OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO PARA PREVISÃO DE CONSUMO DE MATÉRIA PRIMA DE UMA EMPRESA DO SEGMENTO PETROQUÍMICO

Autores
Aneirson Francisco da Silva - aneirson@yahoo.com.br
Fernando Augusto Silva Marins - fmarins@feg.unesp.br
Erica Ximenes Dias – Ericaximenes@yahoo.com.br
Arlenio Paiva- arlenio12@hotmail.com
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

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

A importância da Gestão de Estoques para a Logística e para o Gerenciamento da Cadeia de Suprimentos tem se tornado cada vez mais evidente no meio empresarial. A gestão adequada do inventário da organização pode acarretar impactos significativos nos níveis de serviço ao cliente e nos custos totais da empresa. O objetivo do trabalho é de explorar o impacto do uso de Técnicas de Otimização e Simulação Monte Carlo na previsão do consumo de matéria prima de uma empresa do ramo petroquímico. Os resultados obtidos, considerando-se dados históricos do período de 2007 – 2015, com relação a alguns de seus produtos, foram avaliados, pelos gestores da Empresa estudada, como sendo superiores aos que vinham sendo gerados pelas técnicas de previsão que eles adotavam.

PALAVRAS CHAVE: Gestão de Estoques; Técnicas de Previsão; Simulação Monte Carlo; Otimização; Empresa Petroquímica.

ABSTRACT

The importance of Inventory Management to Logistics and to the Supply Chain Management has become increasingly evident in the business world. Proper management of the organization's inventory can cause significant impact on customer service levels and total costs of the company. The objective of this paper is to explore the impact of the use of the Optimization Techniques and Monte Carlo Simulation in the consumption of raw materials forecasting in a petrochemical industry. The obtained results, considering the historical data related to the period from 2007 to 2015 with respect to some of its products, were considered by the Company managers studied, better than those generated by the forecasting techniques adopted by the enterprise.

KEYWORDS: Inventory Management; Forecasting Techniques, Monte Carlo Simulation; Petrochemical Industry.

1. Introdução

A economia mundial está sujeita a oscilações que podem levar empresas a adequarem seus produtos de acordo com a necessidade do mercado (EUCLIDES FILHO, 2004). Mercados altamente globalizados e exigentes obrigam as empresas a reduzirem seus custos para que seus produtos sejam competitivos (SCHNEIDER; KALLIS; MARTINEZ-ALIER, 2010).

Neste contexto, a importância da Gestão de Estoques para a Logística e para o Gerenciamento da Cadeia de Suprimentos (*Supply Chain Management* – SCM) tem se tornado cada vez mais evidente no meio empresarial. De fato, a gestão de estoque em ambientes complexos como as cadeias de suprimento compostas por diversos estágios, não é um processo trivial, podendo acarretar impactos significativos nos níveis de serviços ao cliente e nos custos totais de qualquer instituição ou empresa.

Na literatura, existem vários métodos que são utilizados na previsão de demanda para diversas finalidades, como, por exemplo, auxiliar na gestão de suprimentos (FERRAZ; FELÍCIO, 2010), como, por exemplo, o uso de redes neurais artificiais, contudo para aplicação desta técnica é necessária uma grande quantidade de dados amostrais, o que não é o caso desta pesquisa. Muitas empresas adotam a análise de regressão como um método tradicional de previsão de demandas (vendas) ou de consumos de matérias primas. Ocorre que, em situações reais, os processos de vendas ou de produção não seguem um modelo linear e apresentam um alto grau de complexidade, tornando difícil, com o uso de métodos tradicionais de previsão, o controle de todas as variáveis (aleatórias) que influenciam nos *outputs* desses processos; e nesses casos, a Simulação Monte Carlo pode exercer um papel relevante no apoio à tomada de decisão.

Neste sentido, esse trabalho descreve uma alternativa, utilizando a Otimização via Simulação Monte Carlo (OvSMC), para a previsão do consumo de matéria prima em processos cujo comportamento apresenta características não lineares. O objeto do estudo foi uma empresa do ramo petrolífero, especificamente no ramo de produções de tubos para extração e transporte de fluídos em situações extremas.

Os dados para realização do trabalho foram coletados entre os anos de 2007 a 2015, complementados por observações de campo. Utilizou-se o so*ftware Crystal Ball* em conjunto com o otimizador *OPTQUEST* para execução da OvSMC.

Seguindo os conceitos desenvolvidos e apresentados por Bertrand e Fransoo (2002), este trabalho 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 - e a forma de abordar o problema é quantitativa, sendo o método de pesquisa Modelagem e Simulação.

Este artigo está organizado como se segue: a Seção 2 aborda técnicas de previsão, técnicas para identificação de *outliers* em séries de dados e Otimização via Simulação de Monte Carlo; Na Seção 3 está a descrição, a modelagem do problema aqui tratado e os resultados obtidos são analisados na Seção 4; finalmente, na Seção 5 estão as conclusões do trabalho seguidas das referências citadas neste texto.

2. Métodos de Previsão, *Outliers* e Otimização via Simulação Monte Carlo

Existem vários métodos que são utilizados na previsão de demanda, como o da regressão polinomial que é uma técnica simples e útil. Como apresentado por Montgomery *et al*. (2001) e Nutter *et al.* (2005), a técnica de regressão polinomial representa matematicamente o relacionamento entre uma variável (Y) dependente e variáveis de

controle (X_i). Como exemplo pode-se utilizar os modelos das expressões (1) - que é um modelo linear, e (2) - que é um modelo quadrático aqui adotado:

$$Y = \beta_0 + \beta_1 X_1 +,.. \beta_n X_n + \varepsilon \quad (1)$$

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2^2,.. \beta_n X_n + \varepsilon \quad (2)$$

A fim de se realizar a previsão de demanda em problemas reais, as equações (1) e (2) são utilizadas para estimar a função objetivo, que pode ser uma função de maximização ou minimização ou mesmo um valor alvo.

Essas funções usualmente apresentam alta complexidade e comportamento não linear, e uma alternativa interessante é utilizar um modelo estocástico (3) - (5) como o proposto por Abdelaziz, Aouni e El Fayedh (2007), observando-se que a notação ~ caracteriza uma variável aleatória associada aos coeficientes das variáveis de decisão na função objetivo e aos coeficientes dos lados direito (RHS – *Right Hand Side*) e esquerdo (LHS – *Left Hand Side*) das restrições:

$$\text{Max (ou Min) } Z = \sum_{j=1}^{n} \widetilde{C}_j x_j \quad (3)$$

s.a:

$$\sum_{j=1}^{n} \widetilde{A}_{kj} x_j \leq \widetilde{b}_k, \forall k \in K \quad (4)$$

$$x_j \geq 0 \quad (5)$$

Quando se trata com séries históricas deve haver uma preocupação em se identificar os *outliers*, que são dados que são estatisticamente inconsistentes com o restante dos dados e cujo tratamento estatístico deve ser feito de forma cuidadosa. O método de Thompson auxilia na tomada de decisão em manter ou não um dado suspeito de inconsistência estatística, conforme ilustrado a seguir (CIMBALA, 2011). Considerando-se uma amostra de n elementos (x_1, x_2, ... ,x_n) de uma variável de interesse, primeiramente deve-se organizar os seus valores em ordem crescente de forma que os *outliers* possam ser identificados de uma forma mais fácil. Para aplicar o método proposto por Thompson, segue-se o seguinte procedimento:

- Calcular a média da amostra $\bar{x}$ e seu desvio padrão S.
- Para cada valor da amostra calcula-se o desvio padrão absoluto:

$$\partial_i = |d_i| = |x_i - \bar{x}| \quad (6)$$

- O elemento da amostra que apresentar o valor máximo para ∂_i é um possível *outlier*.
- O valor modificado de Thompson (τ) é calculado a partir do valor crítico da Tabela t – *student* (MONTGOMERY; RUNGER, 2009):

$$\tau = \frac{t_{a/2} * (n-1)}{\sqrt{n} * \sqrt{n - 2 + t_{a/2}^2}} \quad (7)$$

sendo n o tamanho da amostra, α o nível de significância e $t_{a/2}$ o valor crítico retirado da Tabela *t - student.*

- A regra é: deve-se remover o elemento da série, isto é, ele é um *outlier* se $\partial_i > \tau S$.

O desenvolvimento da Simulação Monte Carlo - SMC tornou possível adequar uma grande classe de modelos matemáticos para retratar a complexidade dos dados encontrados em problemas reais (LIU; CARDIFF; KITANIDIS, 2010). A SMC analisa as variáveis aleatórias dos processos reais considerando suas distribuições de probabilidades, e calcula o valor esperado e o desvio padrão (dispersão) considerando uma faixa de variação. Para mais detalhes sobre SMC e tratamento de *outliers* recomenda-se a leitura de Arunraj *et al*. (2013), Hudson e Tilley (2014), Silva *et al*. (2014) e Ramanathan (2014)

3. Descrição e Modelagem do Problema

Foi escolhida uma empresa do ramo petrolífero, especificamente no ramo de produções de tubos para extração e transporte de fluídos, como sendo o objeto do estudo. Foram identificadas dificuldades no processo de extração dos dados, pois a base disponível no ERP da empresa não era atualizada com o devido cuidado pelos vários departamentos envolvidos. Assim, percebeu-se uma oportunidade de adequação dos preços finais dos produtos, a serem praticados pela empresa, a partir de um estudo a respeito do consumo real de Matéria Prima Auxiliar para as diferentes fábricas.

Na Tabela 1 estão os dados que foram analisados, sendo X_1, X_2 (variáveis independentes ou *inputs*) e Y (variável dependente ou *output*).
Como os dados disponíveis são uma amostra pequena, justifica-se o emprego da otimização estocástica, que utilizará os intervalos de confiança estimados pela análise de regressão, que serão utilizados posteriormente como os parâmetros de uma distribuição triangular.

Tabela 1 – Matriz de *inputs* e *output*

X_1 ([kg])	X_2 ([m])	Y Fator de consumo
15.480,4	8.048,63	1,923
50.082,6	24.406,09	2,052
0,000	320,21	0,000
46.8716	395.894,88	1,184
289.590,1	256.919,31	1,131
2.930,4	1.354,63	2,163
108.507,9	94.545,61	1,148
27.245	21.596,74	1,262
69.211	39.250,69	1,763
293.913,78	228.642,83	1,285
7.088	5.025,39	1,41
7.326	7.483,61	0,979
32.742	23.011,32	1,423
5.284,4	2.219,21	2,381
47.798,6	37.707,46	1,268
42.370	28.594,72	1,482
2.745	882,81	3,109

Na sequência foram removidos os *outliers* pelo método de Thompson, conforme descrito anteriormente. Vale ressaltar que nem todos os itens foram analisados, pois muitos deles impactavam muito pouco no preço final dos produtos. Em um primeiro momento, os dados foram tratados com o *software* Excel a fim de encontrar modelos matemáticos de

regressão lineares e não lineares que descrevessem o consumo da matéria prima no período de 2007 a 2015.

A título de exemplo, a OvSMC foi aplicada sobre o consumo de três matérias primas: Fluxo de Solda (*e*), Pastilha do Torno (*g*) e óleo de corte (*d*). O critério de escolha desses elementos se deu fundamentado nos valores obtidos para os R^2-ajustados dos modelos de regressão que foram superiores a 70% e os *value-p* foram menores que 0,05 (nível de significância = 5%). Os resultados da regressão para as matérias primas, fluxo de solda, Pastilha do Torno e de Óleo de Corte são apresentados nas Figuras 2, 3 e 4, respectivamente.

Figura 2 - Resultados da Regressão – Matéria prima - Fluxo de Solda

RESUMO DOS RESULTADOS -FLUXO	
Estatística de regressão	
R múltiplo	0,942939571
R-Quadrado	0,889135034
R-quadrado ajustado	0,881744036
Erro padrão	0,072907409
Observações	17

ANOVA					
	gl	*SQ*	*MQ*	*F*	*F de significação*
Regressão	1	0,63945205	0,63945205	120,2997301	1,46218E-08
Resíduo	15	0,079732355	0,00531549		
Total	16	0,719184404			

	Coeficientes	*Erro padrão*	*Stat t*	*valor-P*	*95% inferiores*	*95% superiores*	*Inferior 95,0%*	*Superior 95,0%*
Interseção	0,059159926	0,028263629	2,0931469	0,053743428	-0,001082572	0,119402425	-0,001082572	0,119402425
e^2	0,497642096	0,045371672	10,96812336	1,46218E-08	0,400934666	0,594349526	0,400934666	0,594349526

Fonte: MS-excel

Figura 3 - Resultados da Regressão – Matéria prima Pastilha do Torno

SUMMARY OUTPUT - TORNO	
Regression Statistics	
Multiple R	0,956043526
R Square	0,914019224
Adjusted R Square	0,905830579
Standard Error	0,181280155
Observations	24

ANOVA					
	df	*SS*	*MS*	*F*	*Significance F*
Regression	2	7,336244438	3,668122219	111,6203216	6,47462E-12
Residual	21	0,690112387	0,032862495		
Total	23	8,026356825			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	-5,816134971	0,221727482	-26,23100631	1,55851E-17	-6,277242512	-5,35502743	-6,277242512	-5,35502743
g^2	-0,000295541	5,59581E-05	-5,281474531	3,09294E-05	-0,000411913	-0,00017917	-0,000411913	-0,00017917
G^3.E	5,46303E-06	3,76675E-07	14,5032729	2,05604E-12	4,67969E-06	6,24637E-06	4,67969E-06	6,24637E-06

Fonte: MS-excel.

Figura 4 - Resultados da Regressão – Matéria prima Óleo de Corte

SUMMARY OUTPUT - ÓLEO	
Regression Statistics	
Multiple R	0,995747169
R Square	0,991512425
Adjusted R Square	0,937540703
Standard Error	0,262327974
Observations	23

ANOVA	*df*	*SS*	*MS*	*F*	*Significance F*
Regression	4	152,7416023	38,18540057	554,8915868	1,4006E-18
Residual	19	1,307503354	0,068815966		
Total	23	154,0491056			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
e raiz d	-3,795257035	0,843158694	-4,501236911	0,000244497	-5,560008463	-2,030505607	-5,560008463	-2,030505607
ed	0,820941502	0,210296851	3,903727039	0,000954649	0,380785135	1,261097869	0,380785135	1,261097869
d3.e	-0,000219809	6,24766E-05	-3,518258199	0,002298102	-0,000350574	-8,90438E-05	-0,000350574	-8,90438E-05
lne	2,252619288	0,099311526	22,68235492	3,19471E-15	2,044757875	2,460480702	2,044757875	2,460480702

Fonte: MS-excel.

4. Aplicação da OvSMC e comparação com a Previsão da Empresa

Aqui serão apresentados os resultados obtidos com a aplicação da OvSMC às três matérias primas estudadas, com os modelos matemáticos de regressão expressos em (8), (9) e (10), com a notação ~ caracterizando uma variável aleatória:

- Para a matéria prima Fluxo de Solda

$$Y1 = \tilde{I} + \widetilde{e^2} \qquad (8)$$

- Para a matéria prima Pastilha do Torno

$$Y2 = \tilde{I} + \widetilde{g^2} + \widetilde{g^3}.\tilde{e} \qquad (9)$$

- Para a matéria prima Óleo de Corte

$$Y3 = \tilde{e}\sqrt{\tilde{d}} + \tilde{e}.\tilde{d} + \widetilde{d^3}\tilde{e} + Ln(\tilde{e}) \qquad (101)$$

Considerando o intervalo de confiança de 95% para cada coeficiente da regressão, conforme descrito nas Figuras 2, 3 e 4, modelou-se os coeficientes das funções empíricas com base numa função de densidade de probabilidade triangular (SILVA *et al.*, 2014), utilizando os valores dos coeficientes e os valores dos intervalos de confiança inferiores e superiores, para cada matéria prima estudada. A comparação dos resultados da OvSMC com os valores reais ocorridos e com as previsões dos modelos de regressão estão nas Tabela 2, 3 e 4, e ilustrados nas Figuras 5, 6 e 7.

Tabela 2 - Comparação de Resultados para a matéria prima Fluxo de Solda

Equação de Regressão	Otimização via SMC	Real
Valor Y1	Valor Y1	Valor Y1
2,141	1,66<y1<2,07	2,05

Figura 5 – Resultados da OvSMC para o Fluxo de Solda

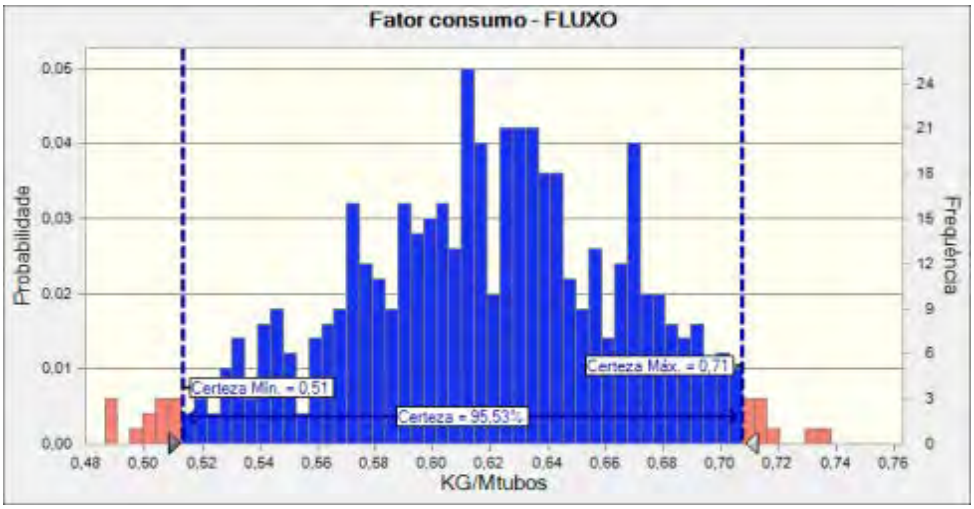

Ilustrando estes resultados, da Tabela 2 e a Figura 5 com a função empírica da regressão, considerando o valor de 1,2 para a variável independente, tem-se o valor de 2,141 para a variável dependente, já utilizando a OvSMC este valor está entre 1,66 a 2,07.

Tabela 3 - Comparação dos resultados para a matéria prima Pastilha do Torno

Equação de Regressão	Otimização via SMC	Real
Y2	Y2	Y2
0,005088	0,0020<y<0,0042	0,0039

Figura 6- Resultados da OvSMC para a matéria prima Pastilha do Torno.

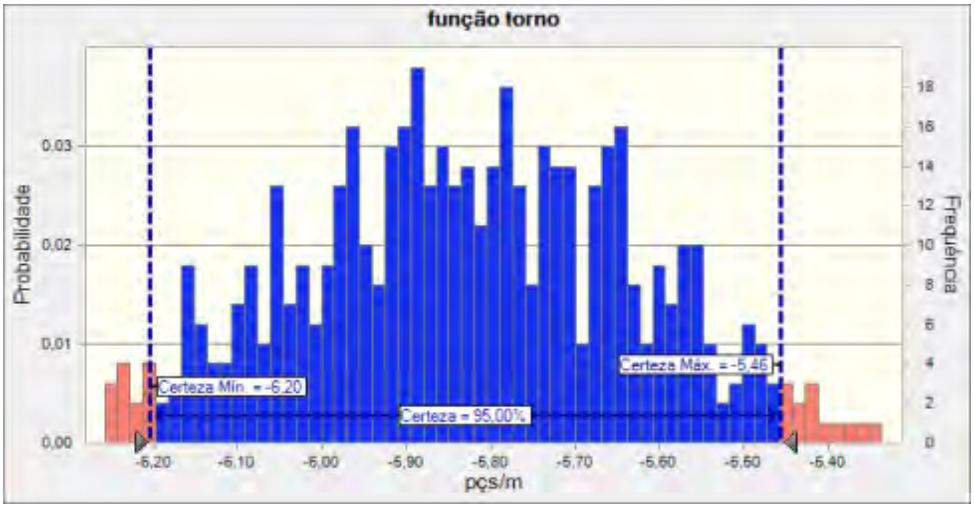

Ilustrando estes resultados, da Tabela 3 e a Figura 6 com a função empírica da regressão, considerando os valores (1,18, 65) para as variáveis independentes, tem-se o valor de 0,005088 para a variável dependente, já utilizando a OvSMC este valor está entre 0,0020 a 0,0042.

Tabela 4 - Comparação de resultados para a matéria prima Óleo de Corte

Regressão	Otimização via SMC	Real
Y3	Y3	Y3
0,1490	0,031<y3<0,577	0,2233

Figura 7 - Resultado da OvSMC para a matéria prima Óleo de Corte

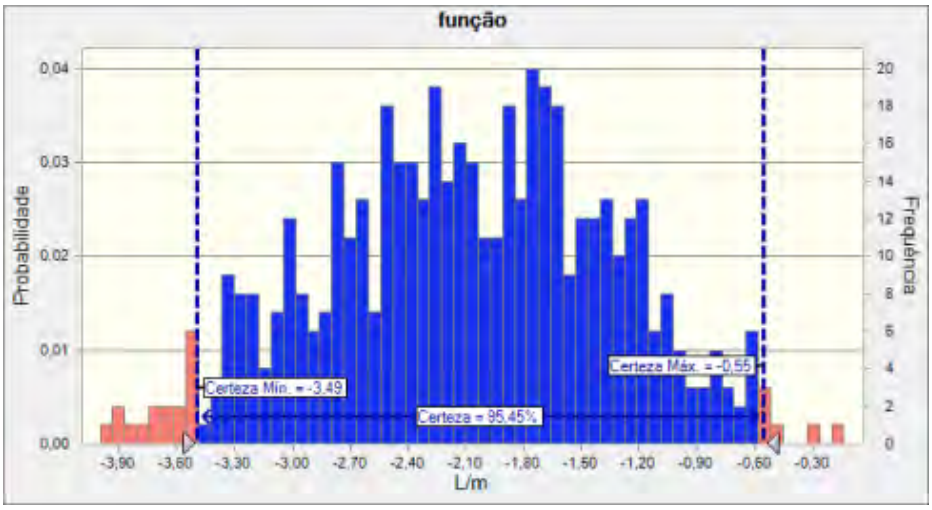

Ilustrando estes resultados da Tabela 4 e a Figura 7 com a função empírica da regressão, considerando os valores (1,18 e 26) para as variáveis independentes, tem-se o valor de 0,149 para o fator de consumo (variável dependente), já pela OvSMC este valor está entre 0,031 a 0,577.

Em resumo, para todos os casos analisados a OvSMC mostrou-se mais confiável, pois ao comparar as predições com os dados reais os valores reais estão dentro do intervalo de confiança gerada pela OvSMC.

5. Conclusões

Este trabalho buscou avaliar a aplicabilidade da OvSMC na otimização do consumo de matéria prima em um cenário real de uma indústria do segmento petroquímico no Brasil. Mesmo havendo possíveis fatores externos que influenciavam o consumo de matérias primas, os modelos matemáticos resultantes da OvSMC apresentaram uma alta aderência com os dados reais históricos fornecidos pela companhia: os valores de R^2 foram 0,889, 0,914 e 0,991 (ver Figuras 2 a 4), respectivamente para os modelos de consumo das matérias primas Fluxo de Solda, Pastilha do Torno e Óleo de Corte.

Os resultados obtidos pela OvSMC foram considerados, pelos gestores da empresa estudada, melhores do que os obtidos pela aplicação da equações de regressão, visto que eles levam em consideração possíveis variações do processo em que as matérias primas são utilizadas, o que não ocorre nas previsões por meio de regressões (funções empíricas determinísticas), e estão mais próximos dos valores reais ocorridos.

Como consequência deste trabalho, a empresa estudada pode prever o consumo das matérias primas para diferentes cenários, e o preço fixado para o produto final é mais realista com os gastos efetivamente despendidos para produzi-lo.

Agradecimentos: Essa pesquisa teve apoio do CNPq – Projeto No. 306214/2015-6 e FAPESP Projeto No. 2015/12711-4.

Referências Bibliográficas

ARUNRAJ, N. S.; MANDAL, S.; MAITI, J. Modeling uncertainty in risk assessment: An integrated approach with fuzzy set theory and Monte Carlo simulation. *Accident Analysis and Prevention,* v. 55, p. 242–255, 2013.

BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. *International Journal of Operation & Production Management,* v.22, n.2, p.241-264, 2002.

CIMBALA J. M. (2011). Outliers [Online]. Disponível em: https://www.mne.psu.edu/me345/Lectures/outliers.pdf. Acessado em abril de 2016

EUCLIDES FILHO, K. Supply chain approach to sustainable beef production from a Brazilian perspective. *Livestock Production Science*, v. 90, n. 1, p. 53–61, 2004.

FERRAZ, J. B. S.; FELÍCIO, P. E. de. Production systems-an example from Brazil. *Meat science*, v. 84, n. 2, p. 238–243, 2010.

HUDSON, A.; TILLEY, D. R. Assessment of uncertainty in emergy evaluations using Monte Carlo simulations. *Ecological Modelling*, v. 271, p. 52–61, 2014.

LIU, X.; CARDIFF, M. A.; KITANIDIS, P. K. Parameter estimation in nonlinear environmental problems. *Stochastic Environmental Research and Risk Assessment*, v. 24, n. 7, p. 1003–1022, 2010.

MONTGOMERY, D. C.; RUNGER, G. C.. **Estatística aplicada e probabilidade para engenheiros,** LTC – Livros Técnicos e Científicos, Editora S.A, Rio de Janeiro, 2009.

RAMANATHAN, U. Performance of supply chain collaboration - A simulation study. *Expert Systems with Applications*, v. 41, n. 1, p. 210–220, 2014.

SILVA, A. F; MARINS, F.A.S; Da Silva, M.D.F.F. Otimização Estocástica com Múltiplos Objetivos e Estratégias de Vendas.Pesquisa Operacional para o Desenvolvimento, v.6, p. 35–53, 2014.

SCHNEIDER, F.; KALLIS, G.; MARTINEZ-ALIER, J. Crisis or opportunity? Economic degrowth for social equity and ecological sustainability. *Journal of Cleaner Production*, v. 18, n. 6, p. 511–518, 2010.