



MODELO MULTI OBJETIVO DE ANÁLISE ENVOLTÓRIA DE DADOS COMBINADO COM O DESENVOLVIMENTO DE FUNÇÕES EMPÍRICAS E OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO

Aneirson Francisco da Silva - aneirson@yahoo.com.br

Fernando Augusto Silva Marins – Fernando.marins@feg.unesp.br

Erica Ximenes Dias – Ericaximenes@yahoo.com.br

Marcelo Vilela Figueiredo- marcelo_mvf@yahoo.com.br

Faculdade de Engenharia – Campus de Guaratinguetá - UNESP Av. Ariberto Pereira da Cunha,
333 – 12516-410 – Guaratinguetá - SP

Rafael de Carvalho Miranda – mirandaprod@yahoo.com.br

Instituto de Engenharia de Produção e Gestão - UNIFEI Av. BPS, 1303, bairro Pinheirinho,
Itajubá - MG Telefone: (35) 3629 - 1101 Fax: (35) 3622 - 3596

Resumo:

O controle de qualidade é um dos principais pilares para um bom rendimento de uma linha de produção, visando garantir maior eficiência, eficácia e redução dos custos de produção. A identificação das causas dos defeitos e seu controle são atividades relativamente complexas devido às muitas variáveis presentes em certos processos produtivos. Este trabalho foi desenvolvido em uma grande indústria siderúrgica do Brasil, que atua na produção de componentes ferroviários e industriais, com o objetivo de reduzir defeitos de fundição de peças ferroviárias. A partir da base de dados, disponível na empresa estudada, foi avaliada a eficiência do processo de produção envolvendo sete produtos e trinta e oito variáveis de processo desses produtos. Nesta análise de eficiência, foi adotado o modelo Bi-objetivo de Análise de Envoltória de Dados (BiO-MCDEA) e foram evidenciadas as variáveis de processo de entrada (*input*) e saída (*output*) que são importantes para a melhoria da eficiência do processo produtivo. Com base neste conjunto de variáveis identificadas pelo modelo BiO-MCDEA, foram desenvolvidas funções empíricas por meio da análise de regressão não linear múltipla para representar o processo produtivo de fundições industriais e ferroviárias. Finalmente, com a transformação de cada coeficiente das funções objetivo em variáveis aleatórias, foi realizada a otimização via simulação Monte Carlo para determinar o melhor ajuste nas variáveis selecionadas como sendo relevantes pelo modelo BiO-MCDEA. Os resultados obtidos para o processo de produção foram interessantes e foram validados estatisticamente.

Keywords: Análise Envoltória de Dados Multicritério, Simulação Monte Carlo, Regressão Não Linear, Eficiência do processo produtivo, Problemas Industriais.



1. Introdução

Desperdício é definido por Ghinato (2002) como atividade completamente desnecessária, que gera custo e não agrega valor, devendo ser totalmente eliminada. Dentre os desperdícios encontrados em processos produtivos, destacam-se os defeitos, os quais são definidos por Menegon et al. (2003) como produtos com alguma de suas características fora da especificação e que, por esta razão, não satisfazem aos requisitos de aplicação.

Há diversas aplicações de ferramentas estatísticas e de simulação na determinação de eficiência de processos produtivos, que são utilizadas para avaliar o nível de qualidade de determinado produto ou processo, e, neste trabalho, foram exploradas:

- MCDEA - *Multi Criteria Data Envelopment Analysis Models* (LI; REEVES, 1999, GHASEMI; IGNATIUS; EMROUZNEJAD, 2014).

- Funções empíricas (WÖLK *et al.*, 2002).

- OvMCS - *Optimization via Monte Carlo Simulation* (KROESE *et al.*, 2011, KAZANTSEV *et al.*, 2015 and KORYTKOWSKI; KARKOSZKA, 2016).

Ghasemi, Ignatius & Emrouznejad (2014) afirmam que a MCDEA tem ampla aplicação prática na determinação de eficiência relativa de DMUs - *Decision Making Units*, e tem sido uma das áreas da Pesquisa Operacional (PO) com maior ritmo de crescimento, tornando-se uma importante ferramenta para análise de eficiência em empresas públicas e privadas. Longo (2006) define OvSMC como uma técnica para resolver problemas matemáticos estocásticos. Em Kandel, Laerke & Elsgaard (2016), Tan, Awaiye & Trabelsi (2014) e Behara *et al.* (2011) pode-se encontrar a descrição e análise de trabalhos que utilizaram a técnica estatística de análise de regressão para obter funções empíricas associadas à diversos problemas industriais.

As Figuras 1 e 2 mostram os resultados relativos às publicações e citações, obtidos na *Web of Knowledge*, utilizando, respectivamente, as palavras-chaves “*Multiple Criteria Data Envelopment Analysis*” e “*Optimization via Monte Carlo Simulation*”. Estes resultados atestam que tais ferramentas têm sido bastante adotadas nas soluções de diversos problemas em variados contextos.

Foi realizada uma busca nas bases de dados *Scopus*, *Web of Knowledge* e *Emerald*, combinando nesta busca as palavras chaves: “*MCDEA - Multiple Criteria Data Envelopment Analysis*”, “*OvMCS - Optimization via Monte Carlo Simulation*”, “*Regression*”, “*Freight Wagon Parts*” e “*Foundry*”. Percebeu-se que não houve nenhuma ocorrência de artigos com essa combinação de palavras-chave, e, portanto, identificou-se lacunas nesta área de pesquisa relativa a avaliação da eficiência de processos produtivos na área siderúrgica. Isto gerou algumas questões de pesquisa que este trabalho buscou responder:

- Como combinar a MCDEA com a OvSMC para avaliar eficiência de processos produtivos na área siderúrgica?

- Há vantagens de se utilizar o modelo MCDEA na seleção de variáveis de entrada (*input*) e de saída (*output*) na análise de eficiência de processos produtivos na área siderúrgica?

- Como validar estatisticamente os resultados da OvSMC quando aplicada na análise de eficiência de processos produtivos na área siderúrgica?

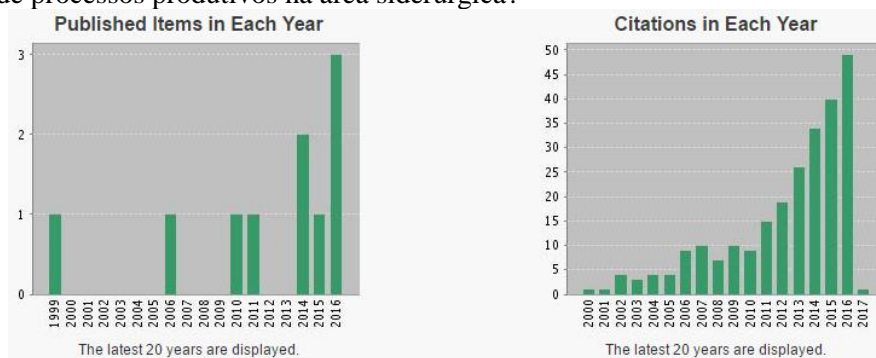


Figura 1. Publicações e citações utilizando a palavra-chave “*Multiple Criteria Data Envelopment Analysis*”. Source: Web of Knowledge

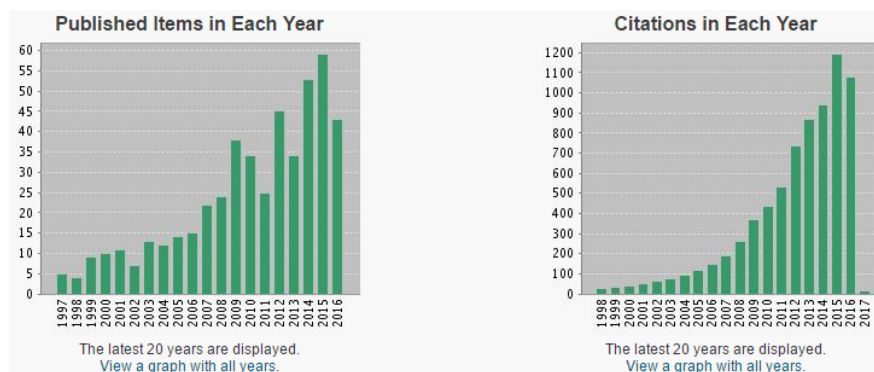


Figura 2. Publicações e citações utilizando a palavra-chave “Optimization via Monte Carlo Simulation”. Source: Web of Knowledge.

Assim, o objetivo geral deste trabalho foi propor uma abordagem inovadora para avaliar eficiência de processos produtivos na área siderúrgica, combinando um modelo Multiobjetivo de Análise Envoltória de Dados, o desenvolvimento de funções empíricas e a Otimização via Simulação Monte Carlo. Os objetivos específicos, que dizem respeito a aplicação da nova abordagem proposta numa indústria siderúrgica brasileira que produz componentes ferroviários e industriais, incluíram:

- Avaliar a eficiência da produção de diferentes peças ferroviárias por meio de um modelo MCDEA.
- Determinar as variáveis (de *input* e de *output*) relevantes na produção de peças ferroviárias por meio de um modelo MCDEA.
- Desenvolver funções empíricas que representem adequadamente o processo produtivo de fundidos ferroviários e industriais.
- Validar estatisticamente os resultados gerados pela OvMCS no ajuste proposto às variáveis identificadas como relevantes por um modelo MCDEA na produção de fundidos ferroviários e industriais.

Como delimitação desta pesquisa, para a obtenção das funções empíricas foi utilizado o algoritmo OLS - *Ordinary Least Squares* (LIU et al., 2016), na OvMCS foi utilizado o otimizador *Optquest* (YANG, 2010) e o modelo MCDEA adotado foi o BiO-MCDEA (GHASEMI; IGNATIUS; EMROUZNEJAD, 2014), pois, dentre os modelos MCDEA, ele tem gerado bons resultados com relação ao aumento da discriminação entre as DMUs, quando não é satisfeita a Regra de Ouro da DEA (BANKER et al., 1989).

Considerando estas características e objetivos do trabalho realizado, com base em Bertrand & Fransoo (2002), ele pode ser classificado como sendo uma pesquisa aplicada, com objetivos empíricos descritivos, pois o modelo desenvolvido descreve de forma adequada as relações causais que podem existir na realidade, favorecendo a compreensão de processos reais. A forma de abordar o problema foi a quantitativa, sendo o método de pesquisa a Modelagem e Simulação.

O artigo está estruturado em mais três seções. A Seção 2 apresenta o referencial teórico, com informações sobre MCDEA, OvSMC, e desenvolvimento de funções empíricas. Já na Seção 3 descreve-se o problema, o método e materiais utilizados, a modelagem realizada, os resultados obtidos e suas análises. Por fim, na Seção 4 são apresentadas as considerações finais, seguidas das referências bibliográficas.

2. MCDEA, OvSMC e Desenvolvimento de Funções Empíricas

Sueyoshi & Goto (2012) afirmam que a *Data Envelopment Analysis* (DEA) tem sido um método quantitativo amplamente utilizado na avaliação de eficiência de empresas nos setores públicos e privados. Neste contexto, Friesner, Mittelhammer and Rosenman (2013) afirmam que a DEA é uma das mais populares ferramentas para se medir eficiência em relação a custos e produtividade em indústrias. Os mesmos autores citam algumas vantagens em se utilizar DEA na determinação de eficiência, tais como:

- Não incorpora regras rígidas, permitindo aos pesquisadores coletarem apenas dados de entrada (*inputs*) e saída (*outputs*) que forem relevantes para as DMUs.



- É técnica não paramétrica, correlacionando *inputs* e *outputs* mesmo sem o atendimento da hipótese de ocorrerem distribuições de probabilidade normal.

Outras características importantes da modelagem DEA são citadas no trabalho de Azadeh, Sheikhalishahi & Koushan (2013), tais como:

- Identifica as DMUs que são *benchmarks* para as demais DMUs analisadas.
- Os dados de entrada e saída são representados na forma numérica.
- Associa o valor 1 (ou 100%) para as DMUs eficientes e valores menores que 1 para as DMUs ineficientes.
- Cria um *ranking* para DMUs ineficientes, porém o mesmo não é feito para as DMUs eficientes.

Dentre os vários modelos da DEA, há o modelo DEA CCR proposto por Charnes, Cooper & Rhodes (1978), com *constant returns to scale* (CRS), podendo ser formulado por:

$$\max w_0 = \sum_{r=1}^s u_r y_{r0} \quad (1)$$

Sujeito a:

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (2)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, \quad j = 1, 2, \dots, n \quad (3)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (4)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (5)$$

sendo w_0 o valor da eficiência da DMU que está sob análise (DMU_0), y_{r0} e x_{i0} , respectivamente, o valor da r -ésima saída e i -ésima entrada para a DMU_0 , y_{rj} o valor da r -ésima saída para a j -ésima DMU, x_{ij} o valor da i -ésima entrada para a j -ésima DMU, u_r a variável de decisão (peso) associada à r -ésima saída, v_i a variável de decisão (peso) associada à i -ésima entrada.

Os modelos DEA podem ser orientados aos *inputs* – buscando reduzir os valores dos recursos utilizados, mantendo os resultados obtidos constantes, ou orientados aos *outputs* – buscando aumentar os valores dos resultados obtidos, mantendo constantes os valores dos recursos utilizados. A partir do modelo DEA CCR, Banker, Charnes & Cooper (1984) propuseram o modelo DEA BCC, com retornos variável de escala, com o acréscimo da variável c_0 , que é livre ou irrestrita, na função objetivo (1) e na restrição (3).

Uma importante questão discutida por Banker *et al* (1989) é que, a fim de evitar problemas com poder de discriminação dos modelos DEA, o número de DMU's deverá ser maior ou igual a três vezes a soma no número de variáveis (*inputs* e *outputs*), ou maior ou igual ao produto do número de variáveis de *input* pelo número de variáveis de *output*, adotando o critério que fornecer a maior quantidade de DMU's. Isto ficou conhecido como a Regra de Ouro da DEA.

De fato, existem dois problemas que podem ocorrer com o uso da DEA, segundo Li e Reeves (1999): poder discriminante fraco - ocorre quando se identificam muitas DMUs como eficientes e a distribuição de pesos irrealista - refere-se à situação em que DMUs podem ser eficientes, mas apresentam valores altos de pesos para uma única saída, ou valores baixos de pesos para uma única entrada.

Para tentar evitar estes problemas citados, Li & Reeves (1999) propuseram o modelo de DEA com Múltiplos Critérios - *Multicriteria Data Envelopment Analysis* (MCDEA), em que cada critério de eficiência é uma função objetivo independente, dado por (6) - (14):

$$\min d_0 \text{ or } \max \sum_{r=1}^s u_r y_{r0} \quad (6)$$



$$\min M \tag{7}$$

$$\min \sum_{j=1}^n d_j \tag{8}$$

Sujeito a:

$$\sum_{i=1}^m v_i x_{i0} = 1 \tag{9}$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j \leq 0, j = 1, 2, \dots, n \tag{10}$$

$$M - d_j \geq 0, j = 1, 2, \dots, n \tag{11}$$

$$u_r \geq 0, r = 1, 2, \dots, s \tag{12}$$

$$v_i \geq 0, i = 1, 2, \dots, m \tag{13}$$

$$d_j \geq 0, j = 1, 2, \dots, n \tag{14}$$

Neste modelo MCDEA há três funções objetivo, sendo que primeira função objetivo d_0 está associada à maximização da eficiência para a DMU analisada. Sendo d_j a função objetivo que visa minimizar a ineficiência para a DMU analisada, e M é a função objetivo que visa minimizar o máximo valor de ineficiência. Os demais parâmetros e variáveis são análogos aos modelos anteriores.

No modelo MCDEA de (6) – (14), os três objetivos são analisados separadamente, sem ordem de preferência definida. Os ganhos de eficiência definidos no âmbito dos critérios de mínimo e máximo são mais restritivos do que os definidos no DEA clássico, e estes dois critérios geralmente identificam menos DMU eficientes. Assim, o objetivo do modelo MCDEA não é extrair uma solução ótima, mas encontrar uma soluções Pareto-ótimas, deixando ao analista a decisão final. Já Ghasemi; Ignatius & Emrouznejad (2014) propuseram o modelo Bi-Objective Weighted DEA model (BiO-MCDEA) que busca tratar dois objetivos simultaneamente, considerando uma dada ponderação destes, segundo a formulação dada por (15) - (21):

$$\text{Min } h = \left(w_2 M + w_3 \sum_{j=1}^n d_j \right) \tag{15}$$

Subject to:

$$\sum_{i=1}^m v_i x_{i0} = 1 \tag{16}$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j = 0, \quad j = 1, 2, \dots, n \tag{17}$$

$$M - d_j \geq 0, \quad j = 1, 2, \dots, n \tag{18}$$

$$u_r \geq \varepsilon, \quad r = 1, 2, \dots, s \tag{19}$$

$$v_i \geq \varepsilon, \quad i = 1, 2, \dots, m \tag{20}$$

$$d_j \geq 0, \quad j = 1, 2, \dots, n \tag{21}$$

Neste artigo objetivou-se avaliar a eficiência da produção de diferentes peças ferroviárias de uma indústria siderúrgica no Brasil, bem como identificar as entradas e saídas variáveis que são importantes neste processo produtivo, para tanto adotou-se um modelo BiO-MCDEA, com $\varepsilon = 0,00001$ (GHASEMI; IGNATIUS; EMROUZNEJAD, 2014), para esta finalidade.

Outra técnica de Pesquisa Operacional que, de acordo com Yang (2010), tem sido aplicada em todas as áreas do conhecimento é Simulação Monte Carlo (SMC). Neste trabalho a SMC foi



utilizada em conjunto com técnicas de otimização, num procedimento conhecido por Otimização via Simulação Monte Carlo (OvSMC), que são indicados para solucionar problemas complexos que apresentem vários ótimos locais, envolvendo um *mix* de variáveis contínuas e discretas (KROESE; TAIMRE; BOTEV, 2011). Neste contexto, destaque-se que vários problemas estocásticos, que são de interesse neste trabalho, como o problema (22) proposto por Shapiro (2001).

$$\min_{x \in X} \{g(x) := E_P[G(x, \omega)]\}, \quad (22)$$

sendo $G : \mathbb{R}^n \times \Omega \rightarrow \mathbb{R}$, a expectativa em relação à medida de probabilidade P definida em um espaço amostral (Ω, F) , e $X \subset \mathbb{R}^n$. Assume-se para cada $x \in X$ a expectativa de $g(x)$ e bem definida. A função $G(x, \omega)$ em si pode ser definida por um problema de otimização. Uma etapa importante do trabalho aqui relatado envolveu a obtenção de funções empíricas que representassem adequadamente o processo produtivo de fundidos ferroviários e industriais.

Sabe-se que uma das maneiras de estimar uma função empírica é por meio da análise de regressão, que, segundo Helene (2013), é amplamente utilizada com esta finalidade em diversas áreas. Regressões múltiplas são utilizadas para estudar a relação entre variáveis dependentes e variáveis independentes (ou explicativas), por meio da obtenção de uma equação linear que represente as relações entre as mesmas, tal como expresso em (23):

$$y_l = \beta_0 + \beta_1 x_{1l} + \beta_2 x_{2l} + \dots + \beta_k x_{kl} + \tau_i, \quad l = 1, 2, \dots, p \quad (23)$$

sendo y_l uma variável dependente, x_1, x_2, \dots, x_k as variáveis independentes, τ_i o fator de erro, e p o número de amostras observadas. Dentre as diversas técnicas de análise regressão, linear ou não linear, optou-se, aqui, pelo algoritmo OLS - *Ordinary Least Squares* (HELENE, 2013, FERRARO; GIORDANI, 2012), que consiste em se desenvolver um modelo por meio de regressão linear ou não linear e refinar os parâmetros com base em sucessivas iterações (LIU *et al.*, 2016).

Na próxima seção será descrito o problema tratado, as etapas do trabalho, incluindo a modelagem MCDEA, a obtenção das funções empíricas para os processos produtivos e a aplicação da OvSMC para a simulação de cenários de interesse da empresa em estudo.

3. Modelagem do Problema e Análises dos Resultados

No desenvolvimento do trabalho foram seguidas as seguintes etapas:

- **Identificação do problema:** Após entrevistas com os gestores de uma empresa brasileira de grande porte, que produz componentes ferroviários e industriais feitos à base de aço, foi estabelecida como questão principal a ser enfocada: Como melhorar a eficiência de processos produtivos industriais?

Num primeiro momento, para ser testada a nova metodologia proposta neste trabalho, foram escolhidos, pelos gestores da empresa estudada, os processos produtivos de sete peças (que foram as DMUs analisadas no modelo BiO-MCDEA) que compõem sistemas de acoplamento entre vagões e sustentação dos mesmos, tais peças pesam entre 300 kg a 1.000 kg, passando por diversos processos produtivos (ver Figura 3).

Após o acompanhamento do processo produtivo destas peças, que se dá conforme o fluxograma da Figura 3, os engenheiros da empresa estudada definiram entradas e saídas que seriam objeto de análise pelo modelo BiO-MCDEA, visando a identificação de melhorias neste processo.

Seguem descrições técnicas das variáveis de entrada:

- x_1 Tempo de Vazamento: Tempo decorrido entre a abertura e o fechamento da válvula de vazamento para a transferência do aço líquido da panela de vazamento para o molde, onde o aço irá solidificar no formato da peça; - x_2 -Tempo de Argônio: Tempo de injeção de Argônio, durante a preparação do aço líquido no forno. Argônio é um gás inerte e sua injeção é necessária para misturar o aço líquido com os demais elementos de liga adicionados, de forma a tornar a solução homogênea; - x_3 Quantidade de Escória: Escória é a camada de materiais que ficam na parte de cima da panela de vazamento e tem a função de isolar termicamente o aço líquido, de forma a evitar troca de calor com o ambiente;- x_4 Tempo entre Moldagem e Vazamento: Tempo decorrido entre a



confeção do molde e o vazamento de aço no molde para a confecção da peça. Tempos muito longos podem ocasionar defeitos nas peças; - x_5 Tempo entre Vazamento e Desmoldagem: Tempo decorrido entre o vazamento de aço líquido no molde e a desmoldagem. Tempos muito curtos podem ocasionar defeitos de conformação nas peças, tais como defeitos dimensionais, trincas, rechupes, dentre outros; - x_6 Tempo com Forno Ligado: Tempo em que o Forno a Arco Elétrico fica ligado para fundir a sucata de aço; - x_7 Tempo na Aciaria: Tempo de todo o processo de confecção de aço líquido, desde o carregamento de sucata no forno, adição de liga, fusão do aço e basculamento (transferência do aço líquido do forno para a panela de vazamento); - x_8 Tempo para Oxidação: Tempo de injeção de oxigênio para a oxidação de elementos de liga presentes no aço líquido; - x_9 Última temperatura no Forno: Última temperatura do aço líquido registrada no forno, antes do basculamento; - x_{10} Valor do Rendimento Energético: Calculado a partir da divisão do KWh gasto para fundir o aço pela tonelada de aço fundida; - x_{11} Quantidade de Sucatas: Total de sucata fundida no forno; - x_{12} Carbono Equivalente (Ceq): Calculado por meio de (24),

$$Ceq = C + \frac{Mn}{6} + \frac{(Cr+Mo+V)}{5} + \frac{(Ni+Cu)}{15} \quad (24)$$

sendo C a quantidade de Carbono, Mn a quantidade de Manganês, Cr a quantidade de Cromo, Mo a quantidade de Molibdênio, V a quantidade de Vanádio, Ni a quantidade de Níquel e Cu a quantidade de Cobre. - x_{13} Quantidade de Alumínio; - x_{14} Quantidade de Carbono: Tem influência nas propriedades de Resistência Mecânica, Dureza, Modelo de Elasticidade, Soldabilidade e Fragilidade das peças produzidas; - x_{15} Quantidade de Cobre; - x_{16} Quantidade de Cromo; - x_{17}

Quantidade de Enxofre: Influencia negativamente no surgimento de trincas (defeito de fundição); - x_{18} Quantidade de Fosforo: Influencia negativamente no surgimento de trincas (defeito de fundição); - x_{19} Quantidade de Manganês; - x_{20} Quantidade de Molibdênio; - x_{21} Quantidade de Nióbio; - x_{22} Quantidade de Níquel; - x_{23} Quantidade de Silício; - x_{24} Quantidade de Titânio; - x_{25} Quantidade de Vanádio; - x_{26} Limite de Resistência: Valor da tensão necessária para a ruptura do corpo de prova; - x_{27} Limite de escoamento: Valor da tensão necessária para iniciar o processo de deformação plástica do corpo de prova; - x_{28}

Alongamento: Utilizada para a medição da elasticidade do aço por meio da comparação do comprimento do corpo de prova antes e depois da ruptura ocasionada no ensaio de tração; - x_{29} Redução de Área: Utilizada para a medição da ductilidade do aço, porém realizada por meio da comparação entre a área da seção transversal da ruptura com a seção transversal inicial do corpo de prova; - x_{30} Medida de Dureza (HB): Utilizada para medir a dureza do aço resultante do processo.

As variáveis de saída x_{31} a x_{37} são consideradas como outputs indesejáveis e, portanto, no modelo BiO-MCDEA foram consideradas como entradas. Seguem as descrições técnicas das variáveis de saídas analisadas: - x_{31} Número de Trincas Externas: Quantidade de trincas na superfície externa da peça; - x_{32} Número de Trincas Internas: Quantidade de trincas na cavidade interna da peça; - x_{33} número de Entradas: Entradas de maçarico. Tal processo é realizado para se retirar as partes indesejadas da peça. Por falha humana ou inclusão de areia do molde na peça pode ocorrer o defeito “entrada de maçarico”, onde ocorre a retirada de aço além do necessário. Tal fato pode ocasionar o retrabalho da peça, preenchendo os vazios com solda ou então o refugo da peça, quando se trata de zona crítica sem a permissão de recuperação; - x_{34} Número de Inclusões Externas: inclusão de materiais indesejáveis dentro do aço líquido que, ao se solidificar, permanecem na superfície externa da peça; - x_{35} Número de Inclusões Internas: Inclusões presentes nas cavidades internas das peças; - x_{36} Número de Defeitos Identificados pelo Ultrassom: Defeitos de inclusão ou trinca presente no interior da peça (fora da superfície); - x_{37} Número de Rejeições pelo Calibre: Rejeições de calibres utilizados para avaliar o dimensional das peças; - y_1 Preço de Venda [\\$].

Destaque-se que, segundo informações dos engenheiros da empresa estudada, as etapas produtivas que mais contribuem para a incidência de defeitos são: Confeção de Moldes, Preparação e Fusão do Aço, Enchimento dos Moldes, Desmoldagem e Tratamento Térmico.

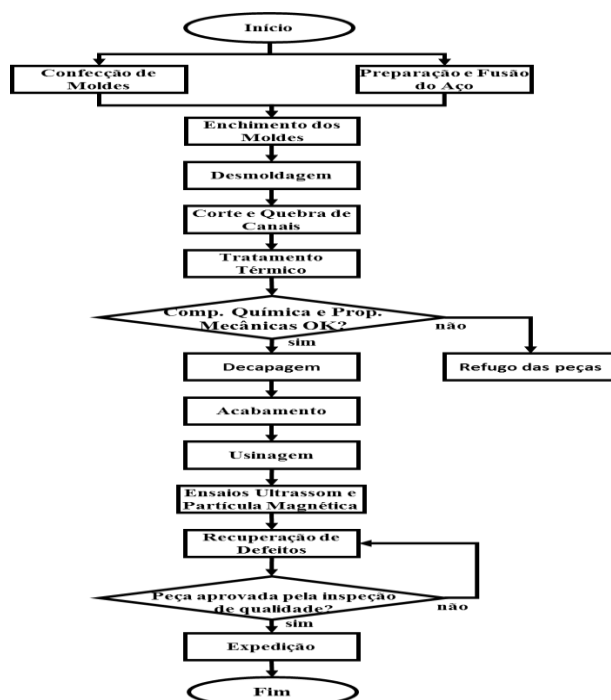


Figura 3. Fluxograma de Produção. Fonte: Empresa estudada.

É interessante observar que, como o total de variáveis de entrada e variáveis de saídas (*TNIOV*) foi trinta e oito, pela DEA Golden Rule (BANKER et al., 1989), seriam necessárias 114 (= 3. *TNIOV*) DMUs, para se utilizar os modelos clássicos da DEA e manter o poder de discriminação da técnica. Este fato também justifica o uso do modelo BiO-MCDEA neste caso, pois há apenas sete DMUs para serem analisadas.

- **Coleta de dados:** As informações sobre os inputs e outputs para cada uma das sete peças (DMUs) estudadas foram obtidas na base de dados da própria empresa. Como o volume de dados é muito grande, por uma questão de conveniência, eles não foram incluídos neste texto, mas encontram-se disponíveis no Apêndice A.

- **Modelagem e solução do problema:** O procedimento proposto neste trabalho para propor melhorias no processo produtivo em questão seguiu o fluxograma da Figura 4.



Fig. 4. Fluxograma de execução do projeto

Para formular e otimizar o modelo BiO-MCDEA visando a identificação dentre as sete DMUs (peças) aquelas com processos produtivos mais eficientes, bem como as variáveis de input e output mais importantes em cada processo produtivo, utilizou-se a programação VBA em Excel®



e o algoritmo Simplex da Programação Linear (HILLIER; LIEBERMAN, 2001), disponível no Solver do Excel®.

Com as variáveis de entrada e saída importantes para cada DMU, foi aplicado o algoritmo OLS, disponível nas funções avançadas do Excel®, para o desenvolvimento das funções empíricas associadas aos respectivos processos produtivos. Para o ajuste das funções empíricas foi executada a OvSMC por intermédio do software Crystal Ball® em conjunto com seu otimizador Optquest (LI; WANG, 2012). Nestas aplicações de métodos quantitativos foi utilizado uma máquina com Intel core i7, processador 2.8 de GHZ com 16 GB de memória RAM e sistema operacional IOS. O tempo computacional na OvSMC foi em média de 5 minutos para cada instância testada.

Passa-se a mostrar os resultados de cada etapa do procedimento e a comentá-los. O ranqueamento dos processos produtivos pelo modelo BiO-MCDEA está na Tabela 1, e percebe-se, que apenas as DMUs 5 e 7 (em negrito) foram eficientes, sendo que, a DMU 6 teve o pior desempenho em termos de eficiência. Atendeu-se, assim, o primeiro objetivo específico “Avaliar a eficiência da produção de diferentes peças ferroviárias por meio de modelo MCDEA”.

Tabela 1. Eficiência das DMUs

DMU	Eficiência
1	0,6719
2	0,6616
3	0,7916
4	0,5187
5	1,0000
6	0,3386
7	1,0000

O próximo passo consistiu em identificar, pelo modelo BiO-MCDEA, quais variáveis de entrada e de saída foram significativas para seus respectivos processos produtivos. Para tanto foram obtidos pelo algoritmo simplex (Solver do Excel®), aplicado ao modelo BiO-MCDEA, os valores dos pesos das variáveis de entrada (v_i) e de saída (u_r) para cada DMU e observou-se quais foram diferentes de zero.

Desta maneira foram identificadas como significativas as variáveis de entrada: Tempo de vazamento (v_1), Quantidade de Molibdênio (v_{20}), Quantidade de Nióbio (v_{21}), Quantidade de Vanádio (v_{25}), Número de Trincas Externas (v_{31}), Número de Trincas Internas (v_{32}), Número de Inclusões Internas (v_{35}), Número de Defeitos Identificados pelo Ultrassom (v_{36}) e Número de Rejeições pelo Calibre (v_{37}). Com isto foi atendido o segundo objetivo específico do artigo “Determinar as variáveis (de *input* e de *output*) relevantes na produção de peças ferroviárias por meio de modelo MCDEA”. Na sequência do trabalho, para as variáveis significativas de cada processo produtivo (DMU) já identificadas, foram construídas as respectivas funções empíricas por meio do algoritmo OLS. Cabe destacar que as saídas indesejáveis na aplicação da BiO-MCDEA passaram a ser as variáveis dependentes (respostas) na etapa de desenvolvimento das funções empíricas.

Não foram estimadas as funções empíricas para as variáveis respostas “Número de Inclusões Internas (v_{35})” e “Número de Defeitos Identificados pelo Ultrassom (v_{36})”, pois estes defeitos são causados por variáveis de processo que não são bem controladas na empresa objeto de estudo, e não foram consideradas na análise realizada. Por razões similares, também não foi estimada a função empírica para a variável dependente (resposta) “Número de Rejeições pelo Calibre (v_{36})”, pois defeitos dimensionais ocorrem devido ao excesso ou pela falta de material onde se passa o calibre para a devida verificação dimensional.

Portanto foram consideradas, nesta etapa de obtenção de funções empíricas para processos produtivos em função das variáveis significativas, apenas as variáveis respostas “Número de Trincas Externas” e “Número de Trincas Internas”; após várias tentativas, chegou-se às formulações genéricas que apresentaram valores de R^2 -ajustado (HELENE, 2013) aceitáveis, ou seja, maiores que 70%, tendo sido utilizada uma amostra com 250 elementos para cada uma das variáveis analisadas:



$$\hat{Y}_1 = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \tilde{\beta}_2 x_{20} + \tilde{\beta}_3 x_{21} + \tilde{\beta}_4 x_{25} + \tilde{\beta}_5 x_1^2 + \tilde{\beta}_6 x_{20}^2 + \tilde{\beta}_7 x_{21} x_{25} \quad (25)$$

$$\hat{Y}_2 = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 x_{20} + \tilde{\beta}_2 \frac{x_{21} x_{20}}{x_1^2 x_{25}} + \tilde{\beta}_3 \frac{\cos(x_{20})}{x_{21}} + \tilde{\beta}_4 \frac{\text{sen}(x_{20})}{x_{25} x_{21} x_1} - \tilde{\beta}_5 \frac{x_1}{x_{21}} - \tilde{\beta}_6 \sqrt{x_1} \frac{x_{25}^2}{x_{20}^2} \quad (26)$$

sendo, \hat{Y}_1 e \hat{Y}_2 , respectivamente, os valores estimados para o “Número de Trincas Externas” e “Número de Trincas Internas”.

As Tabelas 2 e 3, respectivamente, exibem os coeficientes (estatísticas) dos termos matemáticos componentes das funções empíricas de “Número de Trincas Externas” e de “Número de Trincas Internas”, obtidos pela aplicação do algoritmo OLS.

Como os valores de R²-ajustados para \hat{Y}_1 e \hat{Y}_2 foram, respectivamente, 73% e 77%, as funções empíricas foram consideradas adequadas por apresentarem R²-ajustado acima de 70%, *p-value* menor que 5% e por apresentarem resíduos normais, mostrando assim, que não há tendenciosidade nestas funções empíricas adotadas (HELENE, 2013). Destaque-se que, portanto, ficou satisfeito o terceiro objetivo específico deste trabalho “Desenvolver funções empíricas que representem adequadamente o processo produtivo de fundidos ferroviários e industriais”.

Tabela 2. Estatísticas da Função Empírica obtida para “Número de Trincas Externas”.

Source: Excel®

Termos Matemáticos na Expressão (23)	Valores dos Coeficientes (CV)	<i>p-value</i> [%]	Limitantes Inferiores (95%)	Limitantes Superiores (95%)
			(LB)	(UB)
Intercepto ($\tilde{\beta}_0$)	20,9	0,0000	14,6	27,2
x_1	-0,30093	0,3596	-0,5025	-0,0993
x_{20}	-59,3	0,3475	-98,9	-19,7
x_{21}	-674,7	0,0005	-958,2	-391,3
x_{25}	-2,119,2	1,4215	-3,809,5	-429
x_1^2	0,00165	4,0324	0,0001	0,0032
x_{20}^2	622,8	0,0000	465,6	779,9
$x_1 \cdot x_{25}$	39,1	4,2177	1,4	76,8

Tabela 3. Estatísticas da Função Empírica obtida para “Número de Trincas Internas”.

Source: Excel®

Termos Matemáticos na Expressão (24)	Valores dos Coeficientes (CV)	<i>p-value</i> [%]	Limitantes Inferiores (95%)	Limitantes Superiores (95%)
			(LB)	(UB)
Intercepto ($\tilde{\beta}_0$)	1,98042	0,0000	1,3109	2,6500
$x_1 x_{20}$	0,19418	0,0000	0,1486	0,2398
$x_1 x_{20} / (x_{21}^2 x_{25})$	0,0000001	4,2526	0,0000005	0,000002
$\frac{\cos(x_{20})}{x_{21}}$	0,00084	1,0038	0,0002	0,0015
$\frac{\text{sen}(x_{20})}{x_{25} x_{21} x_1}$	0,06978	0,8677	0,0181	0,1215
$\frac{x_{21}}{x_1}$	-0,14871	4,4500	-0,3065	0,0091
$\sqrt{x_1} \frac{x_{25}^2}{x_{20}^2}$	-26,38232	2,0000	-46,6642	-6,1000

Para realizar a OvSMC das funções empíricas (25) e (26), considerou-se cada coeficiente ($\tilde{\beta}$) nestas expressões como sendo uma variável aleatória $x \sim T [LB, CV, UB]$, com distribuição de



probabilidade triangular (KOKONENDJI; KIESSÉ; ZOCCHI, 2007), atendendo (27) e ilustrada na Figura 5; observe-se que os valores dos parâmetros estão nas Tabelas 3 e 4:

$$f(x) = \begin{cases} \frac{2(x-LB)}{(UB-LB)(CV-LB)} & LB \leq x < CV \\ \frac{2}{(UB-LB)} & x = CV \\ \frac{2(UB-x)}{(UB-LB)(UB-CV)} & CV < x \leq UB \\ 0 & \text{para qualquer outro valor} \end{cases} \quad (27)$$

sendo $f(x)$ a função densidade de probabilidade triangular para a variável aleatória x , LB o limitante inferior, CV o valor mais provável e UB o limitante superior.

Função densidade de probabilidade $f(x)$

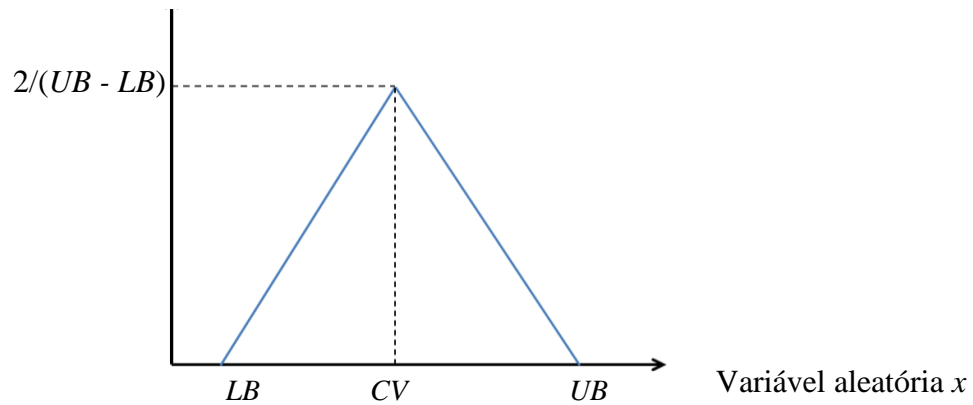


Figura 5. Distribuição de probabilidades triangular para a variável aleatória $x \sim T [LB, CV, UB]$

O problema para o qual foi aplicada a OvSMC para encontrar os valores ajustados das variáveis de entrada importantes já identificadas, e que podem ser adotados pelos gestores nos processos produtivos na prática, está formulado por (28) – (29):

$$\min (\hat{Y}_1 + \hat{Y}_2) \quad (28)$$

s.t:

$$x_i \in X \text{ (Conjunto Discreto de Soluções viáveis)} \quad (29)$$

sendo V o conjunto de combinações de valores das variáveis de entrada utilizados pela Empresa objeto de estudo.

Destaque-se que, antes de aplicar a OvSMC ao problema (28) – (29), foi testada a existência de correlações entre as variáveis de entrada, os resultados do Teste de Correlação de Pearson (MONTGOMERY, 2005) estão na Tabela 4, e constata-se que há correlação alta e positiva (em negrito) entre os pares de variáveis x_{21} - x_{20} , x_{25} - x_{20} e x_{25} - x_{21} , sendo as demais correlações não significativas estatisticamente.

Tabela 4. Pearson Correlation Values (p-values) para variáveis de entrada. Source: *Minitab 17*®

Variables	x_1	x_{20}	x_{21}
x_{20}	-0,028 (p-value 0,661)		
x_{21}	0,008 (p-value 0,932)	0,737 (p-value 0,000)	
x_{25}	-0,052 (p-value 0,414)	0,818 (p-value 0,000)	0,626 (p-value 0,000)



Após a sequência de etapas seguidas na execução da OvSMC (tendo sido utilizado o Crystal Ball e o módulo Optquest), considerando estas correlações significativas entre as variáveis de entrada; obteve-se os resultados estão nas Tabelas 5 – 6 e ilustrados nas Figuras 6 – 7.

Tabela 5. Intervalos $[LB, UB]$ obtidos na OvSMC para variáveis de resposta “Número de Trincas Externas” e de “Número de Trincas Internas”, considerando existência das correlações significativas entre as variáveis de entrada.

Valor final das funções objetivo	LB	UB
\hat{Y}_1	3.3	16.9
\hat{Y}_2	2.5	8.7




Figura 6. Resultado para a variável resposta “Número de Trincas Externas” com a OvSMC considerando existência de correlação. Fonte: Crystal Ball ®




Figura 7. Resultado para a variável resposta “Número de Trincas Internas” com a OvSMC considerando existência de correlação. Fonte: Crystal Ball ®

Tabela 6. Valores ajustados obtidos na OvSMC para variáveis de entrada, considerando existência das correlações significativas entre elas.

Variável de Entrada	Valor
x_1	26
x_{20}	0.01
x_{21}	0.003
x_{25}	0.001

O quarto objetivo específico era “Validar estatisticamente os resultados gerados pela OvMCS no ajuste proposto às variáveis identificadas como relevantes por modelo MCDEA na produção de fundidos ferroviários e industriais”. Para a consecução desta meta, comparou-se os resultados da OvSMC (Tabelas 5 e 6) com os valores reais ocorridos para as variáveis envolvidas disponibilizados no banco de dados da Empresa objeto de estudo. Para fins de ilustração, na Tabela 7 estão alguns valores extraídos deste banco de dados que se situam dentro do intervalo de confiança (95%) gerado pela OvSMC (Tabelas 5 e 6), ficando, portanto, validado o procedimento aqui proposto.



Tabela 7. Valores extraídos da base de dados da empresa estudada para validação dos resultados da OvSMC

Tipo	Variável	Valor
Valores finais das funções objetivo	\hat{Y}_1	6
	\hat{Y}_2	5
Valores de ajuste (recomendados) para as variáveis de entrada significativas	x_1	26
	x_{20}	0.01
	x_{21}	0.003
	x_{25}	0.001

4. Conclusões e Recomendações para Futuras Pesquisas

Passa-se a responder às questões de pesquisa propostas na Seção 1:

- Como combinar a MCDEA com a OvSMC para avaliar eficiência de processos produtivos na área siderúrgica? Foi descrito neste trabalho um procedimento para avaliar eficiência de processos produtivos na área siderúrgica que propiciou resultados interessantes e úteis para a Empresa estudada. Ele combina um Modelo BiO-MCDEA, com a geração de funções empíricas e a aplicação da OvSMC.

- Há vantagens de se utilizar o modelo MCDEA na seleção de variáveis de entrada e de saída na análise de eficiência de processos produtivos na área siderúrgica? O modelo BiO-MCDEA adotado permitiu a identificação das quatro variáveis relevantes (significativas) de entrada e saída para cada processo produtivo, o que facilita a tarefa dos gestores em atuar na melhoria do desempenho destes processos, ajustando os valores destas quatro variáveis conforme Tabela 6.

- Como validar estatisticamente os resultados da OvSMC quando aplicada na análise de eficiência de processos produtivos na área siderúrgica? Os resultados obtidos pela OvSMC, para as duas funções empíricas investigadas, foram validados estatisticamente, utilizando-se uma comparação dos dados reais (banco de dados da Empresa) com os intervalos de confiança (95%) gerados pela OvSMC para as variáveis respostas “Número de Trincas Externas” e Número de Trincas Internas”.

Outro comentário importante se refere a constatação que realizar a OvSMC utilizando toda a informação gerada pela análise de regressão (coeficientes originais e os intervalos de confiança), bem como a inserção da correlação entre as variáveis de entrada, mostrou-se interessante pois possibilitou melhorar a qualidade dos resultados da otimização, e também permitiu a sua validação estatística.

Optou-se pela estratégia de considerar os coeficientes das funções empíricas como sendo variáveis aleatórias (com função de distribuição de probabilidade triangular), o que se mostrou interessante para resolver problemas complexos e reais. Destaque-se, também, que o algoritmo OLS gerou funções empíricas com boa aderência à realidade dos processos produtivos analisados.

Finalmente, pode-se concluir que todos os objetivos propostos neste trabalho foram plenamente atendidos, e que o procedimento proposto é exequível, inovador e pode propiciar informações de muita valia para os gestores de processos produtivos.

Para futuros trabalhos pretende-se:

- Aplicar a abordagem propostas em outros tipos de indústrias.

- Aplicar a abordagem em outros tipos de problemas, como, por exemplo, econômicos e financeiros.

AGRADECIMENTOS

FAPESP (Processos FAPESP - 2015/12711-4; FAPESP- 2015/24560-0), CNPq (Processos CNPq – 306214/2015-6, CNPq - 431758/2016-6), e FAPEMIG (Processo APQ-01188-16).

REFERENCES

Azadeh, A.; Sheikhalishahi, M.; Koushan, M., 2013. An integrated fuzzy MCDEA-Fuzzy simulation approach for optimization of operator allocation with learning effects in multi products CMS. *Applied Mathematical Modeling*, 37, 9922-9933.

Charnes A.; Cooper, W.W; Rhodes, E. 1978. Measuring the efficiency of decision-making units, *Eur. J. Operational Research*, 2, 429-444.



- Banker, R. D.; Charnes, A.; Cooper, W. W.; Swarts, J.; Thomas, D. A., 1989. An Introduction to Data Envelopment Analysis with Some of its Models and Their Uses. *Research in Governmental and Non-Profit Accounting*, 5, 125-163.
- Behara, S. R. B.; Kippax, P.; Larson, L.; Morton, D. A. V.; Stewart, P., 2011. Kinetics of emitted mass – A study with three dry powder inhaler devices. *Chemical Engineering Science*, 66, 5284-5292.
- Bertrand, J. W. M., Fransoo, J. C., 2002. Operations management research methodologies using quantitative modeling. *International Journal of Operations and Production Management*, 22, p. 241-264.
- Ferraro, M. B.; Giordani, P. A., 2012. Multiple linear regression model for imprecise information. *Metrika*, 75, 1049-1068.
- Friesner, D.; Mittelhammer, R.; Rosenman, R., 2013. Inferring the incidence of industry inefficiency from MCDEA estimates. *European Journal of Operational Research*, 224, 414-424.
- Ghasemi, M.; Ignatius, J.; Emrouznejad, A., 2014. A bi-objective weighted model for improving the discrimination power in MCDEA. *European Journal of Operational Research*, 233, 640–650.
- Ghinato, P. Lições Práticas para a Implementação da Produção Enxuta. EDUCS - Editora da Universidade de Caxias do Sul, 2002.
- Helene, W., 2013. Rethinking the linear regression model for spatial ecological data. *Ecology*, 94, 2381-2391.
- Hillier, F. S.; Lieberman, G. J.: *Introduction to Operations Research*, 8th Edition. McGraw-Hill, 2001.
- Kandel, T. P.; Laerke, P. E.; Elsgaard, L., 2016. Effect of chamber enclosure time on soil respiration flux: comparison of linear and non-linear flux calculation methods. *Atmospheric Environment*. 141, 245-254.
- Kazantsev, D. M.; Akhundov, I. O.; Karpov, A. N.; Shwartz, N. L.; Alperovich, V. L.; Terekhov, A. S.; Latyshev, A. V. 2015. Monte Carlo simulation of GaAs (0 0 1) surface smoothing in equilibrium conditions. *Applied Surface Science*, 333, 141-146.
- Kokonendji, C. C., Kiessé, T. S.; Zocchi, S. S., 2007. Discrete triangular distributions and non-parametric estimation for probability mass function. *Journal of Nonparametric Statistics*, 19, 241-257.
- Korytkowski, P.; Karkoszka, R., 2016. Simulation-based efficiency analysis of an in-plant milk-run operator under disturbances. *The International Journal of Advanced Manufacturing Technology*, 82, 827–837.
- Kroese, D. P.; Taimre, T.; Botev, Z. I. *Handbook of Monte Carlo Methods*. John Wiley & Sons, New York, 2011.
- Li, X.; Reeves, G. R., 1999. A multiple criteria approach to data envelopment analysis. *European Journal of Operational Research*, 115, 507-517.
- Li, S.; Wang, C., 2012. Analysis for Quick Response Strategy using OptQuest Simulation. *Applied Mechanics and Materials*, 220-223, 263-267.
- Liu, H.; Wei, G.; Xu, Z.; Liu, P.; Li, Y., 2016. Quantitative analysis of Fe and Co in Co-substituted magnetite using XPS: The application of non-linear least squares fitting (NLLSF). *Applied Surface Science*, 389, 438-446.
- Longo, S., 2006. Monte Carlo simulation of charged species kinetics in weakly ionized gases. *Plasma Sources Science and Technology*, 15, 5181-5188.
- Menegon, D.; Nazareno, R. R.; Rentes, A. F. Relacionamento entre desperdícios e técnicas a serem adotadas em um sistema de produção enxuta. XXIII Encontro Nacional de Engenharia de Produção, 2003.
- Montgomery, D. C. *Design and Analysis of Experiments*. 6th. ed., New York: Wiley, 2005.
- Mosegaard, K.; Tarantola, A., 1995. Monte Carlo sampling of solutions to inverse problems, *J. Geophys. Res.*, 100(B7), 12,431-447.



- Ramón, J.; Cristóbal, S. A., 2011. Multi criteria data envelopment analysis model to evaluate the efficiency of the Renewable Energy technologies. *Renewable Energy*, 36, 2742-2746.
- Shapiro, A., 2001. Monte Carlo Simulation Approach to Stochastic Programming. *Proceedings of the 2001 Winter Simulation Conference* B. A. Peters, J. S. Smith, D. J. Medeiros, and M. W. Rohrer, eds.
- Sueyoshi, T.; Goto, M., 2012. Efficiency-based rank assessment for electric power industry: A combined use of Data Envelopment Analysis (DEA) and DEA-Discriminant Analysis (DA). *Energy Economics*, 34, 634 - 644.
- Wölk, J.; Strey, R.; Heath, C. H.; Wyslouzil, B. E., 2002. Empirical function for homogeneous water nucleation rates. *The Journal of Chemical Physics*, 117, 4954-4960.
- Yang, X. S., 2010. *Engineering optimization. an introduction with metaheuristic applications.* Wiley.