

KAIO MAX ARANDA

**Aplicação da otimização via simulação Monte Carlo na melhoria
de processos de fabricação de peças aeronáuticas**

Guaratinguetá - SP
2017

Kaio Max Aranda

**Aplicação da otimização via simulação Monte Carlo na melhoria
de processos de fabricação de peças aeronáuticas**

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia Mecânica da Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Mecânica.

Orientador: Prof. Dr. Aneirson Francisco da Silva

Guaratinguetá - SP
2017

Aranda, Kaio Max
A662a Aplicação da otimização via simulação Monte Carlo na melhoria de processos de fabricação de peças aeronáuticas/ Kaio Max Aranda – Guaratinguetá, 2017.
55 f : il.
Bibliografia: f. 53-55

Trabalho de Graduação em Engenharia Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2017.
Orientador: Prof. Dr. Aneirson Francisco da Silva

1. Controle de processo – Métodos estatísticos. 2. Monte Carlo – Método. 3. Processos de fabricação. I. Título

CDU 658.511.3



Luciana Máximo

Bibliotecária/CRB-8 3595

KAIO MAX ARANDA

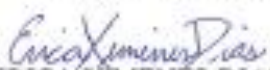
ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE
“GRADUADO EM ENGENHARIA MECÂNICA”


APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA

Prof. Dr. MARCELO SAMPAIO MARTINS
Coordenador

BANCA EXAMINADORA:


Prof. Dr. ANEIRSON FRANCISCO DA SILVA
Orientador/UNESP-FEG


Prof. Dra. ERICA XIMENES DIAS
UNESP-FEG


Eng. PATRICIA BOZOLA
Membro Externo

Novembro, 2017

DADOS CURRICULARES

KAIO MAX ARANDA

NASCIMENTO 04.11.1990 – São Paulo / SP

FILIAÇÃO Antonio Carlos Aranda
Jana Štruncova Aranda

2010/2017 Curso de Graduação em Engenharia Mecânica, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista.

AGRADECIMENTOS

Dedico este trabalho primeiramente a Deus, que sempre me deu forças para concluir mais uma etapa da minha vida, depois especialmente aos meus pais, Antonio Carlos Aranda e Jana Štruncová Aranda, que sempre me incentivaram e me apoiaram em todas decisões que escolhi ao longo do tempo. Não posso deixar de lembrar do meu orientador, Prof. Dr. Aneirson Francisco da Silva, que me proporcionou muito conhecimento, fazendo eu me interessar pelo tema que está em grande desenvolvimento.

“Os sonhos não determinam o lugar em que
você vai estar, mas produzem a força
necessária para tirá-lo do lugar em que está.”

Augusto Cury

RESUMO

O cenário a partir da década de 2010 das organizações corporativas está cada vez mais competitivo e esta busca pela excelência está cada vez mais desafiadora, desta maneira, uma empresa que busca competitividade no mercado está buscando cada vez mais conhecer o seu processo a fim de se ter uma alta eficiência. A partir do momento em que fala-se em alta eficiência, busca-se fazer bem as tarefas, administrar os custos, reduzir as perdas e o desperdício, sendo assim, quando as empresas buscam o conhecimento do processo, ela está altamente ligada no processo de melhoria da linha, a fim de buscar maior produtividade, utilizando-se da gestão de recursos, recursos adequados e ferramentas ligadas à análise estatística de indicadores produtivos. Partindo-se desse fluxo, o objetivo deste trabalho visa prever a matéria-prima (bitola de aço) que deve ser iniciada na linha de produção, partindo de um determinado tempo de fabricação da peça, incluindo tempo de usinagem e ajustagem, por meio de uma função empírica, pois quando os métodos tradicionais estatísticos não atendem os requisitos necessários, métodos computacionais como simulações aparecem como uma outra forte ferramenta disponível na literatura, desta forma o foco é explorar o impacto da utilização da simulação computacional, utilizando a ferramenta otimização via Simulação Monte Carlo a fim de melhorar processos de fabricação de peças aeronáuticas.

PALAVRAS-CHAVE: Melhoria de processos. Simulação Monte Carlo. Modelos matemáticos. Previsão. Aeronáutica.

ABSTRACT

The scenario from the 2010 corporate organizations is increasingly competitive and looking for excellence is challenging, so a company that seeks competitiveness without a market is increasingly seeking to know how the process is working to have a high efficiency. When we talk about high efficiency, we are seeking to do well the tasks, manage costs, reduce losses and waste. This companies are seeking to develop knowledge from the process and it is highly linked to the continuous improvement to manage and adequate resources, a search for greater productivity and statistical tools analysis of productive indicators. Starting from the flow, the objective of this work is to predict the raw material (steel gauge) to be started in the production line, given a certain time of manufacture of the part, including machining and setup, by means of an empirical function, because when alternative methods are not met in the requirements, computational methods like simulations appear as another tool, in this way the focus and the impact of the use of the computational simulation, using the Monte Carlo Simulation in order to optimize the models mathematicians in an aeronautical parts manufacturing industry.

KEYWORDS: Continuous improvement. Monte Carlo simulation. Math model. Forecast. Aeronautics.

LISTA DE ILUSTRAÇÕES

Figura 1 - Publicações gerados pela pesquisa da palavra-chave “Monte Carlo Simulation” ...	15
Figura 2 - Publicações gerados pela pesquisa da palavra-chave “Optimization via Monte Carlo Simulation”	15
Figura 3 – Exemplo do Teste de Hipótese para a correlação	20
Figura 4 - Organização dos insumos	34
Figura 5 - Setup Regressão para a família Batente/Painel/Suporte/Puxador	36
Figura 6 - Regressão Output Usinagem (batente/painel/suporte/puxador)	37
Figura 7 - Regressão Output Ajustagem (batente/painel/suporte/puxador)	38
Figura 8 - OvSMC solução ótima (batente /painel/suporte/ puxador).....	40
Figura 9 - Distribuição normal tempo fabricação (batente/painel/suporte/puxador)	41
Figura 10 - Distribuição normal tempo usinagem (batente/painel/suporte/puxador).....	41
Figura 11 - Distribuição normal tempo ajustagem (batente/painel/suporte/puxador).....	42
Figura 12 - Regressão Output Usinagem (ferragem).....	43
Figura 13 - Regressão Output Ajustagem (ferragem)	44
Figura 14 - OvSMC solução ótima (ferragem).....	46
Figura 15 - Distribuição normal tempo fabricação (ferragem).....	47
Figura 16 - Distribuição normal tempo de usinagem (ferragem)	47
Figura 17 - Distribuição normal tempo de ajustagem (ferragem)	48

LISTA DE TABELAS

Tabela 1 - Artigo Scopus	16
Tabela 2 - Quantidade de peças	35

LISTA DE ABREVIATURAS E SIGLAS

MC	Método Monte Carlo;
MP	Matéria-prima;
SMC	Simulação de Monte Carlo;
OvSMC	Otimização via Simulação Monte Carlo;

LISTA DE SÍMBOLOS

r_{xy}	Coeficiente de correlação de Pearson
$C\hat{O}V$	Covariância
MMQ	Método dos Mínimos Quadrados
SPD	Somatório dos Produtos das Diferenças
SQD	Somatório dos Quadrados das Diferenças

SUMÁRIO

1.	INTRODUÇÃO	13
1.1.	CONSIDERAÇÕES INICIAIS	13
1.2.	OBJETIVO GERAL	14
1.3.	DELIMITAÇÃO	14
1.4.	JUSTIFICATIVA	14
1.5.	MATERIAIS E MÉTODOS	16
1.6.	ESTRUTURA DO TRABALHO	17
2.	REFERENCIAL TEÓRICO	18
2.1.	CONSTRUÇÃO DE FUNÇÕES EMPÍRICAS	18
2.1.1.	Correlação	18
2.1.1.1.	Teste de Significância para o Coeficiente de Correlação	19
2.1.2.	Regressão	20
2.1.2.1.	Regressão Linear Simples	21
2.1.2.2.	Método dos Mínimos Quadrados (MMQ)	22
2.1.2.3.	Coeficiente de Determinação para Regressão Linear Simples	23
2.1.2.4.	Teste de Hipótese na Regressão Linear Simples	24
2.1.3.	Regressão Linear Múltipla	25
2.1.3.1.	Coeficiente de Determinação para Regressão Linear Múltipla	27
2.1.3.2.	Teste de Significância da Regressão Linear Múltipla	27
2.1.3.3.	Método ANOVA (Análise de Variância)	28
2.1.4.	Função de 2º Grau	29
2.2.	OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO	30
3.	DESENVOLVIMENTO E RESULTADOS DO PROBLEMA	33
3.1.	DESCRIÇÃO DO PROBLEMA	33
3.1.1.	Coleta de dados	33
3.1.2.	Modelagem do problema	35
3.1.3.	Solução do modelo	36
3.1.3.1.	Família: Batente/Painel/Suporte/Puxador	36
3.1.3.2.	Família: Ferragem	42
4.	CONCLUSÃO E CONSIDERAÇÕES FINAIS	49
	REFERÊNCIAS	50

1. INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

O Brasil tem apresentado grande crescimento no setor aeronáutico nos últimos 10 anos, tendo sua utilização triplicada, segundo dados da ANAC (Agência Nacional de Aviação Civil), em que comprovam a utilização crescente dos brasileiros no transporte aéreo para sua locomoção. O crescimento se expande também na capacidade de números de aeronaves (5% ao ano) e também nos profissionais do setor (ALMEIDA & MINERVI, 2016).

O aumento crescente da concorrência no ambiente empresarial levou as corporações a fazer uma análise mais crítica do seu processo, o que as levou a uma tomada de decisão mais coesa (CONDUTA & SOUZA, 2013).

O desenvolvimento de novas tecnologias e a evolução das informações geradas por ela, proporcionaram maior efetividade na coleta de dados, impactando na forma de gerenciamento e tomada de decisão dos processos internos das empresas, pois a base de sustentação da informação é a coleta de dados. Os autores Seamster e Kanki (2002) frisaram a importância das bases de dados na aviação, pois além de criar, gerenciar e distribuir os dados de forma adequada o gerenciamento só faz sentido se for utilizado para fins nobres.

O desenvolvimento estratégico das empresas se dá pelo conhecimento e informações aliados aos sistemas, a tecnologia da informação proporcionou que esses sistemas fossem aprimorados, trazendo grandes impactos no mundo dos negócios (CONDUTA & SOUZA, 2013).

Os sistemas de informações podem ser considerados uma ferramenta de simulação na qual obtiveram grandes avanços a partir da década de 80, novos softwares foram desenvolvidos conjuntamente com o aumento da agilidade no processamento de dados, softwares como o Ms-Excel®, Minitab®, MAP/1®, SPSS®, Matlab®, dentre outros similares (CONDUTA & SOUZA, 2013).

A Simulação Monte Carlo é uma das ferramentas fundamentais quando se leva em conta o risco em análises quantitativas e tomadas de decisão, fornecendo ao responsável uma gama de resultados possíveis e as probabilidades de ocorrência de acordo com a decisão (PERDOSO, 2007).

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). Mercado

altamente globalizado e exigente que obrigam as empresas a reduzirem seus custos para que seus produtos ganhem força perante outros, vertentes da literatura defendem um progresso humano com o estacionamento do crescimento econômico e atividade exacerbada da atividade industrial (SCHNEIDER, KALLIS, & MARTINEZ-ALIER, 2010).

Esse estudo gerou a seguinte questão de pesquisa:

- Há vantagens na utilização da Otimização via Simulação Monte Carlo para ajustar processos produtivos aeronáuticos?

1.2. OBJETIVO GERAL

O objetivo geral deste estudo é utilizar a otimização via Simulação Monte Carlo na predição da matéria-prima a ser iniciada no processo de usinagem, dados os tempos de fabricação e *setup* de uma linha produtiva de peças aeronáuticas.

Os objetivos específicos:

- Desenvolver funções empíricas que representem adequadamente o problema analisado.
- Validar estatisticamente os resultados da Otimização via Simulação Monte Carlo.


1.3. DELIMITAÇÃO

O objeto de estudo deste trabalho será com 2 famílias de peças, elas serão escolhidas pelo maior nível de significância, ou seja, com base na maior quantidade de amostras recolhidas no período analisado.

1.4. JUSTIFICATIVA

Analisando o relatório emitido pelo site *Scopus* quando utilizadas as palavras-chave destacadas na Tabela 1 pode-se observar que o assunto sobre Simulação Monte Carlo é um assunto que teve um crescimento rápido e de grande relevância para as pesquisas nos últimos 20 anos, totalizando 153.670 documentos, conforme retratado na Figura 1.


Figura 1 - Publicações gerados pela pesquisa da palavra-chave “*Monte Carlo Simulation*”



Fonte: Scopus (2017)

Quando é realizada a pesquisa com a palavra-chave “*Optimization via Monte Carlo Simulation*”, representado pela Figura 2, não se observa esse mesmo crescimento, cerca de 0,4% se comparado com os resultados obtidos da Figura 1.

Figura 2 - Publicações gerados pela pesquisa da palavra-chave “*Optimization via Monte Carlo Simulation*”



Fonte: Scopus (2017)

O mesmo estudo também foi realizado com a palavra-chave “*Optimization via Monte Carlo Simulation Aerospace*”, obtendo apenas 10 documentos no mesmo período de 20 anos, evidenciando uma lacuna de pesquisa, comprovando que o tema foi explorado vagamente.

Tabela 1 - Artigo Scopus

Site	Palavra chave	Artigos encontrados
Scopus	Monte Carlo Simulation	153.670
Scopus	Optimization via Monte Carlo Simulation	647
Scopus	Optimization via Monte Carlo Simulation Aerospace	10

Fonte: Produção do próprio autor

Com base na escassez de informações no setor, avanço das novas tecnologias, o mercado buscando o reaquecimento e o conceito de redução de custos que se torna cada vez mais forte nas indústrias brasileiras, a empresa do objeto de pesquisa se adequa à causa, dessa maneira foi modelada a função empírica via regressão linear e assim pôde-se analisar o impacto do tipo de matéria-prima à ser iniciada na linha de produção em função do tempo de fabricação, fazendo uso da ferramenta de otimização e validando o modelo via Simulação Monte Carlo.

1.5. MATERIAIS E MÉTODOS

Os materiais utilizados são:

1. Os dados para realização do trabalho foram coletados entre os anos de 2010 a 2015 e também observações de campo.
2. Foi utilizado o *software* Ms-Excel® na coleta dos dados e a fim de encontrar e analisar os modelos matemáticos lineares e não lineares, que vão descrever o comportamento do tempo estimado de *setup* e fabricação dos componentes aeronáuticos.

3. Após a escolha do melhor modelo que descreve o processo estudado, será aplicada a Otimização via Simulação Monte Carlo para a previsão da matéria-prima. Especificamente será utilizado uma ferramenta (*Add-in*) chamada *Crystal Ball* do Excel® na versão de avaliação (*Trial*).

De acordo com Bertrand e Fransoo (2002), este trabalho pode ser classificado como sendo uma pesquisa aplicada, com objetivos empíricos descritivos, pois o modelo de simulação desenvolvido descreve as relações causais que podem existir na realidade, favorecendo a compreensão de processos reais. A forma de abordar o problema é quantitativa, sendo o método de pesquisa a modelagem e simulação.

1.6. ESTRUTURA DO TRABALHO

Este trabalho está estruturado em quatro capítulos, contando com este que está sendo lido. O Capítulo 2, apresenta o referencial teórico, contendo temas que são relatados no trabalho, construção de funções empíricas, SMC e OvSMC. No Capítulo 3, são retratados o desenvolvimento e resultados do problema, bem como a modelagem das funções para suas respectivas análises. Finalizando com o Capítulo 4, onde serão apresentadas as conclusões, verificação dos objetivos e referências bibliográficas.

2. REFERENCIAL TEÓRICO

2.1. CONSTRUÇÃO DE FUNÇÕES EMPÍRICAS

2.1.1. Correlação

É utilizada para estudar a relação estatística de associação e dependência entre duas variáveis quantitativas distintas, isto é, o grau de influência entre duas variáveis aleatórias X e Y (LEVINE, BERENSON, & STEPHAN, 2000). Dessa forma, percebe-se quando se tem alteração no valor de uma variável (independente X), pois a variável dependente (Y) muda conseqüentemente, o diagrama de dispersão pode ser utilizado para representação gráfica, algumas análises podem ser feitas com o diagrama:

- Correlação positiva: o aumento de uma variável acarreta no aumento da outra variável.
- Correlação negativa: a diminuição de uma variável acarreta na diminuição da outra variável.
- Não correlacionada: quando os pontos não apresentam uma tendência, ou seja, os pontos estão dispersos no diagrama, sem definição de direção.

O coeficiente de correlação de Pearson (r_{xy}) é utilizado para se afirmar se existe correlação entre as variáveis, e é correspondido por um valor numérico, caso o módulo desse valor seja maior ou igual a 0,7, diz-se que há uma forte correlação. Sendo uma amostra X e Y, expressão (1):

$$\begin{array}{c|cccc}
 X_i & X_1 & X_2 & X_3 & \dots & X_n \\
 \hline
 Y_i & Y_1 & Y_2 & Y_3 & \dots & Y_n
 \end{array} \quad (1)$$

O coeficiente de correlação de Pearson (r_{xy}) entre os valores X e Y, sendo representado na equação (2):

$$r_{xy} = \frac{C\hat{O}V(X,Y)}{\sqrt{\hat{V}(X)} \cdot \sqrt{\hat{V}(Y)}} = \frac{\frac{SPD_{XY}}{n-1}}{\sqrt{\frac{SQD_X}{n-1} \cdot \frac{SQD_Y}{n-1}}} = \frac{SPD_{XY}}{\sqrt{SQD_X \cdot SQD_Y}} \quad -1 \leq r_{xy} \leq 1 \quad (2)$$

$$SPD_{XY} = \sum_{i=1}^n X_i \cdot Y_i - \frac{[\sum_{i=1}^n X_i][\sum_{i=1}^n Y_i]}{n} \quad (3)$$

$$SQD_X = \sum_{i=1}^n X_i^2 - \frac{[\sum_{i=1}^n X_i]^2}{n} \quad (4)$$

e

$$SQD_Y = \sum_{i=1}^n Y_i^2 - \frac{[\sum_{i=1}^n Y_i]^2}{n} \quad (5)$$

2.1.1.1. Teste de Significância para o Coeficiente de Correlação


Segundo Dancey e Reidy (2006), o teste de hipótese muitas vezes é visto como uma disputa entre 2 hipóteses, ou seja, se há relação entre as 2 variáveis ou não entre a população. Na correlação é chamado de teste de significância, no qual verifica se o valor encontrado na correlação (r_{xy}) é coerente com o tamanho da amostra coletado (n) e com o nível de significância (α), representado na equação (6):

$$t_C = \frac{r_{xy} \cdot \sqrt{n-2}}{\sqrt{1-r_{xy}^2}} \quad (6)$$

O valor encontrado em t_C deve ser comparada com o valor da tabela “*t – Student*” $t_C < t_{tabela}$, aceita H_0 (hipótese nula), ou seja, não existe relação entre as 2 variáveis na população.

- $t_C \geq t_{tabela}$, aceita H_1 (hipótese alternativa), ou seja, existe correlação entre as 2 variáveis na população.

A Figura 3 representa graficamente um exemplo do teste de hipótese.
Figura 3 – Exemplo do Teste de Hipótese para a correlação



Fonte: Minitab® (2017)

2.1.2. Regressão

A análise de regressão é utilizada quando há a necessidade de um estudo estatístico com o objetivo de descobrir se há a existência de uma relação funcional entre uma variável dependente ou variável de resposta (Y) com uma ou mais variáveis independentes ou variáveis de entrada (X), podendo ser representado pelo gráfico de dispersão, onde se nota a relação funcional do comportamento da variável (Y) em função da variável (X) (NAGHETTINI & PINTO, 2007). A relação entre Y e X pode apresentar-se como uma função:

- Linear.
- Quadrática.
- Cúbica.
- Exponencial.
- Logarítmica.
- Etc.

A definição de qual função será representada influenciará no estabelecimento do modelo matemático, a distribuição dos dados nos mostrará qual tipo de curva mais se adequa a representação dos pontos no diagrama de dispersão.

Pelo fato do estabelecimento de um modelo matemático, os pontos do diagrama não ficarão exatamente na curva proposta, pois existem variações das mais variadas espécies, sendo assim, o objetivo central da regressão é obter um modelo matemático que melhor se adequa aos dados observados da variável dependente (Y) em função das variações da variável independente (X) (DANCEY & REIDY, 2006).

O modelo matemático que melhor se adequou deve ser coerente com o que ocorre na prática, assim sendo, devem ser consideradas apenas as variáveis que são relevantes para explicar o fenômeno, ou seja, analisando 5 variáveis independentes (X) e se 3 não influenciarem, deve ser retiradas do estudo e realizar o mesmo novamente (HOFFMANN, 2015).

2.1.2.1. Regressão Linear Simples

Considerando que haja um relacionamento linear entre a variável dependente (Y) e a variável independente (X), o modelo estatístico seria representado na equação (7):

$$Y_i = \beta_0 + \beta_1 X_i + e_i \quad (7)$$

Y_i = variável dependente Y no *i-ésimo* nível da variável independente X.

β_0 = constante de regressão, representa o intercepto da reta com o eixo dos Y.

β_1 = coeficiente de regressão, representa a variação de Y em função da variação de uma unidade da unidade da variável X.

X_i = *i-ésimo* nível da variável independente X ($i = 1, 2, 3, \dots, n$)

e_i = é o erro que está associado à distância entre o valor observado Y_i e o correspondente ponto na curva do modelo proposto, para o mesmo nível de X.

2.1.2.2. Método dos Mínimos Quadrados (MMQ)

É um método utilizado para se obter uma relação funcional mais adequada do modelo, responsável pela minimização da distância entre os pontos do diagrama e do modelo matemático, dessa forma a relação funcional entre X e Y é estimada com um mínimo de erro possível, garantindo uma maior precisão e confiabilidade dos pontos e da curva gerada (NAGHETTINI & PINTO, 2007).

Para se obter a equação estimada de minimização do erro, utilizando o MMQ:

$$e_i = Y_i - \beta_0 - \beta_1 X_i \quad (8)$$

Elevando os membros ao quadrado,

$$e_i^2 = [Y_i - \beta_0 - \beta_1 X_i]^2 = Y_i^2 - 2Y_i\beta_0 - 2Y_i\beta_1 X_i + \beta_0^2 + 2\beta_0\beta_1 X_i + \beta_1^2 X_i^2 \quad (9)$$

Aplicando o somatório,

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n [Y_i - \beta_0 - \beta_1 X_i]^2 = \sum_{i=1}^n Y_i^2 - 2\beta_0 \sum_{i=1}^n Y_i - 2\beta_1 \sum_{i=1}^n Y_i X_i + n\beta_0^2 + 2\beta_0\beta_1 \sum_{i=1}^n X_i + \beta_1^2 \sum_{i=1}^n X_i^2 \quad (10)$$

A minimização da soma de quadrados dos erros é obtida encontrando os estimadores β_0 e β_1 , na expressão (10). Para encontrar o valor de β_0 e β_1 , deve-se derivar a expressão (10) em relação à β_0 e β_1 , igualando-os a zero. Sendo assim, a expressão estimada ficará demonstrada na equação (13):

$$\frac{\partial \sum_{i=1}^n e_i^2}{\partial \beta_0} = -2 \sum_{i=1}^n Y_i + 2n\beta_0 + 2\beta_1 \sum_{i=1}^n X_i = 0 \quad (11)$$

$$\frac{\partial \sum_{i=1}^n e_i^2}{\partial \beta_1} = -2 \sum_{i=1}^n X_i Y_i + 2 \beta_0 \sum_{i=1}^n X_i + 2 \beta_1 \sum_{i=1}^n X_i^2 = 0 \quad (12)$$

isolando as variáveis e multiplicando os sistemas por -1/2,

$$\beta_0 = \frac{\sum_{i=1}^n Y_i}{n} - \beta_1 \frac{\sum_{i=1}^n X_i}{n} = \bar{Y} - \beta_1 \bar{X} \quad (13)$$

e

$$\beta_1 = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \quad (14)$$

2.1.2.3. Coeficiente de Determinação para Regressão Linear Simples

O coeficiente de determinação (R^2 ou r^2) é responsável pela verificação do modelo proposto, se ele de fato foi adequado ou não, trazendo uma informação auxiliar ao resultado da análise de variância da regressão (NAGHETTINI & PINTO, 2007).

$$R^2 = \frac{SQReg}{SQTotal} = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (15)$$

O valor de R^2 indica a proporção da variação de Y que é dita pela regressão, ou seja, qual porcentagem da variação da variável dependente Y está sendo “explicada” pela variável independente X. Esse coeficiente varia de 0 a 1, os valores que mais se aproximam de 1 indicam que o modelo proposto é adequado para descrever o fenômeno (HOFFMANN, 2015).

Para interpretar o coeficiente de determinação de mais variáveis de entrada (X), é recomendado calcular o R^2 ajustado (mais particularmente em modelos de regressão múltipla, explicado no item 2.1.3), para refletir tanto o número de variáveis de entrada quanto o tamanho da amostra.

$$R^2_{ajustado} = 1 - \left[(1 - R^2) \frac{n-1}{n-2} \right] \quad (16)$$

2.1.2.4. Teste de Hipótese na Regressão Linear Simples

Quando se é ajustado a equação por meio da regressão, deve-se verificar se a mesma é adequada, ou seja, sua adequabilidade. Para isso, utiliza-se testes de hipóteses para os parâmetros do modelo, podendo construir intervalos de confiança, porém para fazer essa análise, deve-se partir do pressuposto que os erros tenham distribuição normal (NAGHETTINI & PINTO, 2007).

Como tem-se dois parâmetros no modelo, segundo a equação (1):

$$Y_i = \beta_0 + \beta_1 X_i + e_i$$

Pode-se realizar os seguintes testes:

$$H_0: \beta_1 = \beta_1^* \text{ versus } H_a: \beta_1 \neq \beta_1^*$$

$$H_0: \beta_0 = \beta_0^* \text{ versus } H_a: \beta_0 \neq \beta_0^*$$

Em cada caso a estatística do teste e as conclusões seriam:

$$t_{calc} = \frac{\widehat{\beta}_1 - \beta_1^*}{\sqrt{\widehat{V}(\widehat{\beta}_1)}}, \text{ sendo } \widehat{V}(\widehat{\beta}_1) = \frac{\widehat{\sigma}^2}{SQD_x}; \text{ se } |t_{calc}| \geq t_{\left(\frac{\alpha}{2}, n-2\right)} \Rightarrow \text{rejeita } H_0$$

$$t_{calc} = \frac{\widehat{\beta}_0 - \beta_0^*}{\sqrt{\widehat{V}(\widehat{\beta}_0)}}, \text{ onde } \widehat{V}(\widehat{\beta}_0) = \widehat{\sigma}^2 \left[\frac{1}{n} + \frac{\bar{X}^2}{SQD_x} \right]; \text{ se } |t_{calc}| \geq t_{\left(\frac{\alpha}{2}, n-2\right)} \Rightarrow \text{rejeita } H_0$$

$$\text{OBS: } \widehat{\sigma}^2 = \text{estimativa da variância dos erros} = \frac{SQR_{es}}{n-2} = \frac{SQD_y - \widehat{\beta}_1 SPD_{xy}}{n-2}$$

Uma análise especial seria $H_0: \beta_1 = 0$ versus $H_0: \beta_1 \neq 0$, pois essas 2 hipóteses estão relacionadas com a significância da regressão, ou seja, se há relação linear entre a variável de resposta Y e a variável de entrada X. Sendo assim, se não for rejeitado H_0 pode-se concluir que não há relação linear entre X e Y, porém, se $H_0: \beta_1 = 0$ for rejeitado, a variável X é importante na variabilidade em Y.

2.1.3. Regressão Linear Múltipla

A regressão linear múltipla é uma extensão da regressão linear simples, porém envolvendo 2 ou mais variáveis de entrada ou variáveis independentes (X) e uma variável de resposta ou variável dependente (Y), o objetivo se mantém o mesmo da regressão linear simples, estabelecer uma equação que possa ser usada para fazer a predição entre a variável de saída para valores dados pelas variáveis de entrada (NAGHETTINI & PINTO, 2007).

O modelo geral:

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (17)$$

Y_i = variável dependente Y no i-ésimo nível da variável independente X.

β_0 = constante de regressão, representa o intercepto da reta com o eixo dos Y.

β_i = coeficiente de regressão, representa a variação de Y em função do i-ésimo nível da variável independente X.

X_i = i-ésimo nível da variável independente X ($i = 1, 2, 3, \dots, n$)

e_i = é o erro que está associado à distância entre o valor observado Y_i e o correspondente ponto na curva do modelo proposto, para o mesmo nível de X.

Uma maneira representativa também é a forma matricial (18):

$$[Y] = [X] \cdot [\beta] \quad (18)$$

sendo,

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} X_{1,1} & X_{1,2} & \dots & X_{1,P} \\ X_{2,1} & X_{2,2} & \dots & X_{2,P} \\ \vdots & \vdots & \dots & \vdots \\ X_{n,1} & X_{n,2} & \dots & X_{n,P} \end{bmatrix} \cdot \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad (19)$$

De maneira análoga à análise de regressão linear simples, os coeficientes desconhecidos β_i podem ser descobertos pela minimização do somatório dos erros quadráticos, $\sum_{i=1}^n e_i^2$, onde,

$$e_i = Y_i - \hat{Y}_i = Y_i - \sum_{j=1}^P \hat{\beta}_j X_{i,j} \quad (20)$$

Representando matricialmente a equação (20),

$$\sum e_i^2 = [e]^T [e] = ([Y] - [X\hat{\beta}])^T ([Y] - [X\hat{\beta}]) \quad (21)$$

Diferenciando a equação (21), em relação a $\hat{\beta}$, e igualando a derivada parcial a zero, obtém-se a equação (22),

$$[X]^T [Y] = [X]^T \cdot [X\hat{\beta}] \quad (22)$$

O valor de $\hat{\beta}$ pode ser estimado por:

$$[\hat{\beta}] = ([X]^T [X])^{-1} \cdot [X]^T [Y] \quad (23)$$

De maneira semelhante à regressão linear simples,

$$\sum Y_i^2 = n\bar{Y}^2 + \sum (Y_i - \hat{Y}_i)^2 + \sum (\hat{Y}_i - \bar{Y})^2 \quad (24)$$

Em notação matricial a equação (24) fica,

$$[Y]^T [Y] = n\bar{Y}^2 + \left([\hat{\beta}]^T [X]^T [Y] - n\bar{Y}^2 \right) + \left([Y]^T [Y] - [\hat{\beta}]^T [X]^T [Y] \right) \quad (25)$$

2.1.3.1. Coeficiente de Determinação para Regressão Linear Múltipla

O coeficiente de determinação para regressão linear múltipla segue do mesmo conceito apresentado no item 2.1.2.3, onde:

$$R^2 = \frac{SQReg}{SQT} = \frac{[\hat{\beta}]^T [X]^T [Y] - n\bar{Y}^2}{[Y]^T [Y] - n\bar{Y}^2} \quad (26)$$

O valor do coeficiente de determinação múltipla varia entre 0 a 1, expressando a proporção da variância que é explicada pelo modelo de regressão (NAGHETTINI & PINTO, 2007).

2.1.3.2. Teste de Significância da Regressão Linear Múltipla

Segundo Naghettini & Pinto (2007), o teste também é conhecido como “teste F”, utilizado para testar a razão entre 2 variâncias, podendo verificar a hipótese nula.

$$H_0: \beta_1 = \beta_2 = \dots = \beta_n = 0 \Rightarrow \text{relação entre as variáveis não é linear}$$

$$H_1: \beta_i \neq 0$$

A estatística do teste é a relação entre a variância da regressão linear múltipla e a variância dos resíduos, assim sendo,

$$F = \frac{QMReg}{QMRes} \quad (27)$$

$$QMReg = \frac{SQReg}{p} \quad (28)$$

$$QMRes = \frac{SQRes}{n-1-p} \quad (29)$$

A hipótese nula será aceita se:

$$F_{tabela} > F(\alpha, p, n - 1 - p) \quad (30)$$

F = teste de significância

α = nível de significância

P = número de variáveis independentes

$n - I - P$ = grau de liberdade da distribuição F de Snedecor

2.1.3.3. Método ANOVA (Análise de Variância)

Segundo Hoffman (2015), o método ANOVA também pode testar a significância da regressão, no qual consiste em avaliar a influência de fatores em uma variável dependente por meio da análise de variâncias. O ANOVA é utilizado para 3 ou mais fatores, pelo fato do teste ser paramétrico, os dados devem seguir uma distribuição normal, os grupos têm que ser independentes e a população deve ter a mesma variância (condição de homocedastidade). Assim pode-se ser verificado:

$$\sum(Y_i - \bar{Y})^2 = \sum(\hat{Y}_i - \bar{Y})^2 + \sum(Y_i - \hat{Y}_i)^2 \quad (31)$$

ou,

$$SQT_{total} = SQR_{regressão} + SQR_{resíduo} \quad (32)$$

sendo:

- SQT_{total} = variação total em $Y = SQD_Y$

- $SQR_{regressão}$ = variação em Y explicada pela regressão ajustada = $\hat{\beta}_1 SPD_{XY}$

- $SQR_{resíduo}$ = variação não explicada pela regressão = $SQD_Y - \hat{\beta}_1 SPD_{XY}$

$$SQT_{total} = \sum_{i=1}^n Y_i^2 - \frac{(\sum_{i=1}^n Y_i)^2}{n} \quad (33)$$

$$F = \frac{\frac{SQR_{regressão}}{m-1}}{\frac{SQR_{resíduo}}{N-m}} \quad (34)$$

m = número de grupos

N = tamanho da amostra

2.1.4. Função de 2° Grau

A situação encontrada para esse modelo estatístico é:

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + e_i \quad (35)$$

em que:

Y_i = valor observado para a variável dependente Y no i -ésimo nível da variável dependente X .

β_0 = constante de regressão.

β_1 = constante de regressão.

β_2 = constante de regressão.

X_i = i -ésimo nível da variável independente X ($i = 1, 2, \dots, n$)

X_i^2 = i -ésimo nível da variável independente X , elevado ao quadrado

e_i = erro associado à distância entre o valor observado Y_i e o correspondente ponto na curva para o mesmo nível i de X .

Utilizando o MMQ, no modelo de 2° grau, chegará-se ao sistema de equações normais, para se obter as estimativas de β_0 , β_1 e β_2 :

$$\sum_{i=1}^n Y_i = n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n X_i + \hat{\beta}_2 \sum_{i=1}^n X_i^2 \quad (36)$$

$$\sum_{i=1}^n Y_i X_i = \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2 + \hat{\beta}_2 \sum_{i=1}^n X_i^3 \quad (37)$$

$$\sum_{i=1}^n Y_i X_i^2 = \hat{\beta}_0 \sum_{i=1}^n X_i^2 + \hat{\beta}_1 \sum_{i=1}^n X_i^3 + \hat{\beta}_2 \sum_{i=1}^n X_i^4 \quad (38)$$

Uma vez obtidas essas estimativas, é representada pela equação (39):

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i + \hat{\beta}_2 X_i^2 \quad (39)$$

2.2. OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO

Segundo Andrade (2010), a expressão “Simulação Monte Carlo” surgiu com o intuito de resolver problemas de blindagem de reatores nucleares. O cientista John Von Neumann em parceria de Ulam consideraram a possibilidade de utilizar o método que consiste em simulações diretas de problemas de natureza probabilística relacionados com o coeficiente de difusão do nêutron em certos materiais.

O método de Monte Carlo é um procedimento computacional para a determinação da probabilidade aproximada de um evento específico resultante de uma série de processos estocásticos, assumindo que os parâmetros de entrada são estatisticamente não correlacionados e a distribuição estatística dos parâmetros de entrada é conhecida ou suposta – por exemplo: uniforme, triangular ou Gaussiana (CARVALHO, ARMIGLIATO, ALMEIDA, & DE MUSIS, 2016).

Ela trata de uma técnica de simulação numérica, que partindo da geração de valores randômicos para as variáveis aleatórias, simula combinações de valores, obedecendo às respectivas distribuições, levando aos resultados os quais são o foco da análise.

Devido ao avanço da capacidade de processamento dos computadores aconteceu nas duas últimas décadas um crescimento na utilização do Método Monte Carlo (MMC) e técnicas para modelagem e simulação de sistemas cada vez mais complexos e sofisticados.

Em cada iteração realizada pela simulação, o modelo computacional calcula os valores das variáveis de saída tomando como base a entrada de dados. Para a reprodução dos valores usualmente utiliza-se um algoritmo computacional de geração de sequências de números pseudoaleatórios com distribuição uniforme no intervalo entre 0 e 1, onde os dados são convertidos dependendo das suas respectivas distribuições (CARVALHO, ARMIGLIATO, ALMEIDA, & DE MUSIS, 2016).

De acordo com Corrar & Theóphilo (2009), existem algumas etapas que devem ser seguidas para se executar a simulação de Monte Carlo, são elas:

- a) Desenvolvimento de equações matemáticas apropriadas para o estudo;
- b) Coleta de dados;
- c) Determinar as variáveis de entrada (X) que são importantes para o estudo, bem como as distribuições de probabilidades associadas a elas;
- d) Quando oportuno, construir as distribuições de probabilidades acumuladas para cada uma das variáveis definidas no item anterior;
- e) Definição dos intervalos de números aleatórios para cada variável de entrada (X);
- f) Geração de números aleatórios;
- g) Simulação dos experimentos.

Esse estudo mostra que o método SMC gera de forma, contínua e aleatória, números a fim de criar cenários de eventos possíveis de se sucederem, ou seja, essa aleatoriedade possibilita a geração de cenários a cada iteração.

Os resultados obtidos de cada simulação compõem uma distribuição de probabilidade e a disposição desses valores na distribuição obtida leva a avaliação de uma provável ocorrência de cada evento, podendo assim, por meio de medidas estatística e descritivas chegar a conclusão do tempo mais provável que o processo de perfuração e detonação levariam no caso estudado (VARGAS, KOPPE, & PÉRES, 2014)

A simulação Monte Carlo é um processo de modelagem de um sistema real, onde são conduzidos experimentos para a previsão do comportamento do mesmo, utilizando-se de técnicas estatísticas para realização de simulações estocásticas (SHANNON, 1975).

É uma técnica utilizada a fim de se obter aproximações numéricas de funções complexas, fazendo o uso da amostra obtida e a geração de dados de alguma distribuição de probabilidades para realizar a aproximação da função de interesse. Para facilitar as análises e assim avaliar o sistema de equações ou modelos matemáticos, as aplicações são feitas em computação numérica (CARVALHO, ARMIGLIATO, ALMEIDA, & DE MUSIS, 2016).

Um modelo de simulação pode representar a realidade de forma fiel, desde que sua representatividade dependa de casos concretos, assim o método Monte Carlo se encaixa de forma adequada (ASSIS, 2014).

Kroese (2011) diz que o método Monte Carlo pode ser útil para fins de estimativa e otimização com a aleatorização dos dados no processo, sua eficiência se dá com a utilização de informações conhecidas sobre o modelo de simulação, como, variáveis de controle e amostragens, responsáveis pelas definições das possíveis probabilidades.

Segundo Ramos (2009), a utilização de simulações tem um papel fundamental na avaliação de desempenho dos métodos, pelo fato da complexidade de operações matriciais envolvidas, o que dificulta o julgamento analítico comparativo dos mesmos, podendo assim fazer a comparação entre métodos estatísticos ou determinar as propriedades de estimadores.

A otimização via simulação Monte Carlo é indicado quando é necessário solucionar situações em que há uma mistura de variáveis contínuas e discretas, levando o modelo a restrições complexas e com vários caminhos ótimos (KROESE, TAIMRE, & BOTEV, 2011).

3. DESENVOLVIMENTO E RESULTADOS DO PROBLEMA

Neste capítulo será explicado o estudo de caso abordado no trabalho, bem como a validação gerada pela OvSMC para a solução do problema. Será também exibida a aplicação dos métodos e resultados, responsáveis pela conclusão do trabalho.

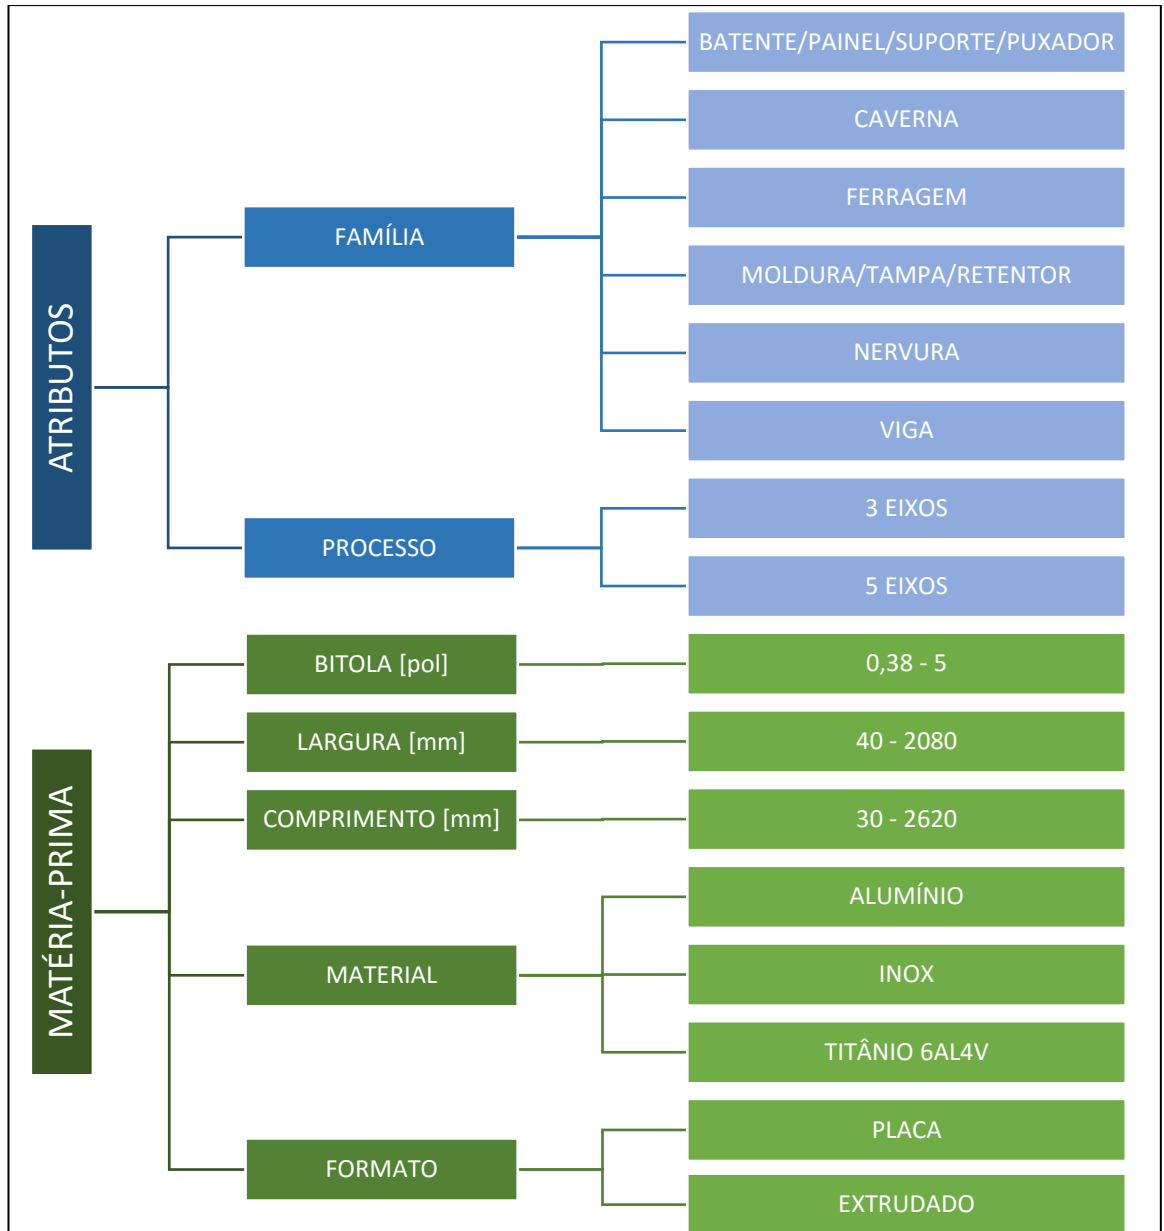
3.1. DESCRIÇÃO DO PROBLEMA

Com base no que foi abordado na introdução, o objetivo deste trabalho é utilizar a otimização via Simulação Monte Carlo na predição do tipo de matéria-prima a ser iniciada na linha de produção, visto que é sabido o tempo de usinagem e *setup*. O objeto de estudo foi em uma empresa do segmento aeronáutico de grande porte.

3.1.1. Coleta de dados

Os dados foram coletados a partir do banco de dados contidos no Microsoft Excel® até o ano de 2015, totalizando 1.868 peças. A organização dos dados está dividida em atributos (família e processo) e matéria-prima (bitola, largura, comprimento, material e formato). A Figura 4 será ilustrada a organização.

Figura 4 - Organização dos insumos



Fonte: Produção do próprio autor

Para âmbitos comparativos foram selecionadas 2 amostras de dados, as escolhas dos mesmos foram de acordo com o maior grau de significância para realizar as simulações, com base na Tabela 2, foram obtidas as amostras de material de alumínio, no formato placa, das famílias batente/painel/suporte/puxador e ferragem, com o processo de 3 eixos, representando 43,9% do total de amostras.

Tabela 2 - Quantidade de peças

Material	Formato	Família	Processo	Total
Alumínio	Placa	Batente/Painel/Suporte/Puxador	3 eixos	541
			5 eixos	183
		Ferragem	3 eixos	279
			5 eixos	242
		Caverna	3 eixos	78
			5 eixos	39
		Moldura / Tampa / Retentor	5 eixos	108
			3 eixos	23
		Nervura	5 eixos	111
			3 eixos	12
		Viga	3 eixos	87
			5 eixos	24
	Perfil Extrudado	Batente/Painel/Suporte/Puxador	3 eixos	20
		Ferragem	3 eixos	4
		Viga	3 eixos	56
Alumínio Total				1807
Titânio 6AL4V	Placa	Batente/Painel/Suporte/Puxador	5 eixos	9
			3 eixos	4
		Ferragem	5 eixos	10
			3 eixos	1
		Caverna	5 eixos	1
		Nervura	5 eixos	6
Titânio 6AL4V Total				31
Inox	Placa	Batente/Painel/Suporte/Puxador	3 eixos	13
			5 eixos	5
		Ferragem	5 eixos	4
		Caverna	5 eixos	7
		Nervura	5 eixos	1
Inox Total				30
Total Geral				1868

Fonte: Produção do próprio autor

3.1.2. Modelagem do problema

Para a realização da modelagem do problema, após definidas as amostras, conforme item 3.1.1, o desenvolvimento das funções empíricas é calculado por meio da regressão linear, utilizando o *software* Microsoft Excel®. A OvSMC será feita pelo *Crystal Ball* (Oracle®), um *Add-in* do Ms-Excel®, em conjunto com o seu otimizador *Optquest*.

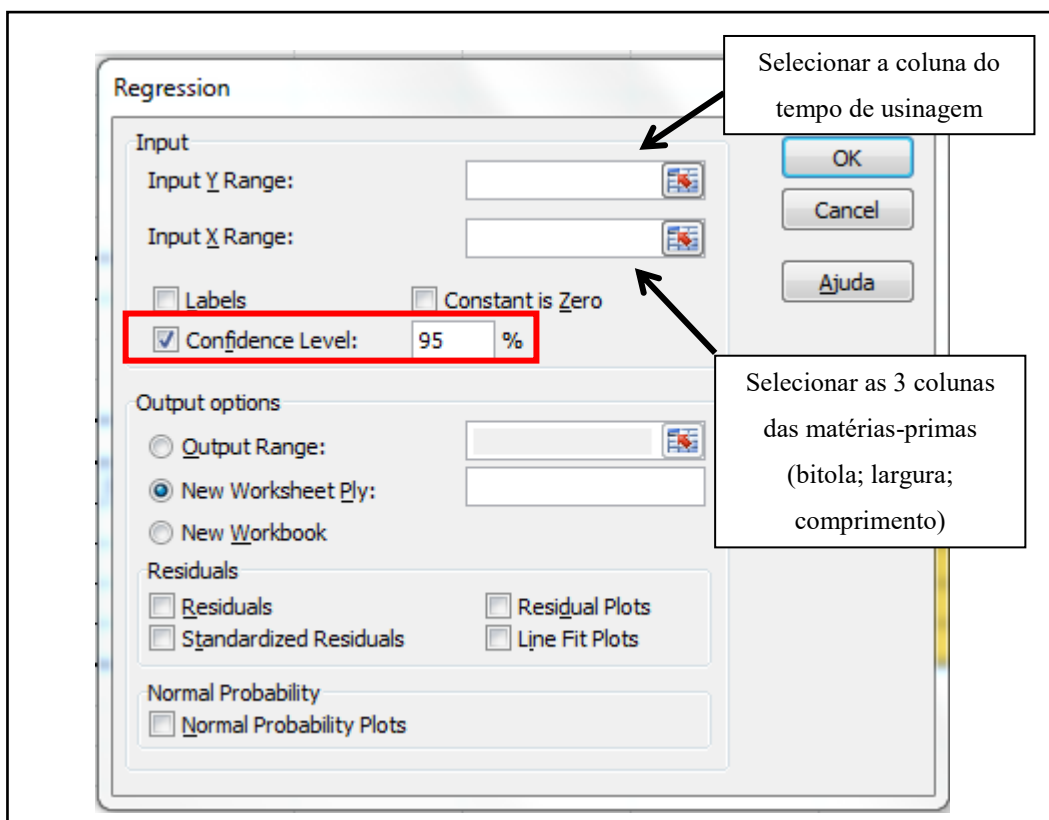
3.1.3. Solução do modelo

3.1.3.1. Família: Batente/Painel/Suporte/Puxador

Para a solução do modelo, será realizado os cálculos de regressão linear, por meio da função “*Data Analysis*” no item “*Regression*”, o *software* abrirá a tela da **Erro! Fonte de referência não encontrada**. Figura 5 e será feito o seguinte *setup* para os dados representados:

- Família: Batente/Painel/Suporte/Puxador.
- Processo: 3 eixo.
- Material: Alumínio.
- Formato: Placa.

Figura 5 - *Setup* Regressão para a família Batente/Painel/Suporte/Puxador



Fonte: Produção do próprio autor

Após realizado o *setup*, o *software* apresentará as informações, conforme Figura 6:

Figura 6 - Regressão *Output* Usinagem (batente/painel/suporte/puxador)

SUMMARY OUTPUT								
<i>Regression Statistics Usinagem</i>								
Multiple R	0,936704524							
R Square	0,877415364							
Adjusted R Square	87,67%							
Standard Error	0,158164601							
Observations	541							
ANOVA								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>			
Regression	3	96,15282774	32,05094258	1281,215623	3,0502E-244			
Residual	537	13,43361403	0,025016041					
Total	540	109,5864418						
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	<i>Lower 95,0%</i>	<i>Upper 95,0%</i>
Intercept	-0,287	0,027	-10,683	0,00%	-0,339	-0,234	-0,339	-0,234
X Variable 1	0,294	0,010	28,223	0,00%	0,273	0,314	0,273	0,314
X Variable 2	0,003	0,000	34,720	0,00%	0,003	0,003	0,003	0,003
X Variable 3	0,003	0,000	40,339	0,00%	0,003	0,003	0,003	0,003

Fonte: Produção do próprio autor

Como o valor de R^2 ajustado é maior que 70% e o *valor-p* é menor que 5%, tem-se a validação do modelo de regressão linear e a equação do modelo é representado em (40):

$$Y_{BU} = -0,287 + 0,294 \cdot X_1 + 0,003 \cdot X_2 + 0,003 \cdot X_3 \quad (40)$$

Y_{BU} = tempo de usinagem [h].

X_1 = valor correspondente à bitola [pol].

X_2 = valor correspondente à largura [mm].

X_3 = valor correspondente ao comprimento [mm].

Utilizando o mesmo método para o cálculo do *output* ajustagem, tem-se os dados conforme Figura 7:

Figura 7 - Regressão *Output* Ajustagem (batente/painel/suporte/puxador)

SUMMARY OUTPUT								
<i>Regression Statistics Ajustagem</i>								
Multiple R	0,956382486							
R Square	0,91466746							
Adjusted R Square	91,42%							
Standard Error	0,048895988							
Observations	541							
ANOVA								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>			
Regression	3	13,76161151	4,587203837	1918,675742	1,7887E-286			
Residual	537	1,283869081	0,002390818					
Total	540	15,04548059						
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	<i>Lower 95,0%</i>	<i>Upper 95,0%</i>
Intercept	-0,091	0,008	-10,949	0,00%	-0,107	-0,075	-0,107	-0,075
X Variable 1	0,114	0,003	35,534	0,00%	0,108	0,121	0,108	0,121
X Variable 2	0,001	0,000	42,840	0,00%	0,001	0,001	0,001	0,001
X Variable 3	0,001	0,000	48,498	0,00%	0,001	0,001	0,001	0,001

Fonte: Produção do próprio autor

Como o valor de R^2 ajustado é maior que 70% e o *valor-p* é menor que 5%, tem-se a validação do modelo de regressão linear e a equação do modelo é representada em (41):

$$Y_{BA} = -0,091 + 0,114 \cdot X_1 + 0,001 \cdot X_2 + 0,001 \cdot X_3 \quad (41)$$

Y_{BA} = tempo de usinagem [h].

X_1 = valor correspondente à bitola [pol].

X_2 = valor correspondente à largura [mm].

X_3 = valor correspondente ao comprimento [mm].

A obtenção do tempo de fabricação total para a família batente/painel/suporte/puxador se deve à soma do tempo de usinagem, equação (40), e o tempo de ajustagem, equação (41) :

$$T_{BF} = Y_{BU} + Y_{BA} \quad (42)$$

T_{BF} = tempo de fabricação

Y_{BU} = tempo de usinagem

Y_{BA} = tempo de ajustagem

$T_{BF} \in F$, (F é um conjunto discreto de soluções)

$Y_{BU} + Y_{BA} \in \hat{Y}$, (\hat{Y} é um conjunto de valores alvo)

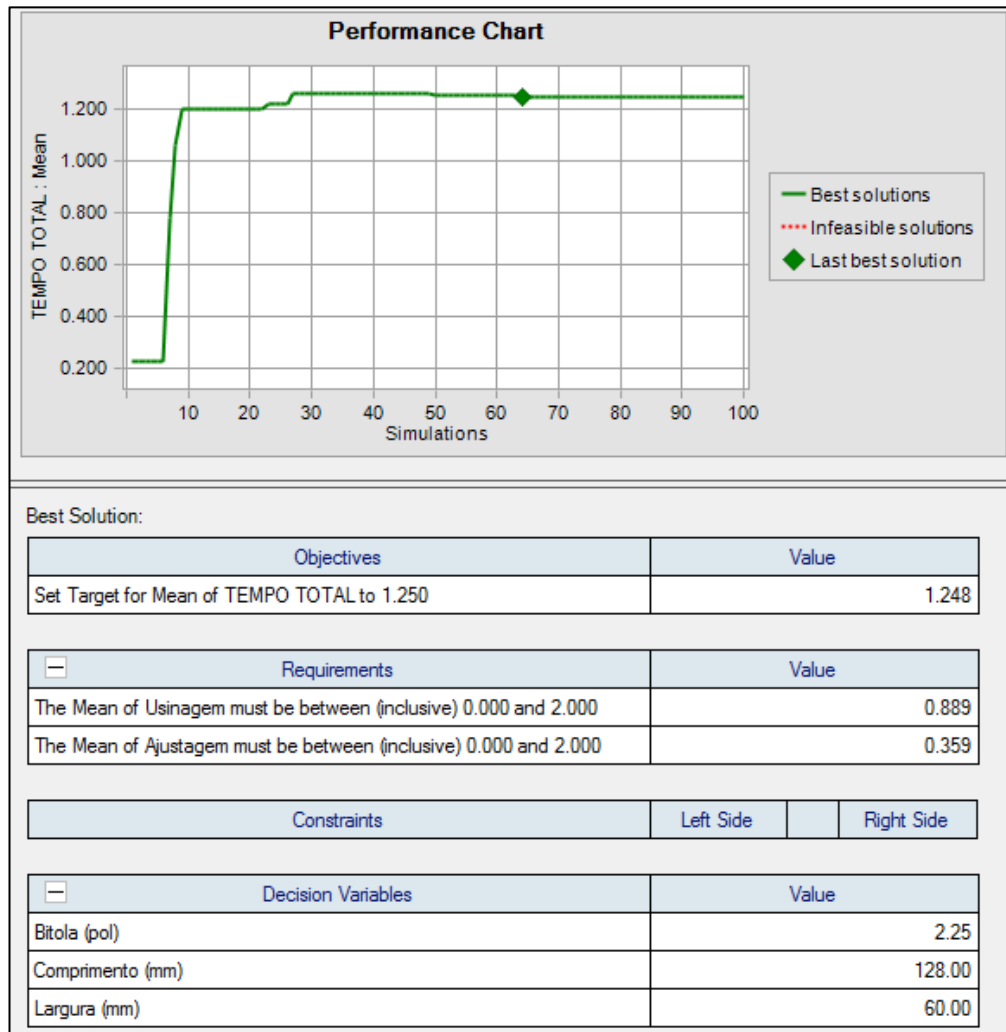
Antes de realizar a simulação, deverá ser feito o *setup* da função *Optquest*:

- Número de simulações: 100
- Número de ensaios: 6.000
- Tempo total de fabricação (T_{BF}): 1,25 [h]
- *Forecast*:
 - Tempo de fabricação (T_{BF})
 - Tempo de usinagem (Y_{BU})
 - Tempo de ajustagem (Y_{BA})
- Variáveis de decisão:
 - Bitola
 - Comprimento
 - Largura
- Tipo de distribuição: triangular, utilizando como valor mínimo os 95% inferiores do intervalo de confiança, e o valor da moda sendo o coeficiente original da regressão, e por fim, o valor máximo foi definido utilizando os 95% superior do intervalo de confiança para cada coeficiente original da regressão.

OBS: *a distribuição triangular é comumente utilizada quando se tem poucas informações, dessa forma não são necessários muitos parâmetros para sua definição, resultando em distribuições assimétricas mais simples e que tenham boa aproximação.

O resultado da OvSMC será mostrado na Figura 8.

Figura 8 - OvSMC solução ótima (batente /painel/suporte/ puxador)




Fonte: Produção do próprio autor

Dessa maneira a solução ótima para o target de 1,25 [h] é a matéria-prima:

- Bitola: 2,25 [pol]
- Comprimento: 128 [mm]
- Largura: 60 [mm]

A Figura 9 será mostrada o gráfico de distribuição normal para o tempo total de fabricação da peça com um índice de confiabilidade de 95%, obtendo a variação entre 1,188 e 1,310 horas.


Figura 9 - Distribuição normal tempo fabricação (batente/painel/suporte/puxador)



Fonte: Produção do próprio autor

A Figura 10 representa o gráfico de distribuição normal para o tempo de usinagem com um índice de confiabilidade de 95%, obtendo a variação entre 0,832 e 0,948 horas.


Figura 10 - Distribuição normal tempo usinagem (batente/painel/suporte/puxador)



Fonte: Produção do próprio autor

A Figura 11 representa o gráfico de distribuição normal para o tempo de ajustagem com um índice de confiabilidade de 95%, obtendo a variação entre 0,342 e 0,377 horas.

Figura 11 - Distribuição normal tempo ajustagem (batente/painel/suporte/puxador)



Fonte: Produção do próprio autor

Conforme as Figuras 9 a 11, observa-se a variação do tempo total de 0,062 [h], equivalente a 3,72 [min], indicando uma precisão muito grande na predição da matéria-prima. Quando comparado o resultado gerado pela simulação com a situação real, é encontrado o tempo de fabricação de 1,20 [h], equivalente a 96%, validando o modelo estudado.

3.1.3.2. Família: Ferragem

Calculando o modelo de regressão linear para a família ferragem:

- Família: Ferragem
- Processo: 3 eixos
- Material: Alumínio
- Formato: Placa

A Figura 12 representa a análise de regressão para usinagem da família ferragem.

Figura 12 - Regressão *Output* Usinagem (ferragem)

SUMMARY OUTPUT								
<i>Regression Statistics Usinagem</i>								
Multiple R	0,95656607							
R Square	0,915018646							
Adjusted R Square	91,41%							
Standard Error	0,444130027							
Observations	279							
ANOVA								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>			
Regression	3	584,0624197	194,6874732	987,0013245	7,6851E-147			
Residual	275	54,24415734	0,197251481					
Total	278	638,3065771						
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	<i>Lower 95,0%</i>	<i>Upper 95,0%</i>
Intercept	-1,046	0,072	-14,481	0,00%	-1,189	-0,904	-1,189	-0,904
X Variable 1	0,461	0,030	15,419	0,00%	0,402	0,520	0,402	0,520
X Variable 2	0,003	0,000	17,607	0,00%	0,003	0,004	0,003	0,004
X Variable 3	0,003	0,000	36,965	0,00%	0,003	0,004	0,003	0,004

Fonte: Produção do próprio autor

Como o valor de R^2 ajustado é maior que 70% e o *valor-p* é menor que 5%, tem-se a validação do modelo de regressão linear e a equação do modelo , está representada em (43):

$$Y_{FU} = -1,046 + 0,461.X_{1,} + 0,003.X_{2,} + 0,003.X_{3,} \quad (43)$$

Y_{FU} = tempo de usinagem [h].

$X_{1,}$ = valor correspondente à bitola [pol].

$X_{2,}$ = valor correspondente à largura [mm].

$X_{3,}$ = valor correspondente ao comprimento [mm].

Utilizando o mesmo método para o cálculo do *output* ajustagem, tem-se os dados conforme Figura 13:

Figura 13 - Regressão *Output* Ajustagem (ferragem)

SUMMARY OUTPUT								
<i>Regression Statistics Ajustagem</i>								
Multiple R	0,954839609							
R Square	0,911718679							
Adjusted R Square	91,08%							
Standard Error	0,178776452							
Observations	279							
ANOVA								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>			
Regression	3	90,77062995	30,2568767	946,6805769	1,4449E-144			
Residual	275	8,789280441	0,03196102					
Total	278	99,55991039						
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	<i>Lower 95,0%</i>	<i>Upper 95,0%</i>
Intercept	-0,419	0,029	-14,401	0,00%	-0,476	-0,362	-0,476	-0,362
X Variable 1	0,188	0,012	15,655	0,00%	0,165	0,212	0,165	0,212
X Variable 2	0,001	0,000	17,688	0,00%	0,001	0,002	0,001	0,002
X Variable 3	0,001	0,000	35,566	0,00%	0,001	0,001	0,001	0,001

Fonte: Produção do próprio autor

Como o valor de R^2 ajustado é maior que 70% e o *valor-p* é menor que 5%, tem-se a validação do modelo de regressão linear e a equação do modelo está representada em (44):

$$Y_{FA} = -0,419 + 0,188.X_{1,} + 0,001.X_{2,} + 0,001.X_{3,} \quad (44)$$

Y_{FA} = tempo de usinagem [h].

$X_{1,}$ = valor correspondente à bitola [pol].

$X_{2,}$ = valor correspondente à largura [mm].

$X_{3,}$ = valor correspondente ao comprimento [mm].

Da mesma forma a obtenção do tempo de fabricação total, equação (45), para a família ferragem se deve à soma do tempo de usinagem, equação (43), e o tempo de ajustagem, equação (44):

$$T_{SF} = Y_{FU} + Y_{FA} \quad (45)$$

T_{SF} = tempo de fabricação

Y_{FU} = tempo de usinagem

Y_{FA} = tempo de ajustagem

$T_{SF} \in F$, (F é um conjunto discreto de soluções)

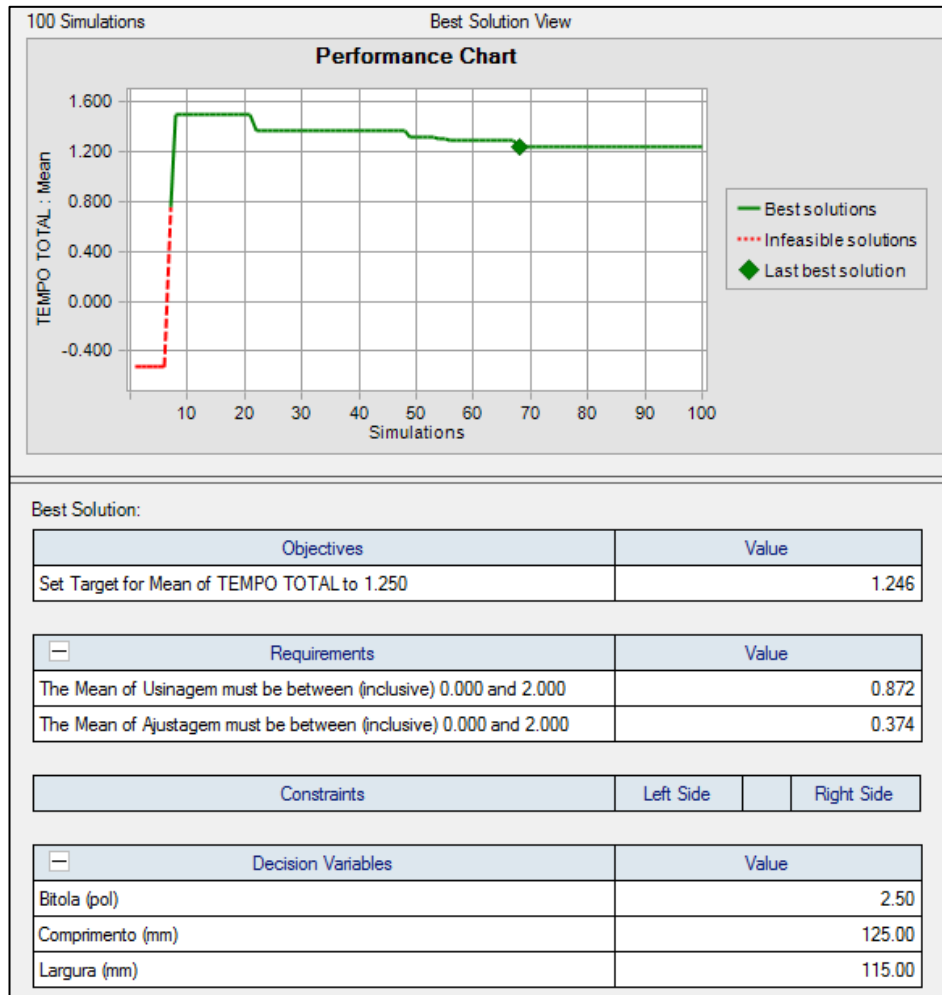
$Y_{FU} + Y_{FA} \in \hat{Y}$, (\hat{Y} é um conjunto de valores alvo)

Antes de realizar a simulação, tem-se a definição do *setup* da função *Optquest*:

- Número de simulações: 100
- Número de ensaios: 6.000
- Tempo total de fabricação (T_{BF}): 1,25 [h]
- *Forecast*:
 - Tempo de fabricação (T_{SF})
 - Tempo de usinagem (Y_{FU})
 - Tempo de ajustagem (Y_{FA})
- Variáveis de decisão:
 - Bitola
 - Comprimento
 - Largura
- Tipo de distribuição: triangular, utilizando como valor mínimo os 95% inferiores do intervalo de confiança, e o valor da moda sendo o coeficiente original da regressão, e por fim, o valor máximo foi definido utilizando os 95% superior do intervalo de confiança para cada coeficiente original da regressão.

O resultado da OvSMC está representado na Figura 14:

Figura 14 - OvSMC solução ótima (ferragem)




Fonte: Produção do próprio autor

Dessa maneira a solução ótima para o target de 1,25 [h] é a matéria prima:

- Bitola: 2,5 [pol]
- Comprimento: 125 [mm]
- Largura: 115 [mm]

A Figura 15 será mostrada o gráfico de distribuição normal para o tempo total de fabricação da peça com um índice de confiabilidade de 95%, obtendo-se os limites entre 1,064 e 1,447 horas.


Figura 15 - Distribuição normal tempo fabricação (ferragem)



Fonte: Produção do próprio autor

A Figura 16 representa o gráfico de distribuição normal para o tempo de usinagem com um índice de confiabilidade de 95%, obtendo a variação entre 0,706 e 1,060 horas.


Figura 16 - Distribuição normal tempo de usinagem (ferragem)



Fonte: Produção do próprio autor

A Figura 17 representa o gráfico de distribuição normal para o tempo de ajustagem com um índice de confiabilidade de 95%, obtendo a variação entre 0,309 e 0,441 horas.

Figura 17 - Distribuição normal tempo de ajustagem (ferragem)



Fonte: Produção do próprio autor

Conforme as figuras 15 a 17, pode-se observar a variação do tempo total de 0,197 [h], equivalente a 12,13 [min], uma precisão grande na predição da matéria-prima, dessa forma validando o modelo estudado.

4. CONCLUSÃO E CONSIDERAÇÕES FINAIS

Com base no estudo realizado a otimização via simulação Monte Carlo possui grande importância em questões relacionadas à tomada de decisão, isso se deve a grandes variedades de informações que a ferramenta proporciona para serem analisadas e compiladas, servindo de base para os gestores no processo decisório, pois, as informações que serão avaliadas servirão como base para uma conclusão mais objetiva e precisa para a administração fabril.

O estudo buscou avaliar a aplicabilidade da SMC na otimização do consumo de matéria-prima em um cenário real e o mesmo comprova a importância da predição no processo de fabricação de peças.

No desenvolvimento dos modelos matemáticos de previsão de consumo foi necessário um entendimento mais preciso dos processos (usinagem e ajustagem) em que as matérias-primas estudadas são aplicadas, de tal forma que tais modelos utilizassem das variáveis em que a fábrica tivesse controle. Mesmo havendo possíveis fatores externos que influenciam o consumo, os modelos matemáticos apresentaram uma alta aderência com os dados reais históricos fornecidos pela companhia.

Em relação ao objetivo específico do estudo, foi possível desenvolver dois modelos matemáticos lineares que descrevessem o consumo real da matéria-prima. Os R-quadrado foram de 0,8767 e 0,9142 para os modelos de usinagem e ajustagem da família batente/painel/suporte/puxador.

Para os modelos de usinagem e ajustagem da família ferragem os valores foram de 0,9141 e 0,9108 respectivamente e todos os *valores-p* apresentaram valores menores que 0,05, ou seja, são modelos que condizem com a realidade e condizem de forma estatística com os dados reais.

Comparando os resultados obtidos com o mesmo tempo de fabricação (1,25 [h]), o resultado da matéria-prima a ser colocado na linha é outro, (bitola: 2,25 [pol], comprimento: 128 [mm], largura: 60 [mm] para família batente/suporte/puxador/painel e bitola: 2,5 [pol], comprimento: 125 [mm] e largura: 115 [mm] para a família ferragem), sendo assim explica-se como as famílias influenciam no processo de produção, sendo o mesmo processo, porém com peças diferentes.

Importante ressaltar a necessidade do PCP realizar a predição da matéria-prima, dado um tempo de produção específico, assim minimizando as chances de faltar recursos na linha de produção.

REFERÊNCIAS

- ALMEIDA, C. A.; MINERVI, N. A. Considerações sobre o uso da modelagem multivariada na prevenção de acidentes aeronáuticos na aviação civil brasileira. **Revista Conexão Sipaer**, Brasília, p. 177-181, 2016.
- ANDRADE, E. L. **Introdução à pesquisa operacional**: métodos e modelos para análise de decisões. Rio de Janeiro: LTC, 2010.
- BERTRAND, J. W.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241-264, 2002.
- CARVALHO, H. P. et al. Análise probabilística de colisões veiculares pelo método de Monte Carlo. **Revista Brasileira de Criminalística**, Cuiabá, p. 46-50, 2016.
- CASTRO, N.; LAMY, P. **Desregulamentação do setor transporte e subsetor transporte aéreo de passageiros**: texto para discussão. São Paulo: IPEA, 1993.
- CHIAVENATO, I. **Introdução à teoria geral da administração**. Elsevier: Rio de Janeiro, 2011.
- CONDUTA, L. F.; SOUZA, M. d. Simulação de monte carlo: contribuição dessa ferramenta na geração de informações para subsídio ao processo de tomada de decisão nas organizações. **WORKSHOP DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO**, 2., Londrina, 2013. **Anais...** Londrina, 2013.
- CORRAR, L. J.; THEÓPHILO, C. R. **Pesquisa operacional**: para decisão em contabilidade e administração. São Paulo: Atlas, 2009.
- DANCEY, C. P.; REIDY, J. **Estatística sem matemática para psicologia**. São Paulo: Artmed Editora S.A, 2006.
- DANTAS, R. **Engenharia de avaliações**: uma introdução à metodologia científica. São Paulo: Pini, 1998.
- DRUCKER, P. F. **Administrando para o futuro**: os anos 90 e a virada do século. 5. ed. São Paulo: Pioneira, 1998.
- EUCLIDES FILHO, K. Supply chain approach to sustainable beef production from a Brazilian perspective. **Livestock Production Science**, p. 53-61, 2004.
- FAY, C. M. **Aviação comercial na América do Sul: 1920-1941**. Dissertação (Mestrado em História, Faculdade de Filosofia e Ciências Humanas) – Pontífica Universidade Católica do Rio Grande do Sul, Porto Alegre, 1990.
- FERNANDES, D. Uma contribuição sobre a construção de indicadores. **Revista da FAE**, Curitiba, p. 1-18, 2004.
- FONSECA, C.; FLEMING, P. An overview of evolutionary algorithms in multiobjective optimization. **Evolutionary Computation. Sheffield**, v. 3, n. 1, p. 1-16, 1995.
- FONSECA, J. J. **Metodologia da pesquisa científica**. Fortaleza: UEC, 2002. 20p.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. São Paulo: Atlas, 2008.

- HOFFMANN, R. **Análise de regressão**: uma introdução à econometria [recurso eletrônico]. Piracicaba: ESALQ/USP, 2015.
- HORN, J. **Handbook of evolutionary computation**. Inglaterra: Oxford University Press, Oxford, 1975.
- LEAL, F. et al. Análise da capacidade de produção e dimensionamento de estoques intermediários de processamento no estudo de um novo processo de manufatura através da simulação de eventos discretos. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 38., Goiânia, 2006. **Anais...** Goiânia, 2006.
- LEÃO, W. **Administradores**: o portal da administração, 2014. Disponível em: <<http://www.administradores.com.br/artigos/academico/o-processo-de-transformacao-input-e-output-entrada-e-saida/78698/>>. Acesso em: 30 nov. 2016.
- LEVINE, D.; BERENSON, M.; STEPHAN, D. **Estatística**: teoria e aplicações. Rio de Janeiro: LTC- Livros Técnicos e Científicos Editora S.A, 2000.
- MALLAGUTTI, A. O. **Evolução da aviação civil no Brasil**. Local: Consultoria Legislativa da Câmara dos Deputados. DP, 2001.
- MINITAB, Inc. **Statistical software data analysis software**. Versão 15, 2013.
- MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Atlas, 2004.
- MOREIRA, M. E. **O caso GOL**. Central de Cases ESPM. EXAME, 2004.
- NAGHETTINI, M.; PINTO, E. **Hidrologia estatística**. Belo Horizonte: CPRM - Serviço Geológico do Brasil, 2007.
- NAKAGAWA, M. **Gestão estratégica de custos: conceitos, sistemas e implementação: JIT/TQC**. São Paulo: Atlas, 2000.
- OLIVEIRA, A. V. **Estudos dos determinantes de preços das companhias aéreas no mercado doméstico**. Rio de Janeiro, 2009.
- PERDOSO, L. H. **Uma sistemática para a identificação, análise qualitativa e análise quantitativa dos riscos em projetos**. Dissertação (Mestrado em Engenharia Naval e Oceânica, Escola Politécnica da Universidade de São Paulo) – Universidade de São Paulo. São Paulo, 2007.
- SCHNEIDER, F.; KALLIS, G.; MARTINEZ-ALIER, J. Crisis or opportunity? Economic degrowth for social equity and ecological sustainability. Introduction to this special issue. **Journal of Cleaner Production**, Sheffield, v. 18, n. 6, p. 511-518, 2010.
- SCOPUS. **Pesquisa referente às palavras-chave do tema**. Disponível em: <<https://www.scopus.com/>>. Acesso em: 04 abr. 2017.
- SEAMSTER, T.; KANKI, B. **Aviation information management: from documents to data**. Vermont: Ashgate Publishing Company Brookfield, 2002.
- SHANNON, R. **Systems simulation the art and science**. Nova Jersey. Editor: Prentice-Hall, 1975.

SINK, D. S.; TUTTLE, T. C. **Planejamento e medição para a performance**. Rio de Janeiro: Qualitymark Editora, 1993.

SLACK, N.; JOHNSTON, R.; CHAMBERS, S. **Administração da produção**. São Paulo, Atlas, 2009.

VARGAS, J. P.; KOPPE, J.; PÉRES, S. **Monte Carlo simulation as a tool for tunneling planning**. Sheffield: Tunnelling and Underground Space Technology, p. 203-209, 2014.