

USO DA TÉCNICA DE SUPERFÍCIE DE RESPOSTA NA OTIMIZAÇÃO DA SIMULAÇÃO COMPUTACIONAL DO PROCESSO

Renato Pontes Rodrigues

Universidade Federal de Itajubá
Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá – MG
renatoehd@yahoo.com.br

Alexandre Ferreira de Pinho

Universidade Federal de Itajubá
Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá – MG
pinho@unifei.edu.br

José Antônio de Queiroz

Universidade Federal de Itajubá
Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá – MG
ja.queiroz@unifei.edu.br

José Henrique de Freitas Gomes

Universidade Federal de Itajubá
Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá – MG
ze_henriquefg@yahoo.com.br

RESUMO

Modelos de simulação são frequentemente aplicados à otimização de problemas complexos, que não podem ser resolvidos por métodos matemáticos. O presente trabalho buscará analisar a viabilidade do uso da Superfície de Resposta (SR) como uma forma organizada e eficiente de buscar a otimização na simulação computacional do processo. Será uma pesquisa quantitativa usando ferramentas estatísticas e usará o método de pesquisa de experimentação, seguindo um modelo empírico normativo. Os resultados a serem encontrados serão os valores de cada variável de entrada do Delineamento de Experimentos (DOE) obtido no ponto ótimo. Depois disso será feita uma comparação com a otimização obtida por um software de mercado, onde tiraremos conclusões a respeito da eficácia do modelo de otimização adotado.

PALAVRAS-CHAVE: Simulação; Otimização; Delineamento de Experimentos (DOE); Superfície de Resposta (SR).

ABSTRACT

Simulation models are frequently applied to optimize complex problems, which can't be solved with mathematics methods. This work will analyze the feasibility of the Response Surface as an organized and efficient way to optimize process computational simulations. It will be a quantitative research using statistical tools and it will use the experimentation research method, using a normative empiric model. The results to be found will be the values of each input variable in the Design of Experiments in the optimal point. After that, a comparison between the optimization by the Response Surface and market software will be made, where conclusions despite the efficacy of the process adopted will be made.

KEYWORDS: Simulation; Optimization; Design of Experiments; Response Surface.

1. Introdução

Este trabalho busca estudar a fase de otimização das variáveis, através de técnicas estatísticas, nesse caso a técnica de DOE. Dentro dessa, estaremos utilizando o Fatorial Completo e a Superfície de Resposta, além da otimização para obtermos os resultados.

Para realização dos experimentos utilizamos um modelo de simulação já testado e validado anteriormente. Portanto, as fases anteriores à otimização das variáveis não estarão em foco neste trabalho.

O objetivo principal do trabalho é apresentar uma forma alternativa de otimização, não dizendo, necessariamente, que essa forma seja melhor ou pior que a apresentada pelos softwares de mercado, mas sim analisando suas vantagens e desvantagens em relação à otimização comercial. Nesse caso, o software utilizado para comparação foi o SimRunner.

Segmentando este objetivo, temos como objetivos específicos:

- Avaliar os principais fatores que afetam o resultado da simulação (através dos valores de P-value e do gráfico de Pareto).
- Detectar interações entre esses fatores.
- Avaliar se o ponto ótimo está dentro da região de solução proposta (através da presença ou não de curvatura).
- Calcular os coeficientes de cada fator (através do experimento de superfície de resposta).
- Calcular o ponto ótimo do experimento (através da planilha de otimização).
- Realizar o experimento de confirmação.
- Analisar as vantagens e desvantagens em relação ao software de otimização (SimRunner).

O presente trabalho seguirá a linha de pesquisa quantitativa, pois usará métodos estatísticos para a resolução do problema. Ou seja, fará a análise de dados de maneira quantitativa com respostas exatas aos diferentes cenários. Gerando, na fase final, um ponto ótimo das variáveis de entrada para maximizar a variável de saída, que nesse caso, será o lucro.

O método de pesquisa utilizado é a experimentação, onde foram feitos vários experimentos, obedecendo ao arranjo fatorial completo do DOE, e posteriormente, foram realizados os experimentos axiais para obtenção da superfície de resposta.

A pesquisa seguirá o modelo Empírico Normativo. Empírico porque, segundo Bertrand e Fransoo (2002), a simulação a ser usada traz uma realidade complexa, que não poderia ser resolvida por modelos matemáticos, ao computador, para que possam ser feitas simulações modificando-se as diversas variáveis do problema. E será normativo porque o objetivo do trabalho é estudar a maneira de otimizar um problema de simulação, propondo um novo método em relação ao usado atualmente.

O objeto de estudo é uma célula de produção do setor bélico, onde foi feita uma simulação de processo de fabricação já testado e validado anteriormente, usando-se o software ProModel.

Foi usado o software Minitab para os cálculos estatísticos do DOE, medindo os efeitos das variáveis e suas interações.

A finalidade da otimização é maximizar o lucro, que é a variável de saída, sendo que, as variáveis de entrada são os números de operadores necessários em cada um dos quatro setores da célula de produção analisada.

2. Fundamentação teórica

Para Saraiva Júnior, Tabosa e Costa (2011), a simulação é uma representação de um processo ou sistema real, num dado período de tempo, que envolve a observação desta para fazer inferências relativas às características do processo. Esta se inicia com o desenvolvimento de um modelo que represente o sistema a ser investigado, com o máximo de fidelidade possível.

Usaremos o modelo adotado para fazer os experimentos. Logo, seguiremos o método de experimentação, que de acordo com Nakano (2008), é o estudo da relação de causa e efeito entre as variáveis de entrada e saída de um sistema sob condições controladas pelo pesquisador. No



caso desse trabalho, como usaremos um sistema simulado para realizar os experimentos, teremos um meta-modelo.

Sturrock (2009) apresenta todos os passos que são importantes para se conduzir metodicamente um projeto de simulação. Dentro desses passos se apresenta o último que é a experimentação, análise e apresentação dos resultados obtidos. Nela se testam os diferentes cenários e se analisam cada um deles, fazendo proposições sobre os melhores valores para as variáveis de entrada a fim de atingir o melhor resultado. Este método, nada mais é, do que a tentativa e erro. É nesta última fase, que se baseia esse trabalho, buscando uma alternativa para a otimização da simulação que difira, tanto da tentativa e erro, bem como da otimização através de softwares.

É possível concluir através do artigo de Montevechi, Miranda e Friend (2011), que uma das maiores desvantagens da simulação é que ela não serve como uma técnica de otimização por si própria. Atualmente, busca-se a otimização mudando-se as variáveis e tomando como valores ótimos os valores das variáveis do cenário que gerou o melhor resultado. E, apesar de existir pacotes com rotinas lógicas de otimização, o usuário nunca sabe se esses valores foram realmente alcançados.

Para Fernandes et al. (2013), a otimização através da simulação tem se tornado cada vez mais frequente e a complexidade dos sistemas atuais impede que soluções analíticas levem a soluções completamente satisfatórias. E afirma que, para usar a simulação na avaliação e na melhoria do desempenho de um processo, é necessário construir cenários, executá-los e analisar os resultados. Porém, isso pode não garantir que as melhores configurações sejam experimentadas. Daí a necessidade de se estudar o método de otimização da simulação, justificativa deste artigo que estudará a aplicabilidade da técnica de Superfície de Resposta, que é umas das subdivisões do DOE, na otimização de simulações.

Em outra publicação, Leal et al. (2007) usa o DOE como uma forma de melhorar a performance da simulação, evitando a tentativa e erro como técnica usada para buscar uma otimização do modelo simulado. O DOE apresenta uma forma ou arranjo organizado de testes, onde são propostas mudanças nas variáveis de entrada de um processo e, depois, observadas as mudanças ocorridas nas variáveis de saída. Essa técnica permite fazer uma análise de sensibilidade das variáveis de entrada a fim de diminuir o número de variáveis que serão inseridas do software de otimização, diminuindo o tempo usado no programa. Além de verificar se há ou não interações entre elas.

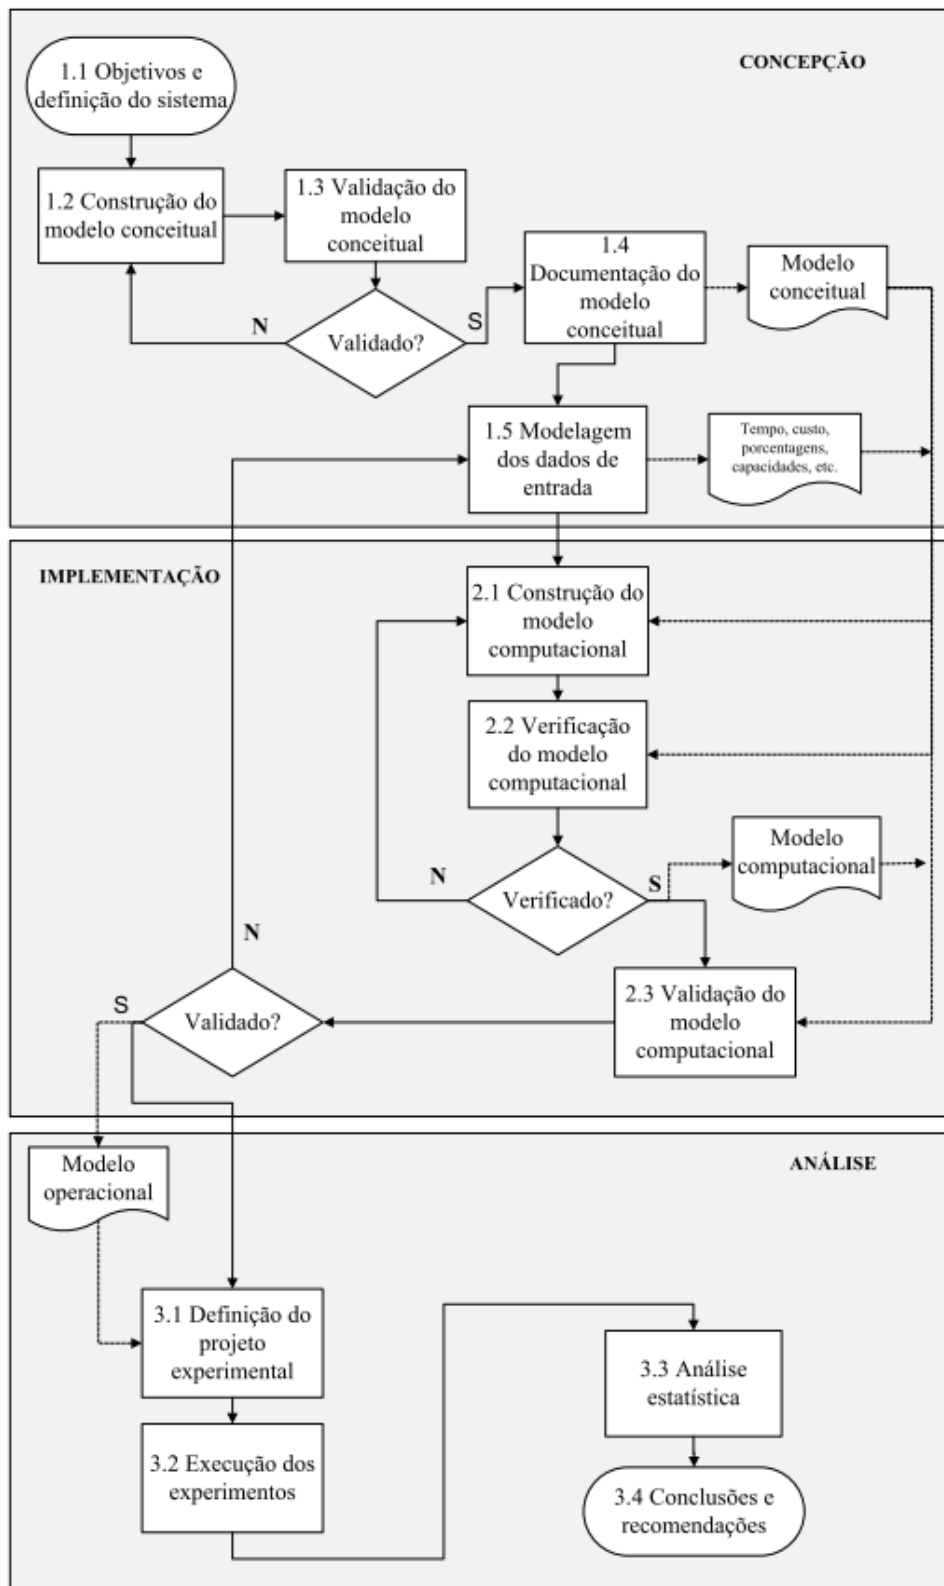


Figura 1: Sequencia de passos para um projeto de simulação. Montevechi et al. (2010).

Montevechi et al. (2010) mostra, em seu trabalho, um fluxograma que serve como guia para conduzir um projeto de simulação. Esse fluxograma apresenta os passos gerais para condução de um projeto de simulação com a integração do DOE como forma de ajuda na otimização. Aqui o foco é somente na análise, que é a última fase. Todos os passos são mostrados

na figura 1. Iremos adotar a mesma estratégia de Leal et al. (2007), porém no artigo citado não são feitos os experimentos axiais para a SR, chegando-se apenas ao experimento fatorial para a análise de sensibilidade e eliminação de variáveis sem peso no resultado.

Segundo Montgomery e Runger (2003), o DOE é uma maneira organizada de realizar experimentos, onde eles são planejados de maneira apropriada, possibilitando que se possa analisar através de técnicas estatísticas, tirando conclusões válidas e realistas. Isso acontece porque no DOE foram planejados os experimentos corretos, o melhor arranjo possível para se tirar conclusões válidas com o mínimo de experimentos, fazendo uma combinação de níveis das variáveis de maneira lógica.

De acordo com Montevechi et al. (2008), além dos efeitos ou pesos nos resultados mostrados pelas variações nos níveis de cada variável de entrada, uma grande vantagem do DOE é que as respostas estatísticas adquiridas nele mostram interações e efeitos combinados, onde o efeito de cada fator depende do nível dos outros fatores.

Caso haja um grande número de variáveis de entrada, para diminuir o número de simulações e o tempo, pode-se usar o fatorial fracionado, onde apenas uma parte de todos os experimentos possíveis são realizados e avaliados. Esse experimento fracionado pode se tornar um fatorial completo à medida que são retiradas variáveis insignificantes do experimento.

De maneira parecida com o trabalho de Dengiz e Belgin (2014), para buscar a otimização utilizaremos a superfície de resposta, a qual produz uma função aproximada que relaciona as variáveis de entrada com as variáveis de saída. E, essa técnica, pode apresentar um ponto ótimo estimado. A aplicação da SR em um modelo de simulação caracteriza um meta-modelo.

Podemos observar no livro de Montgomery e Runger (2003) que a SR é uma coleção de técnicas matemáticas e estatísticas que modelam e analisam problemas onde o interesse é otimizar uma variável de saída que depende de varias variáveis de entrada. A superfície representada pela relação funcional entre essas variáveis $y = f(x_1, x_2)$ é chamada de superfície de resposta. Para a construção de uma superfície curva, onde poderemos localizar um ponto estacionário, necessitamos de uma função quadrática. A partir daí surge a necessidade dos pontos axiais.

Segundo Hu, Yao e Hua (2008) a SR gerada de funções de segunda ordem é eficiente na resolução da maioria dos problemas e usa pouco esforço computacional, sendo rápida e barata. E ainda é importante na comparação dos coeficientes dos parâmetros e eliminando as variáveis não importantes.

Os passos da SR utilizados aqui neste artigo serão:

- Seleção das variáveis de entrada e saída.
- Realização do experimento fatorial juntamente com o ponto central com cinco réplicas. O ponto central é importante para:
 - Obtenção das variáveis relevantes, pois a relevância dessas depende do erro experimental calculado nos pontos centrais.
 - Diminuição do número de experimentos, pois se elimina a necessidade de realização de duas réplicas dos experimentos fatoriais.
 - Além de apresentar a curvatura que mostrará se existe ou não um ponto ótimo na região de solução proposta.
- Caso haja curvatura, realizam-se os experimentos axiais que, somados aos experimentos já realizados, geram a superfície de resposta.
- Otimização da variável de saída, obtendo-se o ponto estacionário da regressão obtida com os coeficientes de cada variável de entrada isolada ou combinada à outra. Para essa fase utiliza-se a função solver do software Excel, restringindo-se os valores das variáveis aos valores inteiros.

3. Delineamento de experimentos

Para começar a explicar a parte prática do trabalho, apresentaremos a tabela 1 que contém todos os experimentos. A simulação contém quatro variáveis a serem otimizadas, que correspondem ao número de operadores em cada um dos quatro setores da célula de produção

analisada. A variável de saída é o lucro, que dependerá da quantidade produzida descontado o valor gasto com mão de obra.

Tabela 1: Experimentos realizados

Ordem	Tipo	A	B	C	D	Lucro
1	1	-1	-1	-1	-1	31666
2	1	1	-1	-1	-1	29866
3	1	-1	1	-1	-1	98296
4	1	1	1	-1	-1	96496
5	1	-1	-1	1	-1	29334
6	1	1	-1	1	-1	27534
7	1	-1	1	1	-1	171394
8	1	1	1	1	-1	169594
9	1	-1	-1	-1	1	29946
10	1	1	-1	-1	1	28146
11	1	-1	1	-1	1	96576
12	1	1	1	-1	1	94776
13	1	-1	-1	1	1	27614
14	1	1	-1	1	1	25814
15	1	-1	1	1	1	169674
16	1	1	1	1	1	167874
17	-1	-2	0	0	0	84009
18	-1	2	0	0	0	113692
19	-1	0	-2	0	0	-47466
20	-1	0	2	0	0	147048
21	-1	0	0	-2	0	-18960
22	-1	0	0	2	0	121208
23	-1	0	0	0	-2	17598
24	-1	0	0	0	2	113772
25	0	0	0	0	0	115492
26	0	0	0	0	0	115150
27	0	0	0	0	0	115106
28	0	0	0	0	0	114900
29	0	0	0	0	0	115178

Vale lembrar que, todo o experimento (fatorial completo e superfície de resposta) foi feito com a média do lucro, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise.

A tabela 1 mostra todos os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial completo, a segunda parte (tipo -1) mostra os pontos axiais e, no fim, o ponto central em suas cinco réplicas (tipo 0).

A tabela 2 contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que será posta a prova quando descobirmos se há ou não curvatura nessa região. Caso haja, existirá ponto ótimo dentro dessa região, fato confirmado por Montgomery e Runger (2003).

Tabela 2: Decodificação dos níveis em número de operadores

	Níveis				
	-2	-1	0	1	2
Operador 1	1	2	3	4	5
Operador 2	1	2	3	4	5
Operador 3	1	2	3	4	5
Operador 4	1	2	3	4	5

3.1. Fatorial completo

Na tabela 3 se encontram os resultados estatísticos da análise do experimento fatorial completo. Nesta fase é feita a análise de sensibilidade de cada variável de entrada no resultado, no caso o lucro, e a presença ou não de curvatura na região de solução.

Tabela 3: Resultado do experimento fatorial completo

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		80912,5	53,18	1521,36	0,000
A	-1800,0	-900,0	53,18	-16,92	0,000
B	104345,0	52172,5	53,18	980,97	0,000
C	35383,0	17691,5	53,18	332,64	0,000
D	-1720,0	-860,0	53,18	-16,17	0,000
A*B	0,0	0,0	53,18	0,00	1,000
A*C	-0,0	-0,0	53,18	-0,00	1,000
A*D	-0,0	-0,0	53,18	-0,00	1,000
B*C	37715,0	18857,5	53,18	354,57	0,000
B*D	0,0	0,0	53,18	0,00	1,000
C*D	0,0	0,0	53,18	0,00	1,000
A*B*C	0,0	0,0	53,18	0,00	1,000
A*B*D	0,0	0,0	53,18	0,00	1,000
A*C*D	-0,0	-0,0	53,18	-0,00	1,000
B*C*D	0,0	0,0	53,18	0,00	1,000
A*B*C*D	-0,0	-0,0	53,18	-0,00	1,000
Ct Pt		34252,7	109,00	314,26	0,000

R-quadrático (ajustado) = 100,00 %




Figura 2: Gráfico de sensibilidade das variáveis de entrada e suas interações

Percebe-se pela figura 2 que as variáveis A e D não têm grande influência no resultado, sendo, portanto, eliminadas do experimento. É possível notar pela tabela 3 que há curvatura na região, pois $ct\ pt < 0.05$, existindo, portanto, um ponto ótimo. Nota-se um R-quadrático (ajustado) = 100%, o que mostra que o modelo com suas variáveis é satisfatório na previsão do resultado.

A tabela 4 mostra a análise fatorial feita apenas com as variáveis B e C. Essa tabela foi obtida através da manipulação das variáveis observando os valores dos P-values.

Tabela 4: Resultado do experimento fatorial completo eliminando-se termos insignificantes

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		80913	312,3	259,05	0,000
B	104345	52172	312,3	167,04	0,000
C	35383	17692	312,3	56,64	0,000
B*C	37715	18857	312,3	60,37	0,000
Ct Pt		34253	640,1	53,51	0,000

R-quadrático (previsão) = 88,56%

R-quadrático (ajustado) = 99,95%

Confirma-se aqui que há curvatura e que essas variáveis são importantes no resultado.

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com 99,95% de confiança.

3.2. Superfície de resposta

A seguir são utilizados os pontos axiais para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas oito experimentos, que são os pontos axiais. Esses pontos são importantes para uma regressão quadrática, onde poderemos obter um ponto ótimo, que é o objetivo principal da SR. Nota-se que aqui utilizamos somente as variáveis importantes na análise de sensibilidade para obtenção da regressão. A tabela 5 mostra os resultados da SR.

Tabela 5: Resultado do experimento de superfície de resposta

Termo	Coefficientes	SE Coeficientes	T	P
Constant	102512	6430	15,943	0,000
B	50991	4353	11,714	0,000
C	23475	4353	5,393	0,000
B*B	-12073	4059	-2,975	0,007
C*C	-11740	4059	-2,893	0,008
B*C	18858	5331	3,537	0,002

R-quadrático (previsão) = 82,07%

R-quadrático (ajustado) = 87,09%

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado um bom grau de confiança, pois o R-quadrático (ajustado) é igual a 87,09%.

Tabela 6: Falta de ajuste

Erro residual	23	10459392339	10459392339	454756189		
Falta de ajuste	3	1864225234	1864225234	621408411	1,45	0,259
Erro puro	20	8595167105	8595167105	429758355		

É possível notar que o modelo não possui falta de ajuste, uma vez que a falta de ajuste é igual a 0,259, maior que 0,05.

O R-quadrático (ajustado) = 87,09% também é satisfatório, dizendo que o modelo é capaz de prever o resultado com um bom grau de confiança. Fato comprovado também pela regressão que tem P-value = 0.

Os coeficientes da equação quadrática originada pelos experimentos de SR são mostrados na tabela 7, e serão usados para obtenção do ponto ótimo de lucro, que será feita usando-se a função solver do software Excel.

Tabela 7: Coeficientes dos termos usados na otimização

Termos	Coefficientes
Constante	102512
B	50991
C	23475
B*B	-12073
C*C	-11740
B*C	18858

3.3. Ponto ótimo

Através dos coeficientes chegamos ao ponto ótimo, mostrado na tabela 8. Os valores de B e C são 1 e 1, respectivamente, que correspondem a 4 operadores em cada um desses setores da célula de produção. As variáveis não analisadas no experimento, no caso A e D, não são significativas no experimento e, portanto, serão deixadas no estado atual, que é o nível -1, pois não há a necessidade de se contratar mais operadores visto que isso não é importante. Esse nível corresponde a 2 operadores. Logo, o ponto ótimo corresponde a: 2, 4, 4 e 2 operadores para os setores A, B, C e D, respectivamente. É importante ressaltar que utilizamos a restrição de valores

inteiros, pois não teria sentido obter valores decimais, uma vez que o número de operadores é uma variável inteira.

Tabela 8: Cálculo do ponto ótimo

Fatores	Coefficientes	z (x)	
b0	102512	1	
b2	50991	1	
b3	23475	1	
b22	-12073	1	
b33	-11740	1	
b23	18858	1	
Y (Lucro)	172023,00		
	Restrição esférica g(x)	2	4

Vemos que, na otimização obtida pela SR, o valor do lucro é de R\$ 172.023,00. Esse valor é válido porque se encontra dentro da restrição esférica $g(x)$, que é o valor de alfa ao quadrado ($\alpha = 2$).

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na tabela 7 (2, 4, 4, 2) 30 vezes e calculando a média, temos um lucro de R\$ 171.394,00. Percebe-se que, esse valor não está muito distante do valor ótimo obtido da regressão.

Quando utilizamos o software do SimRunner, no modo moderado, temos um lucro de R\$ 172.823,00 com 115 experimentos, que é um número muito maior de experimentos para um lucro bem próximo ao obtido pela SR, que só faz 29 experimentos. Além disso, o valor das variáveis de entrada é 2, 5, 4, 2 para A, B, C e D, respectivamente. Esses valores também estão bem próximos dos obtidos na SR, os quais só terão variação em B, saindo de 4 para 5 operadores.

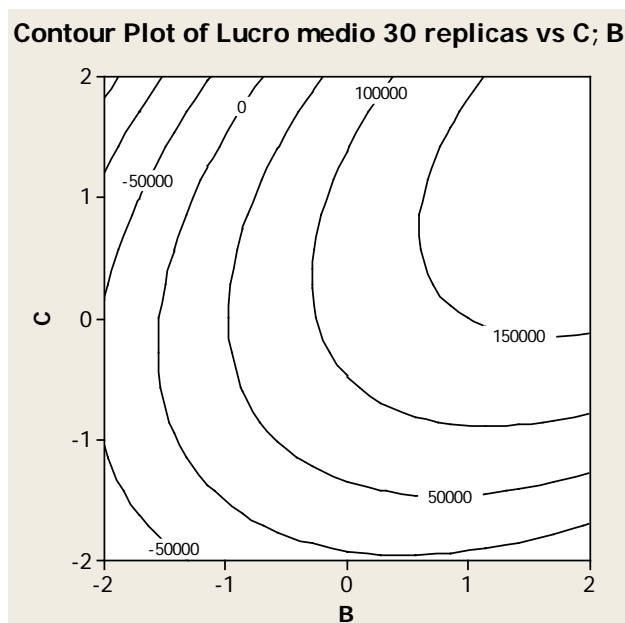


Figura 3: Vista superior da SR – Gráfico de Contorno.




Figura 4: Superfície de Resposta

Fazendo-se uma análise visual da superfície de resposta (figura 4) e do gráfico de contorno (figura 3), que funciona como uma vista superior, pode-se concluir que o ponto ótimo se situa no ponto $B = 2$ e $C = 2$, porém este ponto se situa fora da restrição esférica mostrada na equação (3):

$$g(x) \leq \text{alfa}^2 \quad (1)$$

$$\text{alfa} = 2 \quad (2)$$

$$g(x) \leq 4. \quad (3)$$

Estando fora dessa região, o modelo não serve como referência para previsão do lucro. Por essa razão o ponto ótimo codificado calculado foi $B = 1$ e $C = 1$, que corresponde a 4 operadores em cada célula. Para fazer isso foi usada a restrição de valores inteiros no solver para as variáveis de entrada B e C , como foi dito anteriormente.

4. Conclusões

Foi apresentada uma forma alternativa de otimização em simulações. Essa forma não é, necessariamente, melhor nem pior que a forma utilizada por softwares comerciais, porém tem as suas vantagens e desvantagens:

Vantagens:

- Possibilidade de análise de sensibilidade e interações entre as variáveis de entrada.
- Possível avaliar se o ponto ótimo está dentro da região de solução proposta (através da presença ou não de curvatura).
- Para calcular o ponto ótimo é necessário um menor número de experimentos que a otimização através do SimRunner.

Desvantagens:

- Necessário conhecimento em estatística, na técnica de DOE, tanto em experimentos fatoriais quanto em Superfície de Resposta. Já no caso de softwares como o Simrunner, qualquer profissional da área poderia aprender a otimizar com facilidade.
- Maior possibilidade de erro e gasto de tempo na preparação e análise dos experimentos.

Finalmente, vimos no experimento de confirmação que a regressão foi satisfatória na previsão do resultado, pois foi bem próxima ao experimento real. Além disso, o valor calculado

pelo software comercial usado também foi bem próximo ao da SR, mostrando a eficácia do método adotado para se chegar ao ponto ótimo.

Agradecimentos

Os autores do artigo agradem as agências brasileiras de fundos educacionais CNPQ e FAPEMIG, e ao programa de suporte à engenharia CAPES.

5. Referências bibliográficas

Bertrand, J. W. M., Fransoo, J. C. (2002), Operations management research methodologies using quantitative modeling, *International Journal of Operations & Production Management*, v. 22, n. 2, 241-264.

Dengiz, B. e Belgin, O. (2014), Simulation optimization of a multi-stage multi-product paint shop line with response surface methodology, *Simulation*, 1-10.

Fernandes, L. J. Rodriguez L. A. O., Correa A. R., e Marins F. A. S. (2013), Planejamento e controle da produção de cilindros para laminação: um estudo de caso quantitativo, *Produção*, v. 23, n. 1, 120-135.

Leal, F. Montevechi, J. A. B., Pinho, A. F. e Marins F. A. S. Application of design of experiments on the simulation of a process in an automotive industry, *Winter Simulation Conference*, 2007.

Hu, W. Yao, L. G. e Hua, Z. Z. (2008), Optimization of sheet metal forming processes by adaptive response surface based on intelligent sampling method, *Journal of Materials Processing Technology*, 197, 77-88.

Montevechi, J. A. B. Leal, F. Pinho, A. F. Costa, R. F. S. Oliveira, M. L. M. Silva, A. L. F. Conceptual modeling in simulation projects by mean adapted IDEF: an application in a Brazilian tech company, *Winter Simulation Conference*, 2010.

Montevechi, J. A. B.; Miranda, R. D. C.; Friend, J. D. Sensitivity analysis in discrete-event simulation using design of experiments. Capítulo submetido ao livro *Discrete Event Simulations*, 2011.

Montevechi, J. A. B.; Pinho, A. F.; Leal, F.; Silva, F. A.; Costa, R. F. S. (2008), Improving a process in a brazilian automotive plant applying process mapping, design of experiments and discrete events simulation. *20th European Modeling and Simulation Symposium*, 472-480.

Montgomery, D. C.; Runger, G. C. *Estatística Aplicada e Probabilidade para Engenheiros*, 2 a. ed. Editora LTC, 2003.

Nakano, D. Métodos de pesquisa adotados na engenharia de produção e gestão de operações. Capítulo submetido ao livro *Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações*, Elsevier Editora Ltda, 2012.

Saraiva Júnior, A. F.; Tabosa, C. D. M.; Costa, R. P. (2011), Simulação de Monte Carlo aplicada à análise econômica de pedido, *Produção*, v. 21, n. 1, p. 149-164.

Sturrock, D. T. Tips for successful practice of simulation, *Winter Simulation Conference*, 2009.