

IGOR MAKIYAMA DE SOUZA BARBOSA

Otimização via simulação Monte Carlo na redução de custos com transporte de cargas:
aplicação em uma empresa do segmento de autopeças

Igor Makiyama de Souza Barbosa

**Otimização via simulação Monte Carlo na redução de custos com transporte de cargas:
aplicação em uma empresa do segmento de autopeças**

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: Prof Dr. Aneirson Francisco da Silva

B238o	Barbosa, Igor Makiyama de Souza Otimização via simulação Monte Carlo na redução de custos com transporte de cargas : aplicação em uma empresa do segmento de autopeças / Igor Makiyama de Souza Barbosa. – Guaratinguetá, 2018. 50 f : il. Bibliografia: f. 45-50 Trabalho de Graduação em Engenharia de Produção Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2018. Orientador: Prof. Dr. Aneirson Francisco da Silva 1. Cadeia de logística integrada 2. Monte Carlo, Método de 3. Análise de regressão 4. Transporte de mercadorias I. Título. CDU 658.5
-------	--

IGOR MAKIYAMA DE SOUZA BARBOSA

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


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


Prof. Dr. ANDREIA MARIA PEDRO SALGADO
Coordenadora

BANCA EXAMINADORA:


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


Prof. Dr. FERNANDO AUGUSTO SILVA MARINS
UNESP-FEG


Prof. Dr. ERICA XIMENES DIAS
Membro Externo

Outubro de 2018

DADOS CURRICULARES

IGOR MAKIYAMA DE SOUZA BARBOSA

NASCIMENTO	16.01.1996 – Jacareí / SP
FILIAÇÃO	Marcelo de Souza Barbosa Rosangela Makiyama de Souza Barbosa
2014/2018	Curso de Graduação em Engenharia de Produção Mecânica Faculdade de Engenharia de Guaratinguetá Universidade Estadual Paulista “Júlio de Mesquita Filho”

dedico este trabalho
de modo especial, à minha família

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus, fonte da vida e da graça. Agradeço pela minha vida, minha inteligência, minha família e meus amigos,

à Universidade Estadual Paulista, seu corpo docente, direção e administração pela orientação e apoio,

ao meu orientador, *Prof. Dr. Aneirson Francisco da Silva* pela oportunidade, incentivo e apoio na elaboração deste trabalho,

aos meus pais *Marcelo e Rosangela*, que sempre incentivaram meus estudos,

ao meu irmão *Vitor* e toda minha família pelo apoio,

à minha namorada, *Ana Beatriz*, pelo companheirismo,

aos meus amigos de curso que dividiram comigo as dificuldades da graduação e tornaram esses anos inesquecíveis e indescritíveis,

a todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado!

“Só sabemos com exatidão quando sabemos pouco; à medida que vamos adquirindo conhecimento, instala-se a dúvida.”

Goethe

RESUMO

Os esforços para o aprimoramento das atividades relacionadas à Cadeia de Suprimentos, incluindo o Transporte de Cargas, têm se concentrado em reduzir os custos e amenizar os efeitos das incertezas do mercado. A Simulação Monte Carlo trata-se de uma ferramenta amplamente utilizada para trabalhar as incertezas em problemas de tomada de decisão, e quando combinada com técnicas de otimização gera um procedimento encontrado na literatura como Otimização via Simulação Monte Carlo. As contribuições deste trabalho incluem a consideração das incertezas, por meio da OvSMC, na redução dos custos relacionados ao Transporte de Cargas e o desenvolvimento de função empírica que representa os custos com transporte em uma empresa do segmento de autopeças. Foi possível concluir que há vantagens na aplicação da OvSMC na determinação de parâmetros envolvidos no Transporte de Cargas no setor de autopeças, possibilitando redução de custos.

PALAVRAS-CHAVE: Cadeia de suprimentos. Transporte de cargas. Regressão linear múltipla. Otimização via simulação Monte Carlo.

ABSTRACT

The efforts to improve Supply Chain activities, including Freight Transportation, have focused on reducing costs and mitigating the effects of market uncertainties. Monte Carlo Simulation is a widely used tool to deal with uncertainties in decision-making problems, and when combined with optimization techniques it generates a procedure found in the literature as Optimization via Monte Carlo Simulation. The contributions of this work include the consideration of the uncertainties, through OvSMC, in the reduction of the costs related to Freight Transportation and the development of an empirical function that represents the transportation costs in a company of the auto parts segment. It was possible to conclude that there are advantages in the application of OvSMC in the determination of parameters involved in Freight Transportation in the auto parts sector, thus allowing cost reduction.

KEYWORDS: Supply chain. Freight transportation. Linear multiple regression. Optimization via Monte Carlo simulation.

LISTA DE FIGURAS

Figura 1 - Número de publicações sobre "Optimization" and "Monte Carlo Simulation"	17
Figura 2 - Número de citações sobre "Optimization" and "Monte Carlo Simulation"	17
Figura 3 – Mapeamento das citações sobre " <i>Optimization via Monte Carlo Simulation</i> "	18
Figura 4 – Número de publicações sobre " <i>Optimization via Monte Carlo Simulation</i> "	18
Figura 5 – Número de citações sobre "Optimization via Monte Carlo Simulation"	19
Figura 6 – Número de publicações sobre " <i>Supply Chain</i> " and " <i>Freight Transportation</i> "	19
Figura 7 – Número de citações sobre " <i>Supply Chain</i> " and " <i>Freight Transportation</i> "	20
Figura 8 - Classificação da Pesquisa	22
Figura 9 – Fluxo Metodológico	23
Figura 10 – Cadeia de Suprimentos – Exemplo Simplificado.....	25
Figura 11 – Teste de Normalidade dos Resíduos	35
Figura 12 – Distribuição Uniforme Contínua.....	37
Figura 13 – Inserção dos Limites da Distribuição Uniforme Contínua.....	39
Figura 14 – Comportamento da Função Objetivo Utilizando OvSMC IC – 95%.....	40
Figura 15 – Comportamento da Função Objetivo Utilizando OvSMC IC – 99%.....	41

LISTA DE QUADROS

Quadro 1 – Variáveis Independentes e Dependentes	33
--	----

LISTA DE TABELAS

Tabela 1 – Relatório do número de publicações e citações (1999 a 2018)	16
Tabela 2 – Comportamento dos Dados Utilizados	34
Tabela 3 – Estatísticas R-quadro e R-quadrado ajustado	34
Tabela 4 - Resultados da Análise de Regressão	35
Tabela 5 – Fator Inflação da Variância	36
Tabela 6 – Ocorrência de incertezas nos coeficientes da função empírica	38
Tabela 7 – Intervalo [LI, LS] para 95% de Confiança	40
Tabela 8 - Ajuste Proposto para as Variáveis Independentes.....	41
Tabela 9 - Intervalo [LI, LS] para 95% de Confiança	42
Tabela 10 - Ajuste Proposto para as Variáveis Independentes.....	42
Tabela 11 – Comparação entre os Arranjos Obtidos	42

LISTA DE ABREVIATURAS E SIGLAS

CS	Cadeia de Suprimento
OvSMC	Otimização via Simulação Monte Carlo
SMC	Simulação Monte Carlo
TC	Transporte de Cargas
OLS	<i>Ordinary Least Squares</i>

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	CONTEXTUALIZAÇÃO	14
1.2	JUSTIFICATIVAS E RELEVÂNCIA CIENTÍFICA.....	15
1.3	QUESTÕES DE PESQUISA E OBJETIVOS.....	20
1.4	DELIMITAÇÃO.....	21
1.5	MATERIAIS E PROCEDIMENTO METODOLÓGICO.....	21
1.6	ESTRUTURA DO TRABALHO	23
2	FUNDAMENTAÇÃO TEÓRICA.....	25
2.1	CADEIA DE SUPRIMENTOS E TRANSPORTE DE CARGAS	25
2.2	DESENVOLVIMENTO DE FUNÇÕES EMPÍRICAS.....	27
2.3	OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO	29
3	DESCRIÇÃO DO PROBLEMA E MODELAGEM.....	33
3.1	DESCRIÇÃO DO PROBLEMA	33
3.2	OBTENÇÃO DA FUNÇÃO OBJETIVO	34
4	APLICAÇÃO DA OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO	37
4.1	ADIÇÃO DAS INCERTEZAS NOS COEFICIENTES DA FUNÇÃO OBJETIVO ..	37
4.2	OTIMIZAÇÃO DA FUNÇÃO OBJETIVO CONSIDERANDO AS INCERTEZAS.	38
5	RESULTADOS E DISCUSSÃO.....	40
6	CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS	44
6.1	VERIFICAÇÃO DAS QUESTÕES DE PESQUISA E OBJETIVOS.....	44
6.2	RECOMENDAÇÕES PARA FUTURAS PESQUISAS.....	44
	REFERÊNCIAS.....	45

1 INTRODUÇÃO

Este capítulo apresenta contém a contextualização, justificativa e relevância científica, questões de pesquisa e objetivos, delimitação, materiais e procedimento metodológico e uma breve apresentação a estrutura do trabalho.

1.1 CONTEXTUALIZAÇÃO

A complexidade do ambiente econômico global vem crescendo nos últimos anos, fazendo-se necessária uma melhor tratativa das informações relacionadas à Cadeia de Suprimentos (CS). Por esse motivo, as organizações têm adotado novas abordagens para a obtenção e utilização destas informações em seu planejamento (ALI et al., 2017).

Nesse contexto, deve-se considerar que a movimentação de mercadorias entre os agentes econômicos que as produzem e que as consomem só é possível quando há disponibilidade de redes de transporte, fato que torna o Transporte de Cargas (TC) um componente importante para CS (HOLGUÍN-VERAS et al., 2016).

Segundo Demir et al. (2014), há uma tendência de que, em um nível regional, uma parcela significativa das redes de transporte seja composta pelo modal rodoviário. Muñoz-Villamizar et al. (2018) comentam que o sucesso desta atividade é essencial para o crescimento econômico de cidades, regiões e países.

No Brasil, o TC rodoviário é uma atividade desafiadora, devido à falta de planejamento e à escassez de dados de apoio à tomada de decisão, mesmo que esses fatores possuam valor fundamental para o sucesso das operações (OLIVEIRA et al, 2018).

A partir da década de 2010, os esforços para o aprimoramento das atividades relacionadas à CS, incluindo o TC, concentraram-se em reduzir os custos (DEMIR et al, 2014) e amenizar os efeitos das incertezas do mercado (ALI et al., 2017).

Miranda et al. (2017) afirmam que uma alternativa amplamente utilizada para se trabalhar as incertezas em problemas de tomada de decisão é a simulação. A simulação estocástica, segundo Lee et al. (2013), é uma ferramenta para a descrição e análise de sistemas complexos, sendo utilizada em diversas áreas como, por exemplo, transporte, manufatura e telecomunicações.

Nesse sentido, a Simulação Monte Carlo (SMC) é uma técnica de simulação estocástica que parte do pressuposto de que os parâmetros de um modelo são variáveis aleatórias que podem ser representadas por distribuições de probabilidade e geração de números

pseudoaleatórios (ARUNRAJ et al., 2013). Tal técnica pode ser utilizada em problemas de otimização, como forma de considerar as consequências de incertezas na resolução desses problemas (KROESE et al., 2011).

A combinação da SMC com técnicas de otimização dá origem à um procedimento citado na literatura como Otimização via Simulação Monte Carlo (OvSMC) (SILVA et al., 2014), que será aplicado neste trabalho em um problema de redução de custos no TC.

1.2 JUSTIFICATIVAS E RELEVÂNCIA CIENTÍFICA

A Modelagem e Simulação, como afirmam Diallo et al. (2017), é uma disciplina que fornece suporte à resolução de problemas de diversas áreas, sendo uma aliada em boa parte dos campos da ciência e engenharia. Miranda et al. (2017) acrescenta que esse campo de estudo vem sendo muito explorado pelo mercado, o que se torna evidente com o aumento da disponibilidade de *softwares* de simulação que vêm acompanhados de rotinas de otimização.

Nesta linha, Fávero (2015) comenta que as técnicas de regressão estão entre as mais utilizadas em análise de dados, pois permitem estudar as relações entre o comportamento de um fenômeno específico e as variáveis potencialmente preditoras do fenômeno.

Montgomery et al. (2012) ressaltam que o uso bem-sucedido da regressão requer não somente um bom embasamento teórico, como conhecimento prático dos problemas reais nos quais se aplicam essas técnicas.

O método OvSMC permite adequar funções matemáticas para a representação de problemas reais, sendo adequado à solução de problemas com função objetivo e restrições complexas, com variáveis contínuas ou discretas e muitos ótimos locais (LIU et al., 2010; KROESE et al. 2011; CONWAY & ANGALINE, 2017).

Contudo, como comentam Ehrgott et al. (2014), tratando-se de simulação e otimização, a distância que separa a teoria da prática é consideravelmente grande, uma vez que é desafiadora a aplicação de modelos, conceitos e técnicas em problemas reais.

Na mesma linha do que foi apresentado anteriormente, buscou-se evidenciar a relevância dos temas estudados por meio de uma pesquisa na base de dados *Web of Science*. Para tal, utilizou-se as palavras-chaves “*Supply Chain*”, “*Freight Transportation*”, “*Uncertainty*”, “*Optimization*”, “*Monte Carlo Simulation*” e “*Optimization via Monte Carlo Simulation*”.

Adotaram-se ainda filtros para que a pesquisa se concentrasse em títulos, palavras-chaves e resumos de “*Articles*” e “*Proceedings Papers*” publicados nos últimos 20 anos. A

pesquisa gerou os resultados apresentados na Tabela 1, na qual é possível observar o número de publicações e citações para cada palavra-chave e suas combinações.

Tabela 1 – Relatório do número de publicações e citações (1999 a 2018)


Item	Palavra-Chave	Publicações	Citações
1	<i>"Supply Chain"</i>	44.445	460.511
2	<i>"Freight Transportation"</i>	2.933	18.859
3	<i>"Optimization" and "Monte Carlo Simulation"</i>	3.987	44.834
4	<i>"Optimization via Monte Carlo Simulation"</i>	596	9.198
5	<i>"Supply Chain" and "Freight Transportation"</i>	385	4.318
6	<i>"Supply Chain" and "Freight Transportation" and "Optimization"</i>	90	946
7	<i>"Supply Chain" and "Freight Transportation" and "Uncertainty"</i>	26	245
8	<i>"Supply Chain" and "Optimization" and "Monte Carlo Simulation"</i>	30	283
9	<i>"Freight Transportation" and "Optimization" and "Monte Carlo Simulation"</i>	3	11
10	<i>"Supply Chain" and "Freight Transportation" and "Optimization" and "Monte Carlo Simulation"</i>	0	0

Fonte: Web of Science (2018).

No Item 1, observa-se um resultado de 44.445 publicações e 460.511 citações para a palavra-chave *"Supply Chain"*. No Item 2, observa-se que ao pesquisar a palavra chave *"Freight Transportation"* a base de dados retornou um número de 2.933 publicações e 18.859 citações.


O Item 3 contém os resultados da associação das palavras-chaves *"Optimization"* e *"Monte Carlo Simulation"* (3.987 publicações e 44.834 citações), sua evolução no número de publicações e citações ao longo dos anos está contida nas Figuras 1 e 2, respectivamente, nas quais fica evidente um crescente interesse pelo tema.

Figura 1 - Número de publicações sobre "Optimization" and "Monte Carlo Simulation"



Fonte: Web of Science (2018).

Figura 2 - Número de citações sobre "Optimization" and "Monte Carlo Simulation"



Fonte: Web of Science (2018).


No item 4, observa-se que para a palavra-chave “*Optimization via Monte Carlo Simulation*” o resultado da pesquisa é de 596 publicações e 9.198 citações. Utilizando a mesma palavra-chave obteve-se a Figura 3, na qual é possível observar um mapeamento do número de publicações por área de interesse, sendo que as áreas *Operantions Research*, *Management Science*, *Statistics Probability* e *Engineering Industrial* são contempladas por este trabalho. A Figura 4 mostra a evolução no número de publicações e a Figura 5 a evolução no número de citações, ambas sobre “*Optimization via Monte Carlo Simulation*” e crescentes no período observado.

Figura 3 – Mapeamento das citações sobre "*Optimization via Monte Carlo Simulation*"




Fonte: Web of Science (2018).

Figura 4 – Número de publicações sobre "*Optimization via Monte Carlo Simulation*"



Fonte: Web of Science (2018).

Figura 5 – Número de citações sobre "Optimization via Monte Carlo Simulation"




Fonte: Web of Science (2018).

Ao se combinar as palavras-chaves "*Supply Chain*" e "*Freight Transportation*", no Item 5, obteve-se 385 publicações e 4.318 citações e a evolução dos mesmos números nas últimas duas décadas (Figura 6 e Figura 7). Corroborando com o tópico de contextualização, as Figuras 6 e 7 mostram a relevância da relação entre CS e TC, que vem sendo cada vez mais explorada.

Figura 6 – Número de publicações sobre "*Supply Chain*" and "*Freight Transportation*"


385



Fonte: Web of Science (2018)

Figura 7 – Número de citações sobre *"Supply Chain"* and *"Freight Transportation"*

Número de citações por ano



Fonte: Web of Science (2018)

Ao analisar os itens 6, 7 e 8, é possível entender que há interesse no estudo de *"Supply Chain"* e *"Freight Transportation"* associados à *"Uncertainty"*, *"Optimization"* e *"Monte Carlo Simulation"*. Contudo, como fica visível nos itens 9 e 10, que existem oportunidades de pesquisa combinando *"Freight Transportation"*, *"Optimization"* e *"Monte Carlo Simulation"* (3 publicações) e *"Supply Chain"*, *"Freight Transportation"*, *"Optimization"* e *"Monte Carlo Simulation"* (nenhuma publicação).

1.3 QUESTÕES DE PESQUISA E OBJETIVOS

Compreendido o contexto no qual se insere este trabalho e suas justificativas, foi possível levantar as seguintes questões:

- Como aplicar a OvSMC em problemas de redução de custos no TC?
- Como desenvolver uma função empírica que represente adequadamente o comportamento dos custos com TC de uma empresa do segmento de autopeças?

O objetivo geral deste trabalho foi aplicar a OvSMC na redução dos custos relacionados ao TC. Os objetivos específicos são:

- Desenvolver uma função empírica que represente adequadamente os custos com TC de uma empresa do segmento de autopeças;
- Propor uma ajustagem dos parâmetros vinculados ao processo de TC, de forma a reduzir os custos.
- Validar estatisticamente os resultados gerados pela OvSMC.

1.4 DELIMITAÇÃO

Os dados utilizados neste trabalho foram extraídos da base de dados de uma empresa do segmento de autopeças e referem-se ao transporte de cargas. Os critérios utilizados para a escolha do objeto de estudo foram baseados na localidade da empresa, de fácil acesso, e na exequibilidade, por possuir sistema de coleta de dados e permitir o acesso aos mesmos.

1.5 MATERIAIS E PROCEDIMENTO METODOLÓGICO


As informações sobre a CS e o TC, registros e controle de processos, foram obtidas por meio do sistema ERP da empresa objeto de estudo. Para a coleta e tratamento de dados, tal como para a aplicação dos métodos quantitativos, foram utilizados os seguintes materiais:

- Ms-Excel®: utilizado para o tratamento dos dados e para a modelagem do problema estudado.
- Minitab 18®: utilizado para o tratamento dos dados e para obtenção das estatísticas necessárias para execução e validação do trabalho.
- Oracle Crystall Ball® *Trial Version* e otimizador Optquest®: aplicação baseada em planilhas para desenvolver modelos preditivos, previsão, simulação e otimização (ORACLE, 2018), utilizado para a otimização da função objetivo. Esta ferramenta utiliza uma combinação de diferentes metaheurísticas para compor um algoritmo eficiente na busca de novos cenários, entre as metaheurísticas o Busca Tabu, Redes Neurais e Busca Dispersa (KLEIJNEN & WAN, 2007). O software e otimizador foram configurados para fazer 10.000 rodadas de simulações com 10.000 replicações, totalizando 10^8 iterações.
- Para a modelagem e aplicação da OvSMC foi utilizado um computador com processador Intel® Core™ i5-4210U 1.70GHZ, memória RAM de 8 GB e sistema operacional Windows® 10 64 bits. Com tal recurso e utilizando as configurações de simulação comentadas no tópico anterior, o tempo computacional foi de aproximadamente 20 horas.

Este trabalho possui características que o classificam como uma pesquisa de natureza aplicada. O problema foi estudado sob a ótica da abordagem quantitativa, sendo o método de

pesquisa modelagem e simulação. Observa-se na Figura 8 uma visão geral da classificação de pesquisas científicas (BERTRAND & FRANSOO, 2002; MIGUEL, 2010).


Figura 8 - Classificação da Pesquisa



Fonte: Adaptado de Bertrand e Fransoo (2002) e Miguel et al. (2010).

Pesquisas as quais seguem abordagem quantitativa podem ser ainda classificadas como: empírica descritiva, empírica normativa, axiomática descritiva e axiomática normativa. Esta pesquisa se enquadra no modelo empírico descritivo, uma vez que os estudos desenvolvidos favorecem a compreensão dos processos reais ao descrever as relações causais existentes na realidade (BERTRAND & FRANSOO, 2002). As etapas de aplicação do método proposto podem ser acompanhadas na Figura 9.

Figura 9 – Fluxo Metodológico



Fonte: Próprio autor.

Para a obtenção da função objetivo optou-se neste trabalho pelo algoritmo OLS - *Ordinary Least Squares* (WAGNER, 2013, FERRARO & GIORDANI, 2012).

1.6 ESTRUTURA DO TRABALHO

Este trabalho possui estrutura com mais quatro capítulos. O segundo capítulo trata-se da fundamentação teórica, nele são apresentados os conceitos acerca dos temas Cadeia de Suprimento, Transporte de Cargas e Otimização via Simulação Monte Carlo. O capítulo 3 contempla a descrição e modelagem do problema. No capítulo 4 encontra-se a análise dos

resultados. as conclusões e recomendações para futuras pesquisas, seguidas das referências utilizadas. No capítulo 5 são feitas as conclusões e recomendações para futuras pesquisas.


2 FUNDAMENTAÇÃO TEÓRICA

2.1 CADEIA DE SUPRIMENTOS E TRANSPORTE DE CARGAS

Segundo Christopher (1998), uma CS pode ser definida como uma rede de organizações ligadas em diferentes processos e atividades por meio de relações *upstream* (em direção ao fornecedor) e *downstream* (em direção ao consumidor).

Simchi-Levi et al. (2007) acrescentam que, de forma clássica, uma CS pode ser vista como uma combinação de processos destinados a atender as demandas do mercado consumidor ao menor custo possível, sendo composta por diversos atores como, por exemplo, fornecedores, unidades de produção e montagem, distribuidores, transportadoras, varejistas e clientes (Figura 10 – Exemplo de CS com uma unidade produtiva, duas camadas de fornecedores, duas camadas de clientes e duas transportadoras).

Figura 10 – Cadeia de Suprimentos – Exemplo Simplificado



Fonte: Adaptado de Winter e Knemeyer (2013).

Para Barbosa-Póvoa et al. (2018), a definição de CS vem sendo expandida e na última década passou a incorporar atividades com objetivos não só de cunho econômico, mas que consideram aspectos como, por exemplo, impactos sociais e ambientais.

Winter e Knemeyer (2013) comentam que as CS não são compostas apenas de relações dispostas de forma linear, mas sim complexas redes de colaboração e fornecimento de bens e serviços. Nesse sentido, Lambert (2014) comenta que a mudança de paradigma mais

significativa no ambiente de negócios atual é de que as empresas não podem mais agir e pensar de forma totalmente autônoma e individual, mas sim considerando sua CS. Christopher (2016) afirma ainda que em termos de competitividade, há uma tendência de que o nível de concorrência, antes vista como empresas rivalizando com outras empresas, passe para a competição entre diferentes CS.

Nesse contexto, é importante ressaltar que os objetivos de uma CS estão ligados à integração de uma rede de agentes e processos, que de ponta a ponta possuem o objetivo comum de fornecer produtos e serviços competitivos e com qualidade, para o consumidor final (WINTER & KNEMEYER, 2013; AKBARI, 2018).

Holguín-Veras et al. (2016) explicam que parte essencial de uma CS está relacionada à movimentação de bens entre os agentes econômicos que as produzem e que as consomem, o que só é possível quando redes de transporte estão disponíveis, fato que torna o TC um componente importante para CS.

Nuzzolo e Comi (2014) definem o TC como resultado do processo de tomada de decisão de uma série de *stakeholders* em uma CS, em particular os relacionados aos processos de logística e transporte, frente à necessidade de movimentação de bens. Holguín-Veras et al. (2016) explicam o TC como um conjunto de entidades – equipamentos, infraestrutura, operações, mão-de-obra especializada – que permitem a movimentação de bens, sendo que alguns desses conjuntos possuem localização fixa como, por exemplo, portos e ferrovias, enquanto outros não ficam restritos à uma área de ação, como as companhias de caminhões.

Segundo Demir et al. (2014), em um nível regional, uma parcela significativa das redes de transporte é composta pelo modal rodoviário. Oliveira et al. (2018) afirma que no Brasil o TC rodoviário é uma atividade desafiadora, devido à falta de planejamento e à escassez de dados de apoio ao processo de tomada de decisão, mesmo que esses fatores possuam valor fundamental para o sucesso das operações.

As atividades relacionadas ao TC rodoviário estão entre as mais complexas em uma CS, visto que é necessário responder de forma eficiente às necessidades de negócios e consumidores finais, considerando um cenário de aumento na variação das demandas, regulamentação governamental e preocupação com problemas ambientais (VIEIRA et al., 2015; ZENINI & DE MARCO, 2017).

Os esforços para o aprimoramento das atividades componentes de CS, as quais incluem o TC, concentraram-se na redução de custos (DEMIR et al, 2014) e em amenizar os efeitos das incertezas do mercado (ALI et al., 2017). Para tais objetivos, ferramentas de simulação

estocástica são amplamente utilizadas, inclusive em problemas de transporte (LEE et al., 2013; MIRANDA et al., 2017).

2.2 DESENVOLVIMENTO DE FUNÇÕES EMPÍRICAS

A análise de regressão resulta do processo lógico conceitual de usar uma equação para expressar a dependência entre uma variável de interesse e um conjunto de variáveis preditoras relacionadas. Trata-se de uma técnica estatística para a investigação e modelagem da relação entre variáveis, com aplicação em quase todos os campos do conhecimento (MONTGOMERY et al., 2012).

Segundo Fávero (2015), os modelos de regressão mais estudados compõem o grupo dos Modelos Lineares Generalizados, o qual contempla os modelos de regressão lineares e exponenciais não lineares, em que as variáveis dependentes possuem, por exemplo, distribuição normal, Bernoulli, binomial, Poisson ou Poisson-Gama. São eles:

- Linear: variável dependente quantitativa de distribuição normal;
- Logística Binária: variável dependente qualitativa, com duas categorias e de distribuição Bernoulli;
- Logística Multinomial: variável dependente qualitativa, com mais de duas categorias e de distribuição Binomial;
- Poisson: variável dependente quantitativa, com valores inteiros e não negativos (dados de contagem) e de distribuição Poisson.
- Binomial Negativo: variável dependente quantitativa, com valores inteiros e não negativos (dados de contagem) e de distribuição Poisson-Gama.

Wagner (2013) comenta que os modelos de regressão linear são fundamentais para pesquisas quantitativas em diversas disciplinas. Fávero (2015) completa ainda que, nas mais diversas áreas de estudo, os modelos de regressão simples e regressão múltipla são os mais utilizados.

Como exemplo, é possível observar em Lin e Tsai (2015), Hatimi (2017), Sinthupundaja e Chiadamrong (2017) e Janani e Santhi (2018), aplicações de modelos de regressão linear nas áreas das ciências sociais, marketing, administração e engenharia, respectivamente.

Os modelos de regressão linear simples e linear múltipla podem ser expressos como mostrado nas equações (1) e (2), respectivamente (GHAEDI et al., 2016):

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

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

em que y_i é a variável resposta (variável dependente), x_{ki} são as variáveis explicativas (variáveis independentes), β_k são os coeficientes de cada variável independente, ε é o termo de erro (resultado da diferença entre o valor real da variável dependente e o valor previsto para a mesma) e i representa cada uma das n observações da amostra em análise.

Um aspecto importante relacionado à regressão é a homocedasticidade, o qual se trata de um pressuposto para a utilização de modelos clássicos de regressão linear e define que para esses modelos a variância dos resíduos, condicionada às variáveis independentes, deve ser constante como mostrado na equação (3) (MAIA, 2017):

$$Var(\varepsilon_i / x_{1i}, x_{2i}, \dots, x_{ki}) = \sigma^2 \quad (3)$$

Maia (2017) comenta ainda que o contraponto da homocedasticidade é a heterocedasticidade, a qual torna inválidas as estimativas dos erros padrão e as estatísticas *t-Student* e *F*.

Liu et al. (2016) afirmam que o OLS é amplamente utilizado em regressões lineares, enquanto que para regressões não lineares a técnica mais utilizada é o *Non-linear Least Squares* (NLS). Neste trabalho será dado enfoque para o OLS.

Como definem Bilginol et al. (2015) em seu trabalho, o OLS é um método que consiste em determinar a equação da reta y com melhor adequação à distribuição dos dados em análise, estimando os valores para os fatores β_k de forma a minimizar o quadrado das diferenças (erros quadráticos) entre os valores reais da variável dependente e os valores estimados.

O OLS pode ser expresso na forma matricial, como é possível observar nas equações (4) e (5) (KIM et al., 2013):

$$\min SSE_{OLS} = |\vec{y} - \vec{y}_{est}| \quad (4)$$

$$\hat{\beta} = (X^T X)^{-1} X^T \vec{y} \quad \text{e} \quad \vec{y}_{est} = X(X^T X)^{-1} X^T \vec{y} \quad (5)$$

sendo SSE_{OLS} a soma dos erros quadráticos.

Sobre os resultados da OLS, Fávero (2015) afirma que a estatística R-quadrado ajustado fornece a fração da variável resposta que pode ser explicada por um modelo de regressão, ajustada ao número de variáveis preditoras em relação à quantidade de observações.

Para Freund et al. (2006), outro fator importante relacionado à aplicação do OLS é a multicolinearidade, a qual pode ser descrita como a existência de um grau elevado de correlação entre as variáveis independentes e por isso apresenta sérias consequências nas estimativas dos coeficientes do modelo de regressão. Montgomery et al. (2012) comentam que, existindo multicolinearidade, a variância dos coeficientes da regressão aumenta e esses se tornam irregulares.

Segundo O'Brien (2007), uma boa medida para o grau de multicolinearidade é o Fator Inflação da Variância (VIF), o qual quantifica a proporção de uma variável regressora que pode ser explicada pelas demais variáveis regressoras do modelo. Na equação (6) é possível observar a formulação de uma variável regressora em função das demais.

$$x_{i0} = f(x_i), \quad i = 1, 2, \dots, n \quad x_i \neq x_{i0} \quad (6)$$

O cálculo do VIF pode ser formulado conforme a equação (7):

$$VIF_j = \frac{1}{1-R_j^2}, \quad j = 1, 2, \dots, p \quad (7)$$

sendo j cada uma das p variáveis independentes, R_j^2 o coeficiente de correlação múltipla da regressão de x_i nas outras $(p - 1)$ variáveis independentes.

Sobre a utilização do OLS e os modelos de regressão múltipla, Montgomery et al. (2012) comentam ainda sobre a importância das estatísticas F e t -Student que, respectivamente, podem ser utilizadas para testar, em um modelo, a significância global dos parâmetros e a significância individual de cada um dos coeficientes.

2.3 OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO

A simulação pertence ao campo de conhecimento da Pesquisa Operacional (PO). Tal ferramenta permite a representação de sistemas reais e dos processos que os compõem, gerando uma história artificial que dá bases para se inferir sobre aspectos da realidade (BANKS et al., 1996).

De forma similar à dedução, a simulação começa com premissas colocadas de forma explícita (*inputs*), as quais são tomadas como base para se obter resultados (*outputs*). Contudo, a simulação vai além, pois envolve ainda a indução, uma vez as relações entre as variáveis estudadas podem ser analisadas experimentalmente (ROBINSON, 2014).

A simulação permite a visualização de processos, medição do desempenho de tais processos e a análise de diferentes cenários, sendo utilizada em análises de sistemas complexos e caracterizados por possuir inúmeras iterações. Nesta linha, a simulação é uma ferramenta útil no apoio ao processo de tomada de decisão, permitindo que os gestores aprofundem seu conhecimento sobre o sistema em estudo (BISOGNO et al., 2016).

Segundo Hillier e Lieberman (2010), as etapas básicas da simulação são:

1. Estabelecer a condição atual do sistema;
2. Identificar as condições que o sistema pode assumir;
3. Identificar os eventos que podem atuar sobre o sistema e mudar sua condição;
4. Definir uma forma de controle sobre tempo da simulação;
5. Definir método de geração de eventos;
6. Desenvolver modelo que altere a condição do sistema com base em cada novo evento.

Entre as diversas formas de classificação, os modelos de simulação podem ser definidos como Modelos Determinísticos e Modelos Estocásticos. Os Modelos determinísticos são aqueles nos quais as relações entre as variáveis são fixas e isentas da ação de incertezas. Já os Modelos Estocásticos contemplam incertezas, ou seja, possuem ao menos uma variável de entrada aleatória (RUBINSTEIN e KROESE, 2016).

Segundo Silva et al. (2014), grande parte das variáveis componentes de sistemas reais são de natureza estocástica ou aleatórias, ou seja, o valor destas variáveis não pode ser predito com exatidão. Nesse sentido, como comentam Lee et al. (2013), a simulação estocástica é uma ferramenta que permite a descrição e análise de sistemas reais complexos.

As aplicações da simulação estocástica são diversas. Giles (2015) reconhece que tal ferramenta vem sendo cada vez mais utilizada em áreas como matemática aplicada, ciência da computação, finanças, gestão, biomedicina e engenharia.

A simulação estocástica envolve quatro etapas principais (MESOGITS et al., 2014):

1. Quantificação das incertezas sobre as variáveis de entrada;
2. Inserção das incertezas no modelo;
3. Implementação de método de propagação das incertezas;

4. Quantificação das incertezas sobre as variáveis de saída.

Por incluir aleatoriedade em seu modelo, a SMC é definida como simulação estocástica (RUBINSTEIN & KROESE, 2016). A técnica em questão é frequentemente usada para resolver problemas estocásticos por meio de cálculos estatísticos do estado de um sistema, trata-se de um método robusto e de fácil implementação (MALTBA et al., 2018).

A SMC envolve experimentos numéricos em modelos matemáticos, por meio da geração de números pseudoaleatórios para as variáveis de entrada, considerando suas respectivas distribuições estatísticas (MESOGITS et al., 2014; KANELLOPOULOS et al., 2015).

Os números pseudoaleatórios são gerados por algoritmos computacionais e possuem características similares aos dos números aleatórios, salvo o fato de necessitarem de um valor inicial a partir do qual podem ser determinados (DENG & BOWMAN, 2017).

Os números aleatórios são essencialmente variáveis aleatórias independentes e distribuídas uniformemente, sendo que os métodos para geração desses números são lentos demais para uso geral, além de não garantirem a reprodutibilidade das sequências numéricas geradas. Por esse motivo, é comum o uso de geradores de números pseudoaleatórios (RUBINSTEIN & KROESE, 2016).

Os geradores de números pseudoaleatórios devem garantir a obtenção de sequências de números com uma distribuição estatística definida, estatisticamente independentes e reprodutíveis; seu bom desempenho é crucial para o sucesso da implementação de algoritmos estocásticos como, por exemplo, a SMC (MANSSEN et al., 2012).

Outro aspecto importante que envolve a SMC e a geração de números pseudoaleatórios é o uso de funções densidade de probabilidade, as quais, em modelos que possuem coeficientes aleatórios, definem a probabilidade de o coeficiente assumir um valor dentro de um determinado intervalo (MALTBA et al., 2018).

De maneira geral, gestores buscam otimizar sistemas e processos que são influenciados por incertezas que atuam, por exemplo, sobre os coeficientes das funções objetivo e sobre os coeficientes das restrições (DURUGBO et al., 2013). Ao se combinar um conjunto de técnicas de otimização com a SMC, obtém-se um procedimento que pode ser encontrado na literatura como OvSMC, utilizado na solução de problemas de otimização, como forma de considerar as consequências de incertezas em tais problemas (KROESE et al., 2011).

A OvSMC pode ser formulada como mostra a equação (8) (SILVA et al., 2014):

$$\max g(x) = E_p[G(x, w)], \quad x \in X \quad (8)$$

sendo $G: \mathbb{R}^n \times \Omega \rightarrow \mathbb{R}$ e o valor E esperado é definido com base na probabilidade P definida em um espaço amostral (Ω, F) e $X \subset \mathbb{R}^n$.

3 DESCRIÇÃO DO PROBLEMA E MODELAGEM

3.1 DESCRIÇÃO DO PROBLEMA

A sistemática apresentada na Figura 9 teve início na etapa de identificação do problema experimental, na qual buscou-se a compreensão do contexto em que o processo de transporte de cargas seria estudado. Em primeiro lugar, junto aos gestores da empresa e com base na literatura estudada, foram definidas as variáveis resposta de interesse e as variáveis independentes com influência sobre o processo. Decidiu-se que seriam adotados 8 parâmetros no estudo, dos quais 5 são de entrada (X 's) e 3 de saída (Y 's), como apresentado no Quadro 1. Com isso, foram coletados os dados do problema objeto de estudo, obtendo-se os valores da variável resposta e, de forma associada, das variáveis independentes. Na Tabela 2, para exemplificar, é apresentada parte dos dados utilizados no estudo.

Quadro 1 – Variáveis Independentes e Dependentes

Variáveis	Descrição do parâmetro	[Unidade de Medida]
x_1	Valor diário transportado do produto tipo 1	[Unidade Monetária]
x_2	Valor diário transportado do produto tipo 2	[Unidade Monetária]
x_3	Valor diário transportado do produto tipo 3	[Unidade Monetária]
x_4	Valor diário transportado do produto tipo 4	[Unidade Monetária]
x_5	Valor diário transportado do produto tipo 5	[Unidade Monetária]
y_1	Custo diário com transporte	[Unidade Monetária]
y_2	Valor diário transportado total	[Unidade Monetária]
y_3	Indicador custo com transporte pelo volume transportado	[%]

Fonte: Próprio autor.

Tabela 2 – Comportamento dos Dados Utilizados

x_1	x_2	x_3	x_4	x_5	y_1	y_2	y_3
72.101,30	65.161,25	157.513,79	227.302,78	11.769,66	16.227,78	533.848,78	3,04%
33.573,76	24.114,14	23.556,72	212.949,10	26.884,96	9.524,12	321.078,68	2,97%
25.008,78	30.888,28	58.389,85	171.152,01	44.580,36	9.333,70	330.019,28	2,83%
48.839,12	42.423,68	57.154,92	262.546,52	5.182,56	10.618,19	416.146,80	2,55%
24.799,76	39.301,97	39.506,02	175.664,58	26.979,46	8.674,17	306.251,79	2,83%
66.792,99	67.184,54	97.864,08	300.451,80	5.674,50	15.631,49	537.967,91	2,91%
34.525,75	55.867,91	91.308,52	201.720,32	8.316,41	11.909,78	391.738,91	3,04%
95.336,35	76.203,92	178.971,30	364.129,02	12.126,64	18.551,37	726.767,23	2,55%

Fonte: Próprio autor.

3.2 OBTENÇÃO DA FUNÇÃO OBJETIVO

Selecionadas as variáveis e obtidos os dados, foram geradas a função objetivo, nas quais a variável resposta é descrita em função das variáveis independentes que influenciam o processo.

Utilizou-se os dados obtidos no Passo 1, para gerar a função empírica e os Intervalos de Confiança (95% e 99%), para os coeficientes das variáveis independentes. A escolha dos intervalos de confiança se deu pelo fato de que 95% é o valor padrão utilizado na literatura estudada e 99% é o maior intervalo possível dentro do qual os coeficientes da função empírica podem variar em relação ao valor estimado pela análise de regressão.

Aplicando-se o algoritmo OLS para a Análise de Regressão (FÁVERO, 2015), obteve-se função empírica linear para a variável y_1 (9). Os resultados da Análise de Regressão estão expressos na Tabela 3 e na Tabela 4.

$$y_1 = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 \quad (9)$$

Tabela 3 – Estatísticas R-quadro e R-quadrado ajustado

R-Quadrado	R-quadrado ajustado	F de significação
88,77%	88,68%	4,7748E-275

Fonte: Ms-Excel®. (2018).


Tabela 4 - Resultados da Análise de Regressão

Parâmetros	Coeficientes	<i>p-value</i>	Intervalo de Confiança de 95%		Intervalo de Confiança de 99%	
			Limite Inferior	Limite Superior	Limite Inferior	Limite Superior
β_0	1273,86050	2E-12	926,92813	1620,79287	817,36825	1730,35275
β_1	0,02586	4E-28	0,02148	0,03024	0,02010	0,03162
β_2	0,01154	4E-06	0,00664	0,01643	0,00510	0,01797
β_3	0,01966	3E-26	0,01619	0,02313	0,01510	0,02422
β_4	0,02357	5E-202	0,02259	0,02455	0,02228	0,02486
β_5	0,00803	0,0269	0,00092	0,01514	-0,00132	0,01739

Fonte: Ms-Excel®. (2018).

Como visto na Tabela 3 e na Tabela 4, os valores de R-quadrado ajustados para a variável y_1 foram maiores que 70% (88,68%), o valor F de significação é menor que 5% e os valores de *p-value* são menores que 5%. Além disso, como mostrado na Figura 11, os valores estimados pela função empírica possuem resíduos normais (*p-value* maior que 5%).

Figura 11 – Teste de Normalidade dos Resíduos



Fonte: Minitab 18® (2018).

Dessa forma, conclui-se que a variável dependente pode ser explicada pelos regressores em 88,68% dos casos, o modelo possui significância global, todas as variáveis independentes são significativas e não há tendenciosidade (FÁVERO, 2015).

Outra consideração importante diz respeito à multicolinearidade. O'Brien (2007) comenta que a tolerância para o VIF mais difundida na literatura considera um valor 10 e completa ainda que autores mais conservadores utilizam tolerância de valor 4. Observa-se na Tabela 5 que os valores de VIF para o modelo estudado estão dentro da tolerância, mesmo sob uma ótica mais conservadora.

Tabela 5 – Fator Inflação da Variância

Variáveis	VIF
x_1	1,3489
x_2	1,7533
x_3	1,8246
x_4	1,2281
x_5	1,2183


Fonte: Ms-Excel®. (2018).

4 APLICAÇÃO DA OTIMIZAÇÃO VIA SIMULAÇÃO MONTE CARLO

4.1 ADIÇÃO DAS INCERTEZAS NOS COEFICIENTES DA FUNÇÃO OBJETIVO

Nesta etapa, foram contempladas as incertezas nos coeficientes do modelo obtido na etapa 2. Com base em Rubinstein e Kroese (2016), foi adotada a distribuição uniforme contínua com intervalo $[a, b]$, uma vez que esta distribuição considera que todos os valores pertencentes ao intervalo considerado possuem a mesma probabilidade de ocorrência. É possível observar tal distribuição na Figura 12 e na equação (10).

Figura 12 – Distribuição Uniforme Contínua



Fonte: Montgomery (2012).

$$f(x) = \begin{cases} \frac{1}{b-a} & \rightarrow a \leq x \leq b \\ 0 & \rightarrow x < a \text{ ou } x > b \end{cases} \quad (10)$$

Para cada coeficiente do modelo obtido na etapa 2, foram determinados os intervalos da distribuição uniforme contínua (limite inferior a e limite superior b), utilizando os limites inferiores e superiores associados aos intervalos de confiança de 95% e 99%. Com isso substituímos os valores dos coeficientes lineares e angulares da equação (9) por valores gerados conforme distribuição contínua uniforme ($\sim U[a, b]$), expressos na Tabela 6.

Tabela 6 – Ocorrência de incertezas nos coeficientes da função empírica

Parâmetros	Intervalo de Confiança de 95%	Intervalo de Confiança de 99%
$\beta_0 = 1273,86050$	$\tilde{\beta}_0 \sim U [926,92813; 1620,79287]$	$\tilde{\beta}_0 \sim U [817,36825; 1730,35275]$
$\beta_1 = 0,02586$	$\tilde{\beta}_1 \sim U [0,02148; 0,03024]$	$\tilde{\beta}_1 \sim U [0,02010; 0,03162]$
$\beta_2 = 0,01154$	$\tilde{\beta}_2 \sim U [0,00664; 0,01643]$	$\tilde{\beta}_2 \sim U [0,00510; 0,01797]$
$\beta_3 = 0,01966$	$\tilde{\beta}_3 \sim U [0,01619; 0,02313]$	$\tilde{\beta}_3 \sim U [0,01510; 0,02422]$
$\beta_4 = 0,02357$	$\tilde{\beta}_4 \sim U [0,02259; 0,02455]$	$\tilde{\beta}_4 \sim U [0,02228; 0,02486]$
$\beta_5 = 0,00803$	$\tilde{\beta}_5 \sim U [0,00092; 0,01514]$	$\tilde{\beta}_5 \sim U [-0,00132; 0,01739]$

Fonte: Próprio autor.

4.2 OTIMIZAÇÃO DA FUNÇÃO OBJETIVO CONSIDERANDO AS INCERTEZAS

Para a otimização da função objetivo considerando as incertezas foi aplicada a OvSMC, por meio do *software* Oracle Crystall Ball® *Trial Version* e do otimizador Optquest®. Para tal, utilizando a meta definida pelos gestores da empresa objeto de estudo de 2,5% para $\hat{y}_3$, foi inserido no *software* o modelo como mostrado nas equações de (11) a (15):

$$\hat{y}_3 = \frac{\hat{y}_1}{\hat{y}_2} \in Y \quad (11)$$

$$\hat{y}_1 = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \tilde{\beta}_2 x_2 + \tilde{\beta}_3 x_3 + \tilde{\beta}_4 x_4 + \tilde{\beta}_5 x_5 \quad (12)$$

$$\hat{y}_2 = x_1 + x_2 + x_3 + x_4 + x_5 \quad (13)$$

Sujeito a:


$$\hat{y}_1, \hat{y}_2 \geq 0 \quad (14)$$

$$x_i \in X \quad (15)$$

sendo Y o conjunto de valores-alvo e X o conjunto de valores viáveis para as variáveis independentes.

Foram inseridos os limites da distribuição uniforme contínua para cada coeficiente da equação (11), como mostra a Figura 13 e, então, realizadas as otimizações considerando os coeficientes em intervalo de confiança de 95% e no intervalo de confiança de 99%. Os resultados e discussão estão contidos no capítulo 5.

Figura 13 – Inserção dos Limites da Distribuição Uniforme Contínua




Fonte: Oracle Crystal Ball® *Trial Version* (2018).

5 RESULTADOS E DISCUSSÃO

Após a realização das etapas comentadas anteriormente, obteve-se o resultado das otimizações para a meta de 2,5% do custo do transporte pelo valor transportado ($\hat{y}_3$), a qual foi previamente definida pelos gestores. Primeiramente foi aplicada a OvSMC utilizando intervalo de confiança de 95% para os coeficientes do modelo (OvSMC IC – 95%). A Figura 14 mostra o resultado da OvSMC IC – 95%.

Figura 14 – Comportamento da Função Objetivo Utilizando OvSMC IC – 95%



Fonte: Oracle Crystall Ball® Trial Version (2018).

Na Figura 14 é possível observar os valores do limite inferior e do limite superior da variável dependente $\hat{y}_3$ (Tabela 7), considerando um intervalo de confiança de 95%. Para que seja possível atingir a meta de 2,5%, com intervalo de confiança de 95%, é proposto o ajuste apresentado na Tabela 8, o qual está contido nos dados históricos da empresa objeto de estudo, sendo possível de se praticar.

Tabela 7 – Intervalo [LI, LS] para 95% de Confiança

Variável	Limite Inferior	Limite Superior
$\hat{y}_3$	2,3700%	2,6309%

Fonte: Próprio autor.


Tabela 8 - Ajuste Proposto para as Variáveis Independentes

Variáveis	Ajuste Proposto
x_1	10.590,88
x_2	16.905,73
x_3	135.904,40
x_4	119.896,86
x_5	10.099,27

Fonte: Próprio autor.

Em um segundo momento foi aplicada a OvSMC utilizando intervalo de confiança de 99% para os coeficientes do modelo (OvSMC IC – 99%). A Figura 15 mostra o resultado da OvSMC IC – 99%.

Figura 15 – Comportamento da Função Objetivo Utilizando OvSMC IC – 99%



Fonte: Oracle Crystall Ball® Trial Version (2018).

Na Figura 15, com intervalo de confiança de 95%, observa-se os limites inferior e superior da variável dependente $\hat{y}_3$, os quais estão expressos na Tabela 9. Para que seja possível atingir a meta de 2,5%, com intervalo de confiança de 95%, é proposto o arranjo apresentado na Tabela 10, o qual está contido nos dados históricos da empresa objeto de estudo, sendo possível de se praticar.

Tabela 9 - Intervalo [LI, LS] para 95% de Confiança

Variável	Limite Inferior	Limite Superior
$\hat{y}_3$	2,3390%	2,6633%

Fonte: Próprio autor.

Tabela 10 - Ajuste Proposto para as Variáveis Independentes

Variáveis	Ajuste Proposto
x_1	10.590,88
x_2	17.773,50
x_3	118.694,07
x_4	166.769,34
x_5	10.099,27

Fonte: Próprio autor.

Para fins de comparação, utilizou-se ainda a configuração determinística do Optquest®, sem inserção das incertezas, para obtenção do arranjo das variáveis independentes para $\hat{y}_3$ com meta de 2,5%. A comparação entre os arranjos obtidos de forma determinística (A), por meio da OvSMC IC – 95% (B) e por meio da OvSMC IC – 99% (C) pode ser observada na Tabela 11, a qual contém as diferenças entre os valores obtidos para cada uma das variáveis independentes e os desvios-padrão.

Tabela 11 – Comparação entre os Arranjos Obtidos

Variáveis	A	B	C	$\frac{B}{A} - 1$	$\frac{C}{A} - 1$	Desvio Padrão
	Determinístico	OvSMC IC - 95%	OvSMC IC - 99%			
x_1	10590,88	10590,88	10590,88	0,00	0,00	0
x_2	40194,97	16905,73	17773,5	-0,58	-0,56	0,01
x_3	70643,4	135904,4	118694,07	0,92	0,68	0,17
x_4	138673,2	119896,86	166769,34	-0,14	0,20	0,24
x_5	10099,27	10099,27	10099,27	0,00	0,00	0

Fonte: Próprio autor.

Observa-se que não houve diferença entre os valores obtidos para x_1 e x_5 , mesmo ao se comparar os resultados sem incerteza e com incerteza. A maior diferença entre os valores obtidos está no ajuste proposto para x_4 , apresentando um desvio padrão de 0,24.

Para x_2 , as diferenças entre os resultados obtidos de forma determinística e por meio da OvSMC apresentaram valores de -0,58 entre os ajustes A e B e de -0,56 entre os ajustes A e C. Para os valores de x_4 , as diferenças foram de -0,14 entre A e B, 0,20 entre A e C.

Os arranjos propostos pela OvSMC (IC – 95% e IC – 99%) atendem a meta estipulada com intervalo de confiança de 95%, estão contidos no banco de dados históricos da empresa e são possíveis de serem executados.

Os resultados apontam para a qualidade da otimização por meio da OvSMC, que possibilita uma melhor compreensão e posicionamento frente os efeitos das incertezas, visto que é possível obter os valores para cada variável independente x_i e o intervalo de variação da a variável dependente $\hat{y}$ para a meta estipulada.

6 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

6.1 VERIFICAÇÃO DAS QUESTÕES DE PESQUISA E OBJETIVOS

Ao concluir o estudo, foi possível responder as questões de pesquisa e cumprir os objetivos geral e específicos. O procedimento proposto possibilitou a aplicação da OvSMC em problemas de redução de custos, uma vez que foi possível obter o arranjo das variáveis independentes que atendem à meta estipulada pelos gestores para o custo do transporte por valor transportado.

Considerando que os ajustes propostos condizem com o histórico e a realidade das operações, há vantagens em introduzir a ocorrência de incertezas nos coeficientes da função objetivo, auxiliando o processo de tomada de decisão em um contexto sob incerteza. Em concordância com a afirmação anterior, foi possível observar também que a Distribuição Uniforme Contínua se mostrou apropriada para representar a ocorrência de incertezas.

Outro ponto importante que compõe as questões e objetivos deste trabalho, é o desenvolvimento de função empírica que represente adequadamente o comportamento dos custos com Transporte de Cargas. Conclui-se que foi possível desenvolver função empírica que correspondesse às questões e aos objetivos propostos, uma vez que atendeu as estatísticas e parâmetros necessários.

Vale lembrar, que os materiais utilizados para a obtenção dos resultados descritos não restringem a aplicação da OvSMC na empresa objeto de estudo, garantindo a exequibilidade dos procedimentos propostos.

6.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS

Como recomendação para futuras pesquisas, sugere-se a aplicação do procedimento proposto em problemas de outra natureza, para estudar as vantagens da otimização considerando a ocorrência de incertezas. Sugere-se também a utilização de outras variáveis para compor o modelo de custo com o Transporte de Cargas, contexto no qual seria pertinente o estudo de outras técnicas de modelagem.

REFERÊNCIAS

- AKBARI, M. Logistics outsourcing: a structured literature review. **Benchmarking: an international journal**, Bingley, v. 25, p. 1548 – 1580, 2018.
- ALI, M. M. et al. Supply chain forecasting when information is not shared. **European Journal of Operational Research**, Amsterdam, v. 260, p. 984-994, 2017.
- ARUNRAJ, N. S.; MANDAL, S.; MAITI, J. Modeling uncertainty in risk assessment: an integrated approach with fuzzy set theory and Monte Carlo simulation. **Accident Analysis and Prevention**, Elmsford, v. 55, p. 242-255, 2013.
- BANKS, J.; CARSON, J.; NELSON, B. **Discrete-event system simulation**. New Jersey: Prentice Hall, 1996. 622 p.
- BARBOSA-PÓVOA, A. P.; SILVA, C.; CARVALHO, A. Opportunities and challenges in sustainable supply chain: an operations research perspective. **European Journal of Operational Research**, Amsterdam, v. 268, p. 399-431, 2018.
- BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, Bingley, v. 22, p. 241-264, 2002.
- BILGINOL, K.; DENLI, H.; SEKER, D. Ordinary least squares regression method approach for site selection of automated teller machines. **Procedia Environmental Sciences**, Amsterdam, v. 26, p. 66-69, 2015.
- BISOGNO, S. et al. Combining modelling and simulation approaches: how to measure performance of business processes. **Business Process Management Journal**, Bradford, v. 22, n. 1, p. 56-74, 2016.
- CHRISTOPHER, M. **Logistics & supply chain management: strategies for reducing cost and improving service**. Londres: Financial Times, 1998. 294 p.
- CHRISTOPHER, M. **Logistics and supply chain management**. 5. ed. Londres: Pearson, 2016. 288 p.
- CONWAY, R. T.; SANGALINE, E. W. A monte carlo simulation approach for quantitatively evaluating keyboard layouts for gesture input. **International Journal of Human-Computer Studies**, Londres, v. 99, p. 37-47, 2017.
- DEMIR, E.; BEKTAS, T.; LAPORTE, G. A review of recent research on green road freight transportation. **European Journal of Operational Research**, Amsterdam, v. 237, p. 775-793, 2014.
- DENG, L. Y.; BOWMAN, D. Developments in pseudo-random numbers generators. **Wiley Interdisciplinary Reviews: Computational Statistics**, Houston, v. 9, 2017.

DIALLO, S. et al. Special issue on modeling and simulation in the era of big data and cloud computing: theory, framework and tools. **Simulation: Transactions of the Society for Modeling and Simulation International**, San Diego, v. 93, p. 271–272, 2017.

DURUGBO, C.; TIWARI, A.; ALCOCK, J. Modelling information flow for organisations: A review of approaches and future challenges. **International Journal of Information Management**, Guildford, v. 33, p. 597–610, 2013.

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

EXCEL®. **Editor de planilhas**. Disponível em: < <https://products.office.com/pt-br/excel>>. Acesso em: 10 maio 2018.

FÁVERO, L. P. **Análise de dados: modelos de regressão com Excel®, Stata® E SPSS®**. 1. ed. Rio de Janeiro: Elsevier, 2015. 520 p.

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

FREUND, R. J.; WILSON, W. J.; SA, P. **Regression analysis – statistical modeling of a response variable**. San Diego: Elsevier, 2006. 480 p.

GHAEDI, M. et al. Application of least squares support vector regression and linera multiple regression for modeling removal of methyl orange onto tin oxide nanoparticles loaded on activated carbon and activated carbon prepared from pistacia atlantica wood. **Journal of Colloid and Interface Science**, New York, v. 461, p. 425-434, 2016.

GILES, M. B. Multilevel monte carlo methods. **Acta Numerica**, Cambridge, v. 24, p. 259-328, 2015.

HARIMI, R. Organizational culture and customer relationship management: a simple linear regression analysis. **Journal of Hospitality Marketing & Management**, Amsterdam v. 26, p. 443-449, 2017.

HILLIER, F.S., LIEBERMAN, G.J. **Introduction to operations research**. New York: McGraw-Hill, 2010. 1214 p.

HOLGUÍN-VERAS, J.; SÁNCHEZ-DÍAS, I. Freight demand management and the potential of received-led consolidation programs. **Transportation Research Part A**, Oxford, v. 84, p. 109-130, 2016.

JANANI, S.; SANTHI, A. S. Multiple linear regression model for mechanical properties and impact resistance of concrete with fly ash and hooked-end steel fibers. **International Journal of Technology**, Jakarta, v. 9, p. 526-536, 2018.

KANELLOPOULOS, A., GERDESSEN, J. C., CLAASSEN, G. D. H. Compromise programing: non-interactive calibration of utility-based metrics. **European Journal of Operational Research**, Amsterdam, v. 244, p. 519-524, 2015.

KIM, B.; LEE, T.; TAHA, B. M. J. Total least square method applied to rating curves. **Hydrological Processes**, Chichester, v. 28, p. 4057-4066, 2013.

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

KROESE, D. P., TAIMRE, T., BOTEV, Z. I. **Handbook of monte carlo methods**. New York: John Wiley & Sons, 2011. 772 p.

LAMBERT, D. M. **Supply chain management – processes, partnerships, performance**. 4. ed. San Diego: Supply Chain Management Institute, 2014. 431 p.

LEE, L. H. et al. Advances in simulation optimization and its applications, **IIE Transactions**, Norcross, v. 45, p. 683-684, 2013.

LIN, T.; TSAI, C. A simple linear regression approach to modeling and forecasting mortality rates. **Journal of Forecasting**, Chichester, v. 34, p. 543-559, 2015.

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

MAIA, A. G. **Econometria conceitos e aplicações**. 1 ed. São Paulo: Saint Paul, 2017. 284 p.

MALTBA, T.; GREMAUD, P. A.; TARTAKOVSKY, D. M. Nonlocal PDF methods for langevin equations colored. **Journal of Computational Physics**, Orlando, v. 367, p. 87-101, 2018.

MANSSEN, M.; WEIGEL, M.; HARTMANN, A. K. Random number generators for massively parallel simulations on GPU. **European Physical Journal: Special Topics**, Les Ulis, v. 210, p. 53-71, 2012.

MESOGISTS, T. S.; SKORDOS, A. A.; LONG, A. C. Uncertainty in the manufacturing of fibrous thermosetting composites: a review. **Composites: Part A**, Kidlington, v. 57, p. 67-75, 2014.

MIGUEL, P. A. C., **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 2. ed. Rio de Janeiro: Elsevier, 2010. 280 p.

MINITAB 18®. **Software estatístico**. Disponível em: < <http://www.minitab.com/pt-br/products/minitab/>>. Acesso em: 10 maio 2018.

MIRANDA, R. C. et al. Increasing the efficiency in integer simulation optimization: Reducing the search space through data envelopment analysis and orthogonal arrays. **European Journal of Operational Research**, Amsterdam, v. 262, p. 673-681, 2017.

MONTGOMERY, D. C.; PECK, E. A.; VINING; G. G. **Introduction to linear regression analysis**. 5. ed. Haboken: Wiley, 2012. 672 p.

MUÑOZ-VILLAMIZAR, A. et al. Using OEE to evaluate the effectiveness of urban freight transportation systems: a case study. **International Journal of Production Economics**, Amsterdam, v. 197, p. 232-242, 2018.

NUZZOLO, A.; COMI, A. Urban freight demand forecasting: a mixed quantity/delivery/vehicle-based model. **Transportation Research Part E**, Vancouver, v. 65, p. 84-98, 2014.

O'BRIEN, R. M. A caution regarding rules of thumb for variance inflation factors. **Quality & Quality**, Dordrech, v. 41, p. 673 – 690, 2007.

OLIVEIRA, L. K. et al. An overview of problems and solutions for urban freight transport in brazilian cities. **Sustainability**, Basel, v. 10, p. 1233, 2018.

ORACLE CRYSTALL BALL®. **Software de modelos preditivos, previsão, simulação e otimização**. Disponível em: < <https://www.oracle.com/br/applications/crystalball/>>. Acesso em: 02 jun. 2018.

ROBINSON, S. **Simulation: the practice of model development and use**. New York: John Wiley & Sons, 2014. 340 p.

RUBINSTEIN, R.; KROESE, D. **Simulation and the monte carlo method**. 3. ed. Haboken: Wiley, 2016. 432 p.

SARAIVA JUNIOR, A. F.; TABOSA C. M., DA COSTA, R. P. Simulação de monte carlo aplicada à análise econômica de pedido. **Produção**, São Paulo, v. 21, n. 1, p. 149- 164, 2011.

SILVA, A. F., SILVA, M. F. F., MARINS, F. A. S. Otimização estocástica com múltiplos objetivos e simulação monte carlo no desenvolvimento de estratégias de vendas. **PODes – Revista Eletrônica Pesquisa Operacional para o Desenvolvimento**, Rio de Janeiro, v. 6, n. 1, p. 35-53, 2014.

SIMCHI-LEVI, D.; KAMINSKY, P.; SIMCHI-LEVI, E. **Designing and managing the supply chain: concepts, strategies and case studies**. Singapore: McGraw Hill, 2007. 321 p.

SINTHUPUNDAJA, J.; CHIADAMRONG, N. Investigating the determinants of thai manufacturing public firms: performance using an integration of multiple linear regression and hierarchical linear modelling. **International Journal of Business Excellence**, Olney, v. 11, 2017.

VIEIRA, J.G.V.; FRANSOO, J.C.; CARVALHO, C.D. Freight distribution in megacities: perspectives of shippers, logistics service providers and carriers. **Journal of Transport Geography**, Londres, v. 46, p. 46–54, 2015.

WAGNER, H. H. Rethinking the linear regression model for spatial ecological data. **Ecology**, New York, v. 94, p. 2381-2391, 2013.

WEB OF SCIENSE. **Base de indexação de citações científicas**. Disponível em: <<https://login.webofknowledge.com/>>. Acesso em: 10 mar. 2018.

WINTER, M.; KNEMEYER, A. M. Exploring the integration of sustainability and supply chain management: current state and opportunities for future inquiry. **International Journal of Physical Distribution & Logistics Management**, Bradford, v. 43, p.18-38, 2013.