

# **Método para a contratação de projetos eólicos-fotovoltaicos baseada na programação multiobjetivo**

## **RESUMO**

Devido à ausência de critérios específicos para a contratação de usinas eólicas-FV em processos de licitação no Brasil, o presente trabalho apresenta um modelo para auxiliar os reguladores na contratação de projetos que atendam às necessidades de maximizar o bem-estar do setor elétrico brasileiro. Para tanto, utiliza-se a programação multiobjetivo para lidar simultaneamente com duas funções objetivo, que incluem a maximização da densidade de emissão reduzida e a minimização do *Levelized Cost of Electricity* (LCOE). Nesse aspecto, o método de otimização denominado *Normal Boundary Intersection* (NBI) é aplicado para resolver o problema multiobjetivo e construir a fronteira de Pareto. Além disso, uma métrica baseada na razão entre a entropia e o Erro Percentual Global (EPG) é utilizada para identificar a melhor solução ótima de Pareto. O modelo foi aplicado para avaliar as configurações ótimas da usina eólica-PV em quatro cidades brasileiras, sendo que os resultados obtidos na otimização revelam a capacidade do modelo em indicar a configuração ótima de acordo com o potencial eólico e fotovoltaico de cada cidade.

**Palavras-chave:** Fontes de Energia Renovável, Programação Multiobjetivo, *Normal Boundary Intersection*, Setor Elétrico Brasileiro, Usinas Eólico-Fotovoltaicas.

## ***Method for the contracting of wind-photovoltaic projects based on multiobjective programming***

### ***ABSTRACT***

*Due to the absence of specific criteria for the contracting of PV-wind farms in bidding processes in Brazil, this paper presents a model to assist regulators in contracting projects that meet the needs of maximizing the well-being of the Brazilian electricity sector. For this purpose, multiobjective programming is used to simultaneously handle two objective functions, which include the maximization of the reduced emission density and the minimization of the Levelized Cost of Electricity (LCOE). In this respect, the optimization method called Normal Boundary Intersection (NBI) is applied to solve the multiobjective problem and construct the Pareto frontier. In addition, a metric based on the ratio between entropy and the Global Percentage Error (EPG) is used to identify the best optimal Pareto solution. The model was applied to*

*evaluate the optimal configurations of the PV-wind power plant in four Brazilian cities, and the results obtained in the optimization reveal the capacity of the model to indicate the optimal configuration according to the wind and photovoltaic potential of each city.*

**Keywords:** *Renewable Energy Sources, Multiobjective Programming, Normal Boundary Intersection, Brazilian Electricity Sector, Wind-Photovoltaic Power Plants.*

## 1. Introdução

Devido ao potencial eólico e solar do país, o aproveitamento da geração híbrida a partir de usinas eólico-fotovoltaica (PV) tem se tornado oportuna (EPE, 2017). Trannin (2016) destaca que algumas vantagens da geração de energia elétrica a partir de sistemas híbridos eólico-PV são: a complementariedade das fontes, dado que o regime de ventos é mais intenso à noite, enquanto a incidência de sol ocorre durante o dia; economias de escala, reduzindo o custo médio de geração das empresas que investem nas duas fontes; e também, o fato de ser apenas necessário um único estudo de impacto ambiental para um projeto que utiliza as duas fontes, o que acelera o processo de licenciamento ambiental.

Além disso, o uso das duas fontes de forma combinada ameniza as desvantagens específicas de cada uma. No caso da energia eólica, de acordo com Fadigas (2011), dentre algumas das principais desvantagens estão: a poluição visual causada nos locais em que são instaladas usinas eólicas; poluição sonora devido ao ruído proporcionado pelo som do vento batendo nas pás; e impacto dos aerogeradores sobre as aves do local, podendo ocasionar a morte dos animais que se chocam com os aerogeradores. Conforme é possível observar na Tabela 1, as usinas eólicas ocupam um tamanho de área significativo, e por essa razão, suas construções podem causar uma descaracterização do local em que forem instaladas, aumentar os gastos com terra e limitar a opção de expansão futura do empreendimento.

Tabela 1 – Espaço de terra ocupado por GW instalado de cada fonte  
*Table 1 - Space occupied by GW installed from each source*

| <b>Fonte</b> | <b>Área de terra ocupada em km<sup>2</sup> por GW instalado</b> |
|--------------|---|
| Biomassa     | 25.600  |
| Eólica       | 9.900   |
| Hidrelétrica | 7.600   |
| Solar FV     | 630   |
| Termelétrica | 35  |
| Óleo         | 20  |
| Gás Natural  | 20  |
| Nuclear      | 10  |

Fonte: Ramanathan (2001).

Em relação à energia solar as principais desvantagens são: o fato de não haver produção alguma de energia no período noturno (VAN DER ZWAAN e RABL, 2003); tecnologia ainda em fase de amadurecimento, sendo o LCOE ainda superior à de outras FER, como a eólica e a biomassa (REN 21, 2016); e em locais com latitudes médias e altas a produção cai de forma brusca durante o inverno.

Embora exista o interesse de investidores e o reconhecimento do potencial das usinas eólico-fotovoltaicas, os órgãos reguladores destacam que a carência de métodos específicos para orientar a contratação deste tipo de projeto tem sido um gargalo para disseminar esse tipo de projeto de geração (EPE, 2017). Para tanto, se faz o uso da programação multiobjetivo para orientar a contratação de projetos que atendam simultaneamente às necessidades de redução de emissão de CO<sub>2</sub> por área ocupada e ao mesmo tempo a minimização do custo nivelado de energia (LCOE, do inglês *Levelized Cost of Electricity*).

No que concerne aos problemas de otimização que abrangem mais de um objetivo, a complexidade aumenta, pois os objetivos são função do mesmo conjunto de variáveis de decisão e são conflitantes entre si (BARIL *et al.*, 2011). Para estudar os *trade-offs* entre os objetivos conflitantes e explorar as opções disponíveis, é necessário formular um problema de otimização a partir de métodos capazes de trabalhar com múltiplas funções objetivo.

Os modelos elaborados a partir destes métodos auxiliam na identificação da solução satisfatória, a partir de um conjunto de soluções não-dominadas ou Pareto-ótimas. Na Figura 1 é representada uma fronteira de Pareto ou eficiente, para um problema com dois objetivos.




Figura 11 – Fronteira de Pareto para um problema de minimização com dois objetivos (Fonte: OREE, HASSEN e FLEMING, 2017)

*Figure 1 - Pareto frontier for a minimization problem with two objectives* (Source: OREE, HASSEN e FLEMING, 2017)

Para executar a programação multiobjetivo, o método do *Normal Boundary Intersection* (NBI) se destaca por se tratar de um método geométrico de parametrização intuitiva para produzir um conjunto de pontos na fronteira de Pareto, mesmo para problemas não-convexos, sendo considerada uma técnica eficiente para a comparação entre soluções distribuídas uniformemente na fronteira de Pareto. A abordagem NBI utiliza a seguinte equação para resolver os problemas de otimização multiobjetivo (DAS e DENNIS, 1998):

$$\begin{aligned} & \underset{(x, D)}{\text{Max}} D \\ & \text{s.t.: } \bar{\Phi}w - D\bar{\Phi}e = \bar{F}(x) \\ & \quad x \in \Omega \end{aligned} \quad (1)$$

onde:  $w$  é a ponderação convexa;  $D$  é a distância entre a linha de utopia e a fronteira de Pareto;  $\bar{F}(x)$  é o vetor contendo os valores individuais dos objetivos normalizados;  $e$  é um vetor coluna de valor 1; e  $\Phi$  e  $\bar{\Phi}$  são a matriz payoff e a matriz payoff normalizada, respectivamente, e podem ser escritas como:

$$\Phi = \begin{bmatrix} f_1^*(x_1^*) & \cdots & f_1^*(x_m^*) \\ \vdots & \ddots & \vdots \\ f_m^*(x_1^*) & \cdots & f_m^*(x_m^*) \end{bmatrix} \Rightarrow \bar{\Phi} = \begin{bmatrix} \frac{f_1^*(x_1^*) - f_1^*(x_1^*)}{f_1^*(x_m^*) - f_1^*(x_1^*)} & \cdots & \frac{f_1^*(x_m^*) - f_1^*(x_1^*)}{f_1^*(x_m^*) - f_1^*(x_1^*)} \\ \vdots & \ddots & \vdots \\ \frac{f_m^*(x_1^*) - f_m^*(x_m^*)}{f_m^*(x_1^*) - f_m^*(x_m^*)} & \cdots & \frac{f_m^*(x_m^*) - f_m^*(x_m^*)}{f_m^*(x_1^*) - f_m^*(x_m^*)} \end{bmatrix} \quad (2)$$

A solução que otimiza a  $i$ -ésima função objetivo  $f_i(x)$  pode ser representada como  $f_i^*(x_i^*)$ . Quando obtém-se a otimização individual  $x_i^*$ , nas demais funções objetivo, temos  $f_i(x_i^*)$ .

Como critério para a escolha de uma melhor solução ótima dentro fronteira de Pareto construída a partir do NBI, o presente estudo irá utilizar uma medida que corresponde ao valor máximo da razão entre a entropia e o Erro Percentual Global (EPG). A medida de entropia permite encontrar um ponto ótimo com a máxima diversificação em um sistema com diferentes componentes. Em sistemas caracterizados como misturas, o percentual de cada componente da mistura segue uma distribuição discreta de probabilidade ( $p$ ). Nesse sentido baseado em Shannon (1948), o cálculo da entropia pode ser descrito conforme a Equação 3:

$$H = -\sum_{i=1}^m p_i \log p_i \quad (3)$$

sendo que:  $p_i$  = percentuais das variáveis que fazem parte do sistema a ser diversificado.

O uso da entropia se justifica, por ser uma medida que assume o máximo valor quando os resultados em uma distribuição de probabilidades são igualmente prováveis, e, portanto, compatíveis com os objetivos de aumentar a diversificação da matriz energética brasileira.

O EPG que está associado a uma medida de erro. Rocha *et al.* (2016) explica que quando utilizado para a determinação dos pesos ótimos de um problema multiobjetivo, o EPG calcula o somatório das diferenças das soluções Pareto-ótimas em relação a seus alvos, que estão representados pela linha de utopia. O cálculo do EPG é formulado da seguinte forma:

$$\text{EPG} = \sum_{i=1}^m \left| \frac{y_i^* - T_i}{T_i} \right| \quad (4)$$

sendo que:  $y_i^*$  = valor ótimo das respostas;  $T_i$  = valor alvo;  $m$  = número de objetivos do problema.

Com isso, propõe-se um critério que possa valorizar tanto as questões relacionadas ao planejamento energético, quanto as que consideram a relação da solução obtida pelo método NBI com os valores de utopia. A formulação do método de ponderação que será utilizado é indicada pela Equação 6 (ROCHA *et al.*,2017).

$$\xi = \frac{H}{\text{EPG}} \quad (5)$$

sendo que:  $\xi$  = medida resultante da razão entre a entropia e o EPG.

No presente estudo, utilizou-se a metodologia de Interseção Normal à Fronteira (NBI) para realizar a otimização multiobjetivo, a partir das funções objetivo modeladas no estudo. O método proposto será aplicado para analisar a melhor configuração de uma usina híbrida para as seguintes cidades brasileiras: Araripina (PE); Jundiá (SP); Laguna (SC); e Montes Claros (MG).

## 2. Materiais e Métodos

### 2.1. Objetivos a serem otimizados

O primeiro objetivo considerado se trata da maximização da densidade de emissão reduzida atende um dos objetivos destacados pela ANEEL para o setor elétrico, o qual envolve maximizar os benefícios de cada recurso energético, e ao mesmo tempo minimizar os impactos negativos sobre o ambiente e a sociedade (ANEEL, 2008). A medida está relacionada às questões socioambientais, dado que mensura a quantidade de emissão de CO<sub>2</sub> evitada por km<sup>2</sup>, proporcionada por um projeto de geração limpa. Para encontrar o valor, basta calcular a razão

do produto de um fator de emissão com a produção de energia, pela soma da área ocupada por cada fonte que compõe o projeto de geração. Na Equação 6 é descrito o cálculo da emissão reduzida.

$$ER = F_e E_p \quad (6)$$

onde: ER = emissão de CO<sub>2</sub> reduzida;  $F_e$  = fator de emissão.

Por sua vez, na Equação 8 está descrita a fórmula para o cálculo da densidade de emissão reduzida. Os valores de 9,9 para coeficiente de potência eólica ( $P_w$ ) e 0,63 para potência PV ( $P_{pv}$ ) se referem à área, em km<sup>2</sup> ocupada por cada MW instalado de potência eólica e solar, e foram calculados a partir dos dados da Tabela 1.

$$\rho_{red} CO_2 = \frac{F_e \sum E_{pm}}{9,9P_w + 0,63P_{pv}} \quad (7)$$

onde:  $\rho_{red} CO_2$  é a densidade de emissão reduzida de CO<sub>2</sub> ao ano (tCO<sub>2</sub>/km<sup>2</sup>); e  $E_{pm}$  produção média mensal de energia (MWh).

Já o LCOE será estimado a partir da Equação 9, que é caracterizada pelo método mais tradicional utilizado para o cálculo desse elemento (BRANKER, PATHAK e PEARCE, 2011). Os gastos descontados para o cálculo do LCOE pelo método tradicional, se tratam do desembolso com o investimento no projeto e os custos com operação e manutenção (O&M). Já o valor da produção média anual de energia que será descontada no cálculo do LCOE, será correspondente as estimativas feitas para cada uma das quatro cidades em que será avaliada a instalação do projeto.

$$LCOE = \frac{\sum_{t=0}^T \frac{C_t}{(1+i)^t}}{\sum_{t=0}^T \frac{E_{p_t}}{(1+i)^t}} \quad (8)$$

onde:  $C_t$  = custos totais com a geração de energia em dado período  $t$ ;  $T$  = período final do horizonte de análise;  $E_{p_t}$  = garantia física da usina em cada período  $t$ ;  $i$  = taxa de desconto.

Para estimar a taxa de desconto utilizada no cálculo do LCOE, utilizou-se o *Weighted Average Cost of Capital* (WACC) que se trata de uma metodologia recomendada pelo *Clean Mechanism's Executive Board*, no anexo *Guidelines on the Assessment of Investment Analysis* (UNFCCC, 2011). A Equação 9 apresenta a formulação para o cálculo do WACC.

$$WACC = k_d D(1 - \tau) + k_e E \quad (9)$$

onde:  $k_d$  = o custo de capital de terceiros;  $D$  = fração de capital de terceiros (%);  $\tau$  = alíquota de imposto de renda;  $k_e$  = custo de capital próprio;  $E$  = fração de capital próprio (%).

Para o presente estudo, o WACC foi deflacionado pela inflação dos EUA, conforme ANEEL (2016). Na Tabela 2 são apresentados os parâmetros para o cálculo do WACC.

Tabela 2 – Parâmetros utilizados para o cálculo do WACC

Table 2 - Parameters used to calculate the WACC

| Parâmetro         | Valor  | Fonte            |
|-------------------|--------|------------------|
| $D$               | 63,55% | Damodaran (2017) |
| $E$               | 36,45% | Damodaran (2017) |
| $r_f$             | 2,73%  | U.S (2017)       |
| $r_c$             | 3,37%  | ANEEL (2016)     |
| $r_b$             | 2,62%  | ANEEL (2016)     |
| $r_m$             | 10,29% | ANEEL (2016)     |
| $\beta$           | 1,14   | Damodaran (2017) |
| $k_d$             | 11,63% | Equação 11       |
| $k_e$             | 16,88% | Equação 12       |
| Inflação EUA      | 2,41%  | ANEEL (2016)     |
| WACC              | 13,97% | Calculado        |
| WACC deflacionado | 6,19%  | Calculado        |

Para o cálculo do  $k_d$  foi aplicada a mesma metodologia que Ertürk (2012) e indicada pela ANEEL (2016) para empresas investidoras no setor elétrico. A metodologia corresponde ao cálculo de uma parcela resultante da soma entre a taxa livre de risco, prêmio de risco de crédito e prêmio de risco país. O cálculo está indicado na Equação 10.

$$k_d = r_f + r_c + r_b \quad (10)$$

onde:  $r_f$  = taxa livre de risco;  $r_c$  = prêmio de risco de crédito;  $r_b$  = prêmio de risco país.

Para o cálculo do  $k_e$ , o *Capital Asset Pricing Model* (CAPM), originalmente apresentado por Sharpe (1964), somado ao risco país, é um modelo bastante utilizado na literatura, como nos estudos de Aquila *et al.* (2016), Ertürk (2012) e também na nota de recomendação da ANEEL (2016). O cálculo é apresentado na Equação 11.

$$k_e = r_f + \beta \times (r_m - r_f) + r_b \quad (11)$$

onde:  $r_m$  = prêmio de risco de mercado;  $\beta$  = beta, que mensura o risco do projeto em relação ao mercado.

## 2.2. Arranjo de Misturas

O arranjo de misturas é a única técnica de DOE capaz de fornecer um meio de determinar a formulação para uma mistura específica (CORNELL, 2002). No que concerne ao

arranjo experimental de misturas, os fatores são componentes ou ingredientes de uma mistura, e, portanto, existe uma relação de dependência entre os níveis de composição (MONTGOMERY, 2009). Com isso conseqüentemente se estabelece uma restrição de totalidade para os níveis dos componentes que fazem parte da mistura. Neste aspecto, suponha que  $x_1, x_2, \dots, x_p$  representam as proporções dos  $p$  componentes. Com isso segundo Cornell (2002) tem-se como restrições:  $x_1 + x_2 + \dots + x_p = 1$  e  $0 \leq x_p \leq 1$ .

Os cenários experimentais formados nos arranjos de mistura são configurados a partir de um sistema de coordenadas simples, portanto, nesse contexto os arranjos denominados como simplex são os mais utilizados (CORNELL, 2002). O planejamento de um simplex *lattice*, com  $p$  componentes e modelo polinomial ajustado na ordem  $m$ , é feito a partir de  $m + 1$  proporções, igualmente espaçadas entre 0 e 1, testadas para cada fator no delineamento (MONTGOMERY, 2009). Os níveis dos fatores  $x_i$  são obtidos da seguinte forma:

$$x_i = 0, \frac{1}{m}, \frac{2}{m}, \dots, 1; \text{ para } i = 1, 2, \dots, p \quad (12)$$

Todas as combinações ou misturas são utilizadas, sendo o número de experimentos (N) no simplex *lattice* dado por:

$$N = \frac{(p+m-1)!}{m!(p-1)!} \quad (13)$$

No caso analisado, o arranjo de mistura foi configurado para um projeto eólico-PV conectado à rede, com potência total de 30 MW, a qual corresponde à potência máxima que possibilita ao empreendedor um desconto na tarifa do uso do sistema de transmissão e distribuição. Após a realização dos cálculos de densidade de emissão reduzida e LCOE para cada configuração foram realizadas regressões quadráticas para obter as funções objetivo para os dois *outputs*.

No presente estudo, para estimar as funções objetivo que representam a densidade de emissão reduzida e o LCOE, primeiramente, são gerados cenários experimentais a partir do arranjo de misturas para orientar os cálculos da densidade de emissão reduzida ao ano e o LCOE anual, para cada cidade analisada. A configuração dos arranjos foi baseada no simplex *lattice*, com dois componentes (potência eólica e PV), cinco graus de *lattice*, além do ponto central e os pontos axiais do arranjo, totalizando nove cenários experimentais. Na Tabela 3 está ilustrado o cenário experimental gerado para cada uma das quatro cidades, a partir do arranjo de misturas.



Tabela 3 – Cenários gerados pelo Arranjo de Misturas

Table 3 - Scenarios generated by the Mixture Arrangement

| $x_1$<br>Potência referente à<br>fonte eólica (MW) | $x_2$<br>Potência referente à<br>fonte solar (MW) |
|--|---|
| 30,0   | 0,0   |
| 24,0   | 6,0   |
| 22,5   | 7,5   |
| 18,0   | 12,0  |
| 15,0   | 15,0  |
| 12,0   | 18,0  |
| 7,5  | 22,5  |
| 6,0  | 24,0  |
| 0,0  | 30,0  |

Para cada cenário apresentado no arranjo da Tabela 3, calculou-se as respostas referente a densidade de emissão reduzida e LCOE. No cálculo de ambas as respostas, observa-se a partir das Equações 7 e 8 que a estimativa da produção média anual de energia eólica-FV é fundamental. Portanto, para efeito da comparação do potencial eólico-FV de cada local analisado, considerou-se constantes as demais variáveis necessárias para o cálculo da densidade de emissão reduzida e LCOE para todas as cidades analisadas.

Na estimativa de produção de energia da parcela eólica da usina, a produção média anual de energia eólica é estimada a partir do produto entre a potência eólica, descrita por Amarante (2010), o número de horas de funcionamento dos aerogeradores da usina, equivalente à 8760 horas e as perdas de 7% que ocorrem devido à indisponibilidade e questões técnicas no sistema de transmissão (COELBA,2013; COPEL, 2007). Na Equação 14 é descrito o cálculo da produção anual referente à parcela eólica da usina.

$$E_{p_E} = \frac{8760 \times 0,93}{2} \rho A_r v^3 C_p \eta \quad (14)$$

onde:  $E_{p_E}$  = energia potencial eólica anual (MWh);  $\rho$  = densidade do ar ( $\text{kg/m}^3$ );  $A_r$  = área varrida pelo rotor ( $\text{m}^2$ );  $v$  = velocidade média do vento (m/s);  $C_p$  = coeficiente aerodinâmico de potência do rotor (adimensional);  $\eta$  = eficiência do conjunto gerador-transmissões mecânicas e elétricas (adimensional).

Para estimar a produção de energia eólica, considerou-se os dados de velocidade média de vento coletadas na base de dados do SWERA (2017) são para uma altura de 10m, que foram posteriormente convertidas para a altura de 135m. Para a conversão foi considerado o cálculo para determinar a velocidade do vento em outra altura apresentado por Custodio (2013), descrito na Equação 15, sendo os valores de comprimento de rugosidade ( $z_0$ ) de cada cidade

extraídos de CEPEL (2001). Também foram considerados para estimativa da produção de energia eólica, as características técnicas dos aerogeradores do fabricante Enercon, com potências equivalentes a 2 MW, 3 MW, 3,5 MW e 7,5 MW (ENERCON, 2015).

$$\frac{v_1}{v_2} = \frac{\ln\left(\frac{h_1}{z_0}\right)}{\ln\left(\frac{h_2}{z_0}\right)} \quad (15)$$

Para o cálculo da parcela referente à produção média anual de energia solar foram consideradas as características técnicas das células fotovoltaicas de potência nominal de 300W, da Yingli Solar (2015). Os dados de irradiação solar mensal e temperatura média (T) para cada cidade, também foram coletados da base de dados do SWERA (2017). Foram consideradas perdas de 25% na energia produzida, que de acordo com a ABINEE (2012) ocorrem devido a: sombreamentos; acúmulo de poeira nas células; perdas nos inversores; perdas por indisponibilidade; diferenças nas curvas características dos módulos; perdas no cabeamento. Ainda foi descontada a perda decorrente ao aumento de cada grau de temperatura acima dos 25°C (temperatura ambiente). Na Equação 16 é ilustrado o cálculo realizado para a produção de energia solar.

$$E_{p_{FV}} = 0,75\eta I_m A(1 - \sigma_T T) \quad (16)$$

sendo que:  $E_{p_{FV}}$  = energia potencial fotovoltaica (MWh);  $\eta$  = eficiência do painel;  $A$  = área ocupada pelo painel;  $I_m$  = irradiação média no período (kWh/m<sup>2</sup>).

### 3. Resultados e Discussões

#### 3.1 Formulação das funções objetivo a partir do Arranjo de Misturas

A aplicação do método proposto se divide nas seguintes etapas: cálculo das respostas para cada cenário indicado no arranjo de misturas, obtenção das funções objetivo, aplicação do NBI e escolha da melhor solução ótima na fronteira de Pareto. Nos cálculos de densidade de emissão reduzida, foi aplicada a fórmula descrita na Equação 7, sendo que o valor para o fator de emissão adotado foi de 0,0817 tCO<sub>2</sub>/MWh, equivalente ao fator de emissão anual divulgado pelo MCTIC (2017).

No cálculo dos valores de LCOE, foi utilizada taxa de desconto de 8,42% calculada pelo WACC e os valores de produção anual de energia estimados para cada cidade. Para obter o valor do investimento tanto para a parcela de geração eólica, quanto à de geração solar, a partir dos dados da CCEE (2017), calculou-se a média do valor do investimento por potência instalada

dos projetos de geração contratados desde 2014 para cada fonte. O valor de investimento médio encontrado para a fonte eólica foi de R\$ 3.918.623,32 por MW instalado, já para a fonte solar o valor obtido foi equivalente a R\$ 4.795.304,68 por MW instalado. Como não se tratam de projetos reais, não foram discriminados os valores de investimento por cidade.

Em relação aos custos de O&M, o valor foi calculado com base no valor do investimento. A base de cálculo foi obtida a partir de Mudasser, Yiridoe e Corscadden (2013) e do estudo de Aquila *et al.* (2016), e equivale a 2% do valor do investimento total para uma usina eólica. Já para uma usina solar, os custos de O&M são iguais a 0,5% do investimento total (ABINEE, 2012). Quanto aos juros do financiamento, foi utilizado o valor de 4,99%, indicado na seção 3.1, sobre o valor do investimento em cada cenário.

Com os valores de  $y_1$  (densidade de emissão reduzida) e  $y_2$  (LCOE) calculados para todos os cenários em cada cidade foi possível estimar as funções objetivo. Para isso, foram realizadas regressões quadráticas pelo software *Minitab*®, sendo que para  $y_1$  foi necessário incluir dois termos adicionais para o modelo ter um ajuste ideal, baseado em Hair Jr. (2014). Já para  $y_2$  não foi necessário acrescentar os termos, nas Tabelas 4 e 5 estão descritas as Equações 23 a 46, com as funções objetivo para  $y_1$  e  $y_2$ .

Tabela 4 – Função objetivo para densidade de emissão reduzida ( $y_1$ ) em cada cidade

Table 4 - Target function for reduced emission density ( $y_1$ ) in each city

| Cidade           | R <sup>2</sup> adj | $y_1$   |      |
|------------------|--------------------|---|------|
| Araripina-PE     | 99,34%             | $3,83x_1+20,53x_2-29,49x_1x_2+33,98x_1x_2(x_1-x_2)-36,85 x_1x_2(x_1-x_2)^2$ | (24) |
| Jundiaí-SP       | 99,48%             | $2,49x_1+17,30x_2-26,12x_1x_2+30,10x_1x_2(x_1-x_2)-31,80 x_1x_2(x_1-x_2)^2$ | (27) |
| Laguna-SC        | 99,38%             | $2,74x_1+16,16x_2-23,71x_1x_2+27,32x_1x_2(x_1-x_2)-29,43 x_1x_2(x_1-x_2)^2$ | (28) |
| Montes Claros-MG | 99,47%             | $3,13x_1+20,72x_2-31,05x_1x_2+35,80x_1x_2(x_1-x_2)-37,95x_1x_2(x_1-x_2)^2$  | (31) |

Tabela 5- Função objetivo para LCOE ( $y_2$ ) em cada cidade

Table 5 - Target function for LCOE ( $y_2$ ) in each city

| Cidade           | R <sup>2</sup> adj | $y_2$                                |      |
|------------------|--------------------|--------------------------------------|------|
| Araripina-PE     | 96,19%             | $98,97x_1 + 208,14x_2-168,15x_1x_2$  | (36) |
| Jundiaí-SP       | 93,66%             | $180,56x_1 + 337,91x_2-92,10x_1x_2$  | (39) |
| Laguna-SC        | 95,25%             | $139,26x_1 + 467,77x_2-92,10x_1x_2$  | (40) |
| Montes Claros-MG | 94,30%             | $118,28x_1 + 280,94x_2-111,67x_1x_2$ | (43) |

É possível observar que para cada cidade foram obtidas funções objetivo com coeficientes distintos, tanto para  $y_1$ , quanto para  $y_2$ . Isso revela que foi possível determinar as funções objetivo modeladas de acordo com os diferentes potenciais eólico e solar de cada cidade.

### 3.2 Resultados da otimização pelo NBI

Após serem obtidas as funções objetivo para cada cidade, o passo seguinte é a resolução do problema multiobjetivo por meio do NBI. Desta forma, é montada a matriz *payoff*, conforme indicado na Equação 2. Em seguida, é possível resolver o problema de otimização com a formulação do NBI, apresentada na Equação 2. Cumpre destacar que foram acrescentadas as restrições referentes ao problema de mistura, as quais correspondem a  $x_1 + x_2 + \dots + x_p = 1$  e  $0 \leq x_p \leq 1$ .

A partir dos resultados do NBI foi construída a fronteira de Pareto equiespaçada, com os pesos variando com um incremento de 0,05. Por último, a partir da medida de razão entre entropia e EPG, descrita na Equação 6 foi possível identificar a configuração ótima da usina em cada cidade, conforme ilustrado na Figuras 2.

Observa-se que para cada cidade foram encontrados diferentes percentuais de potência eólica e solar na configuração ótima, além de distintos valores para  $y_1$  e  $y_2$  distintos, conforme descrito na Tabela 6. Com isso, é possível considerar que o modelo responde de forma adequada como um possível critério para processos de licitação para contratação de projetos eólico-FV, no Brasil.

Também nota-se a partir da Tabela 6, que em relação às configurações ótimas entre cidades nota-se que a solução mais adequada nem sempre corresponde a uma solução que indica a mesma importância para as funções objetivo. Em Araripina (PE), por exemplo, a configuração ótima está em um ponto da fronteira, cujo peso do objetivo para maximizar a densidade de emissão reduzida é 10%, enquanto o da minimização do LCOE é 90%. Já em Jundiaí (SP) e Montes Claros (MG), a melhor solução ótima está no ponto em que o peso para maximização da densidade de emissão reduzida é de 15%, enquanto para a minimização do LCOE o peso é de 85%. Ainda é possível observar na Tabela 6, a razão entre  $y_1/y_2$  que possibilita ranquear as cidades em que densidade de emissão reduzida é maximizada por um menor custo.

Por meio da razão entre  $y_1/y_2$  nota-se que a cidade de Araripina (PE) é o local em que é possível evitar uma quantidade maior de emissão de CO<sub>2</sub> por área (tCO<sub>2</sub>/km<sup>2</sup>), com o menor LCOE (R\$/MWh), ou seja, é nessa cidade em que possível maximizar um benefício socioambiental, tendo um menor custo. Já na cidade de Jundiaí (SP) é onde foi obtido o pior resultado de maximização de densidade de emissão reduzida pelo menor custo.

Outro aspecto importante a ser destacado, é a importância do NBI para tornar possível a aplicação de um método para selecionar a melhor configuração ótima. O NBI permite a

construção da fronteira de Pareto de forma equiespaçada, independente do incremento utilizado para os pesos das funções. O uso de outro método poderia gerar falhas na construção da fronteira e prejudicar o processo de seleção da melhor configuração ótima.

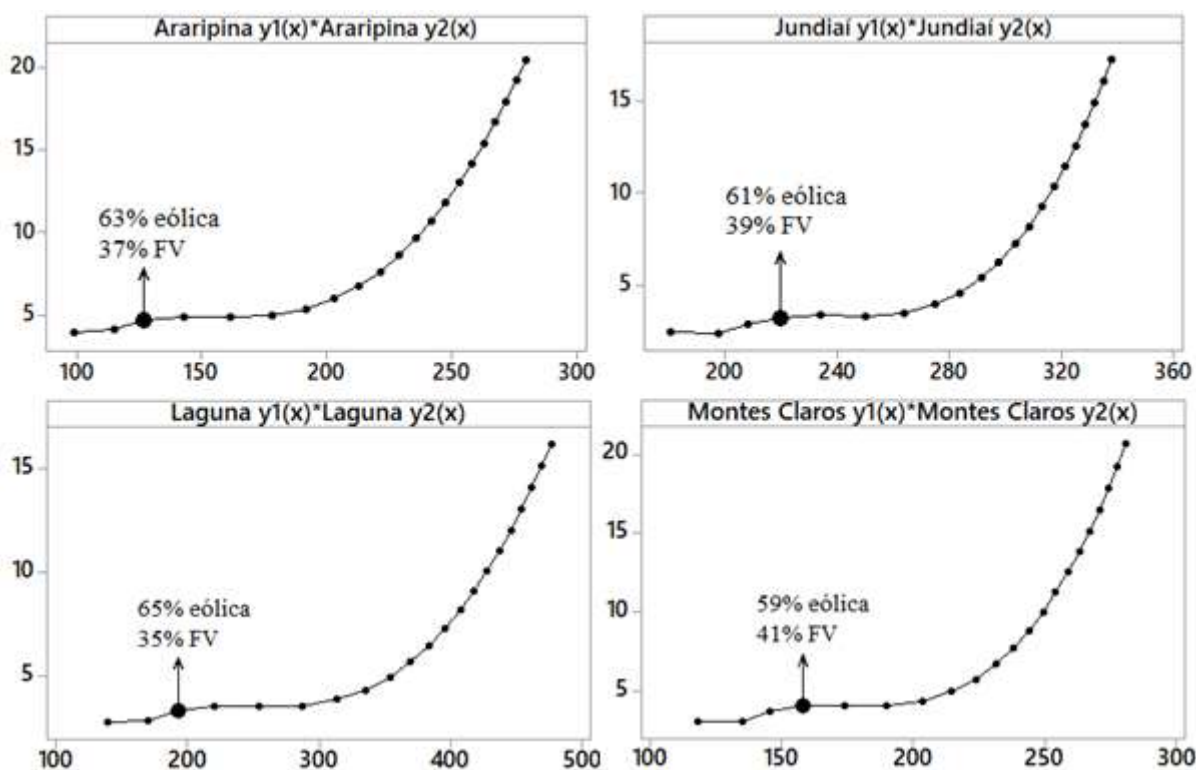


Figura 2 – Fronteira de Pareto e configuração ótima em Araripina, Jundiá, Laguna e Montes Claros  
 Figure 2 - Pareto border and optimal configuration in Araripina, Jundiá, Laguna and Montes Claros

Tabela 6 – Peso das funções objetivo no ponto de configuração ótima da usina

Table 6 - Weight of the objective functions at the optimum configuration point of the plant

| Cidades          | $w_1$ | $w_2$ | $y_1$ | $y_2$  | $y_1/y_2$ |
|------------------|-------|-------|-------|--------|-----------|
| Araripina-PE     | 10%   | 90%   | 4,62  | 124,74 | 0,0364    |
| Montes Claros-MG | 15%   | 85%   | 3,72  | 158,14 | 0,0259    |
| Laguna-SC        | 10%   | 90%   | 3,30  | 192,55 | 0,0172    |
| Jundiá-SP        | 15%   | 85%   | 3.29  | 289.70 | 0,0148    |

#### 4. Conclusão

Este artigo utilizou a programação multiobjetivo a partir do NBI para apresentar uma contribuição para orientar a contratação de projetos de geração eólico-PV, no Brasil. A partir do modelo construído é possível auxiliar os reguladores a orientarem a configuração ótima que os projetos eólico-PV participantes dos leilões de menor preço devem atender para que seja alcançado o objetivo de maximizar o bem estar socioeconômico produzido pelo setor elétrico.

Os resultados indicam que pode-se considerar que o método proposto mostrou-se capaz de contribuir com a tomada de decisão na seleção de projetos eólico-FV. A partir do modelo

foi possível encontrar a configuração ótima tanto dos percentuais de potência eólica e PV instaladas, quanto das respostas para densidade de emissão reduzida e LCOE, levando em consideração o potencial eólico e PV específico de cada local.

Por fim, é importante ressaltar que o modelo proposto é uma primeira contribuição para auxiliar na contratação de projetos de geração eólica-PV, no Brasil. São de grande valia trabalhos futuros com a finalidade de desenvolver novos modelos ou aprimorar o modelo proposto neste trabalho.

## 5. Agradecimentos

Os autores agradecem ao CNPq, CAPES e FAPEMIG pelo apoio financeiro a esta pesquisa.

## 6. Referências

- ABINEE, 2012. **Propostas para Inserção da Energia Solar Fotovoltaica na Matriz Brasileira**. ABINEE, Brasília.
- Amarante, O. A. C, 2010. **Atlas Eólico: Minas Gerais**. Belo Horizonte: CEMIG.
- Antunes, C.H.; Martins, A.G.; Brito, I.S, 2004. A multiple objective mixed integer linear programming model for power generation expansion planning. **Energy**, 29, 613-627.
- ANEEL – Agência Nacional de Energia Elétrica, 2016. **Nota Técnica no 33 /2016–SGT/ANEEL**. Disponível em:<  
[http://www2.aneel.gov.br/aplicacoes/audiencia/arquivo/2016/005/documento/ntecnica\\_33\\_sgt\\_ap\\_caiua.pdf](http://www2.aneel.gov.br/aplicacoes/audiencia/arquivo/2016/005/documento/ntecnica_33_sgt_ap_caiua.pdf)>. Acesso em: 01 de dezembro de 2016.
- ANEEL – Agência Nacional de Energia Elétrica. **Atlas de Energia Elétrica do Brasil**, 2008. 3ªed, Brasília: ANEEL, 236p.
- Aquila, G., Rocha, L.C.S, Rotela Junior, P., Pamplona, E.O., Queiroz, A.R., Paiva, A.P, 2016. Wind power generation: An impact analysis of incentive strategies for cleaner energy provision in Brazil. **Journal of Cleaner Production**, 137, 1100-1108.
- Aquila, G.; Rotela JR.,P.;Pamplona, E.O.; Queiroz, A.R, 2017b. Wind power feasibility analysis under uncertainty in the Brazilian electricity market. **Energy Economics**, 65, 127-136.
- Baril, C.; Yacout, S.; Clément, B, 2011. Design for Six Sigma through collaborative multiobjective optimization. **Computers & Industrial Engineering**, 60, 1, 43-55.
- Banker, K.; Pathak, M.J.M.; Pearce, J.M, 2011. A review of solar photovoltaic levelized cost of electricity. **Renewable Energy and Sustainable Reviews**, 15, 4470-4482.
- CCEE. **Câmara de Comercialização de Energia Elétrica – O que fazemos: Leilões, 2017**. Disponível em:<  
[http://www.ccee.org.br/portal/faces/oquefazemos\\_menu\\_lateral/leiloes?\\_afLoop=5547777042548#%40%3F\\_afrLoop%3D5547777042548%26\\_adf.ctrl-state%3Dp6tr9dqjl\\_112](http://www.ccee.org.br/portal/faces/oquefazemos_menu_lateral/leiloes?_afLoop=5547777042548#%40%3F_afrLoop%3D5547777042548%26_adf.ctrl-state%3Dp6tr9dqjl_112)>.
- CEPEL – Centro de Pesquisas de Energia Elétrica, 2001. **Atlas do Potencial Eólico Brasileiro**. Disponível em:<  
<http://www.cresesb.cepel.br/publicacoes/index.php?task=livro&cid=1>> . Acesso em: 14 de abril de 2017.
- COELBA - Companhia de Eletricidade do Estado da Bahia, 2013. **Atlas do Potencial Eólico do Estado da Bahia**.
- COPEL - Companhia Paranaense de Energia, 2007. **Manual de avaliação técnico-econômica de empreendimentos eólico-elétricos**. Curitiba: LACTEC, 104p.
- Cornell, J, 2002. **Experiments with mixtures: designs, models, and the analysis of mixture data**. 3 ed. New York: John Wiley & Sons, 649 p.

Custódio, R.S., 2013. **Energia Eólica para a Produção de Energia Elétrica**, 2ed. Synergia, Rio de Janeiro.

Damodaran, A. **Betas by sector (US)**. 2017. Disponível em: <[http://people.stern.nyu.edu/adamodar/New\\_Home\\_Page/datafile/Betas.html](http://people.stern.nyu.edu/adamodar/New_Home_Page/datafile/Betas.html)>. Acesso em: 25 fev. 2017.

Das, I.; Dennis, J.E, 1998. Normal boundary intersection: A new method for generating the Pareto surface in nonlinear multicriteria optimization problems. **SIAM Journal on Optimization**, 8 (3), 631-657.

ENERCON. **Linha de produtos Enercon**, 2015. Disponível em: <[http://www.wobben.com.br/fileadmin/user\\_upload/ec\\_product\\_br.pdf](http://www.wobben.com.br/fileadmin/user_upload/ec_product_br.pdf)>. Acesso em: 08 de junho de 2017.

EPE – Empresa de Pesquisa Energética, 2017. **Avaliação da geração de usinas híbridas eólico-fotovoltaicas: Proposta metodológica e estudos de caso**, 32 pp.. EPE, Rio de Janeiro.

Ertürk, M, 2012. The evaluation of feed in tariff regulation of Turkey for onshore wind energy based on the economic analysis. **Energy Policy**, 45, 359-367.

Fadigas, E.A.F.A, 2011. **Energia Eólica**, Barueri: Manole, 285p.

Hair Jr., J.F., Black, W.C., Babin, B.J., Anderson, R.E., 2014. **Multivariate Data Analysis**, 7 ed. Pearson, London.

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES - MCTIC, 2017. **Arquivo dos fatores médios de emissão de CO2 grid mês/ano**.  
[http://www.mctic.gov.br/mctic/opencms/textogeral/emissao\\_corporativos.html](http://www.mctic.gov.br/mctic/opencms/textogeral/emissao_corporativos.html)

Montgomery, D. C, 2009. **Design and Analysis of Experiments**. 7 ed. New York: John Wiley & Sons, 665 p.

Mudasser, M.; Yiridoe, E.Y.; Corscadden, K, 2013. Economic feasibility of large community feed-in tariff-eligible wind energy production in Nova Scotia. **Energy Policy**, v.62, p.966-977.

Oree, V.; Hassen, S.Z.S.; Fleming, P.J, 2017. Generation expansion planning optimisation with renewable energy integration: A review. **Renewable and Sustainable Energy Reviews**, 69, 790-803.

Ramanathan, R, 2001. Comparative Risk Assessment of energy supply technologies: a Data Envelopment Analysis approach, **Energy**, 26, 197-203.

REN 21. **Global Status Report**, 2016. Disponível em: < [http://www.ren21.net/wp-content/uploads/2016/06/GSR\\_2016\\_Full\\_Report.pdf](http://www.ren21.net/wp-content/uploads/2016/06/GSR_2016_Full_Report.pdf) >

Rocha LCS, Paiva AP, Paiva EJ, Balestrassi PP., 2016. Comparing DEA and principal component analysis in the multiobjective optimization of P-GMAW process. **J Braz Soc Mech Sci**, 38 (8), 2513-2526.

Rocha LCS, Paiva AP, Rotela Junior P, Balestrassi PP, Campos PH., 2017. Robust multiple criteria decision making applied to optimization of AISI H13 hardened steel turning with PCBN wiper tool. **Int J Adv Manuf Technol**, 89 (5-8), 2251-2268.

Sharpe, W, 1964. Capital asset prices: a theory of market equilibrium under conditions of risk. **The Journal of Finance**, 19, 3, 425-442.

Solangi K.H; Islum M.R; Saidur R.; Rahim N.A; Fayaz H., 2011. A review on global energy policy. **Renewable and Sustainable Energy Reviews**, 15, 2149-2163.

SWERA – Solar and Wind Energy Resource Assesment, 2017. **National Renewable Energy Laboratory (NREL) maps**. Disponível em:<<https://maps.nrel.gov/swera/#/?aL=0&bL=groad&cE=0&lR=0&mC=40.21244%2C-91.625976&zL=4>>. Acesso em: 20 de março de 2017.

Trannin, M, 2016. **Desafios e oportunidades para a geração de energia elétrica por fontes renováveis no Brasil: Estudo de caso sobre a Usina de Tacaratu (PE)**. FGV Energia.

UNFCCC – United Framework Convention on Climate Change, 2012. **Guidelines on the Assessment of Investment Analysis**.

U.S DEPARTAMENTO DE TREASURY. **Daily Treasury Long Term Data**, 2017. Disponível em: <  
<https://www.treasury.gov/resource-center/data-chart-center/interest-rates/Pages/TextView.aspx?data=longtermrate> >. Acesso em: 07 de outubro de 2017.

Van der Zwann, B; Rabl, A, 2003. Propescts for PV: a learning curve analysis, **Solar Energy**, 74, 19-31.

Yingli Solar, 2015. **Série de células YGE72**. Disponível em:  
<<http://www.yinglisolar.com/br/products/multicrystalline/yge-72-cell-series/>>. Acesso em: 08 de julho de 2017.