

André Ruy de Souza

OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO APLICADA
NA MELHORIA DA PRODUTIVIDADE DE UMA INDÚSTRIA
METALÚRGICA

ANDRÉ RUY DE SOUZA

OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO APLICADA NA MELHORIA DA
PRODUTIVIDADE DE UMA INDÚSTRIA METALÚRGICA

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

Orientador (a): Aneirson Francisco

Guaratinguetá - SP
2016

S729o

Souza, André Ruy de

Otimização via simulação Monte Carlo aplicada na melhoria da produtividade de uma indústria metalúrgica / André Ruy de Souza – Guaratinguetá, 2016.

36 f : il.

Bibliografia: f. 34-35

Trabalho de Graduação em Engenharia de Produção Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2016.

Orientador: Prof. Dr. Aneirson Francisco

1. Monte Carlo, Método de 2. Controle de produção 3. Cadeia de logística integrada 4. Produtividade I. Título

CDU 519.245

ANDRÉ RUY DE SOUZA

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

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM NOME DO CURSO

Profa. Dra. ARMINDA CAMPOS
Coordenadora

BANCA EXAMINADORA:



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



Prof. Dr. MESSIAS BORGES SILVA
UNESP-FEG



ERICA XIMENES DIAS
Membro Externo

Dezembro 2016

DADOS CURRICULARES

ANDRÉ RUY DE SOUZA

NASCIMENTO 16/03/1991 – São Paulo/SP

FILIAÇÃO Leonor Aparecida Rodrigues Ruy de Souza
José Carlos de Souza

2010/2016 Curso de Graduação em Engenharia de Produção Mecânica, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista.

Dedico este trabalho aos meus pais, meu porto seguro, e minha família que me deram suporte e o apoio necessário para realizar o sonho de me tornar engenheiro e ter condições para desenvolver este estudo.

RESUMO

A gestão da cadeia de suprimentos tem vital importância competitiva na indústria. No setor metalúrgico em sistemas *make-to-order* - MTO, nos quais o pedido do cliente guia toda cadeia de valor, os tempos de produção, o *lead time*, material em processo e os retrabalhos são fatores que tem impacto direto na produtividade, no nível de serviço e satisfação do cliente final. O presente trabalho visa, verificar as vantagens competitivas do uso da otimização via simulação Monte Carlo na previsão da produção de tubos em uma indústria do setor metalúrgico. Com base no histórico de produtos em estoque, dimensional, material consumido e *lead time* foi modelada a função empírica e, posteriormente otimizada via simulação Monte Carlo - OvSMC, obtendo-se os resultados de produtos *ready for delivery* RFD, entregues no prazo e minimizando produtos não conformes. Após análise, os resultados obtidos foram validados estatisticamente com 95% de confiança.

PALAVRAS-CHAVE: Otimização. Simulação Monte Carlo. Função Empírica. *Lead Time*.

ABSTRACT

The management of supply chain is essential to enhance competitiveness of industrial area. Through make to order systems in the metallurgic sector, the client's order lead the whole value stream chain, therefore the lead time, work in process product and rework are inputs that impact directly the productivity, service level and the end customer satisfaction. This study aims, through an quantitative approach with a descriptive model based on simulation, to verify the advantages to use optimization via Monte Carlo simulation on prediction of pipes production in a metallurgic company. Based on inventory data series, product diameter and width, raw material usage, lead time, the empirical function was built and optimized via Monte Carlo simulation, in order to obtain the behavior of ready for delivery, pipes delivered, invoiced on time and minimize not conforming products. After this analyses, the results were statistically validated with 95% of confidence.

PALAVRAS-CHAVE: Otimization. Monte Carlo Simulation. Empirical Function. *Lead Time*.

LISTA DE ABREVIATURAS E SIGLAS

ANP	Agência Nacional de Petróleo
JIT	Just in Time
MTO	Make to Order
SMC	Simulação Monte Carlo
OvSMC	Otimização via Simulação Monte Carlo
SPE	Sistema de Produção Enxuto
SPT	Sistema Toyota de Produção
SRQ	Sistema de Rastreabilidade da Qualidade

SUMÁRIO

1 INTRODUÇÃO	9
1.1 Considerações Iniciais	9
1.2 Delimitação e Questão da Pesquisa	10
1.3 Objetivo	10
1.4 Materiais e Métodos	11
1.5 Justificativa	11
1.6 Estrutura do Trabalho	12
2 FUNDAMENTAÇÃO TEÓRICA	13
2.1. Sistema de Produção Enxuta	13
2.1.1 <i>Just-in-Time</i>	14
2.2 Simulação Monte Carlo.....	15
2.3 Função Empírica.....	16
3 DESCRIÇÃO E MODELAGEM DO PROBLEMA.....	20
3.1 Descrição do Problema.....	20
3.2 Matriz <i>input-output</i>	22
3.3 Otimização via Simulação Monte Carlo	23
4 RESULTADOS	26
5 CONCLUSÃO.....	32
5.1 Verificação dos Objetivos.....	32
5.2 Recomendações Futuras.....	33
REFERÊNCIAS.....	34
APÊNDICE A	36

1 INTRODUÇÃO

1.1 Considerações Iniciais

A dinâmica de mercados exige agilidade para responder a volatilidade das demandas, com os ciclos de vida dos produtos mais curtos, desta maneira, a competição e a crescente tendência por customização de produtos e serviços, cria incertezas adicionais a esse cenário (HOFER, 2011).

A competição global, segundo Khanchanapong *et al.* (2014), tem intensificado a pressão para indústria buscar desenvolvimento ao longo de múltiplas dimensões operacionais. Estas dimensões incluem qualidade do produto, *lead-time*, flexibilidade e custo.

O sistema de produção enxuto (SPE) é a filosofia mais amplamente utilizada como meio de aumentar a competitividade e reduzir desperdícios (MARTIN, 2000). Uma grande quantidade de produtos em processo e longo tempo de ciclo sempre resultam em níveis baixos de serviço e satisfação dos clientes em sistemas MTO (*make-to-order*) (OLHAGER; PRAJOGO, 2012).

Segundo Hofer (2011), com a implementação do SPE é esperado uma melhora nos resultados operacionais, por meio do aumento da qualidade, do fluxo de materiais e da redução no tempo de produção, o que resulta em maior produtividade e, conseqüentemente, melhora na performance financeira.

No SPE o fluxo contínuo de produção é garantido pelo *just-in-time* (JIT), desta forma, duas principais formas de desperdício dentro da cadeia produtiva podem ser identificadas por ferramentas associadas ao JIT, o excesso de produtos em processo e os atrasos desnecessários ao longo do fluxo de produção (DEMETER; MATYUSZ, 2011).

O uso desse conceito em conjunto com o estudo do *lead-time* pode auxiliar na gestão de estoque e no planejamento da produção, visando estimar os materiais em processo e os produtos acabados em um horizonte definido de tempo.

Melhorias nas operações da cadeia de suprimentos na indústria tem um grande valor econômico (SIMCHI; KAMINSKY, 2004). Um gerenciamento de estoque eficaz, segundo Schwartz *et al.* (2006), tem um papel fundamental neste aspecto.

Na literatura existem trabalhos que sugerem o uso de estratégias de controle preditivo (GARCÍA; PRETT; MORARI, 1989) suportados por modelos lineares determinísticos para gerenciamento de estoque. Contudo, os problemas em gestão de estoque normalmente

encontrados na prática correpodem a sistemas estocásticos com relativo grau de incerteza (SCHWARTZ; WANG; RIVERA, 2006).

O objetivo central na otimização de estoques é determinar a quantidade de estoque ótima em cada local de produção em uma rede produtiva multi-escalonada, afim de minimizar o custo total (custos de armazenagem, capital de giro, movimentação, produção, etc.) e, ao mesmo tempo manter o nível de serviço ao cliente. (CHU *et al.*, 2015). Neste contexto, a otimização em problemáticas que envolvem estocasticidade, como em gerenciamento de estoques, pode ser realizada via OvSM.

A simulação é uma técnica utilizada tanto para projeto e avaliação de novos sistemas, como para reconfiguração física ou mudanças no controle e/ou regras de operação de sistemas existentes (CHU *et al.*, 2015).

As suas aplicações têm crescido em todas as áreas, auxiliando os gestores na tomada de decisão em problemas complexos, possibilitando um melhor conhecimento dos processos nas organizações (SAKURADA; MIYAKE, 2009).

1.2 Delimitação e Questão da Pesquisa

O Trabalho delimita-se por uma aplicação realizada em uma empresa do segmento metalúrgico e, portanto, não é mérito da pesquisa generalizar a proposta para outros segmentos. Essa pesquisa delimita-se pelo uso de uma metaheurística programada no otimizador *OPTQUEST* (**Scatter Search, Tabu Search e Redes Neurais**).

Questões da pesquisa:

- Há vantagens na utilização da OvSMC na predição da produção de tubos?
- Como validar os resultados da OvSMC?

1.3 Objetivo

Aplicar a OvSMC na predição da produção de tubos de uma empresa do segmento metalúrgico.

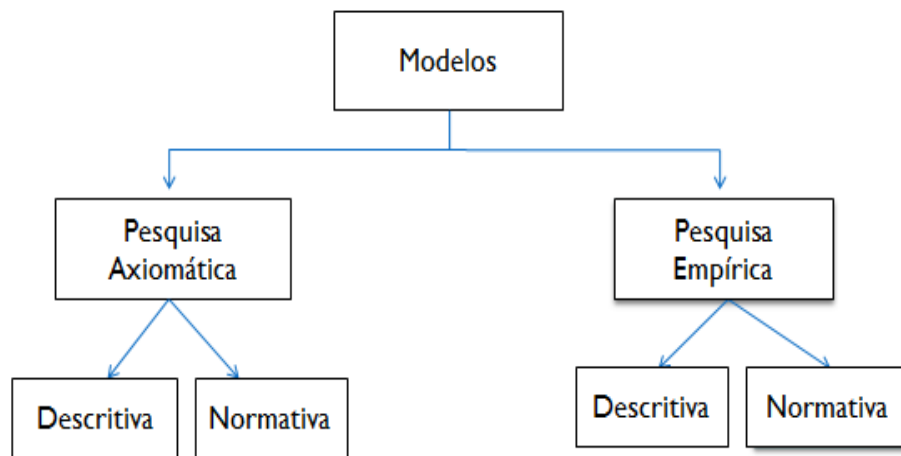
Objetivos Específicos:

- Desenvolver funções empíricas.
- Validar estatisticamente os resultados obtidos pela OvSMC.

1.4 Materiais e Métodos

Segundo Bertrand e Fransoo (2002), esta pesquisa tem natureza aplicada, com objetivo empírico descritivo, a forma de abordar o problema é quantitativa, sendo o método de pesquisa a Modelagem e Simulação.

Figura 1 - Diagrama de metodologia científica.



Fonte: Bertrand e Fransoo (2002)

1.5 Justificativa

O volume de petróleo produzido no mundo em 2014, segundo dados da agência nacional de petróleo (ANP), aumentou em 2,1 milhões de barris/dia (2,4%) em relação a 2013. O Brasil se situou na 13ª posição, após acréscimo de 11% no volume de óleo produzido, totalizando 2,3 milhões de barris/dia (o correspondente a 2,6% do total mundial), dos quais 94,2% são produzidos em campos marítimos (Anuário estatístico brasileiro do petróleo, gás natural e bicombustíveis – ANP; 2015).

Neste contexto, ter uma indústria nacional sólida, que forneça de forma ágil produtos de qualidade para extração e distribuição de óleo e gás é indispensável para alavancar os projetos nos campos *onshore* e *offshore*, e elevar o Brasil no patamar de produtores internacionais.

Na década de 2000, a gestão da cadeia de suprimentos, a qual abrange o planejamento da produção de toda a cadeia de valor, tem se tornado a fundação em gerenciamento de operações (MIRZAPOUR; MALEKLY; ARYANEZHAD, 2011).


Dentro deste cenário, a gestão de estoque tem um papel regulatório fundamental para eficiência dos processos, os quais são possíveis de serem analisados pela relação entre os

insumos, produtos intermediários e produtos finais que atendem as reais necessidades dos clientes.

Otimização por simulação restrita é uma classe de problemas de otimização não linear onde a função objetivo e as restrições podem ser expressas implicitamente por meio de variáveis estocásticas (PASUPATHY; HUNTER, 2014). Contudo, no caso da OvSMC serão utilizadas funções explícitas.


Por meio da base de dados *Web of Science* foi feita uma busca de periódicos sobre os temas otimização via simulação Monte Carlo e função empírica combinados, obtendo-se como resposta o representado nas Figuras 2 e 3, o que indica a relevância científica e atualidade da temática abordada pelo presente trabalho.

Figura 2 - Gráfico de publicações por ano.



Fonte: www.scopus.com (2016)

Figura 3 - Gráfico de citações por ano.



Fonte: www.scopus.com (2016)

1.6 Estrutura do Trabalho

Este trabalho é composto por quatro capítulos. O primeiro capítulo, trata das considerações iniciais, objetivos, material e método, e justificativa da pesquisa. O segundo capítulo contém o referencial teórico. O terceiro capítulo descreve a modelagem do problema, o método de simulação usado, e análise dos resultados. Por fim, o quarto capítulo aborda as conclusões obtidas com a pesquisa e recomendações para estudos futuros, seguido das referências bibliográficas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Sistema de Produção Enxuta

As companhias conhecidas por classe mundial, segundo Pay (2008), estão cada vez mais aderindo ao SPE. Isso tem levado ao desenvolvimento de várias ferramentas nessa área, técnicas, metodologias e um crescente avanço de novas propostas e implementação (GREEN; DICK, 2001).

O SPE, é a filosofia de produção, a qual tem como foco a entrega do maior valor agregado e qualidade, dentro do prazo ao menor custo (LIKER; WU, 2000). Tem se tornado um sistema integrado composto por elementos inter-relacionados e com uma grande variedade de práticas em gestão, incluindo o 5S, *Just-in-Time*, sistemas da qualidade, célula de trabalho, entre outros (SHAH; WARD, 2003).

O SPE pode ser traduzido, segundo Alves *et al.* (2012), como um modelo no qual as pessoas assumem papel de pensantes e seu envolvimento promove um desenvolvimento contínuo, garantindo a companhia a agilidade necessária, tanto para acompanhar a volatilidade da demanda, como as mudanças de mercado atuais e futuras.

Segundo Liker *et al.* (2006), o pensamento enxuto não pode se limitar ao chão de fábrica, sendo que, os princípios de gestão devem se estender além do chão de fábrica, estar presentes no comitê executivo, no departamento comercial e também, naturalmente, no processo de desenvolvimento do produto.

Os princípios e ferramentas do SPE são em sua maioria construídos na história de sucesso do sistema de produção Toyota – SPT, promovendo o aumento da produção com uso de menos recursos, por meio de métodos de eliminação dos desperdícios e foco nas atividades que agregam valor ao produto (DEIF, 2011).

O SPE não é uma exclusividade da manufatura, na literatura existe uma vasta gama de aplicações, indicando uma expansão para diversos setores, como saúde, prestação de serviços, tecnologia da informação, escritórios, construção e até mesmo em organizações sem fins lucrativos, as chamadas ONGs.

2.1.1 *Just-in-Time*

O *just in time* – JIT é um dos conceitos por trás do SPT mais difundidos na indústria (SOHAR, 2014). Refere-se ao fluxo físico por meio dos processos de forma rápida e contínua, alocando o material certo, no local certo e no momento exato de produção. Desta forma, são criados postos de processamento, onde a matéria-prima é movida de uma operação a outra, uma peça por vez, originando um fluxo ininterrupto (LIKER, 2006).

Práticas enxutas são associadas positivamente com a performance do tempo de produção, segundo Sohar *et al.* (2014). De fato, um dos pontos mais marcantes do pensamento enxuto é melhorar a velocidade e a eficiência do fluxo de produção. Esse fluxo é garantido pelo sistema puxado, onde as operações acima da cadeia de valor não acontecem sem o indicativo das operações subsequentes.

O desempenho do *lead-time* tem se tornado um dos principais fatores competitivos na manufatura dentre várias indústrias (TREVILLE, 2004). A redução deste, de acordo com McClelland *et al.* (2000), pode guiar a uma resposta mais rápida as necessidades do cliente, consequentemente, fazendo as organizações mais orientadas ao cliente.

O *lead-time* pode ser entendido como tempo total requerido para se completar uma operação ou processo, segundo Ward e Zhou (2006), pode ser medido de diferentes formas incluindo o tempo de manufatura e o tempo de espera para cliente.

O Primeiro, a somatória dos tempos requeridos em cada etapa para se produzir um item, inclui o tempo de preparação para ingressar a ordem, tempo de fila, tempo de *setup* gasto na preparação dos equipamentos e/ou troca de ferramental necessário, e também, o tempo de inspeção e movimentação dentro do pátio.

Já o tempo de espera do cliente pode ser definido como “o tempo decorrido desde o recebimento de uma ordem até o produto final ser embarcado ou entregue ao cliente” (*Industry Week’s Census Glossary*, 1999).

Duas abordagens podem ser tomadas para reduzir o *lead-time* em processos de manufatura: o uso de tecnologia da informação – TI, integração do fluxo de informações entre áreas e empresas inter-relacionadas pela cadeia de valor e a melhoria de processos produtivos, que de maneira geral, refere-se a implementação do SPE por meio de técnicas como o JIT (WARD; ZHOU, 2006).

O SPE enfatiza a criação de um *layout* de produção eficiente, o qual aumenta o fluxo e a velocidade na qual um produto é feito. Esse *layout* deve ser acompanhado por trocas rápidas na configuração de equipamentos e lotes menores de materiais a serem processados. Desta

forma, tanto a redução do *setup* leva a uma diminuição no tempo de manufatura, como a redução dos lotes a serem processados, pois diminui a fila de materiais em espera nas diferentes fases do processo produtivo (ALSMADI *et al.*, 2012; FLYNN *et al.*, 1995).

2.2 Simulação Monte Carlo

O efeito positivo da interação entre recursos tecnológicos e práticas enxutas, segundo Cooper *et al.* (2012), proporciona grande conhecimento na predição da performance operacional em manufatura, e não devem ser considerados como recursos independentes dentro da organização.

De acordo com a definição universalmente aceita, um Simulador Monte Carlo é um precursor dos possíveis cenários que envolvem o sistema objeto de estudo. O modelo mais aderente depende, não somente das habilidades do seu construtor (i.e., análise de sistemas, coleta de dados, e transcrição lógica), como também do correto procedimento experimental, o qual deve considerar, dentre outros principais pontos, a variabilidade inerente ao sistema, uma vez que esta é diretamente dependente da estocasticidade pela qual a realidade estudada é afetada (CASSETTARI; MOSCA; REVETRIA, 2012).

Amplamente reconhecido na literatura, segundo Markowski *et al.* (2013), os mais efetivos e predominantemente métodos usados para representação de incertezas e aleatoriedades no estudo do comportamento de um sistema, são modelos baseados em teoria probabilística, ou Simulação Monte Carlo - SMC.

Devido à variação de objetivos para a aplicação do modelo de SMC, sua definição pode variar segundo os autores. Entretanto, pode-se defini-la como uma técnica que determina a possível distribuição dos resultados de um processo a partir de valores selecionados randomicamente das variáveis de entrada (HUDSON; TILLEY, 2014).

Kroese *et al.* (2011), afirmam que como principal característica de qualquer método de Monte Carlo, deve haver um gerador de números aleatórios de forma a produzir um vetor infinito $U_1, U_2, \dots, Dist$ de variáveis aleatórias que são independentes e identicamente distribuídas de acordo com uma distribuição de probabilidades *Dist*.

O nome “variável aleatória” refere-se a uma variável em que o seu valor exato não pode ser previsto, portanto, para os matemáticos, o resultado de um modelo no qual essa variável está presente não pode ser previsto com exatidão, no entanto, quanto maior o tamanho da amostra a ser analisada, mais precisa seria a previsão (SOBOL, 1994).

Segundo estudo conduzido por Cardiff (2010), o desenvolvimento do método de Monte Carlo tornou possível adequar uma grande classe de modelos matemáticos que tem como objetivo retratar a complexidade dos dados de problemas reais.

Os resultados obtidos de cada simulação compõem uma distribuição de probabilidade, 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 cenário mais provável (VARGAS; KOPPE; PÉREZ, 2014).

No trabalho de Kroese *et al.* (2011), é citado que métodos de OvSMC é indicado para solucionar situações compostas por vários ótimos locais e com restrições complexas, envolvendo uma mistura de variáveis contínuas e discretas. Dentro de OvSMC, os autores Dhavlikar *et al.* (2013), citam que há dois tipos de abordagem: mono estágio e multi estágio. Os mesmos autores afirmam que na abordagem multi estágio, as simulações são executadas inúmeras vezes, alterando-se os pesos das variáveis independentes, considerando a solução próxima do ótimo obtida na simulação anterior.

2.3 Função Empírica

Algoritmos de otimização baseados em simulação são geralmente aplicados a problemas, nos quais a relação fechada entre os parâmetros a serem otimizados e a função objetivo é desconhecida ou de difícil obtenção (WANG, 2006). Isso ocorre devido a presença de ruído na função ou em razão da relação significativamente complexa entre a função objetivo e os seus parâmetros (SCHWARTZ, 2006).

Um realístico sistema de gestão de estoques, por causa de sua natureza não-linear, estocástica, variável ao longo do tempo, e da presença de interações complexas entre diferentes níveis de produção, pode se tornar um desafio para ser otimizado (CHU *et al.*, 2015). Fato este, que juntamente com a falta de um gradiente explícito de informações, segundo Schwartz *et al.* (2006), justifica o interesse em algoritmos de otimização que dependem unicamente das medições resultantes da função empírica.

A análise de um comportamento pode ser feita por meio de regressão, uma técnica estatística para investigar e modelar a relação entre variáveis. Diversos são os campos de aplicação de regressão, incluindo engenharia, física, economia, administração, biologia e ciência sociais (MONTGOMERY *et al.*, 2001), alguns propósitos para o uso de modelos de regressão são:

- Descrição de dados;
- Estimar parâmetros;
- Previsão;
- Controle.

Outro método de previsão pode ser elaborado por meio de regressão polinomial, essa técnica útil que permite que os dados analisados podem ser visualizados por uma vista espacial por ser composto de mais de uma variável (PEDRINI et al., 2009).

Como apresentado por Montgomery *et al.* (2001) e Nutter *et al.* (2005), a técnica de regressão possui uma base matemática elegante e teoria estatística bem-desenvolvida, podendo ela apresentar relacionamento entre uma variável Y a K's variáveis de controle como é representado pela Equação 1:

$$y_i = a_0 + a_1x_{i1} + a_2x_{i2} + a_3x_{i3} + \dots + a_kx_{ik} + E_i \quad (1)$$

Sendo assim, o coeficiente a_0 da Equação 1 é conhecido como intercepto, pois ele é o valor na qual o equação intercepta o Y e os coeficientes $a_1, a_2 \dots a_k$ são chamados de inclinação, pois são a derivada parcial de Y em relação à variável de controle x_k e o E_i é o erro aleatório

Uma estatística bastante utilizada para mensurar a porcentagem de ajuste de superfície, ou seja, o quanto o modelo matemático atingi dos pontos da amostra, é o R^2 . Ele é calculado como mostrado na Equação 2.

$$R^2 = \frac{SQP}{SQT} \quad (2)$$

Sendo SQP a variação dos dados devido à superfície e SQT a variação total dos dados observados e são calculados utilizando $n =$ número de observações (GOMES et al., 2015). As Equações 3 e 4 mostram o cálculo para SQT e SQP.

$$SQT = \sum y_i^2 - \left[\frac{(\sum y_i)^2}{n} \right] \quad (3)$$

$$SQT = \sum y_i^2 - \left[\frac{(\sum y_i)^2}{n} \right] \quad (4)$$

Para obtenção de modelos matemáticos, um dos métodos mais utilizados na física e na matemática é o Método dos Mínimos Quadrados (MMQ), ajustando os parâmetros analisados a dados empíricos ou experimentais. A fim de apresentar o MMQ, imagine um ajuste dos parâmetros a_0 e b_0 de uma reta $y = a_0 + b_0 \cdot x$, baseando-se em dados experimentos (x_i, y_i, σ_i) nas quais $i = 1, 2 \dots n$, sendo x_i a variável independente, sem erro, e σ_i o seu desvio padrão. Os valores de a_0 e b_0 são desconhecidos e os valores ajustados dessas variáveis serão chamados de \tilde{a}_0 e \tilde{b}_0 . Então, os valores ajustados por meio do MMQ tem como objetivo determinar os valores de a e b que minimizam a soma das diferenças quadráticas entre a reta e os pontos experimentais divididas pelas respectivas variâncias (a variância é o quadrado do desvio padrão). O procedimento é descrito pela Equação 5.

$$Q(a, b) = \sum_{i=1}^n \frac{(y_i - a - bx_i)^2}{\sigma_i^2} \quad (5)$$

A fim de se obter os valores ajustados \tilde{a} e \tilde{b} , deve-se resolver a Equação 6 na matriz.

$$\begin{pmatrix} \tilde{a} \\ \tilde{b} \end{pmatrix} = \begin{pmatrix} \sum \frac{1}{\sigma_i^2} & \sum \frac{x_i}{\sigma_i^2} \\ \sum \frac{x_i}{\sigma_i^2} & \sum \frac{x_i^2}{\sigma_i^2} \end{pmatrix}^{-1} \cdot \begin{pmatrix} \sum \frac{y_i}{\sigma_i^2} \\ \sum \frac{x_i \cdot y_i}{\sigma_i^2} \end{pmatrix} \quad (6)$$

O procedimento descrito é utilizado a fim de obter os parâmetros ajustados para uma reta por meio do método MMQ, contudo, o mesmo método pode ser aplicado para se obter para casos em que modelo matemático não fosse linear. Num caso polinomial, sendo esse o mais abordado nesse estudo, bastava substituir na Equação 5 por $(a + bx_i + cx_i^2 + \dots)$ (HELENE, 2004). O algoritmo completo do MMQ é descrito também pela Equação 7:

$$\hat{Y} = [X^t \cdot X]^{-1} \cdot [X^t \cdot Y] = \begin{bmatrix} b_0 \\ b_1 \\ b_n \end{bmatrix} \quad (7)$$

A fim de se analisar problemas reais nos quais se encontram um grau de complexidade tanto para medições dos parâmetros quanto para a modelagem do problema, pode-se utilizar um processo que se faz uso de variáveis estocástica (MOURA et al., 2011).

3 DESCRIÇÃO E MODELAGEM DO PROBLEMA

3.1 Descrição do Problema

O presente trabalho será aplicado na produção de tubos para extração de óleo e gás, em uma indústria metalúrgica. A empresa em estudo conta com três fábricas de formação, 1 centro de revestimento, onde os tubos são envernizados, um centro de soldagem, para solda e rosqueamento de conectores, e um centro para revestimento interno e externo (concreto, polietileno, poliestireno, epóxi, etc.).

Em seu portfólio, conta com oito famílias de produto. Cada família é classificada pela rota produtiva em que o tubo deve passar, desde sua formação até o estado final, liberado pela qualidade e pronto para ser entregue ao cliente final. Para cada família é associado um *lead time*, determinado com base na série histórica de produção. Na Tab. 1 é possível ver as rotas de produção de algumas famílias de produtos, com seu respectivo *lead time*.

Tabela 1 – Família de produtos

Família de produto	Rota de produção	Tipo de Tubo	Lead Time [dias]
LP Bare	Formação	Nú	3
LP Cond Varnish	Formação → Verniz	Envernizado	17
LP Coated Conc	Formação → Revestimento Externo	Concretado	100
LP Coated Ext	Formação → Revestimento Externo	Revestido	17
LP Coated Ext/Int	Formação → Revestimento Interno → Externo	Revestido	28
OCTG	Formação → Revestimento Interno → Externo → Soldagem Conector	Premium	45

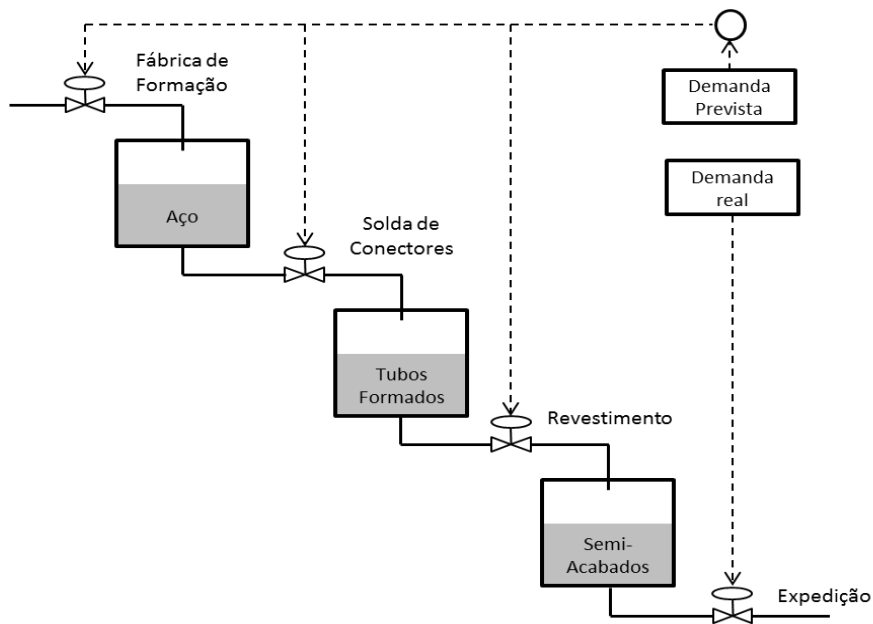
Fonte: Próprio autor.

O *lead time* é usado no cálculo do nível ideal de inventário, sendo importante para a gestão de estoques, por meio deste cálculo é possível prever a quantidade de material entre centros produtivos e o volume de produto final esperado a cada mês. Caso as quantidades esperadas não correspondam com a real, é possível fazer uma análise do desvio e tentar corrigi-lo imediatamente, ou realizar nova estimativa.

Em sistema MTO (*make-to-order*), no qual os tubos são produzidos para atender uma ordem de pedido específica do cliente, esta análise tem especial importância, pois o tempo de entrega do projeto é definido em contrato e qualquer desvio pode resultar em multa ou prêmio por antecipação para a empresa fornecedora.

Como Kempf (2004) demonstrou, uma cadeia de suprimentos assemelha-se a um sistema fluido onde a vazão é determinada pela demanda real, enquanto o represamento de materiais entre centros de produção é dependente da previsão de consumo. Pode-se ver na Fig. 4 como o sistema se comporta.

Figura 4 – Nível de estoque



Fonte: KEMPF (2004).

Imagina-se um sistema real onde o nível de material de cada reservatório, representação dos centros de beneficiamento, seja o nível de inventário que será consumido pelo próprio centro, assim, como temos um processo de produção dependente, pelo *lead time* é possível prever as quantidades de inventário em um horizonte finito.

O *lead time* de uma família de produto para o ano fiscal corrente é definido, analisando a série de dados de produção do ano fiscal anterior. Monta-se uma tabela com o tempo produtivo de cada tubo, exclui-se os *outliers*, e usa-se a média dos tempos para a previsão. Porém como trata-se de eventos dependentes, suscetíveis a flutuação estatística, essa métrica, ou mesmo uma análise puramente determinística, não tem capacidade de retratar a realidade.

Tabela 2 – Lead time por família de produtos.

Família	11/12	12/13	13/14	14/15	15/16	16/17
LP Bare	9	9	9	9	9	3
LP Coated Conc	92	92	92	92	92	100
LP Coated Ext	23	23	23	23	23	23
LP Coated Ext/Int	28	28	28	28	28	60
LP Coated Term	45	45	45	45	45	45
LP Cond Varnish	9	9	9	9	9	13
OCTG HT	62	62	62	62	62	N/A
OCTG NHT	42	42	42	42	42	62

Fonte: Próprio autor.

Portanto, para se conseguir uma análise mais verossímil, pelo uso de método descritivo, será determinada a função empírica e simulada via simulação Monte Carlo, o que garantirá a estocasticidade do modelo.

3.2 Matriz *input-output*

A função empírica foi determinada por regressão linear simples, por meio da matriz de *input-outputs*. A matriz foi estruturada com os *inputs*: diâmetro do tubo em polegadas (OD[in]), espessura do tubo em polegadas (WT[in]), aço consumido em toneladas (aço[Ton]) e o *lead time* em dias; e os *outputs*: tubos faturados dentro do tempo contratual para o cliente (Pipes RFD), e tubos, sobra da obra, que não foram faturados (*Not Invoiced*).


A fim de se estudar o comportamento dos parâmetros e sua influência sobre o resultado, tubos faturados, indicador essencial para se atender a quantidade de entrega especificada pelo cliente e, conseqüentemente, manter o nível de serviço.

A análise foi restrita a uma família de produto, LP Coated Ext/Int, em razão de ter apresentado a maior variação em *lead time* dentre as famílias de produto, 38 dias, passando de 28 no último *budget* (15/16) para 60 dias no budget atual (16/17), e também por apresentar mais de um centro de beneficiamento em sua rota de produção, ao todo, a fábrica de formação, o revestimento interno e o revestimento externo. Espera-se com a OvSMC validar estatisticamente essa variação e, ao mesmo tempo, absorver toda a variância e incertezas inerentes à rota produtiva.

Este foi o último grande projeto realizado pela empresa em 2015/2016, o ROTA, composto por 3 fases: rota 1, 2 e 3. Cada fase tem uma numeração de registro, para qual é vinculada uma ou mais linhas, podendo cada linha ter mais de uma entrega. Para cada linha,

tem-se uma especificação de dimensional (diâmetro e espessura), e uma quantidade de tubos em metros a ser faturada. Na Fig. 5 é possível ver a estrutura do código da obra.

Figura 5 - estrutura do código da obra



Fonte: Próprio autor.

Os parâmetros foram aglutinados por linhas, o que garante um espaço amostral maior em termos do *lead time*, medido por tubo, e viabilidade na obtenção do consumo de aço, registrado por linha pelo SRQ (sistema de rastreabilidade da qualidade). A escolha da família de produto LP Coated Ext/Int, é justificada em função da sua ligeira complexidade de produção, envolve mais de uma etapa produtiva, conseqüentemente está sujeita a variações durante o processo.

O tubo após formado deve cumprir outras duas rotas de produção: revestimento interno e revestimento externo. Espera-se que com a modelagem estocástica essas variações e ruídos sejam absorvidos pelo modelo, garantido por confiabilidade estatística.

Foi necessário o tratamento da informação distribuída entre três bases de dados diferentes usadas pela empresa, o que algumas vezes dificultou o trabalho, por falta ou desencontro de informação.

A matriz consolidada abrange 3 obras, 19 linhas de produção, as quais possuem um total de 37 entregas. Foram tratados com a análise 29.824 tubos, dos quais 29.711 foram faturados e entregues ao cliente, o que representa uma perda de produção de 0,4 %.

3.3 Otimização via Simulação Monte Carlo

Por meio de uma regressão simples foi determinada a função empírica. Obteve-se um R^2 ajustado de 0,98 e todos os valores P menores que 0,05, o que indica, respectivamente, uma boa aderência ao sistema estudado, e todos os parâmetros são significativos. Pode-se ver o resultado da regressão na Fig. 6.

Figura 6 – Estatística da regressão.

Estatística de regressão	
R múltiplo	0,995
R-Quadrado	0,989
R-quadrado ajustado	0,988
Erro padrão	0,112
Observações	37

	(a)		(-b)	(+b)
	<i>Coefficientes</i>	<i>valor-P</i>	<i>95% inferiores</i>	<i>95% superiores</i>
Interseção	1,518062708	0,001276305	0,642639335	2,393486082
OD[in]	-0,06308043	0,003942783	-0,104432463	-0,021728396
WT[in]	-0,054251384	0,007133541	-0,092693122	-0,015809647
Mat. Ajustado [Ton]	0,935953342	2,00752E-27	0,882837542	0,989069141
Lead Time	0,050167365	0,050139986	-3,2536E-05	0,100367266

Fonte: Próprio autor.

A Figura fornece os coeficientes para a modelagem da função empírica, são cinco: a intersecção e outros quatro; um para cada *input*, representados pelas variáveis de decisão. A função pode ser representada de maneira genérica pela Equação 8, em que o símbolo [~] indica estocasticidade.

$$Y = \widetilde{\beta}_0 + \widetilde{\beta}_1 \times X_1 + \widetilde{\beta}_2 \times X_2 + \widetilde{\beta}_3 \times X_3 + \widetilde{\beta}_4 \times X_4 \quad (8)$$

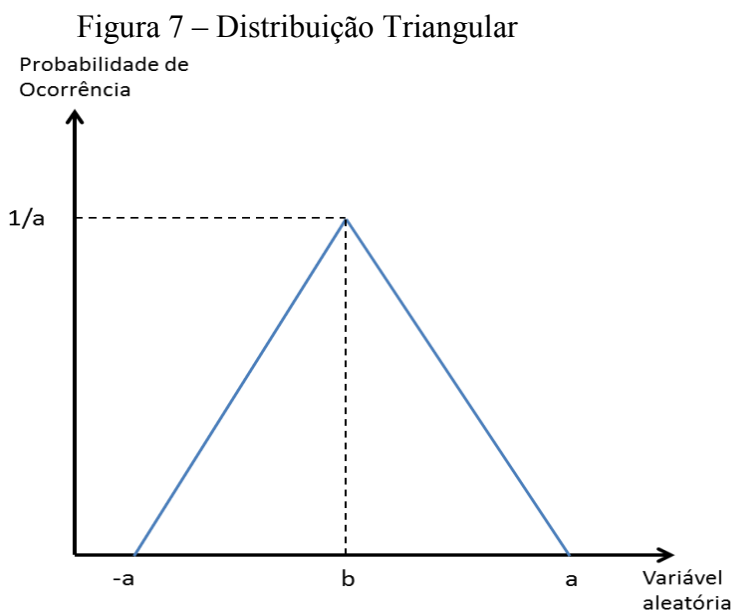
Com o auxílio de uma metaheurística programada dentro do otimizador OPTQUEST. Esta ferramenta seleciona os valores para cada variável de decisão fornecida, entra com os valores em uma planilha, onde executa a OvSMC, grava os resultados obtidos e repete o processo.

Opera de uma forma muito superior para se achar soluções ótimas, quando comparado com o cálculo manual, pois utiliza múltiplas e complementares metodologias de busca incluindo tabu search e scatter search, algoritmos para encontrar as melhores soluções globais.

Com o auxílio de uma planilha em excel, foi escrita a função empírica em termos das variáveis de decisão, os inputs, e dos coeficientes, os valores encontrados com a regressão linear. As amostras de valores são obtidas aleatoriamente em função das frequências de ocorrência dos inputs.

A simulação Monte Carlo permite, a construção de modelos por meio do uso de distribuições de probabilidade. Ao usar distribuições, as variáveis podem apresentar diferentes probabilidades de ocorrência para diferentes resultados. Assim, representam uma forma muito mais realista de descrever as incertezas na análise.

A distribuição usada será a triangular. Essa distribuição trabalha com os seguintes parâmetros: valor mínimo, mais provável e máximo. Os valores mais próximos do mais provável tem, portanto, maior probabilidade de ocorrer. Na Figura 7 podemos ver a representação da distribuição triangular.



Fonte: Próprio autor.

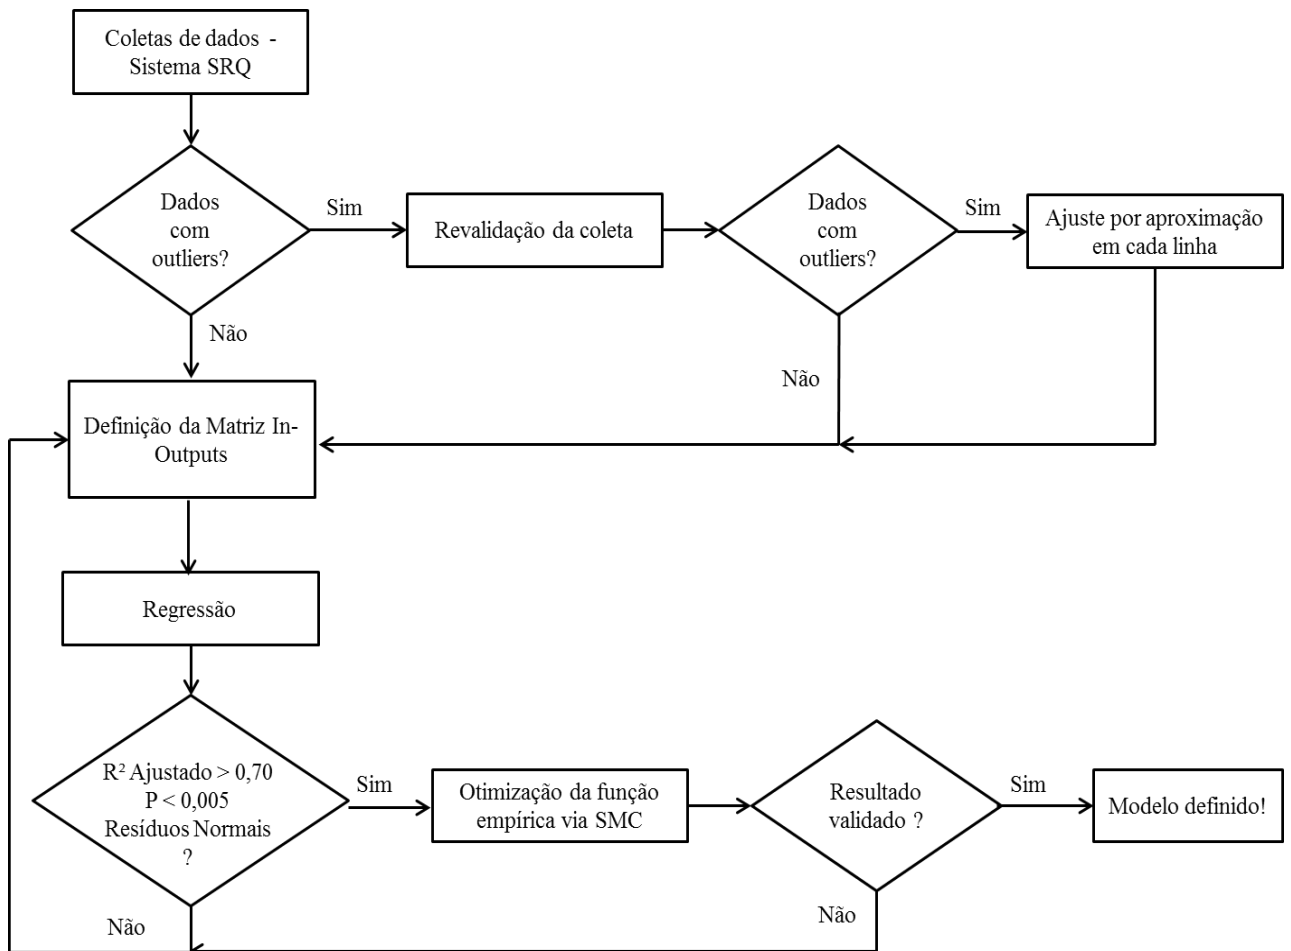
As variáveis aleatórias se distribuem no intervalo $\{-a;a\}$, onde $-a$, b e a são, respectivamente, o valor mínimo, mais provável e máximo. Pela Equação 9 Fica evidente o comportamento da função, para a qual, a área do triângulo corresponde a 1, 100% do espaço amostral.

$$A_t = \frac{(base) \times (altura)}{2} = \frac{(2a) \times \frac{1}{a}}{2} = 1 \quad (9)$$

Os coeficiente X_1 e X_2 da função objetivo obtidos na regressão linear, juntamente com a intersecção, foram distribuídos com comportamento triangular. Os valores inferiores e superiores, correspondentes aos mínimos e máximos, foram determinados com um nível de confiança de 95%.

O processo de obtenção e otimização do modelo via simulação Monte Carlo segue o seguinte fluxograma:

Figura 8 - Fluxograma para processo de modelagem e otimização



Fonte: Próprio autor.

4 RESULTADOS

Em uma primeira análise do comportamento do *lead time* de cada produto, das diferentes linhas da família de produção LP Coated Int/Ext, pode-se verificar a dispersão dos dados. Por meio de histograma e probabilidade acumulada em função do tempo de produção, notou-se que o comportamento das curvas não é simétrico ou tampouco regular, o que indica um grande nível de incerteza inerente ao sistema.

Descobriu-se que são raras as linhas de produção, nas quais o *lead time* se comporta como uma distribuição Normal, com resultados aproximadamente simétricos à média, variando em um desvio padrão (σ).

O histograma foi construído agrupando os *lead times*, em blocos, cada qual variando entre o mínimo e máximo de cada linha. Na Tabela, podemos ver em detalhe os valores

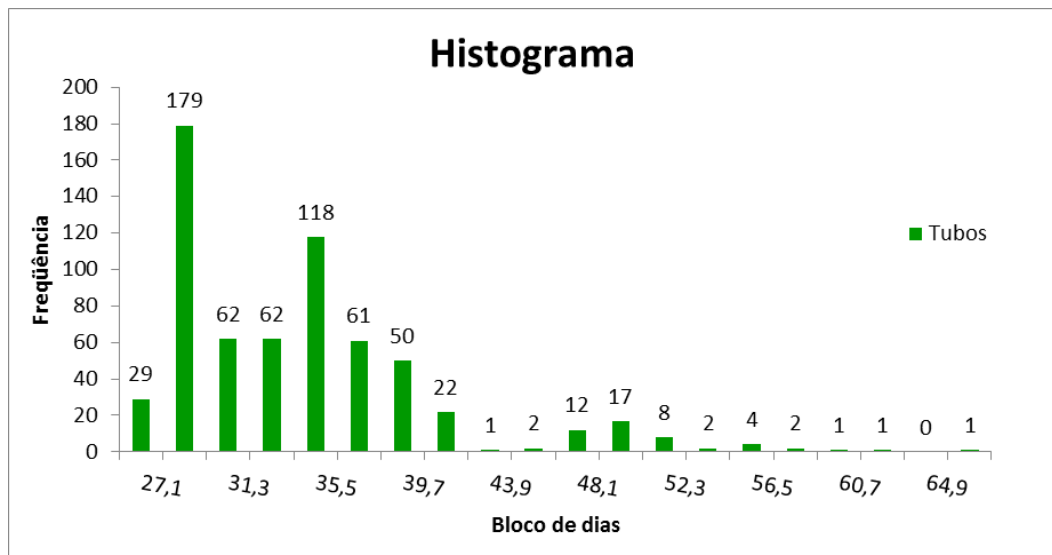
usados para o histograma representado na Fig. 9, correspondem a linha 03, entrega 002 da obra 47383, produto de diâmetro 22” e espessura variando entre 0,94” e 1,25”.

Tabela 3 – Valores da Amostra

Amostra	634
Max	67
Min	25
Bloco	20
Intervalo	2,1
média	34
mediana	33

Fonte: Próprio autor.

Figura 9 - Histograma



Fonte: Próprio autor.

A variação no tempo de produção pode ocorrer por diversos fatores, dentre eles:

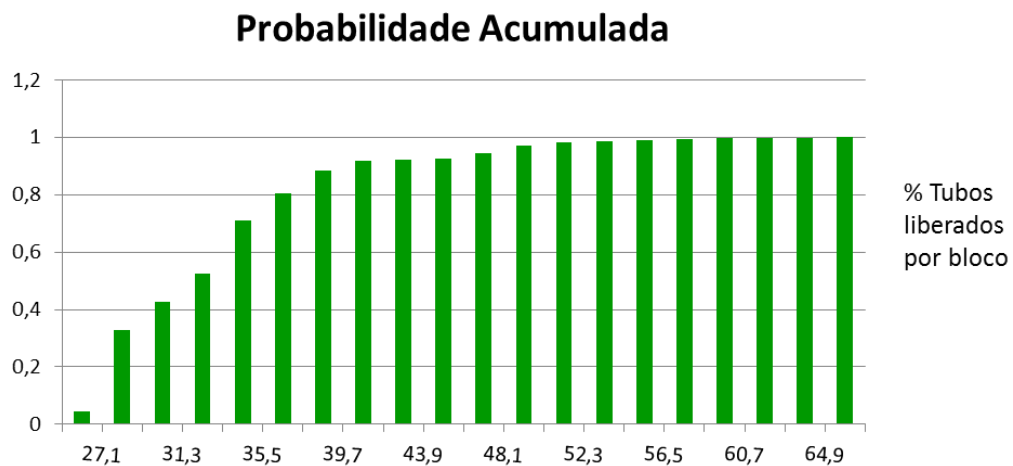
- Paradas da fábrica para manutenção preventiva
- Retrabalhos
- Quebra de ferramental
- Atraso no recebimento de matéria-prima
- Problemas nos sistemas de liberação e Qualidade

Esses problemas têm impacto direto no *lead time* e, conseqüentemente, no nível de serviço, medido em tubos entregues para o cliente dentro do prazo contratual, *output* que será maximizado com a OvSMC.

Pode-se ver um grande número de tubos liberados (179) no segundo bloco, 27-29 dias, seguido por uma leve baixa (62) nos dois blocos seguintes, causada provavelmente por um atraso pontual. Recuperou-se a quantidade liberada (118) durante o bloco 33-35, havendo novamente, logo em seguida, uma baixa. Após os 40 dias de produção vemos a liberação de quantidades menores de tubos em cada bloco, se comparado com o total produzido pela linha (634), o que caracteriza os retrabalhos.

Como podemos observar na curva de probabilidade acumulada, representada na Fig.10, neste caso, um pouco mais de 60% dos tubos são liberados após 34 dias de produção, o que condiz com a média da amostra, porém esta métrica não é confiável, pois há casos em que a média é superior a este valor, deslocada por tubos liberados com atraso em função de alguma anomalia. Assim, com o intuito de padronizar a análise e garantir que, ao menos, 50% dos tubos seja englobado, adotou-se a mediana de cada amostra para o *lead time*.

Figura 10 – Probabilidade acumulada



Fonte: Próprio autor.

Como descrito anteriormente, a função empírica será otimizada via SCM, afim de se absorver e tratar com confiabilidade todas as incertezas inerentes ao sistema, propiciando uma análise mais próxima da realidade.

Para a OvSMC, o valor alvo para a média de simulações foi:

- 817 tubos RFD

Número de tubos RFD determinado pela moda dos *output* para os valores otimizados via SMC, o que indica um número recorrente de tubos liberados na linha, possível de ser demandado em obras futuras, e também, para facilitar a validação.

A OvSMC obtém valores prováveis de faturamento de tubos para o cliente dentro de um intervalo de confiabilidade. Neste trabalho, o grau de confiança almejado é de 95%.

A função empírica obtida por meio da regressão linear da matriz original, em um primeiro momento, não se comportou como desejado durante a SMC, em razão dos dados da base estarem bastante poluídos. Resultou em um gráfico de frequência com valores negativos para os *outputs*, o que restringi o nível de confiança.

Portanto, para diminuir a disparidade dos valores, os dados da matriz foram normalizados, e novamente realizada a regressão. Pode-se ver os resultados desta nova regressão, já apresentados, na Figura 6. Os coeficientes negativos, OD [in] e WT [in], foram modelados de forma a se comportar deterministicamente na simulação, para minimizar o efeito negativo, enquanto os demais continuam variando segundo distribuição trigonal. Na Equação 10 é possível ver a função empírica específica para a realidade estudada:

$$Y = \widetilde{\beta}_0 + \beta_1 \times X_1 + \beta_2 \times X_2 + \widetilde{\beta}_3 \times X_3 + \widetilde{\beta}_4 \times X_4 \quad (10)$$

Onde, as variáveis de decisão (X_1 , X_2 , X_3 e X_4) respeitam uma restrição customizada para os máximos e mínimos computados na matriz:

$$X_1 = \{13,87; 16,64 \}$$


$$X_2 = \{9,56; 13,56 \}$$

$$X_3 = \{0,01; 5,83 \}$$

$$X_4 = \{0,38; 6,00 \}$$

Na 97ª simulação, foram obtidos os valores da otimização mostrados na Figura 11. A Tabela 4, mostra os parâmetros normalizados e os correspondentes reais, multiplicando-se cada um pelo seu respectivo desvio padrão (σ).

Figura 11 – Gráfico da Frequência dos valores de tubos RFD obtidos pela OvSMC.



Fonte: Próprio autor.

Tabela 4 – Valores para os parâmetros obtidos pela OvSMC

Objetivo	Valor Norm.	Valor Real
Alvo para a média de $Y = 0,54$	0,78	1182

Requerimento
O mínimo de $Y =$ deve ser maior que 0,00

Variáveis de Decisão	Valor Norm.	Valor Real
OD[in]	16,64	24
WT[in]	13,56	1
Material Consumido	1,14	6822
Lead time	0,37	27

Fonte: Próprio autor.

Verifica-se que o modelo está validado, pois os valores dos parâmetros obtidos são encontrados na base de dados, assim como, todos os valores para o *output* dentro do intervalo determinado com 95% de confiança.

O *lead time* obtido de 27 dias, parâmetro mais importante para gestão de estoque como discutido anteriormente nas outras seções do trabalho, foi bem próximo do calculado na empresa nos budgets anteriores, de 28 dias. Este fato indica grande concordância com a realidade da companhia. Porém, em contrapartida, nega o aumento de 32 dias para o budget

atual, decorrente provavelmente da incapacidade de uma simples análise determinística, ou do uso de métricas como a média, em absorver as amplitudes presente na base de dados.

Os demais parâmetros seguem uma correspondência verossímil. O valor alvo obtido de 1.182, é um pouco superior ao determinado pela moda da amostra, de 817, contudo durante a simulação observou-se uma constante diminuição deste valor. Pode-se inferir, desta forma, que prosseguindo com a simulação o alvo convergiria, cada vez mais, para o valor fixado.

5 CONCLUSÃO

O presente trabalho avaliou a aplicabilidade da Simulação Monte Carlo na predição e otimização da produção de tubos em um cenário real, vivido no dia a dia de uma indústria metalúrgica do setor de óleo, gás e energia brasileiro. Foi necessário, para o desenvolvimento dos modelos matemáticos, substancial conhecimento da literatura e dos sistemas da empresa em estudo, para obter aquele mais aderente à realidade.

5.1 Verificação dos Objetivos

A coleta de dados e a construção da matriz *input-output*, mostrou-se a etapa mais difícil durante o trabalho, em razão da falta de dados e da desorientação das muitas informações dispostas em diferentes sistemas informacionais, os quais muitas vezes, não estavam alinhados. Como consequência, adaptar a função empírica de forma que traduzisse a realidade e, ao mesmo tempo, possibilita-se uma OvSMC coerente com os objetivos do estudo, foi um desafio a ser vencido. A falta de uma base mais abrangente de dados para dar suporte à matriz, a qual conta, ao todo, com apenas 37 diferentes linhas de produtos, não só impossibilita a extrapolação da análise, como também contribui para o aumento do efeito negativo gerado pela dispersão dos valores.

Como constatou-se, a predição da produção via SMC, pode ser uma vantagem competitiva para a empresa por ser uma técnica de análise estocástica, desta forma, mais aderente à realidade, capaz de tratar as variações inerentes ao sistema produtivo (retrabalhos, quebra e/ou troca de ferramental, paradas programadas e imprevistas), garante também, maior sensibilidade do comportamento da produção, permite identificar anomalias mais rapidamente, possibilitando a intervenção ao traçar um plano de ação corretivo.

Todavia, é necessário esforço na coleta de dados, para garantir uma base de dados robusta, além da habilidade do analista em desenvolver o modelo matemático para simulação, obtendo assim, por meio da regressão linear, a função empírica mais adequada.

Em relação aos objetivos específicos, embora tenha sido necessário normalizar os valores para diminuir a dispersão entre eles, foi possível obter a função empírica que melhor descrevesse o problema com um R^2 -ajustado de 0,98. A regressão linear pelo método dos mínimos quadrados mostrou-se uma ferramenta eficaz para o estudo em questão. Os valores obtidos com a SMC foram validados estatisticamente para um nível de confiança de 95%, todos os parâmetros obtidos para a alvo simulado foram identificados na base de dados.

5.2 Recomendações Futuras

- Recomenda-se como trabalhos futuros utilizar um método para coleta de dados padronizado, afim de se facilitar a obtenção da função empírica e tratar os *outliers*;
- Utilizar outras funções empíricas para testar a aderência e o comportamento da OvSMC;
- Utilizar outras distribuições para estimar o erro dos parâmetros de predição.

REFERÊNCIAS

- BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241-264, mai. 2002.
- CASSETTARI, L.; MOSCA, R.; REVETRIA, R. Monte Carlo simulation models evolving in replicated runs: A methodology to choose the optimal experimental sample size. **Mathematical Problems in Engineering**, v. 12, 2012.
- CHU, Y.; YOU, F.; WASSICK, J. M.; AGARWAL, A. Simulation-based optimization framework for multi-echelon inventory systems under uncertainty. **Computers & Chemical Engineering**, v. 73, n. 2015, p. 1–16, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098135414003032>>. Acesso em: 30 set. 2016
- DEMETER, K.; MATYUSZ, Z. The impact of lean practices on inventory turnover. **International Journal of Production Economics**, v. 133, n. 1, p. 154–163, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.ijpe.2009.10.031>>. Acesso em: 30 set. 2016
- GOMES, O. M.; ANTONIO, C.; DOS, C.; DE, F.; SOUZA, A. S. D. E.; PAIVA, W. D. E.; OLINDA, R. A. D. E.; GRANDE, C. **Modelo de regressão Polinomial**. 2012. Universidade Estadual da Paraíba (UEPB), Departamento de Estatística, Unidade Acadêmica de Ciências Atmosféricas, Recebido Março de 2012 - Ac. p. 47–58, 2015.
- HUDSON, A.; TILLEY, D. R. Assessment of uncertainty in energy evaluations using Monte Carlo simulations. **Ecological Modelling**, v. 271, n. 8, p. 52–61, set. 2014.
- KHANCHANAPONG, T.; PRAJOGO, D.; SOHAL, A. S.; COOPER, B. K.; YEUNG, A. C. L.; CHENG, T. C. E. The unique and complementary effects of manufacturing technologies and lean practices on manufacturing operational performance. **International Journal of Production Economics**, v. 153, p. 191–203, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.ijpe.2014.02.021>>. Acesso em: 30 set. 2016
- MARTIN, C. The Agile Supply Chain : Competing in Volatile Markets. **The Journal of Supply Chain Management**, v. 13, n. 9, p. 102-115, jan. 2000.
- MOURA, S. J.; FATHY, H. K.; CALLAWAY, D. S.; STEIN, J. L. A Stochastic Optimal Control Approach for Power Management in Plug-In Hybrid Electric Vehicles. **Control Systems Technology, IEEE Transactions on**, v. 19, n. 3, p. 545–555, 2011.
- OLHAGER, J.; PRAJOGO, D. I. The impact of manufacturing and supply chain improvement initiatives: A survey comparing make-to-order and make-to-stock firms. **Omega**, v. 40, n. 2, p. 159–165, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.omega.2011.05.001>>. Acesso em: 30 set. 2016
- PEDRINI, D. C.; MARCIO, A.; SANT, O.; SCHWENGBER, C. Sistemática para a aplicação da regressão múltipla. **Journal of Logistics and Management**, v. 14, n. 23, p. 23-39, out. 2009.

SCHWARTZ, J. D.; WANG, W.; RIVERA, D. E. Simulation-based optimization of process control policies for inventory management in supply chains. **Automatica**, v. 42, n. 8, p. 1311–1320, 2006.

SIUTA, D.; MARKOWSKI, A. S.; MANNAN, M. S. Uncertainty techniques in liquefied natural gas (LNG) dispersion calculations. **Journal of Loss Prevention in the Process Industries**, v. 26, n. 3, p. 418–426, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jlp.2012.07.020>>. Acesso em: 30 set. 2016

VARGAS, J. P.; KOPPE, J. C.; PÉREZ, S. Monte Carlo simulation as a tool for tunneling planning. **Tunnelling and Underground Space Technology**, v. 40, p. 203–209, 2014.

WARD, P. AND ZHOU, H. Impact of information technology integration and lean / JIT practices on lead time performance. **Decision Science**, v. 32, n. 2, p. 177–203, 2006.

APÊNDICE A

Tabela 1 – Matriz Input x Output

OD[in]	WT[in]	Matéria Prima	Lead time	Tubos Faturados
13,87	11,06	2,9	0,42	2,89
13,87	11,71	0,08	0,42	0,08
13,87	11,71	5,83	6,00	5,82
13,87	11,71	0,01	0,44	0,01
13,87	11,71	0,01	2,43	0,02
16,64	12,04	0,37	0,75	0,13
16,64	12,04	1,14	0,39	0,41
16,64	12,04	0,06	0,39	0,02
16,64	12,04	0,32	1,68	0,12
16,64	12,04	0,02	1,22	0,01
16,64	12,04	0,01	0,40	0,01
16,64	11,91	0,72	0,90	0,54
16,64	11,91	0,35	2,30	0,26
16,64	11,91	0,01	0,75	0,01
16,64	11,19	0,67	1,26	0,54
16,64	11,19	0,67	1,00	0,54
16,64	11,19	0,67	1,71	0,54
16,64	11,19	0,63	1,79	0,50
16,64	11,19	0,07	2,14	0,05
16,64	10,5	0,63	0,46	0,54
16,64	10,5	0,63	0,60	0,54
16,64	10,5	0,62	0,61	0,54
16,64	10,5	0,63	1,54	0,54
16,64	10,5	0,52	1,64	0,45
16,64	10,52	0,01	0,87	0,01
16,64	10,03	0,6	0,51	0,54
16,64	10,03	0,6	0,83	0,54
16,64	10,03	0,44	0,43	0,40
16,64	9,56	0,45	1,21	0,42
15,25	10,19	0,56	0,50	0,54
15,25	10,19	0,56	0,78	0,54
15,25	10,19	0,39	0,75	0,37
15,25	11,5	0,09	0,37	0,07
15,25	13,56	0,79	0,58	0,54
15,25	13,56	0,61	0,46	0,42
15,25	13,56	0,08	0,69	0,06
15,25	10,19	0,04	0,83	0,04