gere uma população $\Pi = \{\pi^1, \dots, \pi^N\}$, com N indivíduos;
4. Associe cada indivíduo em X com um indivíduo em Π ;
5. Gere N vetores de peso $\lambda \in \Lambda$ para os subproblemas escalares;
6. Calcule a distância Euclidiana entre todos os vetores de peso e, para cada $\lambda^i \in \Lambda$, encontre os T vetores de peso mais próximos a este. Crie uma vizinhança $B(i) = \{i_1, \dots, i_T\}$ com os vetores $\lambda^{i_1}, \dots, \lambda^{i_T}$, que são os T vetores de peso mais próximos a λ^i . Associe cada indivíduo a um vetor de peso de acordo com a distância no espaço de objetivos ou aleatoriamente;
7. Avalie a população X e armazene em FV ;
8. Inicialize a solução utópica estimada $z = (z_1, \dots, z_{n_f})$, que pode ser da forma $z_i = \min f_i(x^j, \pi^j)$, com $x^j \in X$ e $\pi^j \in \Pi$.

B) Ciclo Evolucionário

1. Para cada indivíduo x^i faça:

- i) Gere uma nova solução x_c^i usando operadores evolutivos;
- ii) Atualize a vizinhança das soluções: para cada $j \in B(i)$, se

$$g(x_c^i \mid \pi^j, \lambda^j, z) \leq g(x^j \mid \pi^j, \lambda^j, z) \quad (3.13)$$

então faça $x^j = x_c^i$ e $FV^j = F(x_c^i, \pi^j)$;

2. Para cada $\pi^i \in \Pi$ faça:

- i) Gere uma nova solução π_c^i usando operadores evolutivos;
- ii) Atualize a vizinhança das soluções: para cada $j \in B(i)$, se

$$g(\pi_c^i \mid x^j, \lambda^j, z) \geq g(\pi^j \mid x^j, \lambda^j, z) \quad (3.14)$$

então faça $\pi^j = \pi_c^i$ e $FV^j = F(\pi_c^i, x^j)$;

3. Atualize EP .

De maneira mais específica, o processo evolutivo ocorre da seguinte forma:

- Para cada $x^i \in X$, dois indivíduos x_a^i e x_b^i são selecionados na vizinhança $B(i)$. Após isto, são aplicados operadores evolutivos de modo a produzir um novo indivíduo x_c^i . Neste caso, visa-se a minimização do subproblema dado por:

$$\min_x g(x \mid \pi^i, \lambda^i, z) \quad (3.15)$$

Nota-se que em (3.15) também é considerado o vetor de perturbação π^i . Em seguida é realizada a atualização das soluções pertencentes à vizinhança $B(i)$.

- De maneira análoga, para cada $\pi^i \in \Pi$, são selecionados dois indivíduos π_a^i e π_b^i dentro da vizinhança $B(i)$, e a partir da aplicação de operadores evolutivos é produzido um novo indivíduo π_c^i . Nesta etapa, o objetivo é maximizar a função g , conforme (3.16).

$$\max_{\pi} g(\pi \mid x^i, \lambda^i, z) \quad (3.16)$$

Observa-se que a avaliação de π é dada em função também de x^i , e atualiza-se as soluções da vizinhança $B(i)$. Este algoritmo também é apresentado, de forma simplificada, na Figura 6.

Em comparação com o método MOEA/D original, o MOEA/D Robusto exige um maior esforço computacional, justificado pelo seguinte fato: conforme já discutido, em cada iteração deste algoritmo estão presentes duas populações, de soluções e de perturbações, e em cada uma das N vizinhanças são consideradas T soluções. Quando uma nova solução/perturbação é comparada com cada um dos T vizinhos em questão, ela necessita ser reavaliada nos parâmetros deste vizinho, uma vez que cada vetor de solução x^i é associado ao vetor de perturbação π^i , e a avaliação de x^i é dada em função de π^i e vice-versa. Assim, cada iteração do MOEA/D Robusto necessita de $2NT$ avaliações de função objetivo, consideravelmente superior às N avaliações requeridas pelo MOEA/D.

O custo de $2NT$ avaliações de função objetivo a cada iteração do MOEA/D Robusto é provavelmente inferior ao custo requerido por outros algoritmos de otimização robusta, como, por exemplo, os que empregam o método de Monte Carlo para permitir uma análise do efeito de perturbações. Ressalta-se ainda que o estudo de incertezas no MOEA/D Robusto é realizado a partir da geração de novas soluções através de um processo de otimização, e não por meio da geração de soluções aleatórias. Por fim, destaca-se a escolha deste algoritmo devido a sua capacidade de decompor um problema de otimização multiobjetivo em subproblemas escalares, o que permite, de maneira simples, a realização de uma minimização de pior caso dos objetivos em uma mesma iteração.

Nesta pesquisa, a geração de novas soluções dentro do processo evolutivo é realizada através dos mecanismos presentes no algoritmo MOEA/D-DE, derivado de uma modificação do algoritmo MOEA/D, proposto por Li e Zhang (2009). Este método apresenta as seguintes características:

- Assume-se uma probabilidade δ de que as soluções selecionadas para o processo de evolução sejam provenientes da vizinhança em questão. Por outro lado, tem-se uma probabilidade $1 - \delta$ de que estas soluções sejam provenientes do conjunto formado por todas as soluções;
- Assume-se um parâmetro n_r , que corresponde ao número máximo de soluções substituídas por uma nova solução obtida;
- Na operação de variação é empregado o mecanismo definido no algoritmo *Differential Evolution* (Storn; Price, 1995). Neste mecanismo, a partir de três soluções previamente selecionadas x^1 , x^2 e x^3 , uma nova solução $\bar{y} = (\bar{y}_1, \dots, \bar{y}_{n_v})$ é gerada da seguinte maneira:

$$\bar{y}_k = \begin{cases} x_k^1 + F_{cross}(x_k^2 - x_k^3) & \text{com probabilidade } CR \\ x_k^1 & \text{com probabilidade } 1 - CR \end{cases} \quad (3.17)$$

$$\forall k = \{1, \dots, n_v\}$$

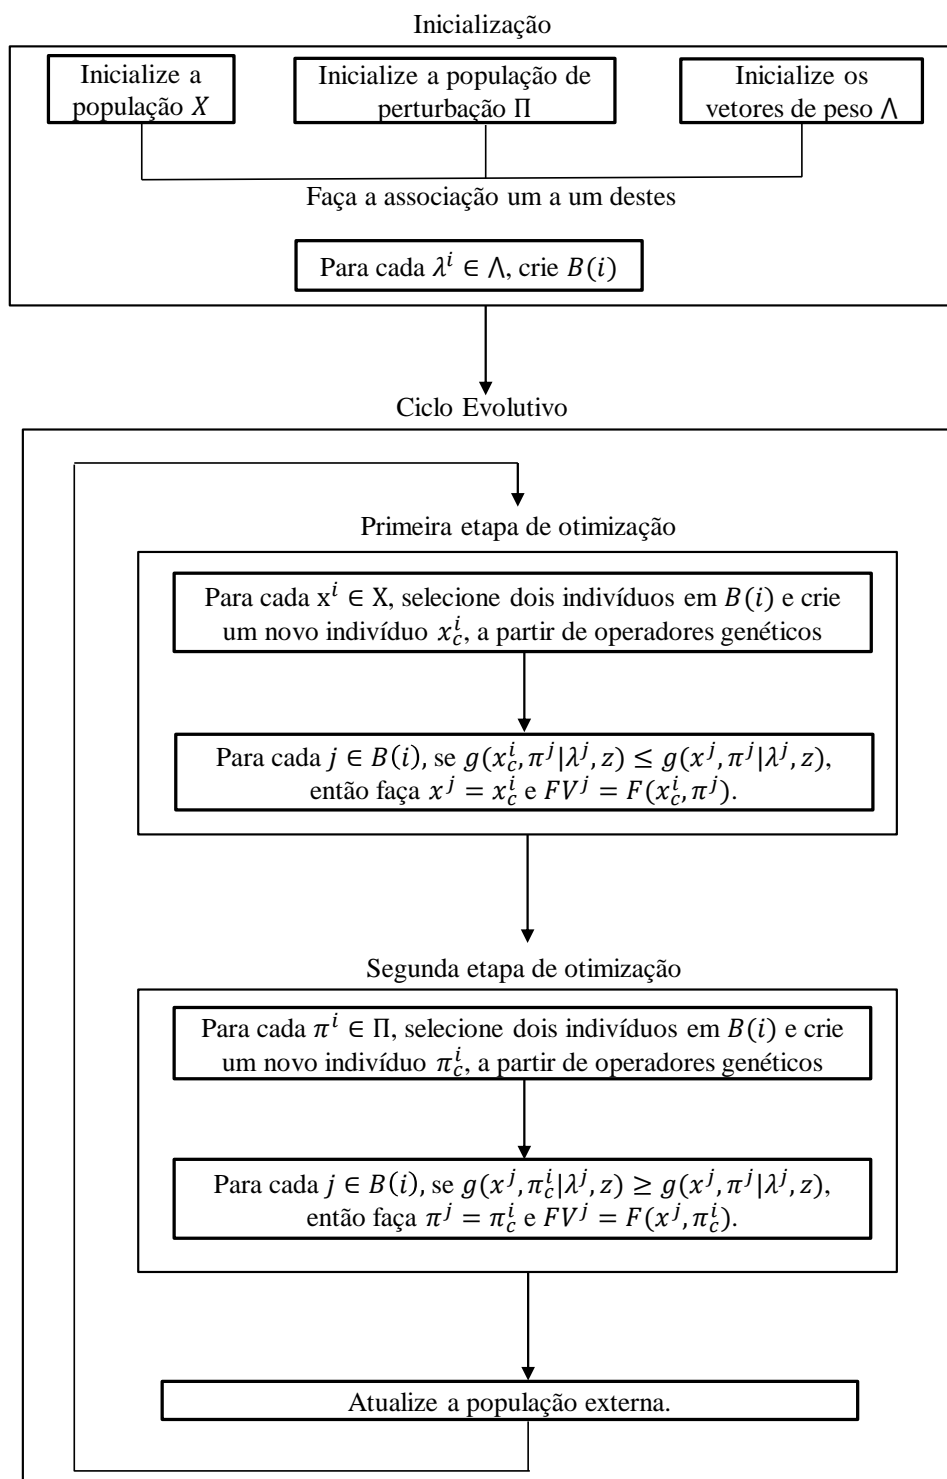


Figura 6 – MOEA/D Robusto.

Fonte: Adaptado de (Meneghini; Guimarães; Gaspar-Cunha, 2016).

em que F_{cross} e CR são dois parâmetros de controle do método *Differential Evolution*.

- Por fim, realiza-se uma mutação polinomial (Deb; Goyal, 1996), obtendo a nova

solução $y = \{y_1, \dots, y_{n_v}\}$ a partir de \bar{y} , conforme a seguir:

$$y_k = \begin{cases} \bar{y}_k + \sigma_k(U_k - L_k) & \text{com probabilidade } p_m \\ \bar{y}_k & \text{com probabilidade } 1 - p_m \end{cases} \quad (3.18)$$

com

$$\sigma_k = \begin{cases} (2 * rand)^{\frac{1}{\eta+1}} - 1 & \text{se } rand < 0.5, \\ 1 - (2 - 2 * rand)^{\frac{1}{\eta+1}} & \text{caso contrário} \end{cases} \quad (3.19)$$

$$\forall k = \{1, \dots, n_v\}$$

em que $rand$ é um número aleatório pertencente ao domínio $[0, 1]$, η é o índice de distribuição, p_m é a probabilidade de mutação, e L_k e U_k são os limites inferior e superior da k -ésima variável de decisão, respectivamente.

Cabe enfatizar que a população X refere-se às variáveis de decisão originais do problema, ou seja, as potências a serem produzidas em cada usina. A população Π , por sua vez, consiste em vetores de perturbação associados aos parâmetros *fuzzy* empregados nas funções objetivo do problema.

3.5 Estratégia de Suporte à Tomada de Decisão

A tomada de decisão envolve essencialmente a escolha da ação (solução) mais apropriada a partir de um conjunto de alternativas possíveis. Esta escolha deve ser feita levando-se em consideração questões, tais como: como e quais recursos serão alocados e como o desempenho da solução será mensurada e revisada no dinâmico ambiente em que opera o sistema (Bhushan; Rai, 2004).

Conforme já destacado anteriormente, poucos trabalhos na literatura apresentam uma abordagem consistente para a definição da ação final a ser implementada frente ao problema de DEA. Nesta pesquisa, propõe-se uma análise multicritério das alternativas que, juntamente com o emprego de métodos de auxílio à tomada de decisão, indicará, de maneira melhor justificada, a solução mais adequada a este problema.

Como critérios empregados nesta análise estão o custo de geração e a emissão de poluentes, i.e., após a obtenção do conjunto de soluções não dominadas, os objetivos originais são assumidos como critérios na etapa de tomada de decisão. Além destes, são definidos outros dois critérios adicionais: o total de perdas de potência ativa dissipada na rede de transmissão e o valor médio do percentual de utilização das unidades geradoras

(razão entre a potência utilizada e a capacidade da usina). Após esta análise, são empregados dois métodos de auxílio à tomada de decisão, o AHP e o TOPSIS, que nesta pesquisa operam de maneira complementar.

Tanto o método AHP quanto o TOPSIS são muito empregados para auxílio à tomada de decisão em várias áreas do conhecimento. Desta forma, visa-se verificar o desempenho destes métodos no contexto do problema estudado. Ressalta-se também a necessidade da definição dos pesos de cada critério para o TOPSIS, o que também motivou o emprego do método AHP, visando auxiliar nesta definição. Estes dois métodos de auxílio à tomada de decisão são discutidos a seguir.

3.5.1 *Analytic Hierarchy Process* - AHP

Desenvolvido na década de 1970, o AHP consiste em uma abordagem sistemática que fornece uma metodologia bem definida, derivada de princípios matemáticos, para uma tomada de decisão baseada na experiência e intuição do projetista (Bhushan; Rai, 2004).

O método AHP apresenta-se como uma teoria de medição (ou classificação) baseada em comparações par a par entre as alternativas. Este método sustenta-se sobre uma escala de prioridades definida a partir de julgamentos de *experts* na área do problema. Estes julgamentos podem ser inconsistentes, mas o AHP permite tanto quantificar essa consistência quanto melhorar tais julgamentos. Este método executa basicamente as seguintes etapas (Bhushan; Rai, 2004):

1. O problema é decomposto em uma hierarquia formada pelo objetivo, critérios, sub-critérios e alternativas. Esta hierarquia indica a relação entre elementos de um nível com aqueles do nível imediatamente abaixo, conforme mostra a Figura 7.
2. São realizadas comparações aos pares entre as alternativas e entre os critérios, em que a ponderação da importância de um elemento em relação à outro é feita com base na Escala Fundamental de Comparações (Saaty, 2008), apresentada na Tabela 5.

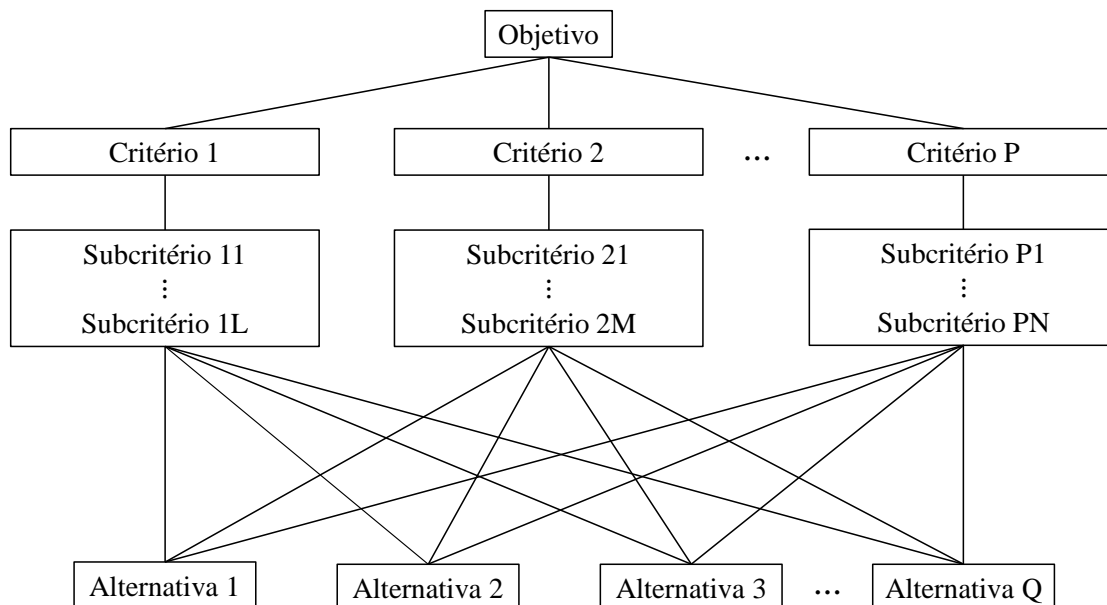


Figura 7 – Estrutura hierárquica genérica adotada no AHP.
 Fonte: Adaptado de (Bhushan; Rai, 2004).

Tabela 5 – Escala Fundamental de Comparações.

| Intensidade da Importância | Definição | Explicação |
|---|-------------------------|--|
| 1 | Preferências Similares | Dois elementos contribuem igualmente para o objetivo |
| 3 | Preferência Moderada | Um elemento é favorecido moderadamente em relação à outro |
| 5 | Preferência Forte | Um elemento é favorecido fortemente em relação à outro |
| 7 | Preferência Muito Forte | Um elemento é favorecido muito fortemente em relação à outro. |
| 9 | Preferência Extrema | A evidência favorecendo um elemento em relação à outro é da mais alta ordem possível de afirmação. |
| Intensidades 2, 4, 6 e 8 podem ser usadas para expressar valores intermediários. Intensidades 1.1, 1.2, 1.3, etc, podem ser usadas para elementos que possuem importâncias muito próximas. | | |

Fonte: (Saaty, 2008).

3. As comparações aos pares entre os critérios/alternativas, definidas no passo 2, são então organizadas em uma matriz quadrada recíproca. Os elementos da diagonal principal são definidos como iguais a 1. O critério presente na i -ésima linha é melhor que o critério da j -ésima coluna se o valor do elemento (i, j) é maior que 1,

caso contrário, o critério da j -ésima coluna será melhor que o da i -ésima linha. O elemento (j, i) será sempre o inverso do elemento (i, j) .

4. O autovetor principal normalizado da matriz de comparações define a importância relativa entre os critérios/alternativas que estão sendo comparados: os elementos deste autovetor normalizado representam os pesos dos critérios ou subcritérios, ou a classificação das alternativas comparadas.
5. A consistência da matriz de comparações, de ordem n , sendo este o número de critérios, subcritérios ou alternativas empregados nas comparações, é então avaliada. Comparações feitas por este método são subjetivas, e se o Índice de Consistência (CI) não atingir um valor mínimo desejado, os julgamentos feitos nas comparações devem ser revistos. Este índice definido no método AHP é dado por:

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (3.20)$$

em que λ_{max} é o máximo autovalor associado à matriz de julgamento. O Índice de Consistência pode ser comparado ao índice associado a uma matriz de julgamentos aleatória, RI. A razão CI/RI é denominada Razão de Consistência (CR) e, em (Saaty, 2008), sugere-se que CR seja menor que 0.1. A Tabela 6 apresenta alguns valores de RI para matrizes de diferentes dimensões n .

Tabela 6 – Valores de RI em função da ordem da matriz.

| | | | | | | | | | | |
|-----------|---|---|------|------|------|------|------|------|------|------|
| n | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| RI | 0 | 0 | 0.52 | 0.89 | 1.11 | 1.25 | 1.35 | 1.40 | 1.45 | 1.49 |

Fonte: (Colin, 2007).

6. A classificação de cada alternativa é multiplicada pelos pesos dos subcritérios, somando-se estes produtos para se obter uma classificação local em relação a cada critério. Esta classificação é então multiplicada pelos pesos dos critérios, e a soma destes produtos resultará na classificação global.

Esta pesquisa emprega o método AHP como forma de auxiliar apenas na definição dos pesos dos critérios assumidos para o problema de DEA. Desta forma, após esta etapa, os pesos obtidos são empregados em outra ferramenta de auxílio à tomada de decisão, o TOPSIS, discutido na seção seguinte, que então aponta para a alternativa mais adequada, dadas as preferências do projetista.

3.5.2 TOPSIS

O método TOPSIS, ou Técnica de Ordem de Preferência por Semelhança a uma Solução Ideal, foi desenvolvido por Tzeng e Huang (1981). Este método visa selecionar a

alternativa que mais se aproxima da solução ideal positiva (PIS) e que, simultaneamente, esteja mais afastada da solução ideal negativa (NIS). A PIS relaciona-se com os melhores valores alcançados pelas alternativas, visando a maximização de benefícios e a minimização de custos. A NIS, por sua vez, visa o oposto, tendo como referência os piores valores alcançados (Alves, 2018).

O TOPSIS realiza as seguintes etapas (Triantaphyllou, 2000):

1. O método constrói inicialmente uma matriz de decisão, D , formada pela avaliação de cada alternativa nos critérios empregados:

$$D = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1n_o} \\ d_{21} & d_{22} & \cdots & d_{2n_o} \\ \vdots & \vdots & & \vdots \\ d_{n_s1} & d_{n_s2} & \cdots & d_{n_s n_o} \end{bmatrix} \quad (3.21)$$

em que n_o é a quantidade de critérios, n_s é a quantidade de soluções/alternativas e d_{ij} quantifica o desempenho da i -ésima solução no j -ésimo critério.

2. A partir da matriz de decisão D , obtém-se a matriz de decisão normalizada, R , conforme (3.22).

$$r_{i,j} = \frac{d_{i,j}}{\sqrt{\sum_{i=1}^{n_s} d_{i,j}^2}} \quad (3.22)$$

3. O TOPSIS requer uma definição dos pesos de cada critério, conforme (3.23). Quanto maior o peso do critério, maior a sua importância no contexto do problema. Obtém-se, então, a matriz de decisão normalizada ponderada, V , conforme (3.24).

$$w = [w_1 \ w_2 \ \cdots \ w_{n_o}], \quad w_j \geq 0, \quad \sum_{j=1}^{n_o} w_j = 1 \quad (3.23)$$

$$v_{i,j} = w_j * r_{i,j} \quad (3.24)$$

em que w_j corresponde ao fator de peso do j -ésimo critério.

4. Nesta etapa, são obtidas a Solução Ideal Positiva (PIS, A^+) e a Solução Ideal Negativa (NIS, A^-):

$$A^+ = \{(\max_i v_{i,j} \mid j \in J'); (\min_i v_{i,j} \mid j \in J'')\} \quad (3.25)$$

$$A^- = \{(\min_i v_{i,j} \mid j \in J'); (\max_i v_{i,j} \mid j \in J'')\} \quad (3.26)$$

em que J' consiste no conjunto dos critérios de benefício e J'' é o conjunto dos critérios de custo.

5. Para cada alternativa i , calcula-se sua distância Euclidiana em relação à PIS e à NIS:

$$S_{i+} = \sqrt{\sum_{j=1}^{n_c} (v_{i,j} - v_{j+})^2} \quad (3.27)$$

$$S_{i-} = \sqrt{\sum_{j=1}^{n_c} (v_{i,j} - v_{j-})^2} \quad (3.28)$$

em que S_{i+} é a distância Euclidiana em relação à PIS, S_{i-} é a distância Euclidiana em relação à NIS, v_{j+} consiste na j -ésima coordenada da PIS e v_{j-} consiste na j -ésima coordenada da NIS.

6. Por fim, para cada solução calcula-se o coeficiente de aproximação, CC_i , que corresponde ao seu desempenho global:

$$CC_i = \frac{S_{i-}}{S_{i+} + S_{i-}} \quad (3.29)$$

O método indicará a solução que apresentar maior valor de coeficiente de aproximação (o que mais se aproximar de 1).

3.6 Conclusões

Este capítulo apresentou toda a metodologia proposta para a resolução do problema de DEA. Destaca-se aqui o problema de minimização sob condições de incerteza e o algoritmo MOEA/D Robusto. Definiu-se também a estratégia adotada para a tomada de decisão, composta por uma análise de diferentes critérios e o emprego de dois métodos de auxílio à tomada de decisão, o AHP e o TOPSIS.

Cabe ressaltar que na tomada de decisão, apenas o emprego do método AHP já seria suficiente para indicar a solução final. Porém, embora seja suficientemente preciso, este exige uma forte interação com a unidade de decisão. Por outro lado, o TOPSIS tem se mostrado eficiente, e necessita apenas da definição dos pesos dos critérios por parte do projetista.

4 Resultados

A abordagem apresentada no capítulo anterior é aqui empregada em dois estudos de caso. Estes testes consistem em dois sistemas termoeletricos de geração, que são apresentados na Seção 4.1. A Seção 4.2 apresenta um estudo visando o melhor ajuste de alguns parâmetros do algoritmo MOEA/D Robusto. Um estudo do impacto do domínio de incertezas é realizado na Seção 4.3. Por fim, na Seção 4.4 a estratégia empregada para a tomada de decisão é aplicada a um dos estudos de caso.

4.1 Estudos de Caso

Os estudos de caso analisados nesta pesquisa consistem em dois sistemas termoeletricos de geração e transmissão: o primeiro é formado por 30 barras, sendo 6 usinas geradoras, 41 linhas de transmissão, tensão base de 138 kV, potência base de 100 MVA e demanda de 2.834 p.u., nomeado na literatura por *6-generator 30-bus standard test system*. Os parâmetros das funções de custo e emissão de poluentes deste sistema estão presentes na Tabela 7. As demais características, tais como dados das linhas e das barras estão descritas em (Zimmerman; Murillo-Sanchez; Thomas, 2011).

Tabela 7 – Parâmetros para o sistema com 6 unidades geradoras

| Unidade | a | b | c | α | β | γ | ξ | φ | P^{min} (p.u.) | P^{max} (p.u.) |
|---------|-----|-----|-----|----------|---------|----------|----------|-----------|---------------------|---------------------|
| 1 | 10 | 200 | 100 | 4.091 | -5.554 | 6.49 | 2.00E-04 | 2.857 | 0.05 | 0.5 |
| 2 | 10 | 150 | 120 | 2.543 | -6.047 | 5.638 | 5.00E-04 | 3.333 | 0.05 | 0.6 |
| 3 | 20 | 180 | 40 | 4.258 | -5.094 | 4.586 | 1.00E-06 | 8 | 0.05 | 1 |
| 4 | 10 | 100 | 60 | 5.326 | -3.55 | 3.38 | 2.00E-03 | 2 | 0.05 | 1.2 |
| 5 | 20 | 180 | 40 | 4.258 | -5.094 | 4.586 | 1.00E-06 | 8 | 0.05 | 1 |
| 6 | 10 | 150 | 100 | 6.131 | -5.555 | 5.151 | 1.00E-05 | 6.667 | 0.05 | 0.6 |

Fonte: (Abido, 2003).

O segundo caso analisado nesta pesquisa consiste em um sistema formado por 39 barras, sendo 10 unidades geradoras, 46 linhas, nível de tensão de 345 kV e demanda de 2000 MW. As Tabelas 8 e 9 apresentam os parâmetros deste sistema, e demais características podem ser consultadas em (Zimmerman; Murillo-Sanchez; Thomas, 2011).

Os parâmetros das instâncias de teste até aqui apresentados estão em sua forma escalar. A conversão destes para números difusos está atrelada ao grau de incerteza a ser considerado. Nesta pesquisa, considera-se uma incerteza de 2.5% sobre os parâmetros das funções objetivo. Desta forma, os parâmetros das funções de custo e emissão de poluentes, apresentados nas Tabelas 7, 8 e 9, são assumidos como valores modais (a_0),

Tabela 8 – Parâmetros para o sistema com 10 unidades geradoras - Parte 1

| Unidade | a | b | c | d | e | α |
|---------|----------|---------|---------|-----|--------|----------|
| 1 | 1000.403 | 40.5407 | 0.12951 | 33 | 0.0174 | 360.0012 |
| 2 | 950.606 | 39.5804 | 0.10908 | 25 | 0.0178 | 350.0056 |
| 3 | 900.705 | 36.5104 | 0.12511 | 32 | 0.0162 | 330.0056 |
| 4 | 800.705 | 39.5104 | 0.12111 | 30 | 0.0168 | 330.0056 |
| 5 | 756.799 | 38.539 | 0.15247 | 30 | 0.0148 | 13.8593 |
| 6 | 451.325 | 46.1592 | 0.10587 | 20 | 0.0163 | 13.8593 |
| 7 | 1243.531 | 38.3055 | 0.03546 | 20 | 0.0152 | 40.2669 |
| 8 | 1049.998 | 40.3965 | 0.02803 | 30 | 0.0128 | 40.2669 |
| 9 | 1658.569 | 36.3278 | 0.02111 | 60 | 0.0136 | 42.8955 |
| 10 | 1356.659 | 38.2704 | 0.01799 | 40 | 0.0141 | 42.8955 |

Fonte: (Zhang et al., 2013).

Tabela 9 – Parâmetros para o sistema com 10 unidades geradoras - Parte 2

| Unidade | β | γ | ξ | φ | P^{min} (MW) | P^{max} (MW) |
|---------|---------|----------|---------|-----------|-------------------|-------------------|
| 1 | -3.9864 | 0.04702 | 0.25475 | 0.01234 | 10 | 55 |
| 2 | -3.9524 | 0.04652 | 0.25475 | 0.01234 | 20 | 80 |
| 3 | -3.9023 | 0.04652 | 0.25163 | 0.01215 | 47 | 120 |
| 4 | -3.9023 | 0.04652 | 0.25163 | 0.01215 | 20 | 130 |
| 5 | 0.3277 | 0.0042 | 0.2497 | 0.012 | 50 | 160 |
| 6 | 0.3277 | 0.0042 | 0.2497 | 0.012 | 70 | 240 |
| 7 | -0.5455 | 0.0068 | 0.248 | 0.0129 | 60 | 300 |
| 8 | -0.5455 | 0.0068 | 0.2499 | 0.01203 | 70 | 340 |
| 9 | -0.5112 | 0.0046 | 0.2547 | 0.01234 | 135 | 470 |
| 10 | -0.5112 | 0.0046 | 0.2547 | 0.01234 | 150 | 470 |

Fonte: (Zhang et al., 2013).

e seus limitantes inferior (\underline{a}) e superior (\bar{a}) são definidos a partir do grau de incerteza considerado, que neste caso resulta em:

$$\tilde{a} = [0.975a_0, a_0, 1.025a_0] \quad (4.1)$$

Uma vez definidos os parâmetros em sua forma *fuzzy*, o método α -cut permite uma ponderação da incerteza definida, conforme discutido na Seção 3.3.

Para o cálculo das perdas de potência ativa nas linhas de transmissão, empregou-se a ferramenta *Matpower* (Zimmerman; Murillo-Sanchez; Thomas, 2011), que consiste em um pacote do *Matlab* desenvolvido por pesquisadores da PSERC (*Power Systems Engineering Research Center*) e é usado para realizar fluxos de potência e fluxo de potência ótimo. O software *Matlab* foi o empregado como plataforma nesta pesquisa.

Na seção seguinte apresenta-se um estudo visando o melhor ajuste de alguns dos

parâmetros do método MOEA/D Robusto. Após estes ajustes, este algoritmo é então aplicado nas instâncias de teste apresentadas, visando uma análise da influência do domínio de incertezas, empregando-se diferentes valores de α (método α -cut). Após estas análises, são então discutidos os resultados da aplicação da estratégia de tomada de decisão, apresentada na Seção 3.5, frente ao cenário de maior incerteza.

4.2 Ajuste de Parâmetros

Nesta seção, três importantes parâmetros do algoritmo MOEA/D Robusto são analisados visando o seu ajuste para o problema em questão. Estes parâmetros consistem no número de soluções em cada vizinhança, T , e nos fatores de variação F_{cross} e CR .

Os testes consistiram na execução do algoritmo em cada instância assumindo diversas combinações destes parâmetros. Considerou-se uma métrica de desempenho apropriada para avaliar a qualidade das fronteiras de soluções não dominadas obtidas.

Como métrica de desempenho, empregou-se o indicador *Hypervolume* (Zitzler; Thiele, 1999). Esta métrica calcula o hipervolume envolto pela fronteira de soluções não dominadas S e um ponto de referência y_r dominado por todas as soluções de S . Em problemas de maximização é comum utilizar o ponto $(0, 0)$, enquanto que para problemas de minimização pode-se empregar o ponto (f_1^{max}, f_2^{max}) . Formalmente, este indicador é descrito como a medida de Lebesgue Λ_{HV} da união dos hipercubos h_i definidos entre um ponto não domindado $s_i \in S$ e y_r , conforme (4.2).

$$HV(S) = \Lambda_{HV} \left(\left\{ \bigcup_i h_i \mid s_i \in S \right\} \right) \quad (4.2)$$

A área sombreada da Figura 8 define o hipervolume do conjunto de soluções S em relação a um ponto de referência.




Figura 8 – Hipervolume de um conjunto de soluções.
 Fonte: Adaptado de (Rego, 2013).

Nos testes realizados, considerou-se um nível máximo de incerteza, igual a 2.5%, e os seguintes valores de parâmetros: $T = \{2, 5, 10, 20, 30\}$, $F_{cross} = \{0.5, 0.6, 0.7, 0.8, 0.9\}$ e $CR = \{0.1, 0.2, 0.5, 0.9, 1.0\}$. Para cada combinação destes três parâmetros, o MOEA/D Robusto foi executado 30 vezes em cada instância. Os resultados obtidos permitiram a elaboração dos *box plots*, conforme Figuras 9 e 10. Uma representação em *box plot* divide o conjunto de dados em quatro agrupamentos, onde a linha central indica a mediana dos dados e as bordas da caixa indicam os percentis relativos a 25% e 75%. O símbolo "+" indica *outliers*.

Conforme Figuras 9 e 10, o ajuste mais atrativo para o parâmetro CR consiste no valor 0.9, pois foi o que apresentou melhor valor mediano do indicador *Hypervolume* e pouca dispersão nas duas instâncias analisadas. Para o parâmetro F_{cross} , escolheu-se o valor corresponde a $F_{cross} = 0.5$, e para o T , optou-se por $T = 20$. Este último também poderia ser ajustado para $T = 30$, que também se apresentou atrativo, porém, a definição $T = 20$ caracteriza um menor custo computacional por iteração e também é um valor recorrente na literatura especializada.

Dados os ajustes para os três parâmetros discutidos, os demais foram definidos conforme sugestões encontradas na literatura: $N = 100$, que define o tamanho da população de soluções, de perturbações e também a quantidade de vetores de peso, $\delta = 0.9$, $n_r = 2$ e $\eta = 20$. O critério de parada empregado consistiu no número máximo de avaliações de função, definido como 10^6 avaliações.

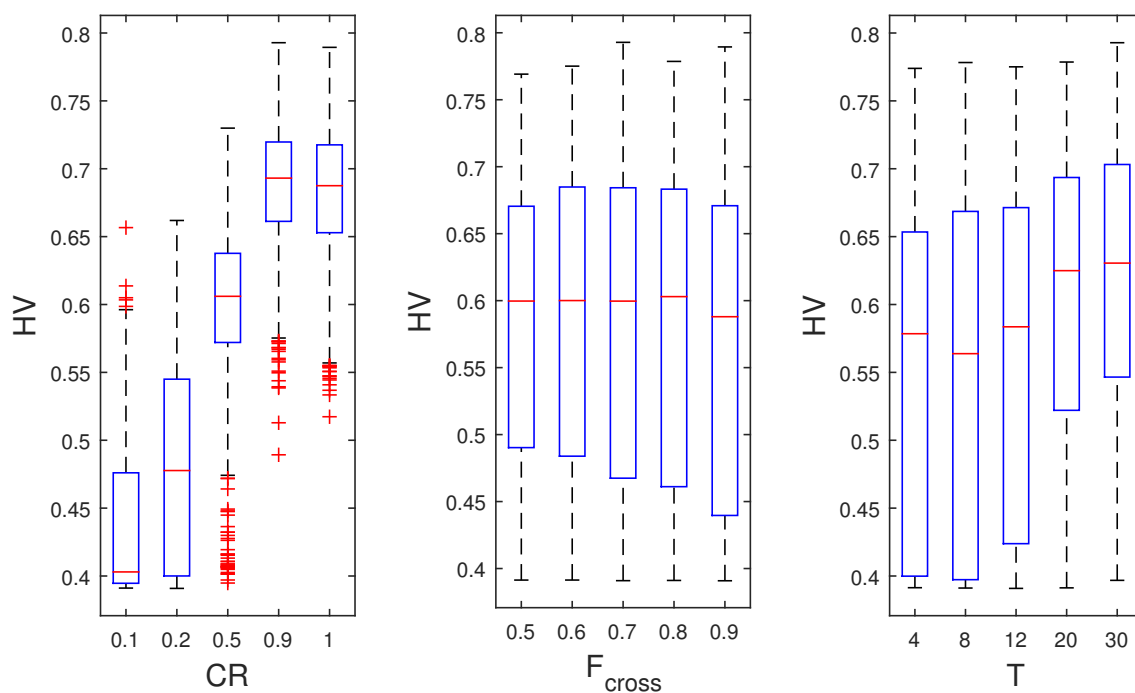


Figura 9 – *Box plot* dos resultados obtidos para o sistema com 6 usinas.

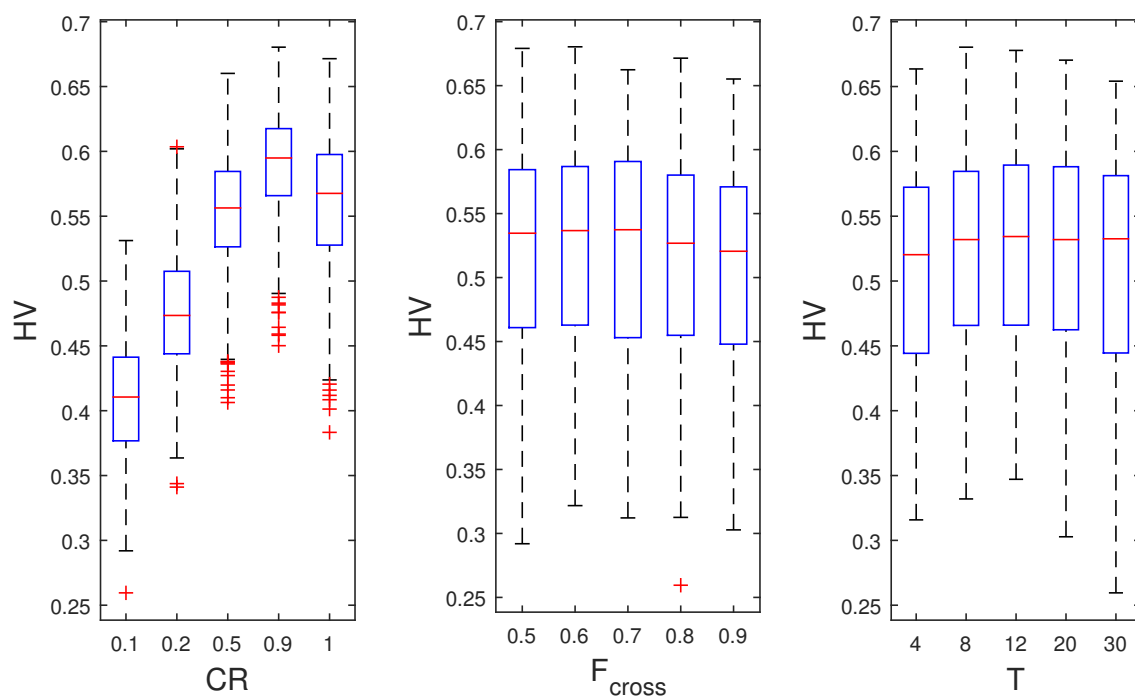


Figura 10 – *Box plot* dos resultados obtidos para o sistema com 10 usinas.

4.3 Análise do Impacto do Domínio de Incertezas

Nesta subseção, são investigadas soluções para o problema de DEA em diferentes cenários de incerteza. Estes cenários são obtidos a partir do emprego do método α -

cut, que permite um controle do nível de incerteza considerado alterando o domínio dos parâmetros *fuzzy*, conforme discutido na Seção 3.3.

Conforme Figura 5, na Seção 3.3, o valor de $\alpha = 1$ representa um cenário sem a presença de incertezas, uma vez que o domínio de cada parâmetro *fuzzy* será apenas seu valor modal. Por outro lado, o valor de $\alpha = 0$ implica na consideração de todo o domínio destes parâmetros. Além disso, valores intermediários de α , compreendidos no intervalo ($0 < \alpha < 1$), podem ser considerados. As Figuras 11 e 12 apresentam os conjuntos de soluções não dominadas obtidos nesta análise para os dois sistemas de teste empregados. Uma vez que o método empregado é estocástico, o mesmo foi executado cinco vezes para cada cenário analisado. Assim, cada fronteira apresentada nas Figuras 11 e 12 corresponde ao conjunto de soluções não dominadas resultante de cinco execuções do MOEA/D Robusto.




Figura 11 – Fronteiras obtidas para diferentes níveis de incerteza para o sistema de 6 usinas.

Conforme a Figura 11, o conjunto de soluções obtido na ausência de incertezas ($\alpha = 1$) é dominado pelos demais conjuntos, pois estes apresentam menores valores de custo e emissão de poluentes. Além disso, vale frisar que as soluções obtidas com $\alpha = 1$ não são robustas, conforme pode ser observado pelos demais conjuntos de soluções mapeadas, i.e., poucas soluções desses conjuntos estão na mesma região que as soluções estimadas para $\alpha = 1$. Por outro lado, para os casos em que $\alpha < 1$, são estimadas soluções robustas, i.e., com qualidades menos sensíveis às variações dos parâmetros de incerteza, uma vez que foram obtidas considerando-se domínios de incerteza.

Observa-se que para $\alpha = 0.9$ estimou-se o conjunto de soluções com a melhor convergência, entretanto, também mapeado em uma região pouco robusta, se comparado ao conjunto estimado para $\alpha = 0$. Nesse último, tem-se as soluções mais robustas, pois foram obtidas considerando-se o maior domínio de incertezas. Nota-se também a presença de soluções deste conjunto próximas aos extremos da fronteira, que correspondem a soluções robustas com elevados custos ou altas emissões.

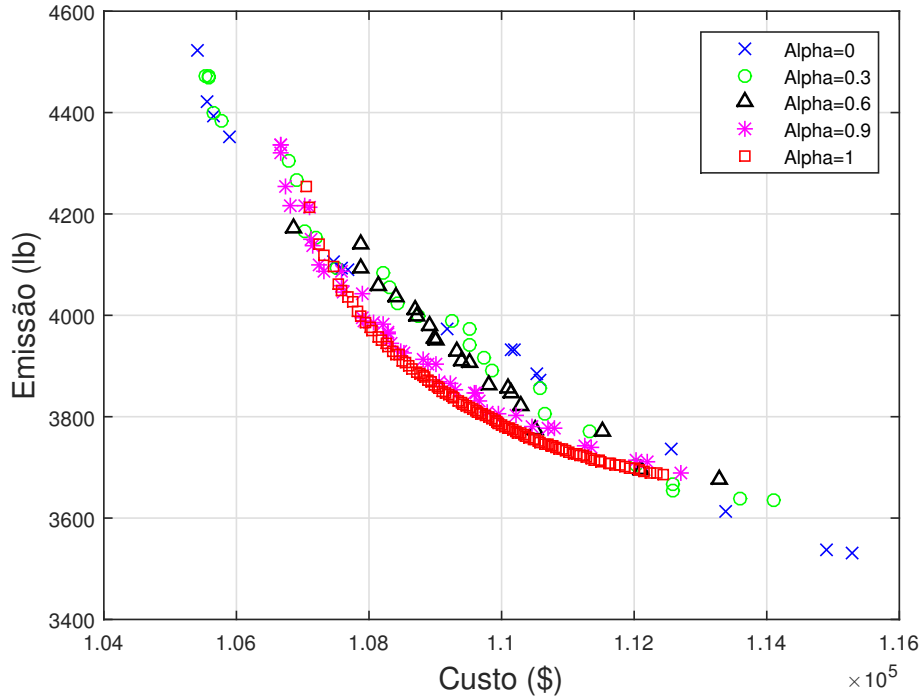


Figura 12 – Fronteiras obtidas para diferentes níveis de incerteza para o sistema de 10 usinas.

Para o problema com 10 unidades geradoras, observa-se, conforme Figura 12, que as soluções obtidas sem a consideração de incertezas dominam a maior parte das demais. Cabe notar também que para $\alpha = 0$, i.e., situação com maior domínio de incertezas, as soluções estimadas são mais esparsas, sugerindo que poucas regiões do espaço de projeto permitem o mapeamento de soluções robustas. Esse fato ressalta a importância desta investigação, para a identificação de soluções realmente plausíveis em um contexto real.

Destaca-se ainda que, como valores menores de α implicam em um maior domínio de incerteza, tem-se também um problema de otimização com um maior espaço de busca. Nesse contexto, para assegurar uma comparação justa, considerou-se um número de avaliações de função (critério de parada) suficientemente elevado para garantir uma convergência adequada do algoritmo para os diferentes valores de α empregados.

Por fim, observa-se diferentes comportamentos para os dois estudos de caso nas variações das fronteiras conforme variação de α . Essas diferenças podem estar relaciona-

das às diferenças nos limites operacionais das usinas destes dois sistemas: As usinas do sistema com 6 unidades apresentam, de maneira geral, faixas de geração ($P_{max} - P_{min}$) relativamente superiores às apresentadas pelas usinas do sistema com 10 unidades, o que permitiu a investigação de soluções robustas em um espaço de busca significativamente maior (mais amplo), o que possibilitou a obtenção de soluções robustas mais baratas e menos poluidoras do que as soluções obtidas sem a consideração de incertezas.

4.4 Tomada de Decisão

Nesta seção, a estratégia proposta para a definição da solução final, apresentada na Seção 3.5, é aplicada ao conjunto de soluções não dominadas obtido para o cenário de maior incerteza ($\alpha = 0$), soluções estas que tendem a ser mais robustas em relação às demais por terem sido sujeitas a um maior domínio de incertezas. As fronteiras de soluções não dominadas obtidas para os dois sistemas estudados são apresentadas nas Tabelas 11, 12, 13 e Figuras 13 e 14. Estas tabelas apresentam, além dos dois objetivos, os valores dos dois critérios adicionais considerados: perdas de potência ativa nas linhas e média dos percentuais de utilização das usinas.

Esta estratégia é comparada a uma abordagem para tomada de decisão muito empregada na literatura frente ao problema de DEA, que se baseia em princípios da teoria de conjuntos *fuzzy*. Desta forma, o processo de tomada de decisão é realizado de três maneiras distintas. Na primeira, apenas os objetivos do problema (assumidos neste momento como critérios) são considerados e é aplicado o método *fuzzy*, procedimento este aqui nomeado **Tomada de Decisão Fuzzy**. No segundo procedimento, também emprega-se o método *fuzzy*, porém, além do custo e da emissão de poluentes, são considerados os dois critérios adicionais (perdas de potência ativa nas linhas e média dos percentuais de utilização das usinas), procedimento este chamado de **Tomada de Decisão Multicritério Fuzzy**. No terceiro procedimento é então empregada a estratégia aqui proposta, juntamente com os quatro critérios assumidos, nomeado como **Tomada de Decisão Multicritério via AHP e TOPSIS**. Estes três procedimentos são descritos a seguir.

- **Tomada de Decisão Fuzzy**: Este método de auxílio à tomada de decisão retorna a solução de melhor compromisso entre os critérios usando um mecanismo baseado em lógica *fuzzy* (Abido, 2003), (Qu et al., 2018), (Shayeghi; Ghasemi, 2014). A partir do conjunto de alternativas analisado, para cada critério O_i é definida uma função de pertinência com base nos valores máximos e mínimos obtidos pelas soluções deste conjunto.

Assim, para cada solução k , tem-se:

$$\mu_i^k = \begin{cases} 1 & \text{se } O_i \leq O_i^{min} \\ \frac{O_i^{max} - O_i}{O_i^{max} - O_i^{min}} & \text{se } O_i^{min} < O_i < O_i^{max} \\ 0 & \text{se } O_i \geq O_i^{max} \end{cases} \quad (4.3)$$

$$\forall i \in \{1, \dots, n_o\}, \forall k \in \{1, \dots, n_s\}$$

em que μ_i^k corresponde ao valor de pertinência associado à k -ésima solução, no i -ésimo critério, n_o corresponde ao número de critérios e n_s é a quantidade de soluções não dominadas analisadas.

Para cada solução não dominada k , o valor de pertinência normalizado μ_{norm}^k é calculado como:

$$\mu_{norm}^k = \frac{\sum_{i=1}^{n_o} \mu_i^k}{\sum_{k=1}^{n_s} \sum_{i=1}^{n_o} \mu_i^k} \quad (4.4)$$

A solução que apresentar o maior valor de μ_{norm}^k será a de melhor compromisso entre os critérios adotados.

- **Tomada de Decisão Multicritério *Fuzzy***: Este procedimento emprega o mesmo método *fuzzy* descrito anteriormente, entretanto, considerando-se os quatro critérios: custo de geração, emissão de poluentes, perdas de potência ativa nas linhas e média dos percentuais de utilização das usinas.

- **Tomada de Decisão Multicritério via AHP e TOPSIS**: Dados os quatro critérios assumidos, esta estratégia emprega o método AHP para auxiliar na definição dos pesos de cada critério e, na sequência, emprega o método TOPSIS, que utiliza estes pesos em sua estrutura para indicação da solução mais adequada.

As comparações entre os critérios no método AHP foram realizadas com base na Escala Fundamental de Comparações (Tabela 5) e são apresentadas na Tabela 10. Conforme esta tabela, assumiu-se preferências similares (fator 1) entre os critérios custo e emissão, uma preferência forte (fator 5) destes em relação às perdas de potência ativa e entre forte e muito forte (fator 6) em relação à média do percentual de utilização das usinas. Já a ponderação das perdas em relação ao percentual de utilização se deu por um fator de 2 (entre similar e moderada).

Tabela 10 – Julgamentos entre os critérios.

| Crítérios | Custo | Emissão | Perdas | % Utilizado |
|-------------|-------|---------|--------|-------------|
| Custo | 1 | 1 | 5 | 6 |
| Emissão | 1 | 1 | 5 | 6 |
| Perdas | 1/5 | 1/5 | 1 | 2 |
| % Utilizado | 1/6 | 1/6 | 1/2 | 1 |

A partir destas preferências, o método retornou os pesos [0.4207 0.4207 0.0965 0.0621] para os critérios custo, emissão, perdas e percentual de utilização, respectivamente, com uma Razão de Consistência igual a 0.0123.

As três abordagens apresentadas indicaram como solução mais adequada para o sistema com 6 usinas a solução numerada por 1, apresentada na Tabela 11 e na Figura 13.

Tabela 11 – Soluções não dominadas robustas para o sistema com 6 usinas.

| Solução | $P_1(p.u.)$ | $P_2(p.u.)$ | $P_3(p.u.)$ | $P_4(p.u.)$ | $P_5(p.u.)$ | $P_6(p.u.)$ | Custo (\$/h) | Emissão (ton/h) | Perdas (p.u.) | Utilização (%) |
|---------|-------------|-------------|-------------|-------------|-------------|-------------|--------------|-----------------|---------------|----------------|
| 1 | 0.222128 | 0.324165 | 0.540317 | 0.834322 | 0.559351 | 0.383932 | 601.5554 | 0.204313 | 0.030216 | 0.549321 |
| 2 | 0.232258 | 0.467558 | 0.56869 | 0.672675 | 0.4779 | 0.442611 | 634.5469 | 0.181029 | 0.027692 | 0.537073 |
| 3 | 0.325316 | 0.395417 | 0.534417 | 0.738487 | 0.457402 | 0.41235 | 632.9046 | 0.181534 | 0.02939 | 0.56932 |
| 4 | 0.144781 | 0.337698 | 0.588777 | 0.868918 | 0.500287 | 0.423161 | 624.097 | 0.188955 | 0.029624 | 0.572684 |
| 5 | 0.317888 | 0.385378 | 0.538903 | 0.792765 | 0.432934 | 0.395862 | 630.7758 | 0.183288 | 0.029729 | 0.527569 |
| 6 | 0.272739 | 0.402989 | 0.535672 | 0.832163 | 0.479589 | 0.340661 | 600.5428 | 0.205267 | 0.029813 | 0.566255 |
| 7 | 0.296545 | 0.379267 | 0.535677 | 0.832165 | 0.479583 | 0.34068 | 600.5639 | 0.205205 | 0.029917 | 0.55147 |
| 8 | 0.219063 | 0.34795 | 0.515109 | 0.81986 | 0.603907 | 0.358775 | 613.6316 | 0.197626 | 0.030664 | 0.553105 |
| 9 | 0.115485 | 0.305283 | 0.596603 | 0.980284 | 0.513833 | 0.353764 | 622.5328 | 0.196675 | 0.031252 | 0.536821 |
| 10 | 0.442728 | 0.442847 | 0.50664 | 0.47087 | 0.507059 | 0.494061 | 649.0647 | 0.178758 | 0.030205 | 0.505755 |
| 11 | 0.289134 | 0.427323 | 0.463513 | 0.69299 | 0.516136 | 0.476276 | 609.7884 | 0.200783 | 0.031372 | 0.620357 |
| 12 | 0.303887 | 0.399732 | 0.562223 | 0.692516 | 0.424665 | 0.479686 | 611.6148 | 0.199498 | 0.02871 | 0.579594 |
| 13 | 0.241777 | 0.411565 | 0.537556 | 0.70803 | 0.521795 | 0.442128 | 605.6637 | 0.201197 | 0.028851 | 0.578932 |
| 14 | 0.191415 | 0.378737 | 0.515992 | 0.81909 | 0.526333 | 0.433235 | 598.2778 | 0.20586 | 0.030802 | 0.563094 |
| 15 | 0.086082 | 0.334676 | 0.596607 | 0.980281 | 0.513834 | 0.353763 | 596.4711 | 0.214194 | 0.031243 | 0.544907 |
| 16 | 0.224449 | 0.353929 | 0.615276 | 0.766663 | 0.466999 | 0.434179 | 627.6365 | 0.183751 | 0.027495 | 0.503772 |
| 17 | 0.220891 | 0.388776 | 0.549413 | 0.798114 | 0.487159 | 0.419024 | 627.4067 | 0.186303 | 0.029378 | 0.550511 |
| 18 | 0.232655 | 0.347078 | 0.549413 | 0.81511 | 0.500446 | 0.419024 | 626.5976 | 0.186768 | 0.029726 | 0.547027 |
| 19 | 0.40322 | 0.492238 | 0.563226 | 0.496924 | 0.475523 | 0.431024 | 652.1695 | 0.177112 | 0.028155 | 0.60976 |
| 20 | 0.401301 | 0.418802 | 0.532729 | 0.643629 | 0.474965 | 0.391623 | 640.9237 | 0.178827 | 0.029049 | 0.59067 |
| 21 | 0.350586 | 0.4355 | 0.59349 | 0.638126 | 0.5333 | 0.309719 | 636.4898 | 0.18021 | 0.026721 | 0.572223 |
| 22 | 0.193877 | 0.456973 | 0.551529 | 0.725566 | 0.510456 | 0.423995 | 630.9962 | 0.182252 | 0.028396 | 0.556622 |




Figura 13 – Soluções não dominadas robustas para o sistema com 6 usinas. A solução representada por 'x' corresponde à solução indicada pelas três estratégias de suporte à tomada de decisão.

Já para o sistema com 10 usinas, a Tomada de Decisão *Fuzzy* indicou como solução mais adequada a numerada por 1, e a solução numerada por 2 foi a indicada pelos processos Tomada de Decisão Multicritério *Fuzzy* e Tomada de Decisão Multicritério via AHP e TOPSIS. Estas soluções são apresentadas nas Tabelas 12, 13 e Figura 14.

Para este sistema, embora a solução 2 apresente um valor de emissão um pouco superior ao obtido pela solução 1, ela se apresenta mais promissora em todos os outros três critérios assumidos. Este resultado ressalta a relevância da análise multicritério proposta, permitindo selecionar as soluções mais adequadas, conforme critérios da unidade de decisão.

Tabela 12 – Soluções não dominadas robustas para o sistema com 10 usinas - Parte 1.

| Solução | $P_1(MW)$ | $P_2(MW)$ | $P_3(MW)$ | $P_4(MW)$ | $P_5(MW)$ | $P_6(MW)$ | $P_7(MW)$ |
|---------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| 1 | 54.8177 | 61.5949 | 86.47952 | 81.7685 | 120.9367 | 162.8746 | 256.4834 |
| 2 | 55 | 70.39701 | 83.19175 | 85.97023 | 98.61557 | 141.7076 | 300 |
| 3 | 54.9575 | 52.40544 | 83.4175 | 85.71876 | 137.9572 | 183.674 | 272.6214 |
| 4 | 54.88662 | 74.60247 | 85.28951 | 83.83479 | 105.3742 | 133.7536 | 287.1106 |
| 5 | 54.74489 | 69.45229 | 85.17873 | 83.65424 | 106.994 | 128.7785 | 295.9324 |
| 6 | 54.87675 | 79.63155 | 71.40143 | 82.06541 | 156.5434 | 235.3491 | 254.671 |
| 7 | 54.84461 | 68.67284 | 87.20737 | 80.03573 | 110.0934 | 139.0315 | 273.1566 |
| 8 | 54.47107 | 46.19182 | 99.81934 | 85.29897 | 93.05899 | 91.25 | 300 |
| 9 | 55 | 68.69035 | 86.09044 | 88.1484 | 79.08392 | 103.145 | 300 |
| 10 | 54.99961 | 61.46807 | 88.69636 | 77.73278 | 148.6079 | 198.9418 | 278.0819 |
| 11 | 54.48206 | 76.95735 | 83.58395 | 78.89838 | 160 | 240 | 276.3058 |
| 12 | 53.13433 | 64.52427 | 88.25019 | 80.64661 | 148.4994 | 199.9207 | 281.3833 |
| 13 | 55 | 76.25628 | 98.22398 | 84.5166 | 85.18753 | 92.46036 | 297.4613 |
| 14 | 55 | 80.01622 | 95.42689 | 85.29381 | 70.42942 | 70 | 300 |
| 15 | 50.86028 | 69.05612 | 90.17505 | 83.74638 | 98.47613 | 110.7213 | 300 |
| 16 | 50.86028 | 73.94375 | 89.04044 | 83.7461 | 94.707 | 110.7213 | 300 |

Tabela 13 – Soluções não dominadas robustas para o sistema com 10 usinas - Parte 2.

| Solução | $P_8(MW)$ | $P_9(MW)$ | $P_{10}(MW)$ | Custo (\$) | Emissão (lb) | Perdas (MW) | Utilização (%) |
|---------|-----------|-----------|--------------|------------|--------------|-------------|----------------|
| 1 | 335.0813 | 410.757 | 441.4278 | 107594 | 4094.102 | 12.22152 | 0.751708 |
| 2 | 293.3541 | 424.8757 | 458.5862 | 107476.7 | 4106.103 | 11.69817 | 0.74561 |
| 3 | 305.357 | 415.8988 | 419.9091 | 112563.1 | 3734.85 | 11.91671 | 0.754333 |
| 4 | 304.2471 | 442.5104 | 440.9157 | 110577.1 | 3871.151 | 12.52492 | 0.75317 |
| 5 | 298.7006 | 448.8137 | 440.4337 | 110533.3 | 3883.601 | 12.68306 | 0.745854 |
| 6 | 299.3296 | 347.4494 | 428.2934 | 114903.8 | 3537.29 | 9.611034 | 0.799518 |
| 7 | 324.6027 | 426.0842 | 448.7027 | 107679.2 | 4091.474 | 12.43161 | 0.749018 |
| 8 | 315.6742 | 462.382 | 465.5215 | 105889.2 | 4353.299 | 13.66779 | 0.713157 |
| 9 | 306.4608 | 456.5295 | 470 | 105556.4 | 4421.904 | 13.14841 | 0.726146 |
| 10 | 294.0506 | 416.8822 | 392.3589 | 109180 | 3971.787 | 11.82005 | 0.777937 |
| 11 | 280.0426 | 379.9767 | 380.2614 | 115280.2 | 3529.502 | 10.50838 | 0.810442 |
| 12 | 297.0726 | 394.488 | 403.1863 | 113378.8 | 3614.681 | 11.10582 | 0.780594 |
| 13 | 309.0437 | 455.0414 | 459.8375 | 105653.3 | 4394.29 | 13.02855 | 0.747618 |
| 14 | 317.7249 | 470 | 470 | 105418.9 | 4523.964 | 13.89121 | 0.736018 |
| 15 | 316.0801 | 447.2027 | 446.7557 | 110192 | 3933.463 | 13.07371 | 0.734751 |
| 16 | 316.0802 | 447.2027 | 446.7557 | 110136.7 | 3933.487 | 13.05736 | 0.737916 |

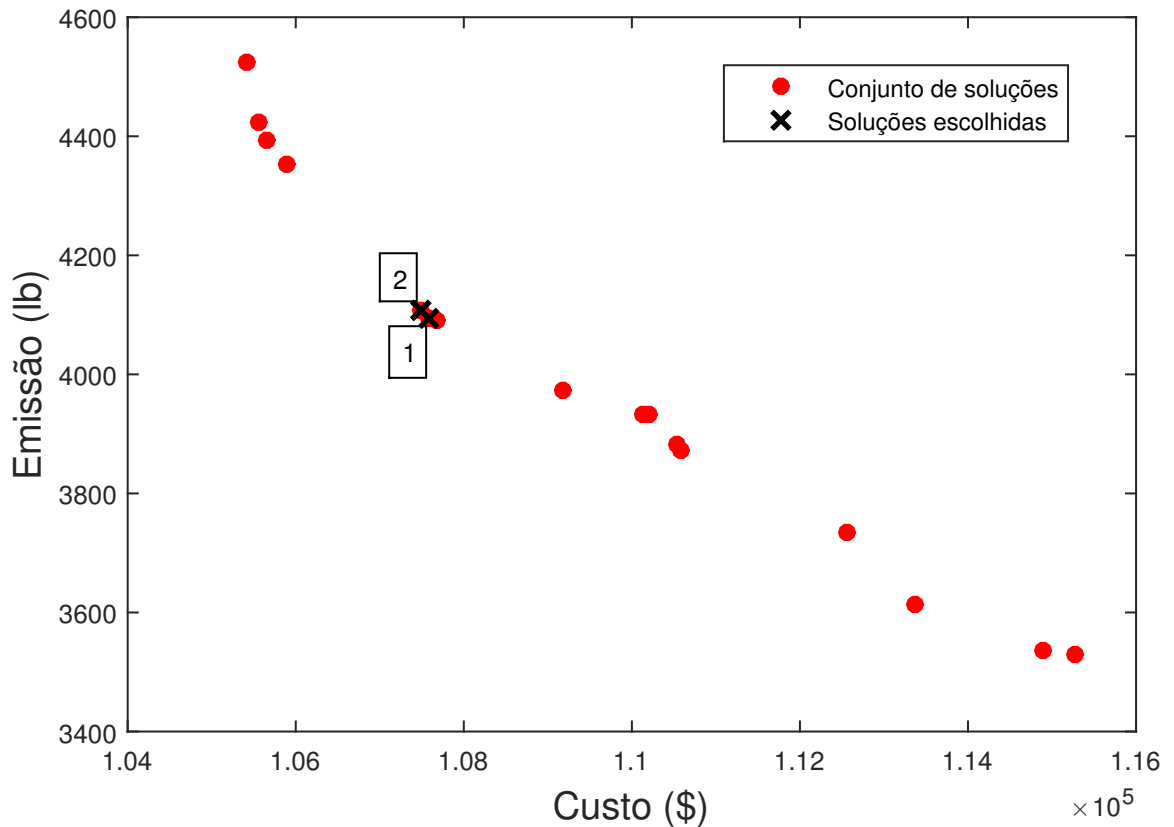


Figura 14 – Soluções não dominadas robustas para o sistema com 10 usinas. A solução numerada por 1 foi a selecionada na Tomada de Decisão Fuzzy e a solução 2 foi a obtida nos processos de Tomada de Decisão Multicritério *Fuzzy* e Tomada de Decisão Multicritério via AHP e TOPSIS.

4.5 Conclusões

Este capítulo foi dedicado à aplicação da metodologia proposta em dois sistemas de geração. De forma geral, pôde-se avaliar o desempenho do algoritmo MOEA/D Robusto frente a diversos cenários de incerteza, obtendo soluções robustas satisfatórias para o problema de DEA. Destaca-se também a relevância da análise multicritério empregada no processo de tomada de decisão, que permitiu a seleção de soluções mais promissoras, de acordo com os critérios utilizados.

5 Conclusões

5.1 Considerações Finais

Propôs-se nesta pesquisa uma abordagem multiobjetivo para o problema de Despacho Econômico e Ambiental, incorporando incertezas na estimação dos objetivos do problema. Essa consideração de incertezas torna-se relevante devido ao dinamismo comercial presente no setor elétrico, no qual também estão presentes as crescentes preocupações com os impactos ambientais.

Na definição do problema, números *fuzzy* foram atribuídos aos parâmetros das funções objetivo. Juntamente a estes, foi empregado o método α -cut, que viabilizou uma análise para diferentes níveis de incerteza. A partir disso, definiu-se um problema de otimização robusta, o qual permite encontrar soluções para o pior cenário de incertezas.

Frente ao problema proposto, empregou-se o algoritmo MOEA/D Robusto. Sua característica baseada na decomposição de um problema multiobjetivo em subproblemas escalares permitiu, a cada iteração, a maximização dos objetivos em relação aos parâmetros incertos e a minimização em relação às variáveis de decisão, permitindo encontrar soluções robustas para o problema.

A abordagem apresentada pôde ser validada pela aplicação em dois sistemas de geração. Após a otimização multiobjetivo, custo e emissão de poluentes foram tomados como critérios, juntamente com a análise das perdas de potência ativa na rede de transmissão e da média do percentual de utilização de cada unidade geradora, permitindo uma análise mais consistente das soluções não dominadas obtidas, auxiliando na tomada de decisão.

No primeiro estudo de caso, a otimização robusta considerando parâmetros incertos permitiu a descoberta de soluções mais baratas e menos poluidoras que as obtidas pela otimização sem a consideração de incertezas. Além disso, estas soluções são robustas à variações destes parâmetros, fatores estes que justificam a relevância deste tipo de abordagem.

Já no segundo estudo de caso, embora as soluções robustas obtidas sejam dominadas pelo conjunto obtido sem a consideração de incertezas, elas ainda se apresentam próximas a este conjunto, ou seja, consistem em soluções aparentemente um pouco inferiores, mas certamente mais robustas às perturbações.

A consideração de incertezas no problema estudado permitiu a identificação de soluções robustas, o que exemplifica e reforça a atual tendência de se abordar problemas de

otimização na presença de incertezas.

De maneira geral, os objetivos desta pesquisa foram alcançados e os resultados foram satisfatórios: a otimização robusta proposta e o algoritmo empregado resultaram em soluções robustas e a análise multicritério proposta permitiu a definição de uma ação (solução) final de maneira mais consistente.

5.2 Propostas de Trabalhos Futuros

Com base na pesquisa desenvolvida nesta dissertação e nos resultados obtidos, sugere-se algumas pesquisas complementares, tais como:

- Inserção de outras fontes de geração, como usinas hidroelétricas e eólicas. Estas são severamente sujeitas à variações e sazonalidades climáticas, o que requer um tratamento adequado de incertezas.
- Abordagem do problema de DEA em sua forma dinâmica, onde se define a operação das usinas para diversos períodos. Nesta abordagem se fazem necessárias restrições de limite de rampa, que levam em consideração o tempo de ajuste de geração das usinas, uma vez que essas mudanças não podem ser realizadas instantaneamente. Esta abordagem é, inclusive, mais próxima do ambiente prático do problema.
- Investigação de diferentes definições de robustez, por exemplo, análise do caso médio ao invés do pior caso.

5.3 Publicações Decorrentes desta Pesquisa

Os resultados desta pesquisa de mestrado permitiram as seguintes publicações:

- Costa, M. M., Batista, L. S. Análise Multicritério do Problema de Despacho Econômico e Ambiental sob Condições de Incerteza. *XVI CEEL - Conferência de Estudos em Engenharia Elétrica*, Uberlândia, MG, 2018. p. 1-6.
- Costa, M. M., Batista, L. S. Otimização Robusta Multiobjetivo do Problema de Despacho Econômico e Ambiental sob Condições de Incerteza, *14º SBAI - Simpósio Brasileiro de Automação Inteligente*, Ouro Preto, MG, 2019. p. 1-8. (em análise).

Referências

- Abido, M. A. Environmental/economic power dispatch using multiobjective evolutionary algorithms. *IEEE Transactions on Power Systems*, v. 18, n. 4, p. 1529–1537, 2003.
- Aichen, W.; Weiguo, P.; Wenhuan, W. A study of multi-objective load optimal dispatch in thermal power unit based on improved particle swarm optimization algorithm. *Advanced Materials Research*, p. 1425–1430, 2014.
- Alves, M. A. *Um Estudo sobre Incertezas em Problemas de Tomada de Decisão Multicritério*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil, 2018.
- Amorim, E. de A. et al. Algoritmo evolutivo multiobjetivo para o despacho econômico e ambiental. *XLI SBPO - Pesquisa Operacional na Gestão do Conhecimento*, p. 1860–1871, 2009.
- ANEEL. *Agência Nacional de Energia Elétrica*. 2018. <<http://www.aneel.gov.br>>. Último acesso: 31/05/2019.
- Assis, J. N. R. et al. Robust evolutionary optimization algorithm for multi-objective environmental/economic dispatch problem with uncertainties. In: *IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2018. p. 1–6.
- Azevedo, R. E. dos S. *Otimização Multicritério Para Despacho Econômico e Ambiental de Usinas Térmicas Utilizando Enxame de Partículas*. Tese (Doutorado) — Universidade Federal do Pará, Belém, PA, Brasil, 2015.
- Bedrinana, M. F. et al. Decisions in power system operation based on fuzzy economic and environmental dispatch. In: *IEEE Lausanne Power Tech*. [S.l.: s.n.], 2007. p. 1296–1301.
- Bhushan, N.; Rai, K. *Strategic Decision Making: Applying the Analytic Hierarchy Process*. [S.l.]: Springer London, 2004. (Decision Engineering). ISBN 9781852337568.
- Bilil, H.; Ellaia, R.; Maaroufi, M. A new multi-objective particle swarm optimization for economic environmental dispatch. In: *IEEE International Conference on Complex Systems (ICCS)*. [S.l.: s.n.], 2012. p. 1–6.
- Cai, J. et al. Chaotic particle swarm optimization for economic dispatch considering the generator constraints. *Energy Conversion and Management*, v. 48, n. 2, p. 645 – 653, 2007.
- CCEE. *Câmara de Comercialização de Energia Elétrica*. 2018. <https://www.ccee.org.br/portal/faces/pages_publico/inicio?_afzLoop=6423987446666&_adf.ctrl-state=14uqfl0g0u_5#!%40%40%3F_afzLoop%3D6423987446666%26_adf.ctrl-state%3D14uqfl0g0u_9>. Último acesso: 31/05/2019.
- Chansareewittaya, S.; Soponronnarit, K.; Boonyanant, P. Modified de/sin for economic dispatch and environmental dispatch. In: *5th International Conference on Business and Industrial Research (ICBIR)*. [S.l.: s.n.], 2018. p. 297–302.

- Colin, E. C. *Pesquisa Operacional: 170 aplicações em Estratégia, Finanças, Logística, Produção, Marketing e Vendas*. [S.l.]: Rio de Janeiro LTC, 2007.
- Deb, K.; Goyal, M. A combined genetic adaptive search (geneas) for engineering design. *Computer Science and Informatics*, v. 26, p. 30–45, 1996.
- Deligiannis, V. F.; Manesis, S. A. Modeling internal combustion engines using a hyper-class of hybrid automata: A case study. In: *IEEE Conference on Computer Aided Control System Design*. [S.l.: s.n.], 2006. p. 2991–2996.
- EPE. *Empresa de Pesquisa Energética - Matriz Energética e Elétrica*. 2018. <<http://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>>. Último acesso: 24/01/2019.
- Farag, A.; Al-Baiyat, S.; Cheng, T. C. Economic load dispatch multiobjective optimization procedures using linear programming techniques. *IEEE Transactions on Power Systems*, v. 10, n. 2, p. 731–738, 1995.
- Ghasemi, A. A fuzzified multi objective interactive honey bee mating optimization for environmental/economic power dispatch with valve point effect. *International Journal of Electrical Power & Energy Systems*, v. 49, p. 308 – 321, 2013.
- Gjengedal, T.; Johansen, S.; Hansen, O. A qualitative approach to economic-environment dispatch-treatment of multiple pollutants. *IEEE Transactions on Energy Conversion*, v. 7, n. 3, p. 367–373, 1992.
- Gong, D. wei; Zhang, Y.; Qi, C. liang. Environmental/economic power dispatch using a hybrid multi-objective optimization algorithm. *International Journal of Electrical Power & Energy Systems*, v. 32, n. 6, p. 607 – 614, 2010.
- Hu, Y.-L.; Wee, W. G. A hierarchical system for economic dispatch with environmental constraints. *IEEE Transactions on Power Systems*, v. 9, n. 2, p. 1076–1082, 1994.
- Hussien, A.; Kamel, S.; Ebeed, M. Solution of economic and environmental dispatch with valve point effect using moth swarm algorithm. In: *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)*. [S.l.: s.n.], 2017. p. 941–946.
- Jang, J. S. R.; Sun, C. T.; Mizutani, E. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. [S.l.]: Prentice Hall, 1997.
- Jin, J. et al. Modeling for dynamic economic emission dispatch under uncertainty. *Electric Power Components and Systems*, Taylor & Francis, v. 43, n. 14, p. 1630–1643, 2015.
- King, R. T. F. A.; Rughooputh, H. C. S.; Deb, K. Evolutionary multi-objective environmental / economic dispatch : Stochastic vs . deterministic approaches. In: . [S.l.: s.n.], 2005. v. 3410, p. 677–691.
- Li, H.; Zhang, Q. Multiobjective optimization problems with complicated pareto sets, moea/d and nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 13, n. 2, p. 284–302, 2009.

- Lora, E. E. S.; Nascimento, M. A. R. do. *Geração Termoelétrica - Planejamento, Projeto e Operação*. 1a edição. ed. [S.l.]: Editora Interciência, 2004. I e II. ISBN 85-7193-105-4.
- Meneghini, I. R.; Guimarães, F. G.; Gaspar-Cunha, A. Competitive coevolutionary algorithm for robust multi-objective optimization: The worst case minimization. In: *IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2016. p. 586–593.
- Miettinen, K. *Nonlinear Multiobjective Optimization*. [S.l.]: Boston: Kluwer Academic Publishers, 1999.
- Moraes, N. M. *Modelo Matemático para Otimização Multiobjetivo do Despacho Econômico Ambiental de Usinas Térmicas usando o NSGA-II*. Tese (Doutorado) — Universidade Federal do Pará, Belém, PA, Brasil, 2017.
- Morsali, R. et al. A new multiobjective procedure for solving nonconvex environmental/economic power dispatch. *Complexity*, v. 20, n. 2, p. 47–62, 2014.
- Mousa, A. A. A. Hybrid ant optimization system for multiobjective economic emission load dispatch problem under fuzziness. *Swarm and Evolutionary Computation*, v. 18, p. 11 – 21, 2014.
- Oliveira, E. da S. *Metaheurísticas aplicadas ao problema do despacho econômico de energia elétrica*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Brasil, 2015.
- ONS. *Operador Nacional do Sistema Elétrico*. 2018. <<http://ons.org.br>>. Último acesso: 31/05/2019.
- Pal, B. B.; Kumar, M. Interval goal programming for economic-environmental power generation - dispatch problems. In: *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. [S.l.: s.n.], 2013. p. 1–8.
- Panta, S.; Premrudeepreechacharn, S. Economic dispatch for power generation using artificial neural network. In: *7th International Conference on Power Electronics*. [S.l.: s.n.], 2007. p. 558–562.
- Qu, B. et al. A survey on multi-objective evolutionary algorithms for the solution of the environmental/economic dispatch problems. *Swarm and Evolutionary Computation*, v. 38, p. 1 – 11, 2018.
- Rego, M. F. *Algoritmos Multiobjetivos para o Problema de Sequenciamento de Tarefas em Uma Máquina com Tempo de Preparação Dependente da Sequência e da Família*. Dissertação (Mestrado) — Universidade Federal de Ouro Preto, Ouro Preto, MG, Brasil, 2013.
- Reis, L. B. dos. *Geração de Energia Elétrica*. 2a edição. ed. [S.l.]: Manole, 2011. ISBN 978-85-204-3039-2.
- Saaty, T. Decision making with the analytic hierarchy process. *Int. J. Services Sciences Int. J. Services Sciences*, v. 1, p. 83–98, 2008.
- Salhi, A.; Naimi, D.; Bouktir, T. Tvac based pso for solving economic and environmental dispatch considering security constraint. In: *International Renewable and Sustainable Energy Conference (IRSEC)*. [S.l.: s.n.], 2013. p. 396–401.

- Shayeghi, H.; Ghasemi, A. A modified artificial bee colony based on chaos theory for solving non-convex emission/economic dispatch. *Energy Conversion and Management*, v. 79, p. 344 – 354, 2014.
- Singh, L.; Dhillon, J. S. Interactive fuzzy approach for economic-environmental electric power load dispatch. In: *IEEE International Conference on Power System Technology (POWERCON)*. [S.l.: s.n.], 2016. p. 1–6.
- Song, Y. H. et al. Environmental/economic dispatch using fuzzy logic controlled genetic algorithms. *IEE Proceedings - Generation, Transmission and Distribution*, v. 144, n. 4, p. 377–382, 1997.
- Storn, R.; Price, K. Differential evolution: A simple and efficient adaptive scheme for global optimization over continuous spaces. *Journal of Global Optimization*, v. 23, 1995.
- Talaq, J. H.; El-Hawary, F.; El-Hawary, M. E. A summary of environmental/economic dispatch algorithms. *IEEE Transactions on Power Systems*, v. 9, n. 3, p. 1508–1516, 1994.
- Triantaphyllou, E. *Multi-Criteria Decision Making Methods: A Comparative Study*. [S.l.]: Springer- Science+Business Media B. V., 2000.
- Tzeng, G. H.; Huang, J. J. *Multiple attribute decision making*. [S.l.]: Springer-Verlag Berlin Heidelberg, 1981.
- Zhang, G. L. et al. Environmental/economic load dispatch based on weighted ideal point and hybrid evolutionary algorithm. In: *2005 International Conference on Machine Learning and Cybernetics*. [S.l.: s.n.], 2005. v. 4, p. 2466–2471.
- Zhang, L. et al. Solved environmental/economic dispatch based on multi-objective pso. In: *International Conference on Intelligent Computation Technology and Automation*. [S.l.: s.n.], 2010. v. 3, p. 352–355.
- Zhang, Q.; Li, H. Moea/d: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, v. 11, n. 6, p. 712–731, 2007.
- Zhang, R. et al. Economic environmental dispatch using an enhanced multi-objective cultural algorithm. *Electric Power Systems Research*, v. 99, p. 18 – 29, 2013.
- Zimmerman, R. D.; Murillo-Sanchez, C. E.; Thomas, R. J. Matpower: Steady-state operations, planning, and analysis tools for power systems research and education. *IEEE Transactions on Power Systems*, v. 26, n. 1, p. 12–19, 2011.
- Zitzler, E.; Thiele, L. Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, v. 3, n. 4, p. 257–271, 1999.