Otimização Robusta Multiobjetivo do Problema de Despacho Econômico e Ambiental sob Condições de Incerteza

Miguel M. Costa*. Lucas S. Batista**

* *Programa de Pós-Graduação em Engenharia Elétrica – Universidade Federal de Minas Gerais*
Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil (e-mail: miguelmonteirorp@yahoo.com.br).

** *Departamento de Engenharia Elétrica, Universidade Federal de Minas Gerais*
Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil (e-mail: lusoba@ufmg.br).

Abstract: With growing concern about environmental degradation, a planning power generation system that aims to minimize only the cost of generation is not an appropriate approach to this task. In this sense, the problem of Economic and Environmental Dispatch studied here aims to minimize two conflicting objectives: cost of generation and emission of pollutants in electric power generation thermoelectric systems. This work proposes an approach that incorporates uncertainties inherent to this problem and a robust optimization, investigating the best solutions for the worst case uncertainty scenario. A variation of the MOEA/D algorithm is employed and the results of the robust optimization are compared to those of the approach without the treatment of uncertainties. Given a set of promising solutions obtained for this problem, a multicriteria analysis of these solutions is also proposed, where decision support methods are used, in order to define a final action in a more adequate way. This methodology is applied to a 30-bar generation thermoelectric system with 6 generating units, highlighting both the potential of the proposed approach and the quality of the final solution indicated.

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 aqui estudado visa minimizar dois objetivos conflitantes: custo de geração e emissão de poluentes em sistemas termoeletrônicos de geração de energia elétrica. Este trabalho propõe uma abordagem que incorpora incertezas inerentes a este problema, propondo também uma otimização robusta, investigando-se as melhores soluções para o pior cenário de incertezas. Uma variação do algoritmo MOEA/D é empregada e os resultados da otimização robusta são comparados aos da abordagem sem o tratamento de incertezas. 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 um sistema termoeletrico de geração de 30 barras, com 6 unidades geradoras, a partir do qual destaca-se tanto o potencial da ferramenta proposta quanto a qualidade da solução final indicada.

Keywords: Environmental Economic Dispatch; Multiobjective Optimization; Uncertainties; Smart Decision Making.

Palavras-chaves: Despacho Econômico e Ambiental; Otimização Multiobjetivo; Incertezas; Tomada de Decisão Inteligente.

1. INTRODUÇÃO

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

No planejamento de sistemas de geração de energia visa-se atender à demanda ao menor custo de geração possível. Essa eficiência pode ser obtida através do Despacho Econômico (DE), que consiste em alocar a potência ativa a ser gerada entre as usinas, de modo a minimizar este custo, sujeito a restrições

operacionais e de carga (Panta and Premrudeepreechacharn, 2007).

Em sistemas termoeletrônicos de geração estão presentes elevadas emissões de poluentes provocadas pelo processo de geração, e devido à crescente preocupação com a degradação ambiental, um planejamento que visa minimizar apenas o custo de geração não configura uma abordagem adequada ao problema. Frente a isso, define-se o problema de Despacho Econômico e Ambiental (DEA), que visa minimizar simultaneamente dois objetivos conflitantes: o custo de geração (atrelado, principalmente, ao consumo de combustível necessário à usinas térmicas) e as emissões de poluentes.

As primeiras pesquisas dedicadas ao problema de DEA datam da década de 90, em que geralmente empregava-se métodos convencionais de otimização. Nesse sentido, tanto em Talaq et al. (1994) como em Farag et al. (1995), o objetivo ambiental foi modelado junto às restrições do problema, tratando este como um problema de programação linear. Ainda neste período, alguns autores propuseram abordagens não lineares, definindo uma soma ponderada entre os objetivos do problema, como em Gjengedal et al. (1992), Hu and Wee (1994) e Song et al. (1997).

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 empregados nos trabalhos aqui destacados.

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. Nesse sentido, algumas pesquisas realizam a otimização simultânea dos objetivos custo de geração e emissão de poluentes, empregando métodos como o SPEA (Abido, 2003), NSGA-II (King; Rughooputh; Deb, 2005), (Assis et al., 2018) e a metaheurística PSO (Zhang et al., 2010), (Bilil; Ellaia; Maaroufi, 2012). Esta metaheurística também é citada em Gong et al. (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*.

Na literatura especializada, alguns trabalhos tratam o problema de DEA considerando incertezas inerentes a este problema. Neste sentido, a pesquisa presente em Jin et al. (2015), propõe 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 et al. (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 foram assumidos como números *fuzzy*.

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.

De forma geral, os trabalhos discutidos anteriormente contribuem com a literatura em diversos aspectos, porém, apresentam limitações quanto a modelagem do problema com a incorporação de incertezas 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 robusta para o problema de DEA, em que os parâmetros das funções objetivo são definidos dentro de um domínio de incertezas, onde 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. Os resultados obtidos indicam que a abordagem integrada proposta permite a identificação de soluções promissoras e robustas à variação dos parâmetros de incertezas.

Este trabalho está organizado da seguinte maneira: A Seção 2 apresenta a modelagem comumente empregada pela literatura para o problema de DEA e também a modelagem proposta neste trabalho. As Seções 3 e 4 apresentam, respectivamente, o método de otimização multiobjetivo e a abordagem de auxílio à tomada de decisão sugeridos neste trabalho. Na Seção 5 são apresentados os resultados, juntamente com a análise multicritério proposta. Por fim, as conclusões são abordadas na Seção 6.

2. MODELAGEM DO PROBLEMA DE DESPACHO ECONÔMICO E AMBIENTAL

Em problemas de otimização multiobjetivo visa-se a otimização simultânea de dois ou mais objetivos conflitantes. Problemas multiobjetivo de minimização podem ser definidos por (Collette, 2011):

$$\min_x \{f_1(x), f_2(x), \dots, f_m(x)\} \quad (1)$$

$$s.a. \begin{cases} g_j(x) \leq 0, & j = 1, \dots, q \\ h_j(x) = 0, & j = q + 1, \dots, p \end{cases} \quad x \in \mathbb{R}^n \quad (2)$$

em que f_i consiste na i -ésima função objetivo do problema, x é o vetor de variáveis de otimização, m é a quantidade de objetivos, g_j e h_j são restrições do problema e n consiste no número de variáveis de otimização.

Neste problema visa-se encontrar não apenas uma, mas sim um conjunto de soluções ditas não dominadas. O conceito de dominância estabelece que: uma solução 'u' domina uma solução 'v' se e somente se 'u' é melhor ou igual a 'v' em todos os objetivos do problema e existe ao menos um objetivo em que 'u' é estritamente melhor que 'v' (Collette, 2011).

Conforme destacado anteriormente, a abordagem mais comum para o problema de DEA consiste na minimização simultânea dos objetivos custo de geração e emissão de poluentes. Esta abordagem é apresentada nesta seção, bem como a que incorpora incertezas e define o problema de otimização robusta proposto nesta pesquisa.

2.1 Despacho Econômico e Ambiental

A função objetivo para o custo de geração de usinas termoeletricas pode ser definida da seguinte forma:

$$\text{Minimizar } F(P) = \sum_{i=1}^N a_i + b_i P_i + c_i P_i^2 \quad (3)$$

em que $F(P)$ refere-se ao custo de geração dado em função da potência ativa gerada em cada usina, N refere-se ao número de usinas termoeletricas do sistema, a_i , b_i , 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 (Shayeghi and Ghasemi, 2014), (Jin et al., 2015). 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, consequentemente, 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 senoidal adicionada à função quadrática do custo de geração, conforme mostrado em (4):

$$\begin{aligned} &\text{Minimizar } F(P) \\ &= \sum_{i=1}^N a_i + b_i P_i + c_i P_i^2 + \left| d_i \sin \left(e_i (P_i^{\min} - P_i) \right) \right| \end{aligned} \quad (4)$$

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.

Já a função objetivo para a emissão de poluentes pode ser modelada conforme (5):

$$\begin{aligned} &\text{Minimizar } E(P) \\ &= \sum_{i=1}^N [10^{-2}(\alpha_i + \beta_i P_i + \gamma_i P_i^2) + \zeta_i \exp(\varphi_i P_i)] \end{aligned} \quad (5)$$

em que $E(P)$ refere-se à emissão de poluentes dada em função da potência ativa gerada em cada usina, α_i , β_i , γ_i , ζ_i , φ_i são os coeficientes da função de emissão de poluentes da i -ésima usina termoeletrica. A seguir são descritas as restrições comumente presentes no problema de DEA.

- 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 (6):

$$\sum_{i=1}^N P_i - P_D - P_{loss} = 0 \quad (6)$$

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

- 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:

$$P_i^{\min} \leq P_i \leq P_i^{\max}, \text{ para todo } i = 1, 2, \dots, N \quad (7)$$

em que $P_i^{\max}$ consiste no valor máximo de potência ativa a ser produzida pela i -ésima termoeletrica.

2.2 Despacho Econômico e Ambiental na Presença de Incertezas

A abordagem proposta neste artigo para o problema de DEA tem como principal objetivo o estudo deste problema 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.

As incertezas associadas aos objetivos do problema são aqui modeladas a partir do emprego de parâmetros incertos nessas funções. Estes parâmetros 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 incertos, com o intuito de 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 em (8) e (9):

$$\min_P \max_{\tilde{z}} F(P, \tilde{z}) = \sum_{i=1}^N \tilde{a}_i + \tilde{b}_i P_i + \tilde{c}_i P_i^2 + \left| \tilde{d}_i \sin \left(\tilde{e}_i (P_i^{\min} - P_i) \right) \right| \quad (8)$$

$$\begin{aligned} &\min_P \max_{\tilde{z}} E(P, \tilde{z}) \\ &= \sum_{i=1}^N [10^{-2}(\tilde{\alpha}_i + \tilde{\beta}_i P_i + \tilde{\gamma}_i P_i^2) + \tilde{\zeta}_i \exp(\tilde{\varphi}_i P_i)] \end{aligned} \quad (9)$$

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

A diferença entre as equações (4)-(5) e (8)-(9) é que nas primeiras os parâmetros das funções de custo e emissão de poluentes consistem em números escalares, diferentemente do que ocorre em (8)-(9), onde estes são assumidos como

números *fuzzy*. Realiza-se, então, a maximização dos objetivos em função destes parâmetros, para posteriormente se realizar a minimização em função das variáveis de decisão originais. Na Seção a seguir, é apresentado o algoritmo para otimização multiobjetivo empregado neste trabalho.

3. MOEA/D ROBUSTO

O algoritmo para a otimização robusta aqui proposto, denominado de MOEA/D Robusto, baseia-se no *Multiobjective Evolutionary Algorithm Based on Decomposition* (MOEA/D) (Zhang and Li, 2007). O MOEA/D realiza a decomposição de um problema de otimização multiobjetivo em um conjunto de problemas escalares (mono objetivo), que são otimizados simultaneamente. Esses subproblemas são definidos por estruturas de vizinhança, estando cada estrutura relacionada 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 , pode ser empregado Soma Ponderada, Tchebycheff, ou ainda *Penalty-based Boundary Intersection* (PBI), todos estes descritos em (Zhang and Li, 2007). Neste artigo, emprega-se o método de Tchebycheff, definido da seguinte maneira:

$$\min g^{te}(x|\lambda, z^*) = \max_{1 \leq i \leq m} \{\lambda_i |f_i(x) - z_i|\} \quad (10)$$

onde $z = (z_1, \dots, z_m)$ é um ponto de referência, isto é, $z_i = \min\{f_i(x)\}$ e $\lambda = \{\lambda_1, \dots, \lambda_m\}$ é um vetor de peso.

O MOEA/D Robusto 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 indivíduos de incerteza (ou população de perturbações). Para cada solução candidata x^i é definido um indivíduo de incerteza π^i . A cada iteração do método, a população X evolui visando a minimização da função g , dados os valores de perturbações presentes em Π . Por outro lado, esta última tem sua evolução visando a maximização de g , dados os valores presentes em X .

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

- 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 uma nova solução x_c^i . Neste caso, visa-se a minimização do subproblema dado por:

$$\min_x g(x|\pi^i, \lambda^i, z) \quad (11)$$

Nota-se que em (11) também é considerado o vetor de perturbação π^i . Desta forma, a atualização das soluções pertencentes à vizinhança $B(i)$ é realizada da seguinte

maneira: para cada $j \in B(i)$, se $g(x_c^i) \leq g(x^j)$, então $x^j = x_c^i$.

- 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 produzida uma nova solução π_c^i . Nesta etapa, o objetivo é maximizar a função g , conforme (12):

$$\max_{\pi} g(\pi|x^i, \lambda^i, z) \quad (12)$$

Conforme (12), a avaliação de π é dada em função também de x^i . De forma similar ao caso anterior, a atualização dos indivíduos de incerteza pertencentes à vizinhança $B(i)$ ocorre da seguinte maneira: para cada $j \in B(i)$, se $g(\pi_c^i) \geq g(\pi^j)$, então $\pi^j = \pi_c^i$.

No processo descrito anteriormente, uma população está minimizando g , dados os valores das incertezas, e outra população está maximizando g , dados os valores das variáveis de decisão. Este algoritmo é descrito em maiores detalhes em Meneghini et al. (2018). Neste artigo, os operadores evolutivos empregados são definidos conforme o algoritmo MOEA/D-DE (Li and Zhang, 2009).

4. MÉTODOS DE AUXÍLIO À TOMADA DE DECISÃO

Problemas práticos de planejamento geralmente envolvem diversos objetivos conflitantes e variados critérios relevantes ao problema analisado. Nesse contexto, frequentemente aplica-se uma abordagem de auxílio à tomada de decisão para assistir o processo de escolha de uma ação final de projeto.

Dentre os trabalhos dedicados ao problema de DEA que realizam este estudo, geralmente empregam um método baseado em conceitos da teoria de conjuntos *fuzzy*, baseado apenas nos objetivos do problema. Nesta pesquisa, é proposta uma análise multicritério e o emprego de dois métodos de auxílio à tomada de decisão, o AHP e o TOPSIS, que atuam de forma conjunta de modo a sustentar, de maneira mais efetiva, o processo de escolha da ação final. Estas metodologias são descritas a seguir.

4.1 Método Baseado em Conceitos Fuzzy

Este método de auxílio à tomada de decisão retorna a solução de melhor compromisso entre as funções objetivo usando um mecanismo baseado em lógica *fuzzy* (Abido, 2003), (Qu, 2018), (Shayegui, 2014). A partir da fronteira de soluções não dominadas obtida, define-se uma função de pertinência com base nos valores máximos e mínimos obtidos pelas soluções desta fronteira. Assim, para cada solução não dominada k , tem-se:

$$\mu_i^k = \begin{cases} 1 & \text{se } F_i \leq F_i^{\min} \\ \frac{F_i^{\max} - F_i}{F_i^{\max} - F_i^{\min}} & \text{se } F_i^{\min} < F_i < F_i^{\max} \\ 0 & \text{se } F_i \geq F_i^{\max} \end{cases} \quad (13)$$

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

onde μ_i^k corresponde ao valor de pertinência da k -ésima solução no i -ésimo objetivo e n_s corresponde ao número de soluções não dominadas analisadas.

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

$$\mu_{norm}^k = \frac{\sum_{i=1}^m \mu_i^k}{\sum_{j=1}^{n_s} \sum_{i=1}^m \mu_i^k} \quad (14)$$

onde μ_{norm}^k é o valor de pertinência normalizado da k -ésima solução. A solução que apresentar o maior valor de μ_{norm}^k será a de melhor compromisso entre os critérios adotados.

4.2 Analytic Hierarchy Process

O *Analytic Hierarchy Process* (AHP) (Saaty, 2008) apresenta-se como uma teoria de medição (ou classificação) baseada em comparações par a par entre as alternativas.

O método AHP é aqui empregado com a finalidade de proporcionar uma ponderação consistente dos critérios assumidos no processo de tomada de decisão. Esta ponderação é empregada em um segundo método, o TOPSIS, que então indicará a solução mais adequada ao problema, dadas as preferências do projetista.

4.3 Técnica de Ordem de Preferência por Semelhança a uma Solução Ideal

O *Technique for Order of Preference by Similarity to Ideal Solution* (TOPSIS) (Triantaphyllou, 2000) tem como princípio básico escolher uma alternativa que esteja o mais próximo possível da solução ideal positiva (PIS) e o mais distante possível da solução ideal negativa (NIS). A solução PIS é uma solução utópica formada pelos melhores valores alcançados pelas alternativas, enquanto o NIS é uma solução anti-utópica proveniente dos piores valores obtidos. O método constrói inicialmente uma matriz de decisão:

$$D = \begin{bmatrix} d_{11} & d_{12} & \dots & d_{1n_c} \\ d_{21} & d_{22} & \dots & d_{2n_c} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n_s1} & d_{n_s2} & \dots & d_{n_sn_c} \end{bmatrix} \quad (15)$$

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

A partir da matriz de decisão D , obtém-se a matriz de decisão normalizada, R , conforme (16).

$$r_{ij} = \frac{d_{ij}}{\sqrt{\sum_{i=1}^{n_s} d_{ij}^2}} \quad (16)$$

O TOPSIS requer uma definição dos pesos de cada critério, conforme (17). 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 (18).

$$w = [w_1 \ w_2 \ \dots \ w_{n_c}]$$

$$w_j \geq 0, \quad \sum_{j=1}^{n_c} w_j = 1 \quad (17)$$

$$v_{ij} = w_j * r_{ij} \quad (18)$$

em que w_j corresponde ao fator de peso do j -ésimo critério. Conforme mencionado anteriormente, esses pesos são obtidos a partir do método AHP.

No passo seguinte, são obtidas a Solução Ideal Positiva (PIS, A^+) e a Solução Ideal Negativa (PIS, A^-):

$$A^+ = \{(\max_i v_{ij} | j \in J'); (\min_i v_{ij} | j \in J'')\} \quad (19)$$

$$A^- = \{(\min_i v_{ij} | j \in J'); (\max_i v_{ij} | j \in J'')\} \quad (20)$$

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

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

$$S_{i+} = \sqrt{\sum_{j=1}^{n_c} (v_{ij} - v_{j+})^2} \quad (21)$$

$$S_{i-} = \sqrt{\sum_{j=1}^{n_c} (v_{ij} - v_{j-})^2} \quad (22)$$

em que S_{i+} é a distância Euclidiana em relação à PIS e S_{i-} é a Distância Euclidiana em relação à NIS.

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

$$CC_i = \frac{S_{i-}}{S_{i+} + S_{i-}} \quad (23)$$

O método selecionará a solução que apresentar maior coeficiente de aproximação.

5. RESULTADOS E DISCUSSÕES

Para validar a formulação proposta, a mesma foi aplicada a um sistema termoeletrico de geração de energia elétrica composto por 30 barras (Abido, 2003), sendo 6 usinas geradoras, 41 linhas de transmissão, demanda de 2.834 p.u. e potência base de 100MVA. A Tabela 1 apresenta os coeficientes das funções de custo e emissão de poluentes, bem como os limites operacionais destas usinas.

Tabela 1. Parâmetros para o sistema com 6 usinas geradoras.

Gerador	a	b	c	α	β	γ	ξ	ψ	P^{min} (p. u.)	P^{max} (p. u.)
1	10	200	100	4,091	-5,554	6,490	2,0e-4	2,857	0,05	0,5
2	10	150	120	2,543	-6,047	5,638	5,0e-4	3,333	0,05	0,6
3	20	180	40	4,258	-5,094	4,586	1,0e-6	8,000	0,05	1,0
4	10	100	60	5,326	-3,550	3,380	2,0e-3	2,000	0,05	1,2
5	20	180	40	4,258	-5,094	4,586	1,0e-6	8,000	0,05	1,0
6	10	150	100	6,131	-5,555	5,151	1,0e-5	6,667	0,05	0,6

Para o cálculo das perdas de potência ativa nas linhas de transmissão, empregou-se a ferramenta *Matpower* (Zimmerman; Murillo-Sánchez; Thomas, 2011), que consiste em um pacote do *Matlab* desenvolvido por investigadores da PSERC (Power Systems Engineering Research Center) e é usado para realizar fluxos de potência e fluxo de potência ótimo

Os parâmetros adotados no MOEA/D Robusto para ambas abordagens apresentadas para o problema de DEA foram: tamanho da população igual a 30, $T = 20$, $F = 0,5$, $Cr = 0,5$ e método de escalarização de Tchebycheff. Para a primeira abordagem, foi definido como critério de parada o número de avaliações de função igual a 3×10^5 . Já para a abordagem com incertezas, fez-se necessário um número maior de avaliações, devido ao maior esforço computacional requerido por uma modelagem do tipo minimax, onde empregou-se 10^6 avaliações de função.

Uma vez que na abordagem com incertezas os parâmetros dos objetivos também se tornam variáveis de otimização, o domínio destes foi definido a partir de uma incerteza de 2,5% aplicada aos valores expostos na Tabela 1. A Figura 1 apresenta as curvas obtidas, onde executou-se o MOEA/D Robusto cinco vezes. A partir destas curvas obteve-se a fronteira de soluções não dominadas (em círculos cheios), que foi comparada à fronteira Pareto aproximada na ausência de incertezas (em quadrados cheios). Esta última é proveniente da otimização das funções descritas por (4) e (5), considerando-se os parâmetros da Tabela 1.

Conforme a Fig. 1, as soluções obtidas para o problema de minimização de pior caso se apresentaram, de maneira geral, melhores (menores valores de custo e emissão de poluentes) que as obtidas para a abordagem sem incertezas. Além disso, estas soluções são robustas em relação aos parâmetros de incerteza, ou seja, sua qualidade é pouco deteriorada com a variação destes parâmetros.

A partir do conjunto de soluções obtido, a escolha da solução mais adequada ao problema proposto é realizada com o emprego dos métodos de auxílio à tomada de decisão apresentados na seção anterior. Esta tarefa é realizada de três maneiras, discutidas a seguir.

Fig. 1 Fronteiras de soluções obtidas.

- Tomada de Decisão *Fuzzy*: Para este caso, aplicou-se o método baseado em conceitos *fuzzy* considerando como critérios apenas o custo de geração e a emissão de poluentes, processo este muito comum na literatura (Abido, 2003), (Qu, 2018), (Shayegui, 2014). A solução obtida por este método é apresentada na Tabela 2, numerada por 1.

- Tomada de Decisão Multicritério *Fuzzy*: Este processo também aplica o método baseado em conceitos *fuzzy*, porém, considera, além dos objetivos do problema, um critério adicional, correspondente às perdas de potência ativa nas linhas de transmissão produzidas por cada alternativa. A partir deste mecanismo, obteve-se a solução numerada por 2, também presente na Tabela 2.

- Tomada de Decisão Multicritério via AHP e Topsis: Neste processo, também são considerados os três critérios: custo de geração, emissão de poluentes e perdas de potência ativa. No método AHP, a ponderação das comparações entre os critérios foi realizada com base na Escala Fundamental de Comparações (Saaty, 2008). Conforme Tabela 3, assumiu-se uma importância moderada (fator 3) do critério custo em relação ao critério emissão e entre moderada e forte (fator 4) em relação às perdas. Uma importância moderada também foi atribuída às emissões em relação às perdas.

A partir destas preferências, o método retornou os pesos [0,6144 0,2684 0,1172] para os critérios custo, emissões e

Tabela 2. Soluções não dominadas obtidas.

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.)
1	0,325713	0,394432	0,551528	0,61858	0,520371	0,451492	638,0124	0,18419	0,028117
2	0,289947	0,343339	0,633534	0,704907	0,534277	0,354119	631,076	0,187595	0,026123
3	0,177176	0,398506	0,652587	0,757199	0,533583	0,340922	616,3714	0,199472	0,025974
4	0,231281	0,329555	0,56332	0,886646	0,523529	0,329651	624,7463	0,194393	0,029983
5	0,31142	0,399098	0,517055	0,725553	0,540519	0,369768	607,7529	0,202075	0,029413
6	0,377644	0,381863	0,447505	0,725553	0,503777	0,430005	636,6204	0,186698	0,032347
7	0,233613	0,305291	0,539385	0,876894	0,555351	0,354269	624,9442	0,192385	0,030803
8	0,373764	0,327582	0,597867	0,648349	0,53988	0,373518	617,3505	0,198355	0,026959
9	0,189669	0,39124	0,506995	0,866243	0,506896	0,404443	599,452	0,204097	0,031487
10	0,263622	0,399189	0,54032	0,736035	0,530775	0,392867	607,6424	0,202675	0,028808
11	0,396257	0,489276	0,506502	0,47002	0,507284	0,494532	654,9766	0,18182	0,029871
12	0,2975	0,493097	0,493799	0,619617	0,536565	0,422884	640,1539	0,183894	0,029462
13	0,329467	0,493097	0,493799	0,544301	0,508668	0,494532	647,0612	0,182394	0,029864
14	0,262294	0,295769	0,596552	0,76714	0,533466	0,406766	628,1282	0,190098	0,027986
15	0,152455	0,305283	0,570547	0,969715	0,513817	0,353765	622,7184	0,197467	0,031582
16	0,325494	0,305283	0,596612	0,766838	0,513817	0,353765	630,2629	0,189524	0,027808
17	0,186183	0,314237	0,596612	0,899597	0,513817	0,353057	623,5104	0,19446	0,029502

perdas, respectivamente, com um Quociente de Consistência (Saaty, 2008) igual a 0,0707. Nesta abordagem, o Topsis indicou como so-lução mais adequada a numerada por 3, na Tabela 2.

Tabela 3. Ponderações entre os critérios.

Critérios	Custo	Emissão	Perdas
Custo	1	3	4
Emissão	1/3	1	3
Perdas	1/4	1/3	1

Conforme a Tabela 2, nota-se que as soluções provenientes da análise multicritério proposta (numeradas por 2 e 3) se apresentaram mais interessantes que a obtida considerando apenas os dois objetivos do problema (numerada por 1). De forma geral, as soluções 2 e 3 mostram-se mais promissoras nos critérios custo e perdas elétricas, e muito similar quanto à emissão de poluentes. Esta observação justifica a aplicação de técnicas de auxílio à decisão mais elaboradas ao invés de procedimentos simplificados usualmente empregados na literatura.

6. CONCLUSÕES

Propôs-se nesta pesquisa uma abordagem multiobjetivo para o problema de Despacho Econômico e Ambiental, incorporando incertezas na estimação dos objetivos do problema a partir de parâmetros incertos, para o qual foi proposta uma otimização robusta, investigando-se as melhores soluções para o pior cenário de incertezas

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, permitindo

uma análise mais consistente das soluções não dominadas obtidas, auxiliando na tomada de decisão.

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.

A comparação das três soluções obtidas nos diferentes processos de tomada de decisão apresentados permite destacar a influência e importância das preferências da unidade de decisão durante o processo de escolha da ação final. Conforme apontado, esse processo pode envolver diversas figuras de mérito do problema alvo e indicar soluções adequadas para o problema, que refletem as preferências do projetista.

AGRADECIMENTOS

Este trabalho foi realizado com o apoio financeiro das agências de fomento brasileiras CAPES, FAPEMIG e CNPq (404988/2016-4).

REFERÊNCIAS

- Abido, M. A. (2003). Environmental/Economic Power Dispatch Using Multiobjective Evolutionary Algorithms: A Comparative Study. *IEEE Transactions on Power Systems*, vol. 18, no.4, pp. 1529-1537.
- Assis, J. N. R., Coelho, T. M. M., Soares, G. L. and Mendes, M. H. S. (2018). Robust evolutionary optimization algorithm for multi-objective environmental/economic dispatch problem with uncertainties. *IEEE Congress on Evolutionary Computation (CEC)*, pp. 1-6.
- Bilil, H., Ellaia, R. and Maaroufi, M. (2012). A new multi-objective particle swarm optimization for economic

- environmental dispatch. *IEEE International Conference on Complex Systems (ICCS)*, pp. 1–6.
- Collette, Y. and Siarry, P. (2011). *Multiobjective Optimization: Principles and Case Studies*, Springer.
- Farag, A., Al-Baiyat, S. and Cheng, T. C (1995). Economic load dispatch multiobjective optimization procedures using linear programming techniques. *IEEE Transactions on Power Systems*, v. 10, n. 2, pp. 731–738.
- Gjengedal, T., Johansen, S. and Hansen, O. (1992). A qualitative approach to economic-environment dispatch-treatment of multiple pollutants. *IEEE Transactions on Energy Conversion*, v. 7, n. 3, p. 367–373.
- Gong, D., Zhang, Y. and Qi, C. (2009). Environmental/economic power dispatch using a hybrid multi-objective optimization algorithm. *Electrical Power and Energy Systems, Elsevier*, vol. 32, pp. 607–614.
- Hu, Y. L. and Wee, W. G. (1994). A hierarchical system for economic dispatch with environmental constraints. *IEEE Transactions on Power Systems*, v. 9, n. 2, p. 1076–1082.
- Jin, J. et al (2015). Modeling for dynamic economic emission dispatch under uncertainty. *Electric Power Components and Systems, Taylor & Francis*, v. 43, n. 14, pp. 1630–1643.
- King, R. T. F. A., Rughooputh, H. C. S., Deb, K (2005). Evolutionary multi-objective environmental/economic dispatch: Stochastic vs. deterministic approaches. *International Conference on Evolutionary Multi-Criterion Optimization*, v. 3410, pp 677–691.
- Li, H. and Zhang, Q. (2009). Multiobjective Optimization Problems With Complicated Pareto Sets, MOEA/D and NSGA-II, *IEEE Transactions on Evolutionary Computation*, vol. 13, no. 2, pp. 284–302.
- Meneghini, I. R., Guimarães, F. G. and Cunha, A. G. (2016). Competitive Coevolutionary Algorithm for Robust Multi-Objective Optimization: The worst case minimization. *IEEE Congress on Evolutionary Computation (CEC)*, pp. 586–593.
- Mousa, A. A. A. (2014). Hybrid ant optimization system for multiobjective economic emission load dispatch problem under fuzziness. *Swarm and Evolutionary Computation*, v. 18, pp. 11 – 21.
- Panta, S. and Premrudeepreechacharn, S. (2007). Economic dispatch for power generation using artificial neural network. *7th International Conference on Power Electronics*. pp. 558–562.
- Qu, B. Y., Zhu, Y. S., Jiao, Y. C., Wu, M. Y. Suganthan, P. N. and Liang, J. J. (2017). A survey on multi-objective evolutionary algorithms for the solution of the environmental/economic dispatch problems. *Swarm and Evolutionary Computation*, vol. 38, pp. 1–11.
- Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *Int. J. Services Sciences*, vol. 1, no. 1, pp. 83–98.
- Shayeghi, H. and Ghasemi, A. (2014). A modified artificial bee colony based on chaos theory for solving non-convex emission/economic dispatch. *Energy Conversion and Management*, vol. 79, pp. 344–354.
- Song, Y. H. et al (1997). Environmental/economic dispatch using fuzzy logic controlled genetic algorithms. *IEE Proceedings - Generation, Transmission and Distribution*, v. 144, n. 4, p. 377–382.
- Talaq, J. H., El-Hawary, F. and El-Hawary, M. E. (1994). A summary of environmental/economic dispatch algorithms. *IEEE Transactions on Power Systems*, v. 9, n. 3, pp. 1508–1516.
- Triantaphyllou, E. (2000). *Multi-Criteria Decision Making Methods: A Comparative Study*, Springer, vol. 44, 1st ed, Flórida.
- Zhang, L. et al (2010). Solved environmental/economic dispatch based on multi-objective pso. *International Conference on Intelligent Computation Technology and Automation*. v. 3, p. 352–355.
- Zhang, Q. and Li, H. (2007). MOEA/D: A Multiojective Evolutionary Algorithm Based on Decomposition. *IEEE Transactions on Evolutionary Computation*, vol. 11, no. 6, pp. 712–731.
- Zimmerman, R. D., Murillo-Sanchez, C. E. and Thomas, R. J. (2011). Matpower: Steady-State Operations, Planning and Analysis Tools for Power Systems Research and Education, Power Systems. *IEEE Transactions*, vol. 26, no. 1, pp. 12–19.