

Otimização via Simulação Monte Carlo na Melhoria de Processos Produtivos Aeronáuticos

Igor Makiyama de Souza Barbosa
igor.msbarbosa@gmail.com
UNESP

Murilo Vieira Strongoli
murilo.strongoli@gmail.com
UNESP

Aneirson Francisco da Silva
aneirson@gmail.com
UNESP

Fernando Augusto Silva Marins
fernando.marins@outlook.com
UNESP

Erica Ximenes Dias

Resumo: A indústria aeronáutica tem características que a distinguem de outros setores industriais, atribuindo-lhe desafios dinâmicos e peculiares. Devido à grande quantidade de variáveis concernentes aos processos industriais, a tomada de decisão relacionada a melhoria de tais processos se mostra uma atividade complexa (RODRIGUES, 2016). Neste trabalho, buscou-se utilizar a Otimização via Simulação Monte Carlo (OvSMC) na previsão de parâmetros de usinagem de peças do setor aeronáutico, os quais deveriam ser utilizados para atender a um período de tempo total determinado. Para tanto, foram utilizados dados de um processo de usinagem de uma indústria do setor aeronáutico brasileiro. Com base nos resultados obtidos com o trabalho, concluiu-se que a OvSMC é uma ferramenta que contribui na melhora da determinação de parâmetros envolvidos em processos de manufatura de peças do setor aeronáutico.

Palavras Chave: Otimização - Simulação - Monte Carlo - Setor Aeronáutico -

1. INTRODUÇÃO

A indústria aeronáutica tem características que a distinguem de outros setores industriais, atribuindo-lhe desafios dinâmicos e peculiares. Por conta de sua complexidade, são necessários elevados níveis de investimento em pesquisa, conhecimento e recursos humanos. Além disso, por conta dos longos processos de desenvolvimento de produto, o setor gera retornos crescentes e economia de escala (MORAES et. al., 2016).

Em função desse contexto, a indústria aeroespacial brasileira se destaca no aspecto econômico por apresentar alto potencial de crescimento, conteúdo tecnológico relevante, alto valor agregado do produto e expressiva contribuição para a balança comercial (MONTORO & MIGON, 2009).

Nas Figuras 1 e 2 é possível visualizar a importância do setor aeronáutico nacional, por meio da contribuição socioeconômica do mesmo, como apresentado anteriormente.

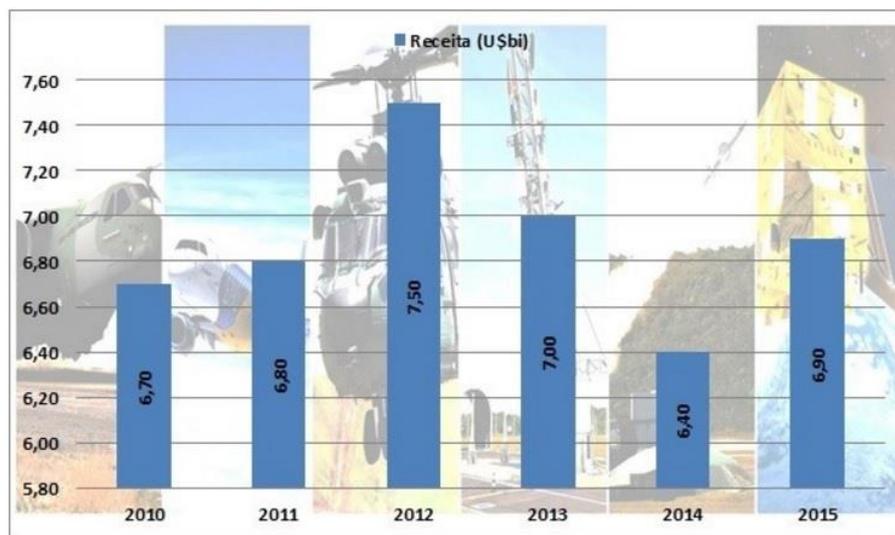


Figura 1: Receita do setor aeronáutico em bilhões de dólares, de 2010 a 2015. FONTE: Associação das Indústrias Aeroespaciais do Brasil, AIAB (2015).

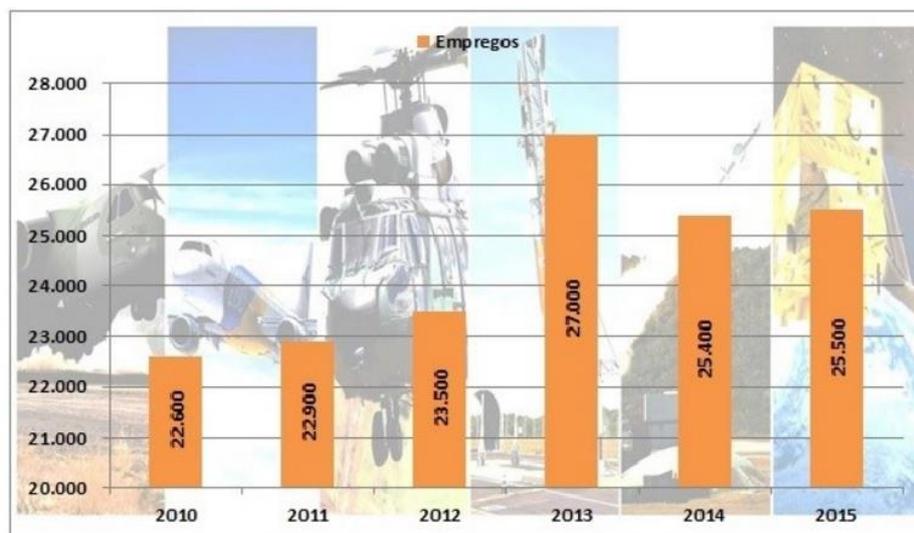


Figura 2: Empregos gerados pelo setor aeronáutico em bilhões de dólares, de 2010 a 2015. FONTE: Associação das Indústrias Aeroespaciais do Brasil, AIAB (2015).

Segundo Gomes (2015), o quadro de tendências que se delineia para os próximos anos aponta para o gradual aumento da concorrência a partir de 2015 devido ao incentivo estatal de países como China, Rússia e Japão ao desenvolvimento da indústria aeronáutica nacional.

Baseado nessas tendências, é possível inferir que nos próximos anos haverá um esforço maior relacionado à melhoria dos processos industriais, considerando que se deve manter o controle sobre os parâmetros de qualidade, visto que os recursos estão cada vez mais escassos. A determinação de arranjos ideais para atingir metas estipuladas representa uma grande parcela de tal esforço (BOYLAN et al., 2013).

Devido à grande quantidade de variáveis concernentes aos processos industriais, a tomada de decisão relacionada a melhoria de tais processos se mostra uma atividade complexa. Além do elevado número de variáveis, ainda é necessário entender o grau de influência entre as variáveis independentes (influenciadoras) e dependentes (influenciadas) (RODRIGUES, 2016). No auxílio a essa difícil atividade, é possível empregar métodos de otimização da Pesquisa Operacional (PO) que resultam em uma maior eficiência destes processos (PAIVA, FERREIRA & PAIVA, 2007).

Entre as diversas técnicas da PO existentes, Yang (2010) comenta que a Simulação Monte Carlo (SMC) tem sido aplicada a todas as áreas do conhecimento. Neste trabalho, a SMC foi combinada com um conjunto de técnicas de otimização gerando um procedimento que pode ser encontrado na literatura como Otimização via Simulação Monte Carlo (OvSMC). Tal procedimento é indicado para solucionar problemas complexos que apresentem vários ótimos locais, envolvendo um *mix* de variáveis contínuas e discretas (KROESE, TAIMRE & BOTEV, 2011).

Uma vez compreendido o contexto no qual o trabalho está inserido, é possível levantar o seguinte questionamento: há vantagens em se utilizar a Otimização via Simulação Monte Carlo (OvSMC) na determinação de parâmetros, relacionados aos processos de manufatura de peças aeronáuticas, de forma a atender metas de tempo estipuladas pelos especialistas do setor?

Como proposta de resposta para a questão levantada, o objetivo geral deste trabalho foi utilizar a OvSMC na predição dos tempos de usinagem e ajustagem do processo de manufatura de peças aeronáuticas. Os objetivos específicos envolveram dois aspectos:

- Desenvolver funções que representem adequadamente o processo de manufatura de peças aeronáuticas;
- Propor uma ajustagem dos parâmetros vinculados ao processo de manufatura, a partir de um tempo de processo determinado.

Ehrgott et al. (2014) comentam que no processo de otimização ainda há lacunas entre teoria e prática, pois não é simples para o gestor aplicar os conceitos, modelos e técnicas desenvolvidas pelos pesquisadores diretamente nos seus problemas do dia a dia que possuem características especiais. Os dados observados na Figura 3 justificam a aplicação da OvSMC na indústria aeronáutica, sendo possível observar um crescente número de publicações e citações relacionadas com OvSMC, utilizando a palavra-chave “Optimization via Monte Carlo Simulation” na base de dados Web of Science, enquanto há somente uma publicação quando associamos as palavras-chave “Optimization via Monte Carlo Simulation” e “Aeronautical Industry” na mesma base de dados. Observa-se que, embora a área de estudo esteja em alta, a aplicação prática no ramo aeronáutico ainda pode ser mais explorada.

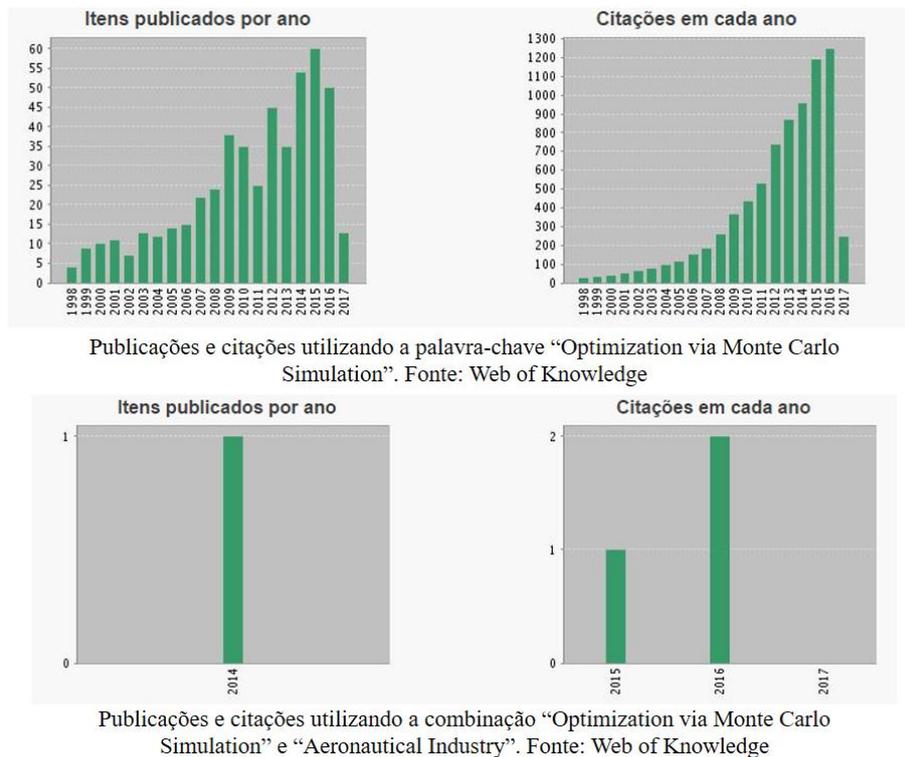


Figura 3: Progressão anual de publicações e citações sobre OvSMC e Indústria Aeronáutica. FONTE: Web of Knowledge.

Este trabalho recebe, segundo Bertrand e Fransoo (2002), a classificação de pesquisa aplicada, sendo seus objetivos empíricos descritivos, uma vez que as relações causais existentes na realidade são descritas adequadamente pelo modelo desenvolvido. O método de pesquisa utilizado foi a modelagem e simulação, seguindo uma abordagem quantitativa.

Para a execução do trabalho, foi utilizado o *software* Crystal Ball® em conjunto com o Excel® para modelagem e simulação e posterior otimização do problema. O *software* MiniTab17® foi utilizado para testar a normalidade dos resíduos do modelo. A FEG – UNESP possui computadores adequados para a execução deste estudo. Dessa forma, não houve limitações físicas ou de *software* para que a pesquisa fosse desenvolvida.

Este trabalho está estruturado em mais três seções além desta seção introdutória. A Seção 2 contemplou a fundamentação teórica sobre os temas abordados na pesquisa. A Seção 3 abordou a solução do problema e análise dos resultados, e por fim, a Seção 4 contemplou as conclusões e recomendações para futuras pesquisas.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 SIMULAÇÃO E FUNÇÕES EMPÍRICAS

De maneira geral, a simulação é uma ferramenta usada tanto na concepção de sistemas, como na adequação de sistemas já existentes, incluindo reconfigurações físicas, no controle e/ou nas regras que regem a operação de tais sistemas. Segundo Sakurada e Miyake (2009), a aplicabilidade da simulação como ferramenta de auxílio à tomada de decisão vem se expandindo em todas as áreas, fato que permite um conhecimento mais consistente a respeito das organizações e seus processos.

Realizar uma simulação significa realizar uma série de etapas, que podem ser resumidas, segundo Hillier e Lieberman (2010), da seguinte forma:

1. Definir o estado atual do sistema.
2. Identificar os possíveis estados do sistema.

3. Identificar os eventos que podem alterar os estados do sistema.
4. Estabelecer uma forma de controlar o tempo de simulação.
5. Estabelecer um método para gerar eventos aleatórios.
6. Formular um modelo que identifique os eventos e altere o estado do sistema.

Segundo Helene (2013), a análise de regressão pode ser usada para estimar uma função empírica, sendo aplicada com essa finalidade em muitas áreas do conhecimento. Por meio da construção de uma função empírica, é possível executar a fase de formulação do modelo, proposta por Hillier e Lieberman (2010).

A análise de regressão é uma ferramenta utilizada para avaliar a relação entre variáveis dependentes e independentes, por meio de uma equação linear, tal como expresso em (1):

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (1)$$

sendo y_i variável dependente, x_1, x_2, \dots, x_k as variáveis independentes, ε o fator de erro, e n o número de amostras observadas.

Existem diversas técnicas de análise de regressão, neste trabalho optou-se 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).

Estudando uma forma de solucionar problemas de blindagem em reatores nucleares, os pesquisadores Von Neumann e Ulam desenvolveram, em meados de 1940, a ferramenta conhecida como Simulação Monte Carlo (SMC) (CORRAR, 1993).

A função da SMC é satisfazer a 5ª etapa descrita por Hillier e Lieberman (2010), gerando números (eventos) aleatórios para alimentar o modelo matemático. Silva et al. (2014) comentam sobre a natureza estocástica de grande parte das variáveis em sistemas reais, entre as quais é possível citar o tempo das atividades de um projeto, objeto de estudo deste trabalho.

As amostras de números aleatórios são, em geral, obtidas computacionalmente (OLIVEIRA, BARROS e DOS REIS, 2007). Devem possuir parâmetros como média, desvio padrão e/ou seus limites máximo e mínimo, sendo modeladas seguindo distribuições de probabilidade como, por exemplo, Normal, Uniforme e Triangular, dentre outras. A função de densidade de distribuição de probabilidade triangular foi utilizada na realização do trabalho, como será apresentado adiante.

Assis et al. (2013) ressaltam que a SMC se destaca por, entre outras características, tratar-se de um método quantitativo, conforme ocorre a estabilização da curva de distribuição de probabilidade das variáveis dependentes do modelo matemático. Contudo, algumas desvantagens merecem destaque:

1. Demanda por grande capacidade computacional para realizar o processamento de dados.
2. Necessidade de conhecer a fundo o sistema com que se está trabalhando, a ponto de ser capaz de determinar as distribuições de probabilidade das variáveis de entrada.

Segundo Shahinidis (2004), a otimização por meio da simulação estocástica é aplicável a diversas frentes do conhecimento. Sua aplicabilidade se justifica por possibilitar a análise de diferentes cenários, pois gera informações relevantes acerca do sistema estudado (ABDELAZIZ, AOUNI & EL FAYEDH, 2007; AOUNI, ABDELAZIZ & MARTEL, 2005; DEB, 2001).

Abdelaziz, Aouni e El Fayedh (2007) propõem uma formulação genérica para a otimização estocástica:

$$\text{Max} \quad \sum_{j=1}^n \tilde{C}_j x_j \quad (2)$$

S.a:

$$\sum_{j=1}^n \tilde{A}_{ij} x_j \leq \tilde{b}_i \quad i = 1, 2, \dots, m \quad (3)$$

$$x \in X, X \text{ é o conjunto de soluções viáveis} \quad (4)$$

sendo $\tilde{C}_j, \tilde{A}_{ij}$ matrizes aleatórias e \tilde{b}_i um recurso aleatório estocástico.

O *software Crystal Ball®*, que será utilizado na realização deste trabalho, foi criado com base na SMC, e uma de suas ferramentas para solução é o *Optquest* (ORACLE, 2015). O *Optquest* é um otimizador que trata o modelo de simulação como uma “caixa-preta”, ou seja, o usuário só toma conhecimento das entradas e saídas do modelo de simulação. Ainda, esta ferramenta utiliza de maneira combinada as metaheurísticas de Busca Tabu, Redes Neurais e Busca Dispersa em uma única heurística de busca (KLEIJNEN & WAN, 2007).

O uso desta combinação de metaheurísticas significa que o otimizador *Optquest* do *software Crystal Ball®* busca as melhores soluções candidatas, entre essas soluções, aquelas que não atenderem às restrições são descartadas. Tais restrições podem ser definidas pelo usuário, sendo possível também especificar os limites para as saídas da simulação aleatória. Ele requer a definição de valores mínimos, sugeridos e máximos para as variáveis a serem otimizadas. O ponto de partida da busca são os valores sugeridos, e assim sendo, esta escolha afeta a eficiência e eficácia da busca (RODRIGUES, 2016).

3. SOLUÇÃO DO PROBLEMA E ANÁLISE DOS RESULTADOS

Este trabalho foi desenvolvido numa indústria do setor aeronáutico. O foco do estudo envolveu um processo de usinagem de componentes aeronáuticos, buscando otimizar os tempos de usinagem e ajustagem da máquina-ferramenta utilizada, dadas as dimensões da peça a ser usinada referentes a bitola, ao comprimento e a largura.

A modelagem foi realizada com base nos dados históricos do processo fornecidos pela empresa. Havia 541 linhas de dados, com as dimensões da peça a ser usinada: bitola (em polegadas), comprimento (em milímetros), largura (em milímetros) e, também, os tempos de usinagem e ajustagem referentes a cada peça (ambos em horas). A título de exemplo, os dados referentes a algumas linhas estão apresentados na Figura 4.

Com base no que foi apresentado pela empresa, definiu-se como variáveis de decisão:

- X1 – Bitola [pol]
- X2 – Largura [mm]
- X3 – Comprimento [mm]

As variáveis dependentes foram escolhidas, após consulta aos gestores da empresa, como sendo:

- Y1 – Tempo de usinagem [h]
- Y2 – Tempo de Ajustagem [h]
- Y3 = Y1 + Y2 - Tempo total do processo [h]

	A	B	C	D	E
1	Bitola (pol)	Largura (mm)	Comprimento (mm)	Usinagem (Y1)	Ajustagem (Y2)
2	0,75	275	225	1,35	0,5
3	1	275	225	1,5	0,55
4	1,25	185	890	2,6	0,9
5	0,75	165	120	0,65	0,3
6	1,25	130	160	0,85	0,4
7	1,25	370	170	1,45	0,6
8	1,25	170	380	1,45	0,6
9	2,5	90	120	1,05	0,4
10	2,5	90	120	1,05	0,4
11	2,25	100	110	1,05	0,4
12	2,25	115	75	0,95	0,35
13	2,5	90	120	0,85	0,4
14	2,5	115	95	1,05	0,4
15	2,5	90	120	0,85	0,4
16	2,5	125	95	0,9	0,4
17	1,75	195	100	0,95	0,4
18	2,5	115	100	0,9	0,45
19	2,25	120	130	1,15	0,45
20	2,25	100	120	1,05	0,4
21	1,5	230	330	1,7	0,7
22	0,75	155	125	0,65	0,3
23	2,5	205	140	1,35	0,6
24	2,75	160	190	1,65	0,6
25	1,75	80	380	1,4	0,5
26	1,75	70	180	1,1	0,35

Figura 4: Histórico de dados. Fonte: Empresa estudada

A modelagem do problema foi realizada utilizando-se ferramentas de regressão linear disponíveis no Excel® por meio do algoritmo dos mínimos quadrados ordinários (OLS). Os resultados da regressão estão apresentados na Figura 5 (tempo de usinagem) e na Figura 6 (tempo de ajustagem).

1	RESUMO DOS RESULTADOS								
2									
3	<i>Estatística de regressão</i>								
4	R múltiplo	0,936704524							
5	R-Quadrado	0,877415364							
6	R-quadrado ajustado	0,876730534	>70%						
7	Erro padrão	0,158164601							
8	Observações	541							
9									
10	ANOVA								
11		<i>gl</i>	<i>SQ</i>	<i>MQ</i>	<i>F</i>	<i>F de significação</i>			
12	Regressão	3	96,15282774	32,05094258	1281,215623	3,0502E-244			
13	Resíduo	537	13,43361403	0,025016041					
14	Total	540	109,5864418						
15									
16		<i>Coefficientes</i>	<i>Erro padrão</i>	<i>Stat t</i>	<i>valor-P</i>	<i>95% inferiores</i>	<i>% superior</i>	<i>Inferior 95,0%</i>	<i>Superior 95,0%</i>
17	Interseção	-0,286678377	0,026835829	-10,68267274	2,76304E-24	-0,339394449	-0,23396	-0,339394449	-0,233962305
18	Variável X 1	0,293673616	0,01040537	28,22327345	3,81E-108	0,273233395	0,314114	0,273233395	0,314113837
19	Variável X 2	0,002721168	7,83747E-05	34,71997506	2,297E-139	0,002567209	0,002875	0,002567209	0,002875126
20	Variável X 3	0,002746155	6,80774E-05	40,3387366	1,1706E-164	0,002612425	0,00288	0,002612425	0,002879886
21									

Figura 5: Resultados da Regressão do tempo de usinagem. Fonte: Excel®

1	RESUMO DOS RESULTADOS								
2									
3	<i>Estatística de regressão</i>								
4	R múltiplo	0,956382486							
5	R-Quadrado	0,91466746							
6	R-quadrado ajustado	0,914190741							
7	Erro padrão	0,048895988							
8	Observações	541							
9									
10	ANOVA								
11		<i>gl</i>	<i>SQ</i>	<i>MQ</i>	<i>F</i>	<i>F de significação</i>			
12	Regressão	3	13,76161151	4,587203837	1918,675742	1,7887E-286			
13	Resíduo	537	1,283869081	0,002390818					
14	Total	540	15,04548059						
15									
16		<i>Coefficientes</i>	<i>Erro padrão</i>	<i>Stat t</i>	<i>valor-P</i>	<i>95% inferiores</i>	<i>95% superiores</i>	<i>Inferior 95,0%</i>	<i>Superior 95,0%</i>
17	Interseção	-0,090832329	0,008296195	-10,94867334	2,55182E-25	-0,107129303	-0,074535354	-0,107129303	-0,074535354
18	Variável X 1	0,114306693	0,003216781	35,5344972	3,8922E-143	0,107987676	0,120625709	0,107987676	0,120625709
19	Variável X 2	0,001037978	2,42292E-05	42,83986868	2,2885E-175	0,000990382	0,001085573	0,000990382	0,001085573
20	Variável X 3	0,001020693	2,10459E-05	48,49849354	2,3142E-198	0,00097935	0,001062035	0,00097935	0,001062035
21									

Figura 6: Resultados da Regressão do tempo de ajustagem. Fonte: Excel®

Como visto nas Figuras 5 e 6, os valores de R²-ajustados para as variáveis Y1 e Y2 foram maiores que 70% (88% e 91%, respectivamente), apresentaram *p-value* menor que 5% e resíduos normais (como se destacará adiante). Dessa forma, conclui-se que não há tendenciosidade nas funções empíricas (HELENE, 2013). Portanto o nível descritivo dos coeficientes encontrados é satisfatório, sendo possível construir modelos para as variáveis dependentes, como descrito na Equação 5 e na Equação 6:

$$\hat{Y}_1 = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \tilde{\beta}_2 x_2 + \tilde{\beta}_3 x_3 \quad (5)$$

$$\hat{Y}_2 = \tilde{\beta}'_0 + \tilde{\beta}'_1 x_1 + \tilde{\beta}'_2 x_2 + \tilde{\beta}'_3 x_3 \quad (6)$$

Para verificar se os valores estimados pelo modelo matemático representavam a realidade, foi feita uma análise dos resíduos utilizando o *software MiniTab17®*. Como verificado nas Figuras 7 e 8, os valores dos resíduos seguiram uma distribuição normal (os valores de *p-value* foram maiores que 5%, aceitando-se a hipótese nula H₀), o que mostra que não há tendenciosidade no modelo, validando o mesmo.

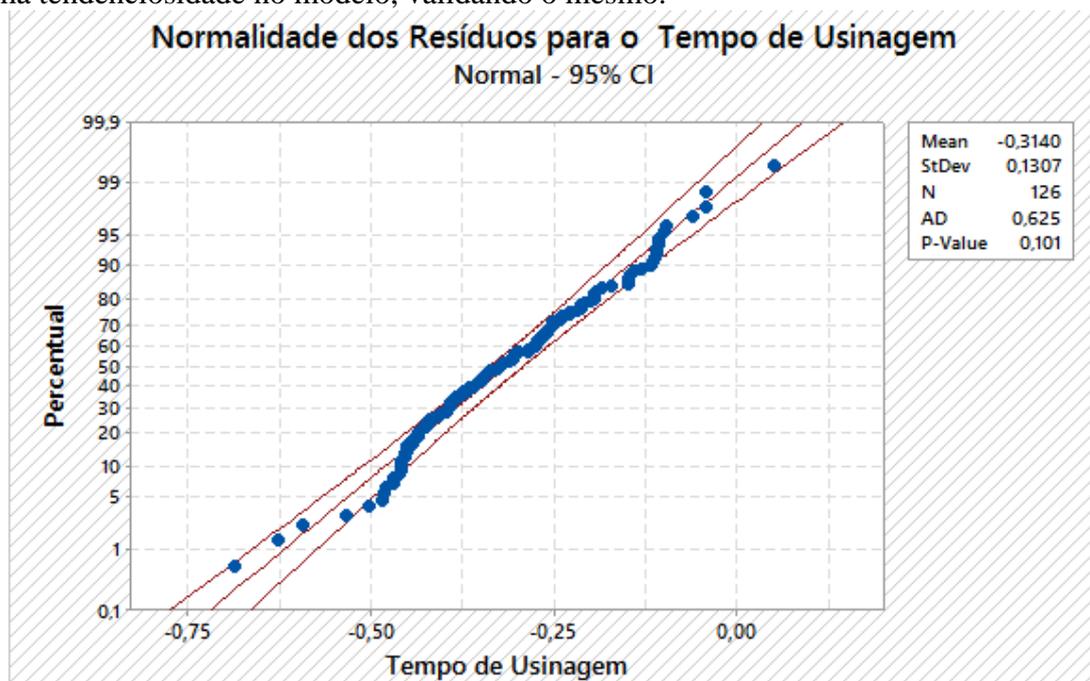


Figura 7: Análise de resíduos do modelo Y1. Fonte: MiniTab17®

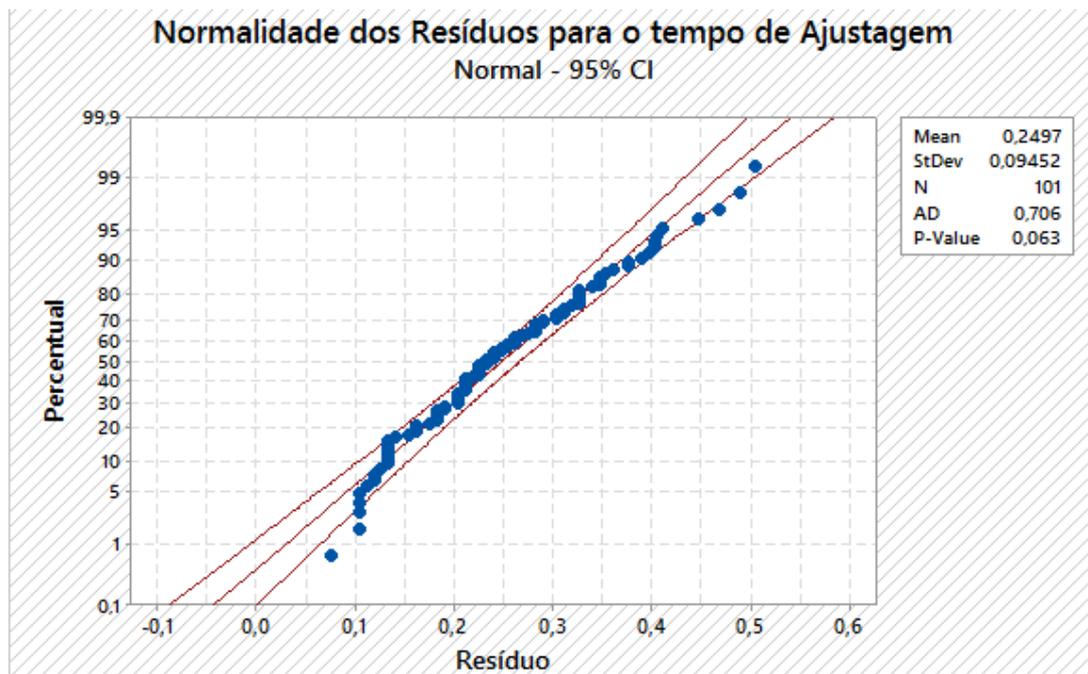


Figura 8: Análise de resíduos do modelo Y2. Fonte: *MiniTab17*®

Com o modelo validado, partiu-se para a otimização do mesmo por meio do *software Crystal Ball*® em conjunto com o otimizador *OptQuest*. A primeira etapa consistiu em informar as variáveis de decisão como discretas (ou seja, as variáveis assumiriam valores limitados pelo banco de dados da empresa, evitando que houvesse uma otimização de valores impossíveis de serem obtidos).

A próxima etapa consistiu em atribuir valores aleatórios para cada um dos coeficientes (β e β') das expressões (5) e (6), para tal, foram atribuídos valores $x \sim T$ [LI, VP, LS], com distribuição de probabilidade triangular (KOKONENDJI; KIESSÉ, ZOCCHI, 2007). Os valores dos parâmetros estão dispostos na Figura 8.

Y1	Coefficientes	95% inferiores (LB)	95% superiores (UB)
Interseção	-0,28667838	-0,339394449	-0,233962305
Variável X 1	0,293673616	0,273233395	0,314113837
Variável X 2	0,002721168	0,002567209	0,002875126
Variável X 3	0,002746155	0,002612425	0,002879886

Y2	Coefficientes	95% inferiores (LB)	95% superiores (UB)
Interseção	-0,09083233	-0,107129303	-0,074535354
Variável X 1	0,114306693	0,107987676	0,120625709
Variável X 2	0,001037978	0,000990382	0,001085573
Variável X 3	0,001020693	0,00097935	0,001062035

Figura 8: Parâmetros da distribuição de probabilidade triangular. Fonte: Excel®

A probabilidade triangular deve atender à Equação (7):

$$f(x) = \begin{cases} \frac{2(x - LI)}{(LS - LI)(VP - LI)} & LI \leq x < VP \\ \frac{2}{(LS - LI)} & x = VP \\ \frac{2(LS - x)}{(LS - LI)(LS - VP)} & VP < x \leq LS \\ 0 & \text{para qualquer outro valor} \end{cases} \quad (7)$$

sendo x uma variável aleatória e $f(x)$ a função que descreve sua densidade de probabilidade triangular, LI o limite inferior, VP o valor mais provável e LS o limite superior. Como exemplo, na Figura 9, é possível ver a distribuição triangular para o coeficiente $\tilde{\beta}_0$ da variável dependente $Y1$.

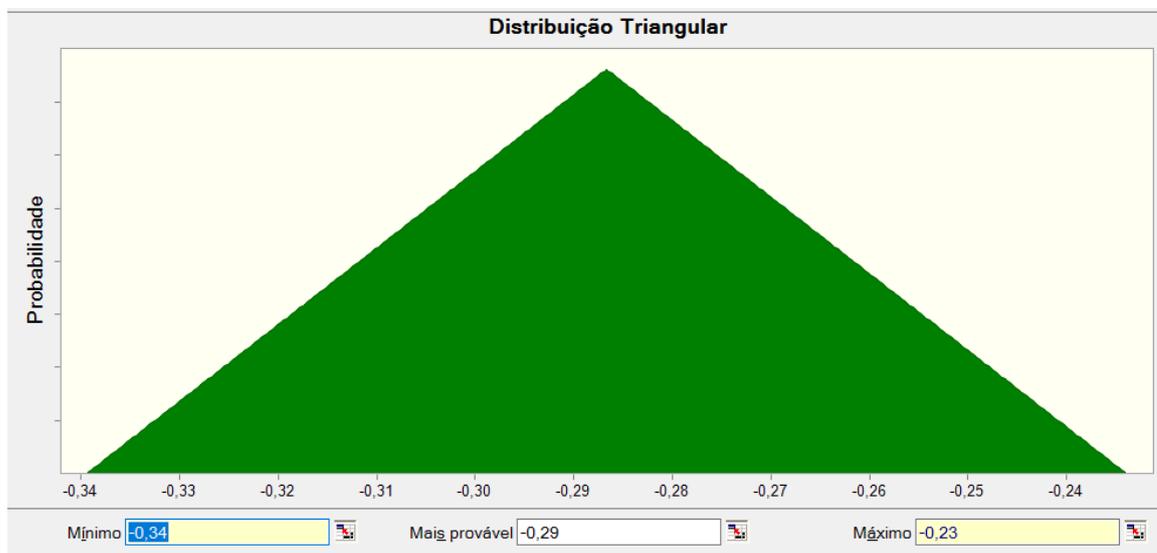


Figura 9: Distribuição triangular do coeficiente $\tilde{\beta}_0$. Fonte: *Crystal Ball*®

A OvSMC foi utilizada para determinar os valores das variáveis de entrada (dimensões da bitola, comprimento e largura) que atendem a uma certa especificação de tempo (valores-alvo). Para tal, foi utilizada a Equação (8) sujeita às restrições expressas nas Equações (9) e (10).

$$\tilde{Y}_3 = (\tilde{Y}_1 + \tilde{Y}_2) \in Y \text{ (conjunto dos valores - alvo)} \quad (8)$$

Sujeito a: (9)

$$\tilde{Y}_1, \tilde{Y}_2 \geq 0 \text{ (Tempo maior que zero)}$$

$$x_i \in X \text{ (Conjunto discreto de soluções viáveis)} \quad (10)$$

Foi determinado, em conjunto com os gestores da empresa, que seria pertinente definir como meta para $Y3$ o valor de 2 horas. Os resultados da OvSMC são apresentados nas Figuras 10 e 11.

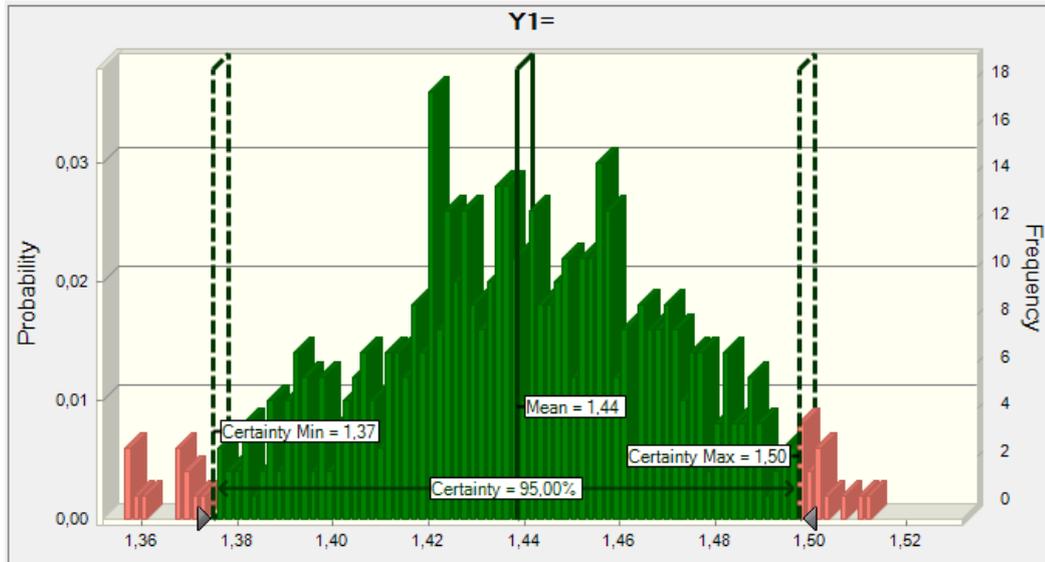


Figura 10: Resultado para a variável resposta “Tempo de Usinagem” Fonte: *Crystal Ball*®

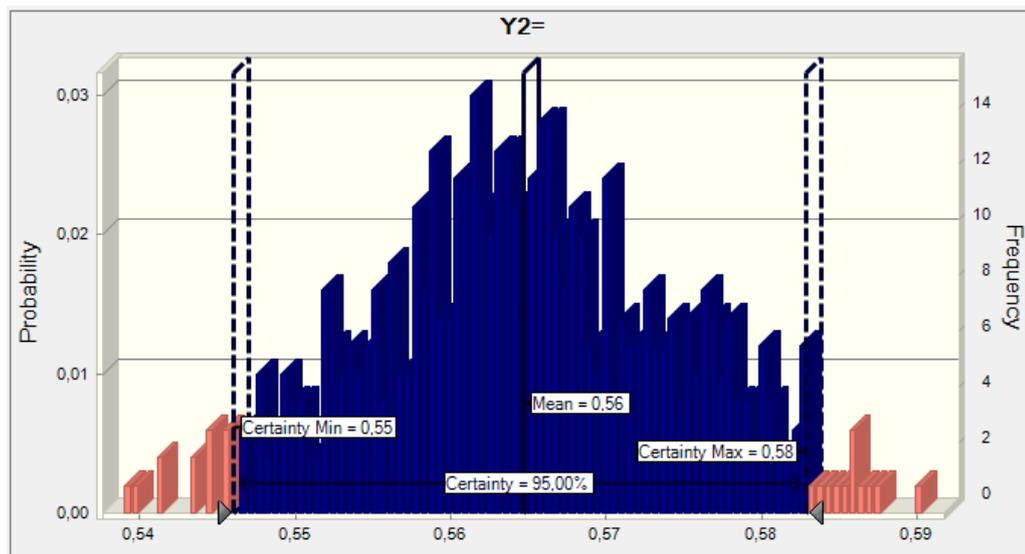


Figura 11: Resultado para a variável resposta “Tempo de Ajustagem” Fonte: *Crystal Ball*®

Observa-se nas Figuras 10 e 11 os valores dos limites inferior e superior das variáveis dependentes (ver Tabela 1) para um intervalo de confiança de 95%. Os ajustes propostos para as variáveis independentes (fatores ou variáveis x 's), que atendem à meta estipulada de 2 horas, estão especificados na Tabela 2.

Tabela 1: Intervalos (LI, LS) obtidos na OvSMC para variáveis de resposta.

Valor final das funções objetivo	LI	LS
\hat{Y}_1	1.37	1.5
\hat{Y}_2	0.55	0.58

Tabela 2: Ajuste proposto para as variáveis independentes

Variável de Entrada	Valor
x_1 [pol]	1,5
x_2 [mm]	245
x_3 [mm]	225

A fim de tornar os resultados do modelo mais próximos da realidade, realizou-se ainda um teste de correlação entre as variáveis independentes por meio do *software MiniTab17*®. Para tal foi utilizado o Teste de Correlação não paramétrico de Spearman, pois as variáveis em questão não seguem distribuição normal de probabilidades (Figura 12).

	X1	X2	X3
X2	-0,095 0,027		
X3	-0,150 0,000	-0,042 0,330	

Cell Contents: Spearman rho
P-Value

Figura 12: Teste de correlação entre as variáveis independentes. Fonte: *MiniTab17*®

Pelo Teste de Correlação de Spearman foi possível observar que há relação entre as variáveis comprimento (X_3) e bitola (X_1); largura (X_2) e bitola (X_1), pois em ambos os casos o *p-value* foi menor do que 5%, rejeitando-se H_0 , sendo tal hipótese referente à “não há correlação”.

Mesmo a correlação entre as variáveis sendo fraca (menor que 0,3), para maior acuracidade nos resultados da OvSMC, os valores encontrados foram adicionados à matriz de correlação do *Crystal Ball*®. Os resultados da nova simulação estão ilustrados nas Figuras 13 e 14.

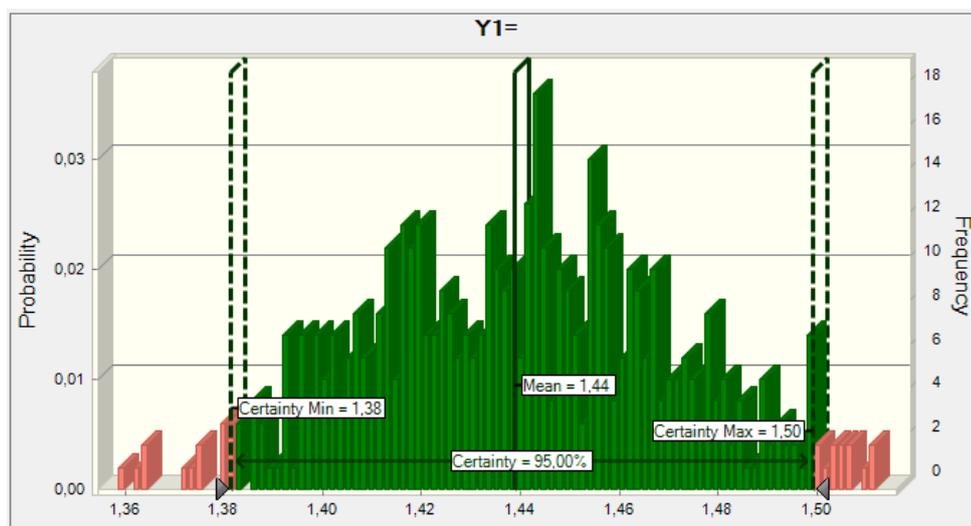


Figura 13: Resultado para a variável resposta “Tempo de Usinagem” com correlação. Fonte: *Crystal Ball*®

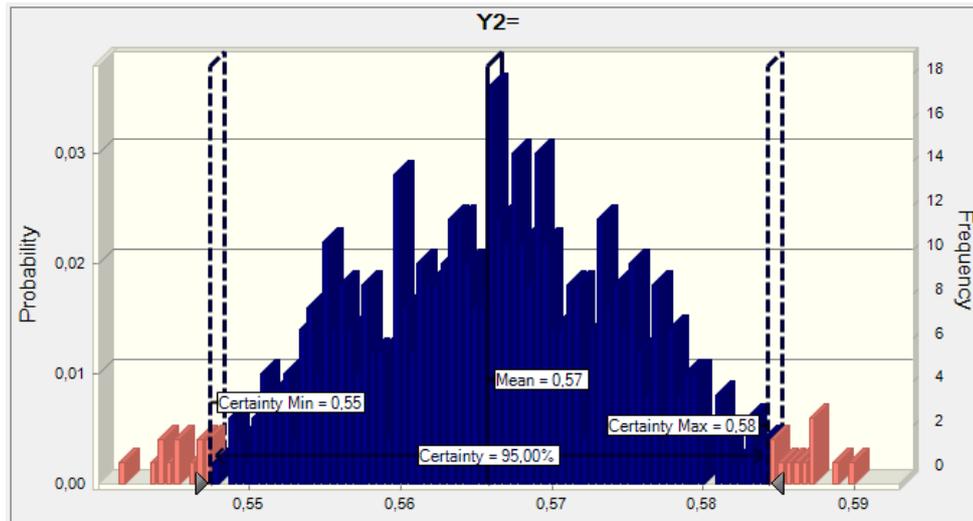


Figura 14: Resultado para a variável resposta “Tempo de Ajustagem” com correlação. Fonte: *Crystal Ball®*

Na Tabela 3 são apresentados os limites superior e inferior, com 95% de confiança, para as variáveis dependentes. Na Tabela 4 são apresentados os ajustes propostos para as variáveis independentes.

Tabela 3: Intervalos $([LI, LS])$ obtidos na OvSMC para variáveis de resposta com correlação.

Valor final das funções objetivo	LI	LS
\hat{Y}_1	1.38	1.5
\hat{Y}_2	0.55	0.58

Tabela 4: Ajuste proposto para as variáveis independentes com correlação

Variável de Entrada	Valor
X_1 [pol]	1,5
X_2 [mm]	290
X_3 [mm]	180

Entre os gestores consultados, todos pertencentes à empresa que foi objeto do estudo deste trabalho, foi consensual que os ajustes propostos eram possíveis e atenderam à meta de tempo estipulada, sendo os resultados da OvSMC considerando o efeito da correlação mais aderentes a realidade da empresa.

4. CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

Todos os objetivos gerais e específicos foram plenamente atendidos, e os resultados gerados foram promissores e aplicáveis na prática, respondendo à questão da pesquisa.

Com base nos resultados obtidos, é possível concluir que a OvSMC é uma ferramenta que contribui na melhora da determinação de parâmetros envolvidos em processos de manufatura de peças do setor aeronáutico. Tal conclusão se justifica à medida que os ajustes propostos foram validados junto aos gestores da empresa e atenderam ao tempo de processo estipulado pelos mesmos gestores, dentro de um intervalo de confiança de 95%.

Os objetivos específicos foram satisfeitos ao passo que a função empírica desenvolvida foi adequada para representar o processo real de manufatura da empresa, bem como forneceu ajustes apropriados para bitola, comprimento e largura, predizendo os tempos de usinagem e ajustagem por meio da OvSMC.

Vale ressaltar que, na elaboração de um modelo que represente de forma aderente à realidade, a análise de correlação foi importante e influenciou no ajuste das variáveis de decisão, pois, no caso apresentado, foram geradas variações na solução proposta, mesmo a correlação tendo sido fraca (menor que 0,3).

Para futuros trabalhos se sugere a aplicação de modelos de OvSMC em indústrias de diferentes setores ou em problemas de natureza diferente como, por exemplo, no mercado financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDELAZIZ, F. B.; AOUNI, B. & EL FAYEDH, R. Multi-objective stochastic programming for portfolio selection. *European Journal of Operational Research*, v. 177, 1811-1823, 2007.

AOUNI, B., BEN ABDELAZIZ, F. & MARTEL, J. M. Decision-makers preferences modeling in the stochastic goal programming. *European Journal of Operational Research*, v. 162, p. 610-618, 2005.

ASSIS, A. FRANCIS, F. RABECHINI JR, R. Gestão de Riscos: Fundamentos e Práticas – Análise Qualitativa e Quantitativa de Riscos. 100 p. Goiânia, 2013.

ASSOCIAÇÃO DAS INDÚSTRIAS AEROESPACIAIS DO BRASIL – AIAB. Números da Associação das Indústrias Aeroespaciais do Brasil. 2017 Acesso em: 11 de abril de 2017. Disponível em: <<http://www.aiab.org.br/numeros-da-aiab.asp>>.

BERTRAND, J. W. M, FRANSOO, J. C. Operations management research methodologies using quantitative modeling. *International Journal of Operations and Production Management*, v. 22, p. 241 – 264, 2002.

BOYLAN, G. L.; GOETHALS, P. L.; CHO, B. R. Robust parameter design in resource-constrained environments: an investigation of trade-offs between costs and precision within variable processes. *Applied Mathematical Modelling*, v. 37, p. 2394-2416, 2013.

CORRAR, L. J. O modelo econômico da empresa em condições de incerteza - aplicação do método de simulação de Monte Carlo. *Caderno de Estudos*, São Paulo: FIPECAFI/FEA/USP, n. 8, p. 1-13, 1993.

DEB, K. Multi-Objective optimization using evolutionary algorithms. Chichester: John Wiley & Sons, 2001.

EHRGOTT, M.; IDE, J.; SCHÖBEL, A. Minmax robustness for multi-objective optimization problems. *European Journal of Operational Research*, v. 239, p. 17- 31, 2014.

FERRARO, M. B.; GIORDANI, P. A. Multiple linear regression model for imprecise information. *Metrika*, v. 75, p.1049-1068, 2012.

GOMES, S. B. V. A indústria aeronáutica no Brasil: evolução recente e perspectivas. Rio de Janeiro: BNDES, 2015.

HELENE, W . Rethinking the linear regression model for spatial ecological data. *Ecology*. 94, p. 2381 -2391, 2013.

HILLIER, F.S., LIEBERMAN, G.J. Introduction to Operations Research, ninth ed. McGraw-Hill, New York, 2010.

KLEIJNEN, J. P. C.; WAN, J. Optimization of simulated systems: Optquest and alternatives. *Simulation Modelling Practice and Theory*, v. 15, p. 354-362, 2007.

KOKONENDJI, C. C., KIESSÉ, T. S.; ZOCCHI, S. S. Discrete triangular distributions and non-parametric estimation for probability mass function. *Journal of Nonparametric Statistics*, v. 19, p. 241-257, 2007.

LIU, H.; WEI, G.; XU, Z.; LIU, P.; LI, Y. Quantitative analysis of Fe and Co in Co-substituted magnetite using XPS: The application of non-linear least squares fitting (NLLSF). *Applied Surface Science*, v. 389, p. 438-446, 2016.

MONTORO, G. C. F.; MIGON, M. N. Cadeia Produtiva Aeronáutica Brasileira: oportunidades e desafios. Rio de Janeiro: BNDES, 2009. Acesso em: 11 de abril de 2017. Disponível em: <<https://web.bndes.gov.br/bib/jspui/handle/1408/1911>>

MORAES, M. B.; OLIVEIRA, E. A. A. Q.; LOBOSCO, A.; SOUZA, V. B. R. Regional Innovation System of Brazilian Aeronautical Industry. Latin American Journal of Business Management, v. 7, n. 1, p. 152-166, 2016.

OLIVEIRA, P.H.D. BARROS, N.R. dos REIS, S.G. Aplicabilidade do Método de Simulação Monte Carlo na Previsão dos Custos de Produção de Companhias Industriais: O Caso da Companhia Vale do Rio Doce. Revista de Contabilidade e Organizações – USP. São Paulo, 2010. Acesso em: 14 de abril de 2017. Disponível em: <<http://www.revistas.usp.br/rco/article/view/34781>>

ORACLE. Oracle Crystal Ball – Visão Geral. Disponível em: <<http://www.oracle.com/br/products/applications/crystalball/overview/index.html>>. Acesso em: 22 de abril de 2017.

PAIVA, E. J.; FERREIRA, J. R.; PAIVA, A. P. Otimização de processos de manufatura com múltiplas respostas baseada em índices de capacidade Cpm. ENEGEP, Foz do Iguaçu, Paraná, Brasil, 2007. Acesso em: 22 de abril de 2017. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2007_TR580439_0302.pdf>

RODRIGUES, D. M. Otimização Multiobjetivo em Problemas de Delineamento de Experimentos. Guaratinguetá: FEG – UNESP; 2016. Acesso em: 22 de abril de 2017. Disponível em: <<https://repositorio.unesp.br/handle/11449/144446>>.

SAKURADA, N. MIYAKE, D.I. Aplicação de Simuladores de Eventos Discretos no Processo de Modelagem de Sistemas de Operações de Serviços. Gestão da Produção, v.16, n.1, p. 25-43. São Carlos, 2009.

SHAHINIDIS, N. V. Optimization under uncertainty: state of the art and opportunities. Computers and Chemical Engineering, v. 28, p. 971–983, 2004.

SILVA, A.F., SILVA, M.F.F., MARINS, F.A.S. Otimização Estocástica com Múltiplos Objetivos e Simulação Monte Carlo no Desenvolvimento de Estratégias de Vendas. PODes – Revista Eletrônica Pesquisa Operacional para o Desenvolvimento, v.6, n.1, p.35-53. Rio de Janeiro, 2014.