

ANÁLISE ENVOLTÓRIA DE DADOS EM ESTRUTURA DE REDE: UMA NOVA ABORDAGEM PARA REDUÇÃO DO ESPAÇO DE BUSCA EM PROBLEMAS DE OTIMIZAÇÃO VIA SIMULAÇÃO

Victor E M Valerio

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
victor.dmv@gmail.com

Edson de O Pamplona

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
pamplona@unifei.edu.br

José Arnaldo B Montevechi

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
montevechi@unifei.edu.br

Paulo Rotela Junior

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
paulo.rotela@gmail.com

Giancarlo Aquila

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
giancarloaquila@ig.com.br

Marcelo Nunes Fonseca

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
marcelonunes21@yahoo.com.br

Luiz Célio S Rocha

Universidade Federal de Itajubá
Caixa Postal 50, CEP: 37500-903, Itajubá-MG
luizrochamg@hotmail.com

RESUMO

As aplicações da técnica de otimização via simulação vem crescendo consideravelmente devido a capacidade de auxiliar a tomada de decisão em problemas reais. Contudo, o grande problema da aplicação desta técnica está relacionado ao elevado custo computacional de convergência dos otimizadores. Dessa forma, o objetivo deste artigo é apresentar uma nova abordagem para a sistemática de redução do espaço de busca para problemas reais de otimização via simulação. Esta nova abordagem propõe um procedimento que associa Arranjos Ortogonais de Taguchi, função de produção Cobb-Douglas e a Análise Envoltória de Dados em estrutura de rede na otimização via simulação. Os resultados alcançados validam a nova abordagem, ao alcançar reduções de cerca de 96% no espaço de busca e reduções de cerca de 35% na quantidade de experimentações necessárias para convergência do otimizador considerando um problema real.

PALAVRAS-CHAVES. Otimização via Simulação. Redução do Espaço de Busca. DEA em Estruturas de Rede. Arranjos Ortogonais de Taguchi. Função de Produção Cobb-Douglas.

ÁREA PRINCIPAL: SIM

ABSTRACT

The applications of simulation optimization technique have increased considerably due to the ability to support decision making in real problem. However, the major problem of the application of this technique is related to the high computational cost of convergence of optimizers. Thus, the aim of this paper is present a new approach to systematic reduction of the search space for simulation optimization real problems. This new approach proposes a procedure involving Taguchi's Orthogonal Arrays, Cobb-Douglas production function and Network Data Envelopment Analysis in simulation optimization. The results obtained validate the new approach, promoting reductions of 96% in the search space and 35% reductions in the amount of experimentation required for convergence of the optimizer considers a real problem.

KEYWORDS. Simulation Optimization. Reduced Space Searching. Network-DEA. Taguchi's Orthogonal Arrays. Cobb-Douglas Production Function.

ÁREA PRINCIPAL: SIM



1 Introdução

Assim como expresso por Wang e Shi (2013) e Hillier e Lieberman (2010), a otimização via simulação (OVS) é uma ferramenta poderosa para se resolver uma grande variedade de problemas reais, sendo que, seu principal objetivo está relacionado a determinação dos valores dos parâmetros em análise a fim de se obter as melhores medidas de desempenho.

Os autores Figueira e Almada-Lobo (2014) acrescentam que é possível observar um aumento considerável no número de aplicações, em engenharia de produção, que se apropriam da associação entre as técnicas de simulação e otimização. Sobre este aspecto, Yang et al. (2014), argumenta que este crescimento se deu com maior intensidade nos últimos cinco anos, representando hoje uma tendência para pesquisadores e consultores.

Como demonstrado por Singh (2015), o crescimento da utilização dessas técnicas combinadas está diretamente ligado à dificuldade em se estudar sistemas reais complexos. De acordo com Chwif e Medina (2010), a referida complexidade dos casos práticos fundamenta-se na natureza dinâmica e aleatória destes, fato que inviabiliza uma análise a partir do desenvolvimento de uma modelagem estritamente analítica.

Neste sentido, Lee et al. (2008) e Chwif e Medina (2010), afirmam que a simulação a eventos discretos (SED) ganha especial importância na medida em que possui a capacidade de reproduzir, em um ambiente computacional, o comportamento do sistema real simulado, possibilitando, desta forma, a avaliação do desempenho destes sistemas.

É importante salientar que, assim como evidenciado por Singh (2015), é improvável que as técnicas de simulação a eventos discretos e de otimização, não associadas, sejam aplicadas de maneira apropriada e eficiente quando tratamos de sistemas reais complexos. A partir de Lee et al. (2008), pode-se afirmar que a integração entre estes instrumentos de análise é de crucial importância para validade e relevância das conclusões.

Levando-se em consideração os argumentos de Raska e Ulrych (2014), pode-se observar que existe um crescimento de instrumentos de otimização que estão sendo associadas a simulação a eventos discretos. Conforme, Fu (2002), tanto o crescimento de instrumentos de otimização e SED associados, quanto o número de aplicações destas associações, só se tornaram possíveis devido ao grande desenvolvimento computacional dos últimos anos.

Já Yang et al. (2014) afirmam que existem algumas tendências de estudos relacionados ao desenvolvimento no âmbito computacional da otimização via simulação. Segundo o mesmo autor, estas tendências estão relacionadas ao desenvolvimento de algoritmos de otimização, abordagem de otimização multiobjetivo e redução do custo computacional oriundo do tamanho do espaço amostral de busca para o valor ótimo.

Ainda em congruência com Yang et al. (2014), a principal atividade de pesquisa relacionada a otimização via simulação diz respeito ao desafio de desenvolvimento de algoritmos para se reduzir o custo computacional no processo de otimização. Tal afirmação baseia-se na tendência de aumento de dificuldade dos problemas simulados, visto que, estes estão cada vez se tornando maiores e exigindo uma precisão também maior.

Levando-se em consideração as tendências de pesquisas apontadas, Miranda et al. (2013) e Miranda et al. (2014) propõem um procedimento padrão para redução do espaço de busca para problemas de otimização via simulação.

Segundo o procedimento proposto pelos mesmos autores, inicialmente delimita-se um conjunto de cenários através de Arranjos Ortogonais de Taguchi (TAGUCHI, 1987) e a partir do modelo de Análise Envoltória de Dados (Data Envelopment Analysis - DEA) proposto por Banker et al. (1984) seleciona-se os cenários mais eficientes. Na proporção que apenas os cenários mais eficientes delimitarão o espaço de busca, este último é reduzido por esta sistemática.

Tal procedimento possui como objetivo a diminuição do custo computacional e do tempo requerido para possível convergência ao valor ótimo de um problema de otimização via simulação.

A partir da contextualização do problema de pesquisa, o presente trabalho possui como objetivo geral propor uma nova abordagem para o procedimento de redução do espaço de busca de uma problema de otimização via simulação, descrito acima. Para tanto, será aplicado um modelo de Análise Envoltória de Dados em estrutura de rede desenvolvido por Kao (2014). Espera-se que

a delimitação de uma nova fronteira de eficiência possa reduzir o espaço de busca da otimização e, além disso, fornecer informações úteis para os administradores operacionais. Como objetivo específico, ressalta-se que este estudo aplicará a nova abordagem proposta ao estudo de caso desenvolvido por Miranda et al. (2014).

Com a finalidade de cumprir com os objetivos propostos, este artigo está organizado em 5 seções. A seção 2 pretende apresentar a fundamentação teórica pautada na otimização via simulação, a seção 3 é destinada a apresentar o procedimento de otimização sistematizado pelos autores apontados acima para, posteriormente, ressaltar a modificação proposta. A seção 4 faz a aplicação do novo procedimento e discute os resultados alcançados para, por fim, a seção 5 apresentar as considerações finais.


2. Otimização via Simulação

Para Dengiz e Belgin (2014), o aumento de complexidade das relações econômicas atuais forçam as empresas a buscarem trabalhar de maneira cada vez mais eficiente, isto ocorre devido ao aumento da concorrência entre as instituições. É neste ambiente que a simulação cresce em importância, visto que, representa um instrumento poderoso de avaliação de desempenho de uma instituição.

Entretanto, Yang et al. (2014) assume que o grande desafio atual é conciliar um modelo de simulação devidamente validado e um instrumento de otimização que combine um bom algoritmo de busca com baixo custo computacional.

Segundo a interpretação de Carson e Maria (1997), um modelo de simulação pode ser descrito como no organograma representado pela Figura 1 abaixo:

Figura 1 – Modelo Geral de Simulação



Fonte: Adaptado de Carson e Maria (1997)

Segundo a Figura 1, existem n variáveis de entrada, x_1, x_2, \dots, x_n , e m variáveis de saída y_1, y_2, \dots, y_m . Associando a estrutura do modelo de simulação com Singh (2015), podemos afirmar que a otimização combinada com a simulação visa responder a pergunta sobre o que é melhor ao se levar em consideração um conjunto de restrições e condições particulares. De acordo com Harrel et al. (2002), pode-se entender a otimização a partir do questionamento de como as variáveis de entrada x_1, x_2, \dots, x_n , podem maximizar (e/ou minimizar) variáveis de saída y_1, y_2, \dots, y_m .

Para Fu (2002) e Chwif e Medina (2010), a integração entre ferramentas de otimização e simulação constituem não só um conjunto de procedimentos sistemáticos de otimização com o intuito de se avaliar possíveis soluções para o problema em questão, mas sim um instrumento de geração de soluções para o problema real.

Os autores Figueira e Almada-Lobo (2014) afirmam que um dos méritos da abordagem híbrida de OVS refere-se a possibilidade de análise sob condições de risco. Segundo estes autores, a precisão de detalhes dos modelos de simulação em condições de risco são consideravelmente maiores em comparado com os modelos analíticos. Isto ocorre, simultaneamente à menor dificuldade de modelagem do sistema real.

Assim como expresso por Wang e Shi (2013), em geral, os problemas de otimização via simulação podem ser descritos como na Equação (1), a seguir:

$$\min_{\theta \in \emptyset} f(\theta) \tag{1}$$

Segundo a Equação 1, θ pode ser uma única variável ou um vetor p -dimensional de todas as variáveis de decisão, e \emptyset é a região viável. No caso de problemas de otimização via simulação, não se tem muito conhecimento sobre a estrutura de $f(\theta)$ e sua expressão analítica pode não ser

obtida (ou até mesmo pode não existir). Desta maneira, Wang e Shi (2013) apontam que a função objetivo de um modelo de simulação deve ser baseada nas saídas das simulações, como na Equação (2), abaixo:

$$f(\theta) = E[L(\theta, \omega)] \quad (2)$$

Segundo a Equação 2, tem-se representados a aleatoriedade do sistema simulado, ω , e $L(\theta, \omega)$ corresponde ao valor do desempenho obtidos a partir das saídas do modelo simulado. Em geral, o objetivo da otimização é encontrar o θ ideal para minimizar (ou maximizar) $f(\theta)$. Cumpre destacar que esta é uma estimativa não enviesada da função objetivo.

3. Nova Abordagem de Procedimento para Redução do Espaço de Busca em Problemas de Otimização via Simulação

3.1 Procedimento Baseado na Supereficiência

Levando-se em consideração as contribuições de Miranda et al. (2013), o procedimento adequado para se reduzir um espaço de busca em um problemas de otimização via simulação combina um modelo de simulação a eventos discretos, arranjos ortogonais de Taguchi (TAGUCHI, 1987) e a análise de supereficiência desenvolvida por Banker et al. (1984).

Segundo o modelo sistematizado pelos mesmos autores, o espaço de busca inicial é gerado a partir de uma arranjo ortogonal de Taguchi. O referido arranjo determina os cenários iniciais a serem simulados. Em posse das saídas destes cenários, é realizada uma análise de eficiência dos mesmos a partir do modelo de Análise Envoltória de Dados (*Data Envelopment Analysis – DEA*) BCC (modelo de supereficiência). Com base nos resultados alcançados pelo modelo DEA BCC, são selecionados os dois cenários considerados mais eficientes. Estes cenários delimitarão os novos limites das variáveis do problema de otimização.

A Tabela 1, ilustrada abaixo, apresenta a descrição dos passos necessários para se reduzir o espaço de busca de um problema de otimização baseado em simulação.

Tabela 1 – Procedimento Para Redução do Espaço de Busca

1º Passo:	Determinar as Variáveis de Decisão do Problema de OVS e Determinar os Limites de Variação para cada Variável.
2º Passo	Determinar as Variáveis de Saída que serão Otimizadas: Minimização ou Maximização de uma ou mais Variáveis de Saída.
3º Passo	Seleção do Arranjo Ortogonal de Taguchi em Função do Número de Variáveis de Decisão, de seus limites de Variação e do Número Mínimo de DMUs.
4º Passo	Geração da Matriz Experimental que Representa a Região de Solução.
5º Passo	Execução dos Experimentos no Simulador e Armazenamento dos Dados Simulados Para Análise.
6º Passo	Determinação da Supereficiência de cada cenário (DMU) por meio da Aplicação do Modelo DEA BCC
7º Passo	Ranquear os Cenários mais Eficientes a partir do Conceito de Supereficiência
8º Passo	Baseando-se nos dois Cenários mais Eficientes, Definir a Nova Faixa de Variação para as Variáveis de Decisão
9º Passo	Otimizar o Modelo de Simulação Utilizando a Nova Faixa de Variação Para Cada Variável de Decisão
10º Passo	Analisar os Resultados e, Com Base Nestes, Tomar a Decisão

Fonte: Adaptado de Miranda et al. (2014)

O procedimento sistematizado pela Tabela 1, foi testado em Miranda et al. (2013) e Miranda et al. (2014) ao ser aplicado em modelos de simulação específicos. Os resultados encontrados validaram o método proposto, reduzindo o espaço de busca de uma solução de igual qualidade quando comparada a otimização do modelo de simulação sem a redução do espaço de busca.

3.2 Procedimento Baseado em Estruturas de Rede

Assim como demonstrado, o procedimento de redução do espaço de busca explicitado no tópico acima, apropria-se do modelo de análise envoltória de dados supereficiente, assumindo retornos variáveis de escala (Modelo BCC).

Todavia, o autor Banker et al. (1996) afirma ser necessário realizar uma análise dos retornos a escala das DMU's que compõem a amostra e, principalmente, de elasticidade das mesmas. Tal passo tem por objetivo adequar o modelo DEA a realidade do sistema.

Com a finalidade de se explorar a influência das elasticidades dos fatores de produção na análise de eficiência (e para o contexto da presente pesquisa, na determinação do espaço de busca), foi realizado estudos de elasticidade para a mesma empresa foco dos trabalhos de Miranda et al. (2014). A referida análise possui como norte os resultados alcançados por Banker et al. (2011), segundo o qual, afirma-se ser relevante estimar uma função Cobb-Douglas e a partir dos coeficientes destas estimar as elasticidades de cada fator de produção em relação a produção total.

As informações de elasticidades são importantes quando contrapostas ao modelo DEA utilizado como proposta adjacente do presente artigo, vale ressaltar, será utilizado o DEA em estruturas de redes desenvolvido por Kao (2014). A Equação (3), a seguir, apresenta a formulação geral deste modelo.

$$\begin{aligned}
 \text{Máx } \theta_k &= \sum_{r=1}^s u_r Y_{rk} \\
 \text{S. a.} \\
 \left(\sum_{i=1}^m v_i X_{ik} \right) &= 1 \\
 \left(\sum_{r=1}^s u_r Y_{rj} \right) - \left(\sum_{i=1}^m v_i X_{ij} \right) &\leq 0, j = 1, \dots, n \\
 \left(\sum_{r \in O^{(1)}} u_r Y_{rj}^{(1)} + \sum_{f \in M^{(1)}} w_f Z_{fj}^{(1)} \right) - \left(\sum_{i \in I^{(1)}} v_i X_{ij}^{(1)} \right) &\leq 0, j = 1, \dots, n \\
 \left(\sum_{r \in O^{(p)}} u_r Y_{rj}^{(p)} + \sum_{f \in M^{(p)}} w_f Z_{fj}^{(p)} \right) - \left(\sum_{i \in I^{(p)}} v_i X_{ij}^{(p)} + \sum_{f \in M^{(p-1)}} w_f Z_{fj}^{(p-1)} \right) &\leq 0, \\
 p = 2, \dots, (q-1); j = 1, \dots, n \\
 \left(\sum_{r \in O^{(q)}} u_r Y_{rj}^{(q)} \right) - \left(\sum_{i \in I^{(q)}} v_i X_{ij}^{(q)} + \sum_{f \in M^{(q-1)}} w_f Z_{fj}^{(q-1)} \right) &\leq 0, j = 1, \dots, n \\
 u_r, v_i, w_f &\geq 0, r = 1, \dots, s; i = 1, \dots, m; f = 1, \dots, g
 \end{aligned} \tag{3}$$

O presente modelo permite inferir não só a estimativa do sistema geral, como também a estimativa de cada sub-processo existente no sistema total. Cumpre destacar que, Ebrahimnejad et al. (2014) demonstra que os modelos tradicionais DEA são enviesados, e a estrutura de rede minimiza o problema de viés ao levar em consideração as assertivas acima.

Sendo assim, este estudo propõe duas modificações nos procedimentos relacionados ao 6º e 7º passos demonstrados na Figura 2, tais modificações podem assim ser elucidadas.

Em primeiro lugar, no 6º passo, este estudo propõe a estimação da função de produção Cobb-Douglas para análise de elasticidade. Vale repetir que, em linhas gerais, a análise de elasticidade permite inferir qual fator de produção possui o maior impacto na produção final, tal possibilidade será de crucial importância nos passos seguintes. É também nesta etapa do procedimento para redução do espaço de busca que se estimará os níveis de eficiência totais e, em especial, os níveis de eficiência em cada fator de produção (análise permitida pela utilização do modelo de Análise Envoltória de Dados em estruturas de rede).

No 7º passo, com o objetivo de se ranquear os cenários mais eficientes, a presente pesquisa sugere a associação entre a análise de elasticidade (fornecida pela função de produção Cobb-Douglas) e a análise das eficiências de cada sub-processo, ou seja, de cada fator de produção (fornecida pelo modelo DEA em estrutura de rede). A referida associação consiste em, inicialmente, mensurar qual fator de produção possui maior impacto para a produção final e, em posse dessa informação, selecionar os cenários mais eficientes justamente neste fator de produção.

4. Aplicação da Nova Abordagem de Procedimento de Otimização e Discussão de Resultados

O objeto de estudo da presente pesquisa é apresentado em sua versão original por Miranda et al. (2014). Trata-se de uma empresa do setor automobilístico localizada no Sul de Minas Gerais, esta empresa compõe uma das unidades de produção de uma multinacional fabricante de autopeças. O sistema simulado é formado por duas unidades produtivas, com o mesmo conjunto de máquinas e operadores que desempenham as mesmas funções. Todas as etapas de verificação e validação foram devidamente realizadas de maneira que o modelo representa de maneira adequada o sistema que se busca otimizar.

Conforme descrito por Miranda et al. (2014), o objeto de estudo em análise possui três variáveis de decisão, são elas:

- 1 Número de Operadores de Retífica (x_1 e x_2);
- 2 Número de Operadores de Lapidadora (x_3 e x_4);
- 3 Número de Retíficas na Célula (x_5 e x_6).

Com o intuito de se manter as mesmas condições que o estudo original, todas as variáveis foram mantidas com a mesma situação experimental, ou seja, foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 5, conforme apresentado na Tabela 2.

Tabela 2 – Variáveis de Decisão, Tipos e Limites para o Objeto de Estudo

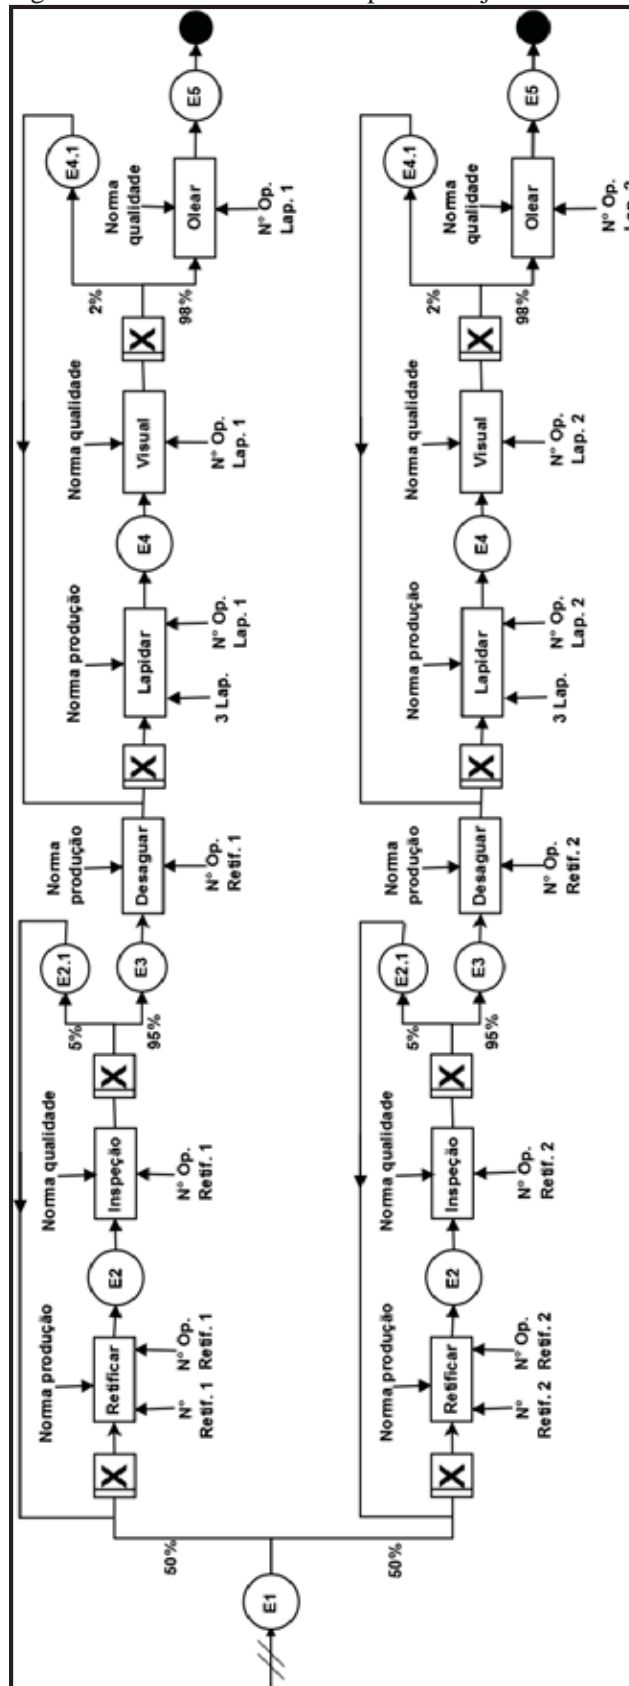
	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Nº Operadores Retífica 1	Inteira	1	5
x_2	Nº Operadores Lapidadora 1	Inteira	1	5
x_3	Nº Operadores Retífica 2	Inteira	1	5
x_4	Nº Operadores Lapidadora 2	Inteira	1	5
x_5	Nº de Retíficas 1	Inteira	1	5
x_6	Nº de Retíficas 2	Inteira	1	5

Como afirmado, o objetivo da otimização é encontrar a melhor combinação das variáveis de decisão de forma a maximizar a produção total (y_1). Neste sentido, o problema em questão possui como espaço de busca para a melhor solução 15.625,00 cenários.

Mais uma vez, com o intuito de manter as mesmas condições experimentais realizadas por Miranda et al. (2014), gerou-se um arranjo de Taguchi com 25 cenários (L25). Para cada cenário foram simuladas 5 réplicas e os dados foram armazenado com a finalidade de se utiliza-los para estimar a função Cobb-Douglas e, posteriormente o DEA em estrutura de rede.

A Figura 2, que segue, representa o modelo conceitual por meio da técnica IDEF-SIM desenvolvida por Leal et al. (2008)

Figura 2 – Modelo Conceitual para o Objeto de Estudo



Fonte: Miranda et al. (2014)

Mais uma vez, com o intuito de manter as mesmas condições experimentais realizadas por Miranda et al. (2014), gerou-se um arranjo de Taguchi com 25 cenários (L25). Para cada cenário foram simuladas 5 réplicas e os dados foram armazenados com a finalidade de se utilizá-los para estimar a função Cobb-Douglas e, posteriormente o DEA em estrutura de rede.

Os resultados encontrados para as variáveis médias de saída dos respectivos cenários são demonstrados na Tabela 3, abaixo, vale destacar que os valores de y estão em unidades produzidas. Em posse desses dados foram adotados os 2 passos propostos, cumpre repetir, estimação da função Cobb-Douglas (com o intuito de se mensurar as elasticidades e, desta forma, os fatores de produção que mais contribuem para a produção total) e cálculo das eficiências dos sistemas de cada DMU e de seus respectivos sub-processos, a partir do DEA em rede.

Tabela 3 – Resultados dos Cenários Simulados

DMU	X1	X2	X3	X4	X5	X6	Y1
1	1	1	1	1	1	1	195000,00
2	1	2	2	2	2	2	260000,00
3	1	3	3	3	3	3	299000,00
4	1	4	4	4	4	4	312000,00
5	1	5	5	5	5	5	312000,00
6	2	1	2	3	4	5	234000,00
7	2	2	3	4	5	1	338000,00
8	2	3	4	5	1	2	353600,00
9	2	4	5	1	2	3	247000,00
10	2	5	1	2	3	4	221000,00
11	3	1	3	5	2	4	273000,00
12	3	2	4	1	3	5	265200,00
13	3	3	5	2	4	1	345800,00
14	3	4	1	3	5	2	265200,00
15	3	5	2	4	1	3	332800,00
16	4	1	4	2	5	3	286000,00
17	4	2	5	3	1	4	348400,00
18	4	3	1	4	2	5	257400,00
19	4	4	2	5	3	1	304200,00
20	4	5	3	1	4	2	262600,00
21	5	1	5	4	3	2	286000,00
22	5	2	1	5	4	3	249600,00
23	5	3	2	1	5	4	208000,00
24	5	4	3	2	1	5	366600,00
25	5	5	4	3	2	1	384800,00

A partir destes resultados estimou-se uma função Cobb-Douglas com o intuito de se avaliar as elasticidades dos fatores de produção. Considerou-se os operadores da retífica das duas linhas como um fator de produção, os operadores da lapidadora das duas linhas como um fator de produção e o número de retíficas das duas linhas como um fator de produção. Tal aglutinação refere-se a concepção original da função em que se trabalha apenas com estimativas de capital e trabalho.

Os resultados encontrados para a estimação realizada estão dispostos na Equação (4), abaixo.

$$\text{Produção (y)} = 11,9 \times \text{Operadores retífica (x1)}^{0,005} \times \text{Operadores lapidadora (x2)}^{0,320} \times \text{Número de retíficas (x3)}^{0,0359} \quad (4)$$

R^2 ajustado = 70,02%

Posteriormente, calculou-se as eficiências globais e as eficiências de cada sub-processo. A Tabela 4 apresenta os desempenhos encontrados a partir do modelo DEA em rede, a partir de sua estatística descritiva.

Tabela 4 – Estatística Descritiva do Desempenho Global e por sub-processo das DMUs

	Eficiência Geral	Eficiência Estágio Retífica	Eficiência Estágio Lapidadora
Média	0,69	0,84	0,85
Desvio Padrão	0,18	0,19	0,19

Conforme informação da estimação, os operadores da lapidadora apresentaram maior elasticidade em relação a produção, neste sentido, selecionou-se as DMU's com maior eficiência neste sub-processo. Destaca-se que as DMU's 1 e 25 foram as únicas a alcançar a eficiência máxima em todos os níveis (e também as únicas a alcançar eficiência máxima no sub-processo da lapidadora).

Ao dar continuidade, então, com o procedimento proposto por Miranda et al. (2014), assume-se que uma vez definidas as duas DMUs mais eficientes, pode-se definir a nova faixa de variação para cada variável de decisão. A variável x_6 teve seu valor fixado em um, isto pois este é o valor em ambas as DMU's eficientes. A Tabela 5 demonstra os novos intervalos para cada variável.

Tabela 5 - Variáveis de Decisão, Tipos e Novos Limites para o Objeto de Estudo

	Variável	Tipo	Limite Inferior	Limite Superior
x1	Nº Operadores Retífica 1	Inteira	1	5
x2	Nº Operadores Lapidadora 1	Inteira	1	5
x3	Nº Operadores Retífica 2	Inteira	1	4
x4	Nº Operadores Lapidadora 2	Inteira	1	3
x5	Nº de Retíficas 1	Inteira	1	2
x6	Nº de Retíficas 2	Inteira	1	1

A partir da Tabela 5 apresentada, pode-se inferir que o espaço de busca diminuiu consideravelmente, dada a redução do intervalo de variação das variáveis. Tal queda representou cerca de 96% do espaço de busca (com a redução do intervalo de variação para cada variável, o número de cenários possíveis para otimização caiu de 15.625 para 600). Para testar a eficiência desta proposta, um software comercial de otimização, *SimRunner®*, foi empregado.

Com o intuito de se minimizar influências exógenas, manteve-se as mesmas condições padrões do software, conforme explicado por Miranda et al. (2014). A configuração alterada diz respeito a seleção da função objetivo, para o caso, a maximização da produção total (y) a partir da variação original das variáveis e, posteriormente, a partir da nova faixa de variação, definida pela nova abordagem proposta. Cumpre destacar, que as demais condições do otimizador foram mantidas constantes para as rodadas de otimização.

A Tabela 6, apresenta-se o resultado da otimização para o range de variação original (criado pelo procedimento de Miranda et al., (2014) e para o novo range de variação (criado pelo procedimento deste estudo).

Tabela 6 – Resultados da Otimização

	Variável		Novo Range	Range Original
x1	Nº Operadores Retífica 1		4	4
x2	Nº Operadores Lapidadora 1		4	4
x3	Nº Operadores Retífica 2		4	4
x4	Nº Operadores Lapidadora 2		4	2
x5	Nº de Retíficas 1		2	3
x6	Nº de Retíficas 2		1	1
y	Produção Total		403.000,00	403.000,00

Com base no descrito pela Tabela 6, pode-se observar que ambos os ranges alcançaram os mesmo resultados. Acrescenta-se que para o Range original o otimizador realizou 114 experimentações, enquanto que, para o caso do Novo Range o número de experimentações reduziu-se para 74 experimentações, este fato demonstra a diminuição do custo computacional para se convergir ao valor ótimo (o que representa uma redução de cerca de 35% no número de experimentações necessárias para se alcançar o ótimo).

Além das definições de alocação de recursos, apresentadas acima, o modelo DEA em estrutura de rede permite algumas análises gerenciais incrementais, devido a possibilidade de se identificar a ineficiência em cada sub-processo. Sobre este aspecto é possível observar que a empresa em análise possui uma tendência em ser mais eficiente nas atividades relacionadas a lapidadora (eficiência média de 0,85 em contraposição a uma eficiência média de 0,83 nas atividades relacionadas a retífica), este fato ganha especial importância pois, como já afirmado, estas atividades possuem maior elasticidade em relação a produção.

Com base na tendência observada acima, elaborou-se o teste de hipótese não paramétrico denominado Kruskal-Wallis. O p-valor de referência encontrado para este teste foi de 0,158, ou seja, não há evidências estatísticas suficientes para afirmar que a empresa possui maior eficiência nas atividades relacionada a lapidadora, em detrimento de sua tendência.

5. Considerações Finais

O presente trabalho buscou analisar uma proposta alternativa para o procedimento sugerido por Miranda (2014) a respeito da diminuição de um espaço de busca de problemas híbridos de otimização e simulação a eventos discretos. A referida proposta alternativa pautou-se na substituição do modelo de supereficiência DEA BCC utilizado por Miranda (2014) e partir de um modelo DEA em estrutura de rede associado a análise de elasticidade da função de produção da empresa analisada.

Demonstrou-se que a nova sistemática sugerida pelo presente artigo é eficiente para se reduzir o espaço de busca e, desta forma, amenizar o custo computacional característico de problemas de otimização via simulação. Cumpre destacar que, sobre este aspecto, a redução do espaço de busca para o objeto de estudo deste artigo foi de cerca de 96% (de 15625 para 600 cenários possíveis de se analisar) e, além disso, também se reduziu a quantidade de experimentos necessários para se convergir ao ótimo em cerca de 35% (de 114 para 74).

Quanto ao valor ótimo encontrado, ao se aplicar a modificação do procedimento de redução do espaço de busca, chegamos ao mesmo valor total produzido quando comparado ao procedimento original. Porém, o valor das variáveis foram diferentes. Dado que a elasticidade das atividades relacionadas a lapidadora é maior, valor ótimo encontrado a partir do novo range, baseou-se em um maior número de funcionários na lapidadora (fato que corrobora à consistência da técnica proposta no presente artigo).

Por fim, identificou-se o potencial de associação entre decisões de gestão operacional e os resultados encontrados com o DEA em estrutura de rede. Isto pois, o referido modelo de programação linear fornece o nível de eficiência de cada sub-processo. Permitindo uma análise mais aprofundada do processo de fabricação analisado.

Com relação ao ponto anterior, observou-se que há uma tendência de maior eficiência nas atividades relacionadas a lapidadora, tal cenário se mostra positivo, visto que, como dito, este fator de produção impacta mais intensamente na produção total da instituição analisada.

Sugere-se como proposta de melhoria futura para o presente estudo, aumentar o número de replicações com a finalidade de dar maior confiabilidade aos resultados encontrados (como a possibilidade de uma análise intervalar dos resultados). Outro ponto a se desenvolver, diz respeito a programação estocástica da estrutura de rede, atribuindo nível de risco ao desempenho de cada DMU.

Agradecimentos

Agradecimentos à FAPEMIG, CNPq e CAPES pelo apoio financeiro e incentivo à pesquisa.

Referências Bibliográficas

- BANKER, R. D.; CHANG, H.; W. W. COOPER. Equivalence and Implementation of Alternative Methods for Determining Returns to Scale in Data Envelopment Analysis. **European Journal of Operational Research**, v. 89, n. 3, p. 473–481, 1996.
- BANKER, R. D.; CHARNES, A.; COOPER, W. W. Some Models for Estimating Technical and Scale Inefficiencies in Data Envelopment Analysis. **Management Science**, v. 30, n. 9, p. 1078–1092, 1984.
- BANKER, R. D.; COOPER, W. W.; SEIFORD, L. M.; ZHU, J. **Handbook on Data Envelopment Analysis**. 2^o ed. Boston, MA: Springer US, 2011.
- CARSON, Y.; MARIA, A. Simulation optimization: methods and applications. Proceedings of the 29th conference on Winter simulation. **Anais...** p.118–126, 1997.
- CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações**. 2^a ed. São Paulo: Editora dos Autores, 2010.
- DENGIZ, B.; BELGIN, O. Simulation optimization of a multi-stage multi-product paint shop line with Response Surface Methodology. **Simulation: Transactions of the Society for Modeling and Simulation International**, v. 90, n. 3, p. 265–274, 2014.
- EBRAHIMNEJAD, A.; TAVANA, M.; LOTFI, F. H.; SHAHVERDI, R.; YOUSEFPOUR, M. A Three-stage Data Envelopment Analysis Model with Application to Banking Industry. **Measurement**, v. 49, p. 308–319, 2014.
- FIGUEIRA, G.; ALMADA-LOBO, B. Hybrid simulation–optimization methods: A taxonomy and discussion. **Simulation Modelling Practice and Theory**, v. 46, p. 118–134, 2014.
- FU, M. C. Optimization for simulation: Theory vs. practice. **Journal on Computing**, v. 14, n. 3, p. 192–215, 2002.
- HARREL, C. R.; MOTT, J. R. A.; BATEMAN, R. E.; BOWDEN, R. G.; GOGG, T. J. **Simulação: Otimizando os Sistemas**. 2^a ed. São Paulo: IMAM, 2002.
- HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to Operations Research**. 9^a ed. New York: McGraw-Hill, 2010.
- KAO, C. Efficiency decomposition for general multi-stage systems in data envelopment analysis. **European Journal of Operational Research**, v. 232, n. 1, p. 117–124, 2014.
- LEAL, F.; ALMEIDA, D. A. DE; MONTEVECHI, J. A. B. Uma Proposta De Técnica De Modelagem Conceitual Para a Simulação Através De Elementos Do Idef. XL Simpósio Brasileiro de Pesquisa Operacional. **Anais...**, 2008. João Pessoa, PB.
- LEE, L. H.; CHEW, E. P.; TENG, S.; CHEN, Y. Multi-objective simulation-based evolutionary algorithm for an aircraft spare parts allocation problem. **European Journal of Operational Research**, v. 189, n. 2, p. 476–491, 2008.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F. Redução do Espaço de Busca em Problemas de Otimização via Simulação. XLV Simpósio Brasileiro de Pesquisa Operacional. **Anais...** p.1332–1343, 2013. Natal, RN.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F. Redução do Espaço de Busca em Problemas de Otimização via Simulação Multiobjetivo. XLVI Simpósio Brasileiro de Pesquisa Operacional. **Anais...** p.1332–1343, 2014. Salvador, BA.
- RASKA, P.; ULRZYCH, Z. Testing Optimization Methods on Discrete Event Simulation Models and Testing Functions. **Procedia Engineering**, v. 69, p. 768–777, 2014.
- SINGH, A. Managing the environmental problem of seawater intrusion in coastal aquifers through simulation–optimization modeling. **Ecological Indicators**, v. 48, p. 498–504, 2015.
- TAGUCHI, G. **System of Experimental Design: Engineering Methods to Optimize Quality and Minimize Costs**. 1^a ed. New York: UNIPUB/Kraus International Publications, 1987.
- WANG, L.-F.; SHI, L.-Y. Simulation Optimization: A Review on Theory and Applications. **Acta Automatica Sinica**, v. 39, n. 11, p. 1957–1968, 2013.
- YANG, X.-S.; KOZIEL, S.; LEIFSSON, L. Computational Optimization, Modelling and Simulation: Past, Present and Future. **Procedia Computer Science**, v. 29, n. Coms, p. 754–758, 2014.