

CAMILA TERUMI KOKETSU MAEDA

**Simulação Monte Carlo aplicada na análise de indicadores de desempenho
em um contexto sob incerteza: um estudo na cadeia de suprimentos
de uma indústria de grande porte**

Camila Terumi Koketsu Maeda

Simulação Monte Carlo aplicada na análise de indicadores de desempenho em um contexto sob incerteza: um estudo na cadeia de suprimentos de uma indústria de grande porte

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 da Silva

M184s Maeda, Camila Terumi Koketsu
Simulação Monte Carlo aplicada na análise de indicadores de desempenho em um contexto sob incerteza: um estudo na cadeia de suprimentos de uma indústria de grande porte / Camila Terumi Koketsu Maeda – Guaratinguetá, 2017.
48 f : il.
Bibliografia: f. 45

Trabalho de Graduação em Engenharia de Produção Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2017.

Orientador: Prof. Dr. Aneirson Francisco da Silva

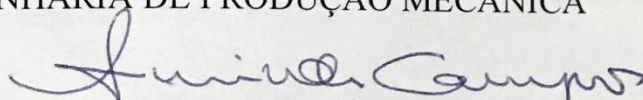
1. Cadeia de logística integrada. 2. Monte Carlo -Método. 3. Incerteza
I. Título

CDU 658.5

CAMILA TERUMI KOKETSU MAEDA

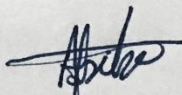
ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE
“ENGENHARIA DE PRODUÇÃO MECÂNICA”

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

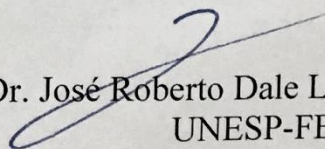


Prof. Dr. ARMINDA EUGÊNIA MARQUES CAMPOS
Coordenador

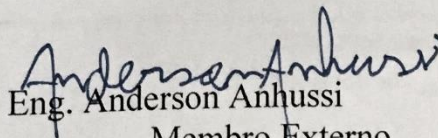
BANCA EXAMINADORA:



Prof. Dr. Aneirson Francisco da Silva
Orientador/UNESP-FEG



Prof. Dr. José Roberto Dale Luche
UNESP-FEG



Eng. Anderson Anhussi
Membro Externo

Dezembro de 2017

DADOS CURRICULARES

CAMILA TERUMI KOKETSU MAEDA

NASCIMENTO 08.01.1993 – Atibaia/SP

FILIAÇÃO Ademar Hifumi Maeda
Lidia Sayuri Koketsu

2012/2017 Curso de Graduação em Engenharia de Produção Mecânica
Universidade Estadual Paulista “Júlio de Mesquita Filho”

dedico este trabalho
de modo especial, à minha família

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus, pela força e saúde para superar as dificuldades. Agradeço também por minha vida, família e amigos.

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

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

aos meus pais *Lidia Sayuri Koketsu e Ademar Hifumi Maeda*, que sempre confiaram em mim, incentivaram meus estudos e foram imprescindíveis na minha educação e na mulher que me tornei.

à minha irmã *Juliana Maeda*, que ao me tomar como exemplo e acreditar em mim, foi essencial no meu desenvolvimento e crescimento pessoal e profissional.

à toda minha *família*: tias, tios, primas, primos, avós e avôs, que apesar da distância durante os anos da faculdade sempre incentivaram meus estudos.

à *república Bela Espelunca* pela família que formamos, os anos de muita amizade e momentos compartilhados desde o começo da faculdade.

aos meus *amigos de curso* que dividiram comigo as dificuldades da graduação e tornaram esses anos inesquecíveis e indescritíveis. Agradeço pelos grandes amigos que nos tornamos.

à *Jr. Eng*, que foi essencial no meu desenvolvimento e preparação profissional.

ao *Lucas Froidi*, pelo incansável apoio, incentivo e carinho durante o desenvolvimento deste trabalho.

à todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigada!

“Se não existe esforço, não existe progresso.”

Frederick Douglass

RESUMO

A crescente competitividade e volatilidade do ambiente econômico vêm forçando as empresas a buscar maior eficiência em todos os processos de sua cadeia de suprimentos. Visando aumentar essa visibilidade da cadeia de suprimentos, a presente pesquisa tem como principal objetivo a análise de indicadores de desempenho (*Key Performance Indicators* – KPIs) em um contexto sob incerteza, uma vez que indicadores de desempenho são desenvolvidos com base nos objetivos estratégicos da companhia. O método utilizado para realizar essa análise, é a modelagem e simulação, via Simulação Monte Carlo (SMC). Para realizar estes estudos, foram utilizados os materiais *Crystal Ball*[®] e o software Microsoft Office Excel[®]. Os tópicos abordados na fundamentação teórica são: KPI, Modelagem e Simulação e SMC. A empresa em estudo foi escolhida com base nos critérios de localidade, por ser de acesso facilitado, e no critério de exequibilidade, por já possuir um histórico de medições de KPIs. O trabalho em questão objetivou a análise da aplicabilidade da SMC na análise de indicadores de desempenho em um contexto sob incerteza. Como resultado da pesquisa evidenciou-se que dos três KPIs simulados, dois deles poderiam ser aplicados utilizando-se o *Crystal Ball*[®], e o terceiro necessitaria também a aplicação VBA para poder auxiliar na tomada de decisão.

PALAVRAS-CHAVE: Simulação Monte Carlo. Indicador de desempenho. Incerteza.

ABSTRACT

The increasing competitiveness and volatility of the economic environment have forced companies to seek greater efficiency in all the processes of their supply chain. In order to increase this supply chain visibility, the main objective of this research is to analyze Key Performance Indicators (KPIs) in a context under uncertainty, since performance indicators are developed based on the strategic objectives of the company. The method used to perform this analysis is modeling and simulation, via Monte Carlo Simulation (SMC). To perform these studies, Crystal Ball[®] and Microsoft Office Excel[®] software were used. The topics covered in the theoretical foundation are: KPI, Modeling and Simulation and SMC. The company under study was chosen based on the locality criteria, once there is an easy access, and in the feasibility criteria, once it already has a history of measurements of KPIs. The work in question aims to analyze the applicability of SMC in the analysis of performance indicators in a context under uncertainty. As a result of the research, it was demonstrated that from the three KPIs that was simulated, two of them could be applied using Crystal Ball[®], and the third would also need the VBA application to be able to aid in a decision making.

KEYWORDS: Monte Carlo simulation. Key process indicator. Uncertainty.

LISTA DE ILUSTRAÇÕES

Figura 1 – Classificação da pesquisa	14
Figura 2 – Publicações e citações sobre SMC	16
Figura 3 – Documentos relacionados à SMC, por área de pesquisa.....	16
Figura 4 – Publicações e citações sobre KPIs	16
Figura 5 – Publicações e citações sobre SMC e KPIs	17
Quadro 1 – Descrição das siglas dos KPIs	27
Quadro 2 – Mecanismo de formação de extrusões e intrusões	27
Figura 6 – Representação dos KPIs de UTS e <i>Kanban Adherence</i> no tempo	31
Figura 7 – Teste de aderência do item A (UTS)	33
Figura 8 – Teste de aderência do item B (UTS)	33
Figura 9 – Simulação do UTS com 95% de confiança.....	34
Figura 10 – Simulação do UTS definindo a meta de no máximo 7%	34
Figura 11 – Pressupostos da Simulação <i>Kanban Adherence</i>	36
Figura 12 – Simulação do <i>Kanban Adherence</i> com 95% de confiança.....	37
Figura 13 – Simulação do <i>Kanban Adherence</i> definindo a meta de no mínimo 90%.....	37
Figura 14 – Simulação LIFR <i>Export</i> com 95% de confiança.....	40
Figura 15 – Simulação LIFR <i>Export</i> definindo a meta de no mínimo 95%.....	40

LISTA DE TABELAS

Tabela 1 – Resultados da pesquisa bibliográfica.....	18
Tabela 2 – Metas dos KPIs.....	27
Tabela 3 – Exemplo de cálculo de LIFR.....	28
Tabela 4 – Exemplo de cálculo de UTS.....	28
Tabela 5 – Exemplo Kanban Adherence.....	29
Tabela 6 – Dados LIFR <i>Export</i> - de Março à Setembro de 2017.....	30
Tabela 7 – Dados simulados do UTS.....	32
Tabela 8 – Dados <i>Kanban Adherence</i>	35
Tabela 9 – Dados LIFR <i>Export</i>	38
Tabela 10 – Dados LIFR <i>Export</i> Normalizados.....	39

SUMÁRIO

1	INTRODUÇÃO	12
1.1	CONSIDERAÇÕES INICIAIS	12
1.2	DELIMITAÇÃO E QUESTÃO DA PESQUISA	13
1.3	OBJETIVOS	13
1.4	MATERIAIS E MÉTODOS.....	14
1.5	JUSTIFICATIVA	15
1.6	ESTRUTURA DO TRABALHO	18
2	FUNDAMENTAÇÃO TEÓRICA.....	19
2.1	INDICADORES DE DESEMPENHO	19
2.2	MODELAGEM E SIMULAÇÃO	22
3	DESCRIÇÃO E MODELAGEM DO PROBLEMA.....	26
3.1	DESCRIÇÃO DO PROBLEMA	26
3.1.1	Identificação do problema	26
3.1.2	Descrição dos KPIs	26
3.1.3	Coleta dos dados	29
3.2	SIMULAÇÃO	31
3.2.1	Simulação do UTS	31
3.2.2	Simulação Kanban Adherence	35
3.2.3	Simulação LIFR Export.....	37
3.3	DISCUSSÃO DOS RESULTADOS	41
4	CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS	42
4.1	VERIFICAÇÃO DAS QUESTÕES DA PESQUISA E OBJETIVOS	42
4.2	RECOMENDAÇÕES PARA FUTURAS PESQUISAS	42
	REFERÊNCIAS	43

1 INTRODUÇÃO

Este capítulo apresenta as considerações iniciais, a delimitação e questão da pesquisa, os objetivos, os métodos e materiais, a justificativa, e por fim, a estrutura do trabalho.

1.1 CONSIDERAÇÕES INICIAIS

O ambiente econômico vem se tornando cada vez mais volátil, e uma eficiente e adequada visibilidade da cadeia de suprimentos se faz necessária quando se visa amenizar estas incertezas (ALI et al., 2017).

Com estas rápidas mudanças, empresas precisam se concentrar em suas principais competências e encontrar suas vantagens competitivas (FERREIRA, 2012). Neste contexto, quanto maior a visibilidade da cadeia de suprimentos, e quanto mais a empresa conhecer seus pontos fortes e fracos, maiores são as oportunidades para os gestores planejarem eficientemente e reagirem de maneira apropriada às informações incorretas (ALI et al., 2017).

A análise de desempenho é um componente essencial em qualquer tipo de organização, uma vez que os indicadores de desempenho – *Key Performance Indicators* (KPIs) – demonstram, por meio de medidas objetivas, sistemáticas e uma vasta variedade de dados estatísticos, como está a performance da organização (TEE et al., 2014).

Porém, apenas a medição de KPIs pode gerar incertezas durante um processo decisório, pois muitas vezes, ferramentas tradicionais não permitem que gestores consigam sintetizar o impacto total de *inputs* de várias variáveis (MURIANA et al., 2016).

Um método muito utilizado para mensurar a incerteza em problemas decisórios é a simulação (MIRANDA et al., 2017). Segundo Bisogno et al. (2015), a Simulação se inicia com hipóteses explícitas (dados de entrada), dos quais obtém-se resultados (dados de saída). No entanto, a simulação também envolve a indução, pois as relações entre as variáveis podem ser analisadas por meio de experimentos (BISOGNO et al., 2015). Além disto, a modelagem e simulação vêm sendo amplamente aceitas no mercado, como pode ser evidenciado pela disponibilidade de softwares de simulação com integradas rotinas de otimização (MIRANDA et al., 2017).

A Simulação Monte Carlo (SMC) é uma simulação estocástica que utiliza números aleatórios, que são variáveis aleatórias independentes distribuídas uniformemente, para a solução de um problema (KROESE et al., 2017). E segundo Lee et al. (2013), a simulação

estocástica é uma ferramenta de modelagem para analisar sistemas logicamente complexos que incluam variáveis não algébricas e suas restrições.

1.2 DELIMITAÇÃO E QUESTÃO DA PESQUISA

Os dados utilizados neste trabalho foram extraídos de uma indústria de grande porte, que atua no setor de saúde, focada na produção de dispositivos médicos, localizada no Vale do Paraíba. O período analisado foi de aproximadamente 30 semanas.

O trabalho visou responder à duas questões:

- Há vantagens em aplicar a SMC para analisar de indicadores de desempenho empresariais em um contexto de incertezas?

- Como a SMC pode auxiliar gestores na tomada de decisão baseada em indicadores de desempenho?

Os motivos de escolha da empresa em estudo foram baseados nos critérios de exequibilidade, localidade, pela facilidade de acesso aos dados e para possíveis coletas de dados. Além disto, a empresa já mapeia seus KPIs a um tempo ideal para a realização de simulação de dados.

Os KPIs que foram estudados e simulados neste trabalho foram os seguintes, e serão detalhados no capítulo 3:

- LIFR Export;
- MRM UTS;
- MRM Kanban Adherence.

A seleção desses KPIs baseou-se nos seguintes critérios: quantidade de amostras coletadas por indicador, criticidade do indicador no momento em que o trabalho foi desenvolvido, importância e influência do indicador para a companhia.

1.3 OBJETIVOS

O objetivo geral deste trabalho foi analisar KPIs em um contexto sob incerteza, dentro da cadeia de suprimentos de uma indústria de grande porte do setor de dispositivos médicos por meio da SMC.

1.4 MATERIAIS E MÉTODOS

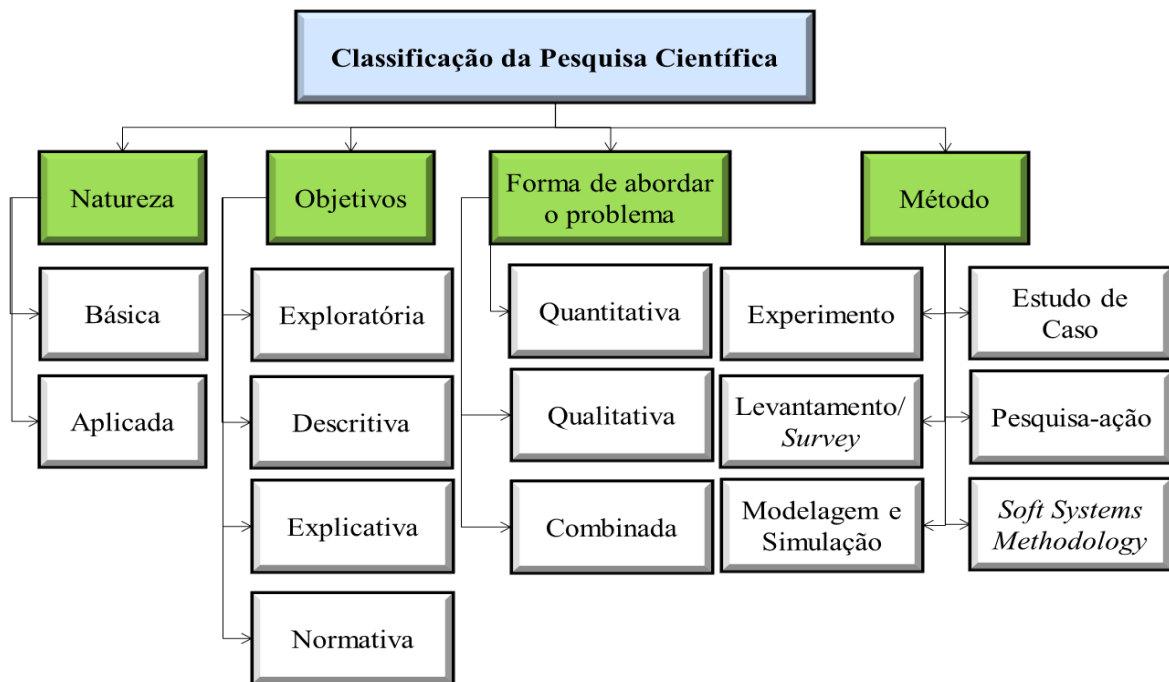
Os materiais utilizados são:

- Software *Crystal Ball*[®].
- O software Microsoft Office Excel[®].
- Consulta nos bancos de dados da empresa.

A pesquisa pode ser classificada da seguinte maneira:

De acordo com Bertrand e Fransoo (2002) e Miguel *et al.* (2010), este trabalho pode ser classificado como uma pesquisa de natureza aplicada, por meio do método de Modelagem e Simulação, abordando o problema de forma quantitativa. A Figura 1 ilustra a visão geral da classificação de uma pesquisa científica.

Figura 1 – Classificação da pesquisa



Fonte: Adaptado de Bertrand e Fransoo (2002) e Miguel (2012)

As pesquisas quantitativas podem ser divididas em quatro modelos: empírica descritiva, empírica normativa, axiomática descritiva e axiomática normativa (BERTRAND, FRANSOO, 2002). Esta pesquisa se encaixa no modelo empírico descritivo, uma vez que os estudos desenvolvidos favorecem a compreensão dos processos reais ao descrever as relações causais que podem existir na realidade.

1.5 JUSTIFICATIVA

No ambiente industrial, nota-se um aumento da competição no mercado global, com elevada necessidade de aumentar a flexibilidade das empresas a fim de responder rapidamente às alterações das necessidades dos clientes, além do aumento da demanda por produtos inovadores, com alta qualidade e personalizados (VALLEJO et al., 2012).

Ademais, a identificação de oportunidades no mercado não é uma tarefa direta, e o tempo para realizar esta identificação vem diminuindo cada vez mais (VALLEJO et al., 2012).


Visando auxiliar na identificação de oportunidades de melhoria na cadeia de suprimentos de uma empresa de grande porte, o trabalho em questão analisou alguns KPIs por meio da SMC.

Um dos motivos que levou à escolha da análise de KPIs foi a sua importância para o crescimento de uma empresa, pois segundo Waal e Kourtit (2013), empresas que implementam a gestão e medição de desempenho, entregam melhores resultados do que as que não implementam.

O trabalho contribuirá para a área de Pesquisa Operacional (PO), na subárea de Modelagem, Simulação e Otimização. Segundo Vallejo (2012), modelos de simulação podem ser utilizados para resolver problemas que impactam na visão geral de sistemas empresariais e na interação de seus componentes. Da mesma maneira, Diallo et al. (2017) afirma que a Modelagem e Simulação é uma disciplina que eficaz para resolução de problemas. Porém, assim como a estatística, ela pode ser utilizada em quase todos os estudos em engenharia e ciência, produzindo um aliado para os cientistas e engenheiros (DIALLO et al., 2017).

Ao analisar as quantidades de publicações e citações que abordam o tema SMC, é possível notar que este é um tema muito estudado, pois nos últimos 3 anos pelo menos 21 mil artigos relacionados a este tema podem ser encontrados, como pode-se verificar na Figura 2.


Figura 2 – Publicações e citações sobre SMC



Fonte: Scopus (2017)

Dentre os artigos relacionados à SMC, o tema estudado neste trabalho se enquadra na área de *Decision Science*. Porém, em meio aos documentos encontrados no site Scopus, *Decision Science* possui uma baixa representatividade, de apenas 3,0%. Segue a Figura 3, que apresenta as áreas de pesquisa de maior representatividade.


Figura 3 – Documentos relacionados à SMC, por área de pesquisa



Fonte: Scopus (2017)

Quando analisadas as publicações sobre KPIs durante os últimos vinte anos, estes números somam 500 artigos, como está ilustrado na Figura 4.


Figura 4 – Publicações e citações sobre KPIs



Fonte: Web of Science (2017)

Quando pesquisados os dois temas juntos, 5 artigos podem ser encontrados nos últimos 20 anos, como pode-se evidenciar na Figura 5. Porém, seus temas, que abordam redes de transportes, tecnologia veicular, diagnóstico de falhas em processos de automação, circuitos elétricos e indicadores financeiros, não se assemelham ao tema estudado neste trabalho. Sendo assim, encontra-se um gap de pesquisa que este trabalho visa preencher, fornecendo uma melhor visão destes assuntos, e analisando a viabilidade e conveniência desta combinação.

Figura 5 – Publicações e citações sobre SMC e KPIs



Fonte: Web of Science (2017)

A Tabela 1 mostra as ocorrências de publicações e citações das palavras-chave desta pesquisa. Nela é possível comprovar que o trabalho foi vagamente estudado quando as três palavras-chave são agrupadas.

Tabela 1 – Resultados da pesquisa bibliográfica

Base de Dados	Palavra-Chave	Ocorrência de Publicação	Ocorrência de Citação
<i>Web of Science</i>	<i>Monte Carlo Simulation</i>	61.316	
<i>Web of Science</i>	<i>KPI</i>	501	1.915
<i>Web of Science</i>	<i>Uncertainty e Monte Carlo Simulation</i>	5.018	60.669
<i>Web of Science</i>	<i>Uncertainty e KPI</i>	9	37
<i>Web of Science</i>	<i>KPI e Monte Carlo Simulation</i>	5	28
<i>Web of Science</i>	<i>Uncertainty, Monte Carlo Simulation and KPI</i>	0	0

Fonte: Web of Science (2017)

1.6 ESTRUTURA DO TRABALHO

Este trabalho será estruturado em mais três capítulos. O segundo capítulo possui a fundamentação teórica envolvendo os conceitos de KPI e a SMC. O capítulo 3 apresenta a descrição e modelagem do problema, e também a análise dos resultados. No capítulo 4 encontram-se as conclusões e recomendações de trabalhos futuros, seguidas das referências bibliográficas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta definições e informações gerais sobre KPIs, modelagem e simulação, e mais especificamente, a Simulação Monte Carlo.

2.1 INDICADORES DE DESEMPENHO

Os ambientes industriais não estão mais centralizados em apenas uma fábrica, ou uma região geográfica, mas estão descentralizados pelo globo, visando alcançar benefícios para o negócio, e manter a competitividade da organização (FERREIRA et al., 2012).

Além disto, houve um aumento na demanda por qualidade, e conseqüentemente, uma maior ênfase na melhoria do desempenho operacional dos processos em larga escala (ZHANG et al., 2017). Neste contexto, Ding et al. (2013) afirma que uma abordagem comum para tratar destes problemas é o uso de *Key Performance Indicators* (KPIs).

KPIs são medidas quantitativas e são utilizadas para avaliar ou comparar o desempenho e eficiência em termos de metas estratégicas e operacionais, visando alcançar os objetivos estratégicos, uma vez que são desenvolvidas com base na natureza das funções do negócio (JAHANGIRIAN et al., 2017; TEE et al., 2014).

Segundo Hao et al. (2014), KPIs vêm se tornando um importante conceito em indústrias de larga escala, pois podem estabelecer relações quantitativas entre muitas variáveis, como os desempenhos de componentes técnicos, qualidade de produção, eficiência de produção, além do consumo de energia e matérias-primas.

Apesar de haver muitas vantagens na utilização de KPIs, eles podem ser muito prejudiciais e custosos se utilizados imprudentemente (TEE et al., 2014). Por exemplo, se as metas forem muito altas, irrealis e improváveis, podem causar a desmotivação dos funcionários (TEE et al., 2014).

Segundo Falconi (2013), uma cultura de metas, a qual engloba metas factíveis, seguidas por um plano de ação, acompanhamento, ajustes e padronização, é essencial para o bom desempenho e crescimento de uma empresa.

O primeiro passo para a criação de metas é a identificação das lacunas, que é a diferença entre o resultado atual e o melhor resultado que se conhece no País ou no mundo. A meta deve ser uma fração desta lacuna, e deve oscilar entre 30% e 70%, sendo que menos de 30% não é desafiador, e mais de 70% é muito difícil de alcançar, gerando a desmotivação da equipe (FALCONI, 2013).

Além disto, Gondim (2016) complementa que a escolha dos KPIs corretos e seu acompanhamento podem ser um grande desafio devido à dificuldade de integrar e processar dados da forma correta para atingir metas.

Segundo Ferreira et al. (2013), há uma preocupação implícita quando se trata de medição de desempenho, a qual inclui o desenvolvimento de estratégias e medidas necessárias para a melhora do desempenho baseada nas informações fornecidas pelos KPIs, pois a medição dos KPIs só se torna completamente benéfica quando há a sua análise.

Hao et al. (2014), mostrou que quando analisados no ambiente industrial, os KPIs podem ser classificados em três grupos:

- 1) KPIs que se referem o desempenho técnica da planta, como por exemplo, a qualidade do produto.
- 2) KPIs de manutenção que se referem à taxa de operação e, portanto, tempo e gastos com a manutenção.
- 3) KPIs financeiros, que se referem ao faturamento do negócio e são vitais para o negócio, pois nenhuma empresa consegue sobreviver sem recursos financeiros.

Nestes três grupos, pode-se notar que os KPIs estão muito relacionados à medição de variáveis do processo, o que muitas vezes pode tornar esta medição mais complexa (ZHANG et al., 2017).

Além disto, é necessária a análise da quantidade de indicadores que devem ser utilizados para avaliar a performance da organização, a qual depende principalmente da estrutura de dados disponíveis, ou da complexidade do processo de medição (FERREIRA et al., 2012).

Segundo Hamouda (2013), uma das melhores utilidades dos KPIs está no emprego dele em um *Balanced Scorecard* (BSC). O BSC é um método utilizada para medir o desempenho e definir objetivos do ponto de vista financeiro e operacional, e foi originado na década de 90 por Robert Kaplan (*Harvard Business School*) e David Norton (*Renaissance Solutions Inc.*), visando oferecer aos gestores uma visão mais “balanceada” da performance organizacional (KAPLAN e NORTON,1992).

Segundo Modak et al. (2017), as estratégias de negócios são o caminho para alcançar a missão e visão de uma organização. Ao buscar a criação de valor e crescimento contínuo, o BSC pode ser empregado como uma ferramenta de avaliação de desempenho que auxilia no desenvolvimento de uma estratégia integrada (MODAK et al., 2017).

Complementando as definições anteriores, Grigoroudis et al. (2012) afirma que o método BSC inclui um sistema de planejamento estratégico que é amplamente utilizado em organizações empresariais, industriais, governamentais e sem fins lucrativos em todo mundo, a fim de alinhar as atividades comerciais à visão estratégica da organização, melhorar internamente e externamente as comunicações e monitorar a performance das organizações.

Segundo Modak et al. (2017), gestores frequentemente limitam suas decisões focando na medição financeira à curto prazo, sem analisar o serviço ao cliente ou o desenvolvimento organizacional, que também são facilitadores para o crescimento futuro da empresa.

Sabendo disto, Kaplan e Norton introduziram o BSC, que se conecta aos indicadores de desempenho ao analisar a visão estratégica do negócio a partir de quatro perspectivas: financeira, cliente, processos internos, e aprendizado e crescimento (HAMOUDA, 2013). Segundo Modak et al., (2017), as perspectivas do BSC podem ser definidas como:

a) Perspectiva Financeira

A perspectiva financeira inclui o desempenho econômico que é relacionada à rentabilidade da empresa. Os elementos financeiros comuns são retorno ao investimento, fluxo de caixa, valor econômico acrescentado, rentabilidade, etc.

b) Perspectiva do Cliente

A perspectiva do cliente lida com as métricas relacionadas à satisfação dos clientes e o alcance das metas esperadas. Algumas destas métricas são satisfação do cliente, retenção do cliente, *market share*, e a aquisição de novos clientes.

c) Processos Internos

A perspectiva dos processos internos lida com atividades operacionais, visando alcançar a performance que atenda a demanda e satisfação dos clientes. Essas são as atividades da cadeia de valor na manutenção das necessidades atuais e futuras que envolvem inovação, operações de produtividade, atividades para melhorar a eficiência operacional e serviços pós-venda

d) Aprendizado e Crescimento

A perspectiva de aprendizagem e crescimento da empresa lida com o desenvolvimento e motivação dos recursos humanos dentro da organização. Tais medidas incluem satisfação dos funcionários, treinamento e plano de carreira do empregado, aprimoramento e retenção de competências dos funcionários, e assim por diante.

Segundo Hamouoda (2013), cada uma das quatro perspectivas é considerada em vários parâmetros, que incluem:

- a) Objetivos – o que precisa ser alcançado para se obter o sucesso;
- b) KPIs – quais parâmetros serão utilizados para se saber se o sucesso foi alcançado;
- c) Metas – valores quantitativos que serão utilizados para definir o sucesso da medição.

Além destes quatro parâmetros, é possível encontrar estudos que adicionem outros aspectos ou dimensões que se adequem à sua realidade como, por exemplo, Bazrkar e Iranzadeh (2017) que analisaram mais dois parâmetros: meio ambiente e comunidade, e satisfação dos empregados.

As duas dimensões adicionadas se encaixaram no contexto proposto e contribuíram para o processo de investigação estudado, sendo que a perspectiva de meio ambiente e comunidade analisou o alinhamento com a principal estratégia social e conformidade com leis ambientais, e a satisfação dos empregados analisou o número de queixas dos funcionários e taxa de movimento pessoal (BAZRKAR e IRANZADEH, 2017).

Grigoroudis et al. (2012) complementa que a metodologia BSC concentra-se em questões críticas das organizações empresariais modernas: a medição efetiva do desempenho corporativo e a avaliação do sucesso da implementação da estratégia corporativa.

Por fim, Ferreira et al. (2012) afirma que as organizações precisam notar que o melhor caminho para a formação de um negócio efetivo, é a colaboração entre todas as áreas da companhia em prol de um mesmo objetivo, o que demanda uma contínua troca de informações entre essas áreas parceiras.

2.2 MODELAGEM E SIMULAÇÃO

Segundo Montevechi *et al.* (2012), o uso da simulação vem crescendo durante as últimas décadas, e é uma técnica muito utilizada em variados setores devido à sua versatilidade, flexibilidade e potencial de análises.

Modelos de simulação estão presentes em vários problemas reais como, por exemplo, a previsão do tempo que simula o sistema climático, ou até mesmo jogos que simulam atividades, levando a um conceito de simulação que não é totalmente desconhecido por nós. (ROBINSON, 2014).

A Simulação possui a capacidade de imitar a dinâmica de um sistema real, o que garante sua estrutura, função e maneira única de analisar resultados (INGALLS, 2013). Ainda segundo o mesmo autor, a Simulação é o processo de criação de um modelo dinâmico de um

atual sistema dinâmico, visando o entendimento do comportamento do sistema, ou a avaliação de várias estratégias para o funcionamento do sistema.

Segundo Robinson (2014), uma simulação é um experimento realizado por meio de imitações computadorizadas simplificadas de um sistema de operações que progride com o passar do tempo, com o propósito de entender ou otimizar o sistema.

Seguindo a mesma linha de raciocínio, Diallo et al. (2017) diz que a Modelagem e Simulação é uma disciplina que foca na resolução de problemas por meio do uso de modelos e simulações, e que pode ser utilizada em quase todas as disciplinas científicas, e disciplinas relacionadas à engenharia.

Complementando, Vallejo et al. (2012) diz que modelos de simulação podem ser utilizados para solucionar problemas relacionados à visão geral dos sistemas empresariais e a interação entre seus componentes. Desta maneira, pode-se notar a multidisciplinariedade da Modelagem e Simulação. Segundo Diallo et al. (2017), isto dificulta a identificação, aplicação e união de teorias, além do desenvolvimento de ferramentas aplicáveis a mais de um problema por área.

Além disto, o contínuo desenvolvimento da Modelagem e Simulação dependem de teorias que precisam ser transformadas em abordagens coerentes e que precisam ser implementadas em ferramentas coerentes (DIALLO et al., 2017).

Diallo et al. (2017) reforça a ideia de que é necessário que as ferramentas sejam criadas a partir de estruturas baseadas em teoria, pois à medida que entramos em novas áreas computacionais, é necessária a análise da aplicabilidade de teorias, estruturas e ferramentas existentes, adaptando-as, ou criando novas.

Quando apropriadamente projetada, a Modelagem e Simulação fornece resultados que estão abertos a medições e análises, levando à diferentes iterações e múltiplas variações, que permitem ao analista ou gerente aprofundar seu conhecimento sobre o sistema em estudo (BISOGNO et al., 2015).

Outra vantagem da Modelagem e Simulação, é que ela pode ser utilizada para avaliar as estratégias da empresa antes de ser implementada no mundo real, pois com a realização de diferentes simulações, é possível a obtenção de um resultado estimado de como a empresa pode executar determinadas estratégias (VALLEJO et al., 2012).

Fu (1994) afirma que um tradicional problema de minimização com um objetivo único via simulação, é:

$$\min f(\theta) \tag{1}$$

sendo $f(\theta) = [\varphi(\theta, u)]$ o valor esperado para a performance estimada do sistema, baseada em um modelo de simulação, $\varphi(\theta, u)$ indicando os valores observados da performance, u representa o pseudo número aleatório e θ é um vetor de p parâmetros.

Segundo Kleijnen et al. (2015), a amplitude de variações e a quantidade de variáveis no modelo de simulação influenciam na complexidade do processo de simulação devido às demandas computacionais.

Ingalls (2013) aponta que a simulação é utilizada para avaliar diferentes cenários, mas que não define qual é o melhor cenário para ser escolhido, e que cabe ao gestor analisar junto à dinâmica do sistema qual a melhor opção.

Em suma, no dinâmico ambiente empresarial, que conta com a crescente heterogeneidade do mercado, as empresas são desafiadas a se adaptar as rápidas mudanças do mercado, e a Modelagem e Simulação podem auxiliar nestas adaptações (FERREIRA et al., 2012).

Segundo Rubinstein e Kroese (2016), os modelos de simulação computacionais podem ser classificados de várias maneiras:

- a) Modelo Estático *versus* dinâmico: Modelos estáticos são aqueles que não representam a passagem do tempo, e os dinâmicos representam sistemas que envolvem o tempo.
- b) Modelo Determinístico *versus* estocástico: Em modelos determinísticos, todas as relações matemáticas e lógicas entre variáveis são fixas, e não sujeitas à incertezas. Em contrapartida, um modelo estocástico é aquele que há pelo menos um *input* aleatório.
- c) Modelo Contínuo *versus* Simulação Discreta: Em modelos de simulação discreta, a variável muda instantaneamente em um ponto discreto no tempo, enquanto em um modelo contínuo, o estado muda constantemente através do tempo.

A Simulação Monte Carlo (SMC) pode ser definida como uma simulação estática, discreta e estocástica, pois inclui a aleatoriedade em seu modelo, e não evolui sobre o tempo (RUBINSTEIN e KROESE, 2016).

O termo Simulação Monte Carlo (SMC) era utilizado por von Neumann e Ulam, durante a segunda guerra mundial como uma palavra código para o trabalho secreto quando havia problemas relacionados à bomba atômica, uma vez que este trabalho envolvia a

simulação da difusão de nêutrons aleatórios em materiais nucleares (RUBINSTEIN e KROESE, 2016).

Segundo Lee et al. (2013), a simulação estocástica é uma ferramenta de modelagem poderosa pois analisa sistemas complexos, uma vez que permite a descrição precisa do sistema por meio do uso de variáveis e restrições complexas e não algébricas.

A SMC vem sendo amplamente utilizada em muitas aplicações, como transporte, manufatura, telecomunicação, gestão da cadeia de suprimentos, e muitas aplicações industriais, mas ainda funciona principalmente como uma ferramenta de avaliação (LEE et al., 2016).

Segundo Madic et al. (2014), é necessário o cálculo de uma grande quantidade de casos especiais, uma análise estatística apropriada e a utilização de um computador de boa configuração para se obter resultados razoavelmente precisos.

3 DESCRIÇÃO E MODELAGEM DO PROBLEMA

3.1 DESCRIÇÃO DO PROBLEMA

Conforme visto na literatura, a simulação e os KPIs são amplamente utilizados na indústria, visando melhorar o desempenho dos processos e conseqüentemente, o atendimento ao cliente.

Este trabalho buscou analisar uma multinacional do ramo da saúde, fabricante de dispositivos médicos, localizada no Vale do Paraíba, no interior do Estado de São Paulo. A região localiza-se nas margens da rodovia Presidente Dutra (BR-116), entre as cidades de São Paulo e Rio de Janeiro, e se destaca por concentrar uma parcela considerável do PIB do Brasil por ser altamente industrializada.

A empresa é uma multinacional americana, e atua no Brasil desde 1933, nos segmentos de saúde, higiene pessoal e beleza.

O estudo analisou as métricas da área de Planejamento de Produção da empresa descrita, realizando simulações das métricas, em um contexto sob incerteza, que demonstram de maneira mais completa a situação e panorama atual. As simulações foram realizadas utilizando o Microsoft Office Excel[®] e uma versão *trial* do software *Crystal Ball*[®].

3.1.1 Identificação do problema

A necessidade de uma análise mais sistemática dos principais KPIs da área surgiu por meio de um *brainstorm* durante um evento Kaizen realizado anualmente na área. Esses KPIs são diretamente relacionados ao serviço de atendimento ao cliente, e refletem o quanto a cadeia de suprimentos como um todo, está atendendo às necessidades deles.

O problema se baseia na simulação de cinco KPIs, que foram medidos por 30 semanas consecutivas, e simulados por meio de uma versão *trial* do software *Crystal Ball*[®].

3.1.2 Descrição dos KPIs

Foram escolhidas métricas da área de Planejamento de Produção da empresa estudada, e os KPIs selecionados para o estudo foram: BO (LatAm), LIFR (LatAm), LIFR (*Export*), UTS (MRM) e *Kanban Adherence* (MRM).

Durante a análise de escolha dos KPIs a serem estudados, levou-se em consideração a importância, criticidade e o impacto que estas métricas representam para o negócio.

O Quadro 1 descreve as siglas anteriormente citadas, e a Tabela 2 cita as metas de cada um dos KPIs.

Quadro 1 – Descrição das siglas dos KPIs

Siglas	Descrição
LIFR	<i>Line Item Fill Rate</i>
UTS	<i>Unable to Schedule</i>
MRM	<i>Manufactured Raw Material</i>

Fonte: Produção do próprio autor

Tabela 2 – Metas dos KPIs

KPI	Meta
LIFR (Export)	Acima de 95%
UTS (MRM)	Abaixo de 7%
Kanban Adherence (MRM)	Acima de 90%

Fonte: Produção do próprio autor

O cálculo do LIFR foi desenvolvido visando a análise do preenchimento total dos pedidos dos clientes, considerando linha a linha, por um específico período de tempo. Este trabalho estudou o LIFR do conjunto de clientes chamado *Export*.

Os clientes *Export* são os que englobam EUA, Europa e alguns países asiáticos.

A Tabela 3 exemplifica do cálculo do LIFR, que se baseia em:

$$\text{LIFR} = \frac{\text{Linhas de pedidos atendidas}}{\text{Total de linhas de pedidos}} \quad (2)$$

Tabela 3 – Exemplo de cálculo de LIFR

Código	LIFR - Semana X			LIFR
	Total de Linhas	Linhas Atendidas	Linhas Não Atendidas	
X1	17	17	0	100%
X2	43	36	7	84%
X3	2	2	0	100%
X4	2	2	0	100%
X5	73	37	36	51%
X6	14	14	0	100%
X7	2	2	0	100%
X8	3	3	0	100%
X9	31	0	31	0%
X10	5	5	0	100%
Total	192	118	74	61%

Fonte: Produção do próprio autor

O UTS de MRM reflete o cálculo da quantidade de produtos que não foram possíveis de serem planejados, produzidos e enviados no tempo estipulado. Este cálculo estuda os MRM, ou seja, matérias primas manufaturadas na planta, e que além de serem utilizadas para a produção de produtos acabados na planta, são exportados. Segue exemplo de cálculo do UTS na Tabela 4.

Tabela 4 – Exemplo de cálculo de UTS

Código	Soma da demanda efetiva	Soma da quantidade de UTS	UTS %
ABC	1.762	0	0,0%
ABD	3.884	1.346	34,7%
ACD	491	129	26,3%
DBA	13.767	0	0,0%
ADC	66.494	12.474	18,8%
DCA	1.685	1.685	100,0%
DAC	79.097	0	0,0%
CDA	31.085	0	0,0%
Total	198.265	15.634	7,9%

Fonte: Produção do próprio autor

O *Kanban Adherence* analisa a quantidade de produtos no estoque que estejam acima de 50% do estoque de segurança. Por exemplo, se o estoque de segurança do produto ABC for de 50 produtos, e o estoque atual for 20, o *Kanban Adherence* será pontuado.

Neste contexto, se o nível de inventário oscilar entre 24 produtos, ou 0 produtos, a métrica de *Kanban Adherence* será pontuada da mesma maneira, pois ambos estão abaixo de 50% do estoque de segurança. Segue exemplo de cálculo do *Kanban Adherence* na Tabela 5.

Tabela 5 – Exemplo Kanban Adherence

Código	Estoque de segurança	Inventário	Número de códigos por site	50% estoque de segurança atendido?	Kanban Adherence
A	545	7.890	1	1	100%
B	107	5.413	1	1	100%
C	17.790	0	1	0	0%
D	3.976	21.210	1	1	100%
E	11.890	93.460	1	1	100%
F	4.703	48.460	1	1	100%
G	153.200	231.100	1	1	100%
H	4.850	29.700	1	1	100%
I	2.746	2.350	1	1	100%
J	0	12.730	1	1	100%
K	6.009	2.417	1	0	0%
L	205.816	454.730	11	9	82%

Fonte: Produção do próprio autor

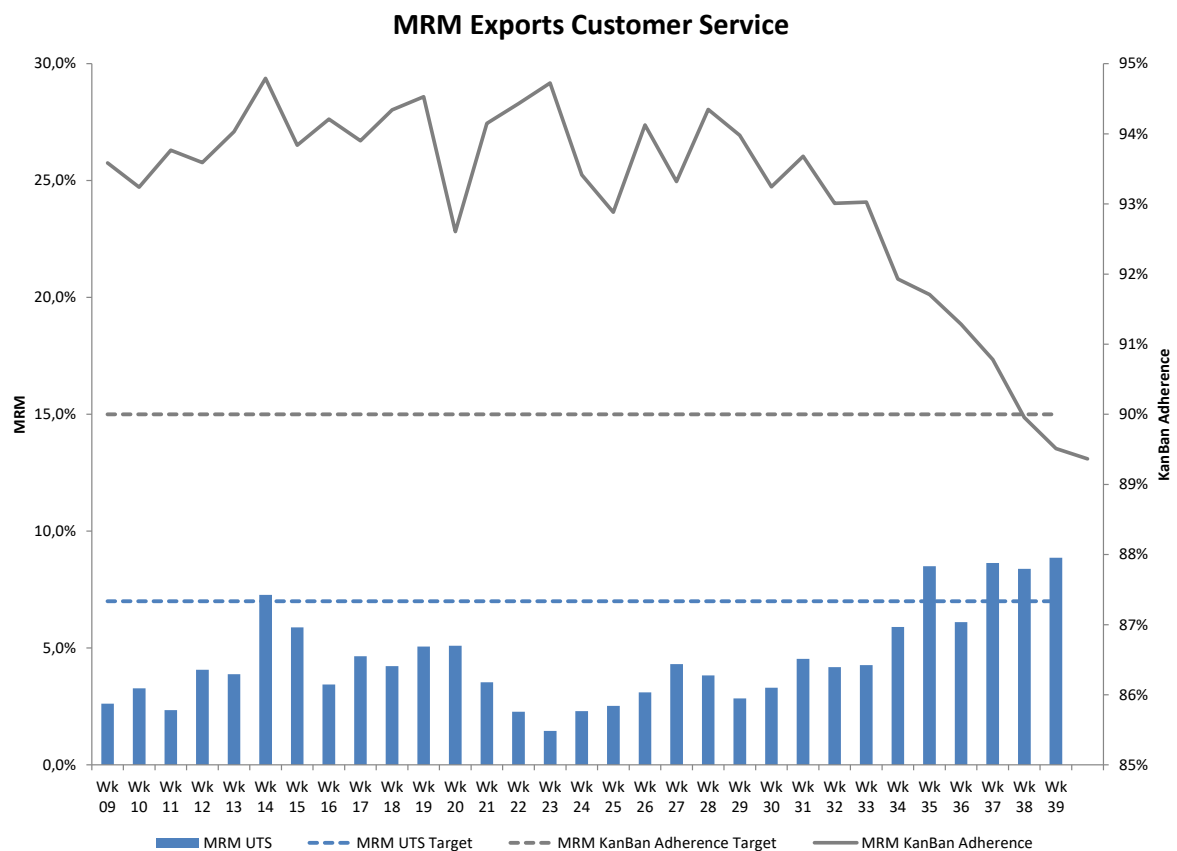
3.1.3 Coleta dos dados

Visando assegurar a equivalência dos resultados para a função objetivo, foram coletados dados de 30 semanas consecutivas, durante os meses de Março à Setembro de 2017, como segue na Tabela 6.

Tabela 6 – Dados LIFR *Export* - de Março à Setembro de 2017

	LIFR <i>Export</i>	MRM UTS	MRM <i>Kanban Adherence</i>
Semana 1	98,41%	3,30%	93,40%
Semana 2	97,63%	2,30%	93,50%
Semana 3	98,08%	4,10%	93,50%
Semana 4	98,75%	3,90%	93,60%
Semana 5	99,66%	7,30%	94,80%
Semana 6	98,55%	5,90%	94,30%
Semana 7	99,90%	3,40%	94,30%
Semana 8	99,37%	4,60%	94,20%
Semana 9	99,54%	4,20%	94,30%
Semana 10	98,98%	5,10%	94,40%
Semana 11	96,10%	5,10%	93,80%
Semana 12	96,63%	3,50%	93,90%
Semana 13	98,12%	2,30%	94,40%
Semana 14	96,65%	1,50%	94,60%
Semana 15	99,04%	2,30%	94,20%
Semana 16	99,23%	2,50%	93,90%
Semana 17	99,09%	3,10%	93,90%
Semana 18	99,60%	4,30%	93,30%
Semana 19	96,20%	3,80%	93,80%
Semana 20	82,73%	2,80%	93,90%
Semana 21	82,30%	3,30%	93,70%
Semana 22	80,34%	4,50%	93,70%
Semana 23	80,77%	4,20%	93,30%
Semana 24	78,44%	4,30%	93,20%
Semana 25	83,53%	5,90%	92,90%
Semana 26	92,31%	8,50%	91,70%
Semana 27	91,42%	6,10%	91,50%
Semana 28	89,30%	8,60%	91,30%
Semana 29	83,70%	8,40%	90,90%
Semana 30	85,12%	8,90%	90,70%

Fonte: Produção do próprio autor

Figura 6 – Representação dos KPIs de UTS e *Kanban Adherence* no tempo

Fonte: Produção do próprio autor

3.2 SIMULAÇÃO

3.2.1 Simulação do UTS

A primeira métrica simulada foi o UTS dos materiais manufaturados na planta. Como detalhado no capítulo anterior, o UTS é a divisão da quantidade de produtos que não estavam disponíveis para o cliente (A) pela quantidade de produtos que foram requeridas pelos mesmos (B). Foram simulados os dados de 30 semanas consecutivas, que se encontram na Tabela 7.

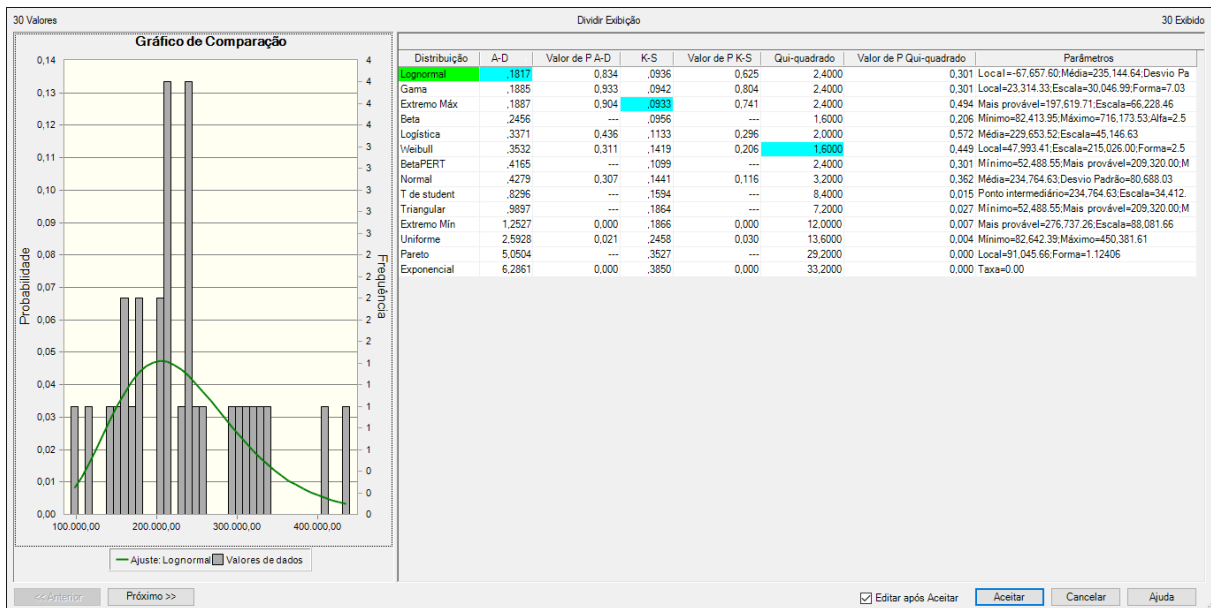
Como pode se verificar na Figura 6, de acordo com o software utilizado, a equação mais adequada para a curva do item A é a Lognormal. Porém, escolheu-se a curva Logística para simular estes dados, levando-se em consideração o maior Valor de P Qui-quadrado encontrado, de 0,572.

Para a curva do item B, o software recomendou a utilização da curva *Weibull*, como pode ser verificado na Figura 7. Assim como no item anterior, escolheu-se a curva Logística por possuir maior Valor de P Qui-quadrado, de 0,362.

Tabela 7 – Dados simulados do UTS

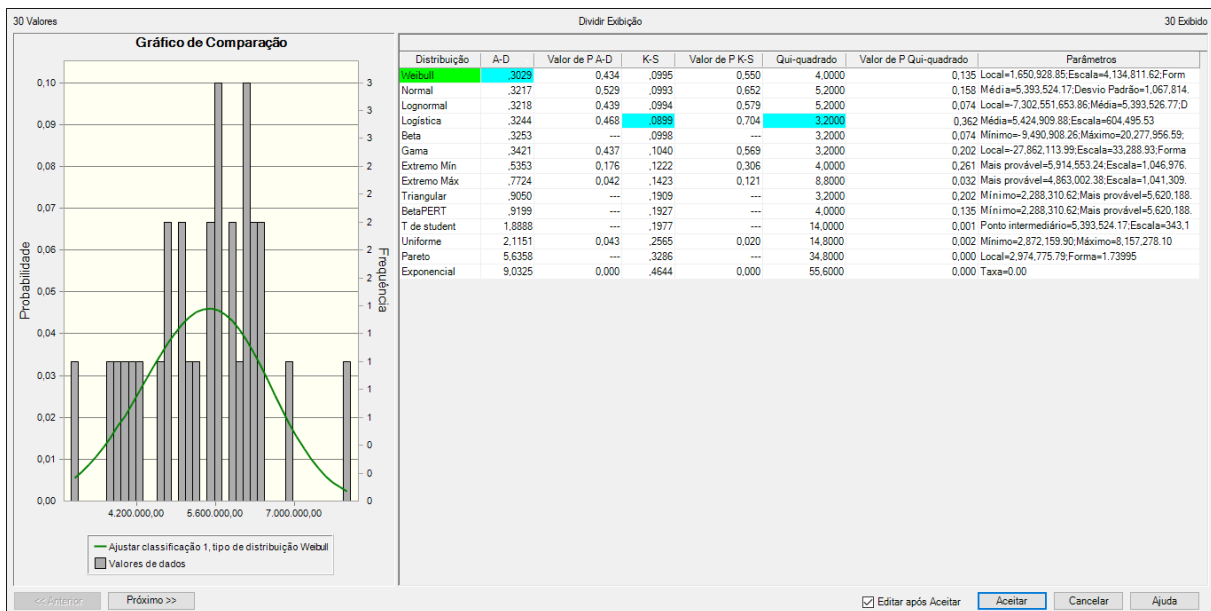
	A	B	UTS
1	166.553	5.077.183	3,3%
2	118.378	5.044.858	2,3%
3	228.568	5.620.189	4,1%
4	213.951	5.511.769	3,9%
5	439.238	6.034.238	7,3%
6	330.423	5.615.216	5,9%
7	214.004	6.226.531	3,4%
8	298.400	6.419.525	4,6%
9	250.513	5.923.704	4,2%
10	296.664	5.858.781	5,1%
11	314.277	6.165.847	5,1%
12	215.934	6.104.903	3,5%
13	141.080	6.199.938	2,3%
14	93.786	6.449.516	1,5%
15	158.618	6.891.949	2,3%
16	202.202	7.997.123	2,5%
17	176.397	5.688.821	3,1%
18	180.450	4.181.163	4,3%
19	239.248	6.248.930	3,8%
20	156.080	5.481.090	2,8%
21	155.651	4.711.879	3,3%
22	237.051	5.227.858	4,5%
23	209.320	5.002.391	4,2%
24	204.209	4.787.241	4,3%
25	237.840	4.029.389	5,9%
26	315.719	3.714.257	8,5%
27	239.330	3.915.184	6,1%
28	261.928	3.032.315	8,6%
29	340.675	4.060.496	8,4%
30	406.452	4.583.442	8,9%
Soma	7.042.939	161.805.726	
Média			4,3%

Figura 7 – Teste de Aderência para o item A (UTS)



Fonte: Produção do próprio autor

Figura 8 – Teste de Aderência para o item B (UTS)



Fonte: Produção do próprio autor

Com a definição de ambas as curvas, os dados foram simulados através da fórmula:


$$UTS = \frac{A}{B} \quad (3)$$

Foram simuladas 100.000 rodadas utilizando 95% de confiança. Com estes parâmetros,

a simulação variou entre 1% à 9%, conforme mostra a Figura 7.


Visando a meta deste KPI, analisou-se qual seria o nível de confiança para até 7%. Como pode-se ver na Figura 8, há uma probabilidade de 91,48% deste KPI estar abaixo de 7%.

Figura 9 – Simulação do UTS com 95% de confiança



Fonte: Produção do próprio autor

Figura 10 – Simulação do UTS definindo a meta de no máximo 7%



Fonte: Produção do próprio autor

3.2.2 Simulação *Kanban Adherence*

O segundo KPI simulado foi o *Kanban Adherence*. Como descrito anteriormente, este KPI é a divisão entre a quantidade de itens abaixo de 50% do estoque de segurança (X1) e o número de códigos totais (X2). Foram simulados os dados de 27 semanas consecutivas, que se encontram na Tabela 8.

Tabela 8 – Dados *Kanban Adherence*

	X1	X2	<i>Kanban Adherence</i>
1	1.292	1.363	94,8%
2	1.279	1.363	93,8%
3	1.285	1.364	94,2%
4	1.278	1.361	93,9%
5	1.284	1.361	94,3%
6	1.296	1.371	94,5%
7	1.265	1.366	92,6%
8	1.287	1.367	94,1%
9	1.289	1.365	94,4%
10	1.293	1.365	94,7%
11	1.277	1.367	93,4%
12	1.266	1.363	92,9%
13	1.282	1.362	94,1%
14	1.271	1.362	93,3%
15	1.285	1.362	94,3%
16	1.280	1.362	94,0%
17	1.270	1.362	93,2%
18	1.275	1.361	93,7%
19	1.264	1.359	93,0%
20	1.267	1.362	93,0%
21	1.253	1.363	91,9%
22	1.250	1.363	91,7%
23	1.236	1.354	91,3%
24	1.231	1.356	90,8%
25	1.218	1.354	90,0%
26	1.212	1.354	89,5%
27	1.210	1.354	89,4%
Soma	34.195	36.766	
Média			93,0%

Fonte: Produção do próprio autor

Com a utilização do software *Crystal Ball*[®], buscou-se encontrar a curva que melhor representasse os dados X e Y, porém nenhum ajuste válido foi encontrado para as distribuições analisadas. Sendo assim, escolheu-se utilizar a distribuição Uniforme Discreta, conforme segue Figura 11.

Foram simuladas 100.000 rodadas utilizando 95% de confiança. Com estes parâmetros, a simulação variou entre 89% à 95% (Figura 12).

Figura 11 – Pressupostos da Simulação *Kanban Adherence*

Pressupostos


Planilha: [SIMULAÇÃO KANBAN.xlsx]Kanban Adherence

Pressuposto: X1

Célula: E7

Uniforme Discreto distribuição com parâmetros:

Mínimo	1.210,00
Máximo	1.296,00




Pressuposto: X2

Célula: E8

Uniforme Discreto distribuição com parâmetros:


Mínimo	1.354,00
Máximo	1.371,00



Fonte: Produção do próprio autor


Visando a meta deste KPI, analisou-se qual seria o nível de confiança para que a métrica atinja no mínimo 90%. Como pode-se ver na Figura 13, há uma probabilidade de 81,48% deste KPI estar entre 90% e 100%.

Figura 12 – Simulação do Kanban Adherence com 95% de confiança



Fonte: Produção do próprio autor

Figura 13 - Simulação do Kanban Adherence definindo a meta de no mínimo 90%



Fonte: Produção do próprio autor

3.2.3 Simulação LIFR *Export*

O terceiro KPI simulado foi o LIFR *Export*. Como descrito anteriormente, este KPI é a divisão entre a quantidade linhas não atendidas (Y1) pela quantidade de linhas de pedidos dos clientes (Y2).

Foram simulados os 30 valores da Tabela 9, utilizando a distribuição Uniforme Discreta. Porém, ao simular estes dados, notou-se que aproximadamente 18% das simulações resultavam em um LIFR maior do que 100%.

Como a quantidade de linhas não atendidas nunca ultrapassam a quantidade de linhas de pedidos em uma mesma semana, este KPI jamais poderia resultar em um número maior do que 1. Todavia, como a quantidade de pedidos variam entre as semanas, as simulações resultam em números maiores do que 1.

Tabela 9 – Dados LIFR *Export*

	Y1	Y2	LIFR <i>Export</i>
1	2.046	2.079	98,41%
2	1.932	1.979	97,63%
3	1.995	2.034	98,08%
4	1.902	1.926	98,75%
5	2.076	2.083	99,66%
6	2.244	2.277	98,55%
7	1.997	1.999	99,90%
8	1.726	1.737	99,37%
9	1.969	1.978	99,54%
10	1.945	1.965	98,98%
11	1.994	2.075	96,10%
12	1.837	1.901	96,63%
13	1.980	2.018	98,12%
14	1.844	1.908	96,65%
15	2.061	2.081	99,04%
16	1.929	1.944	99,23%
17	2.168	2.188	99,09%
18	2.002	2.010	99,60%
19	2.050	2.131	96,20%
20	2.194	2.652	82,73%
21	1.511	1.836	82,30%
22	1.532	1.907	80,34%
23	1.348	1.669	80,77%
24	1.284	1.637	78,44%
25	1.522	1.822	83,53%
26	1.765	1.912	92,31%
27	1.875	2.051	91,42%
28	1.802	2.018	89,30%
29	1.778	2.123	83,75%
30	1.991	2.339	85,12%
Soma	56.229	60.279	
Média			93,40%

Visando aprimorar esta simulação, normalizou-se os valores de Y1 e Y2, obtendo um valor de LIFR *Export* Normalizado.

Tabela 10 – Dados LIFR *Export* Normalizados

	Y1 Normalizado	Y2 Normalizado	LIFR <i>Export</i> - Normalizado
1	8,67	10,55	82,1%
2	8,18	10,04	81,5%
3	8,45	10,32	81,9%
4	8,06	9,77	82,4%
5	8,79	10,57	83,2%
6	9,50	11,56	82,3%
7	8,46	10,14	83,4%
8	7,31	8,81	82,9%
9	8,34	10,04	83,1%
10	8,24	9,97	82,6%
11	8,45	10,53	80,2%
12	7,78	9,65	80,7%
13	8,39	10,24	81,9%
14	7,81	9,68	80,7%
15	8,73	10,56	82,7%
16	8,17	9,87	82,8%
17	9,18	11,10	82,7%
18	8,48	10,20	83,1%
19	8,68	10,81	80,3%
20	9,29	13,46	69,1%
21	6,40	9,32	68,7%
22	6,49	9,68	67,1%
23	5,71	8,47	67,4%
24	5,44	8,31	65,5%
25	6,45	9,25	69,7%
26	7,48	9,70	77,0%
27	7,94	10,41	76,3%
28	7,63	10,24	74,5%
29	7,53	10,77	69,9%
30	8,43	11,87	71,0%

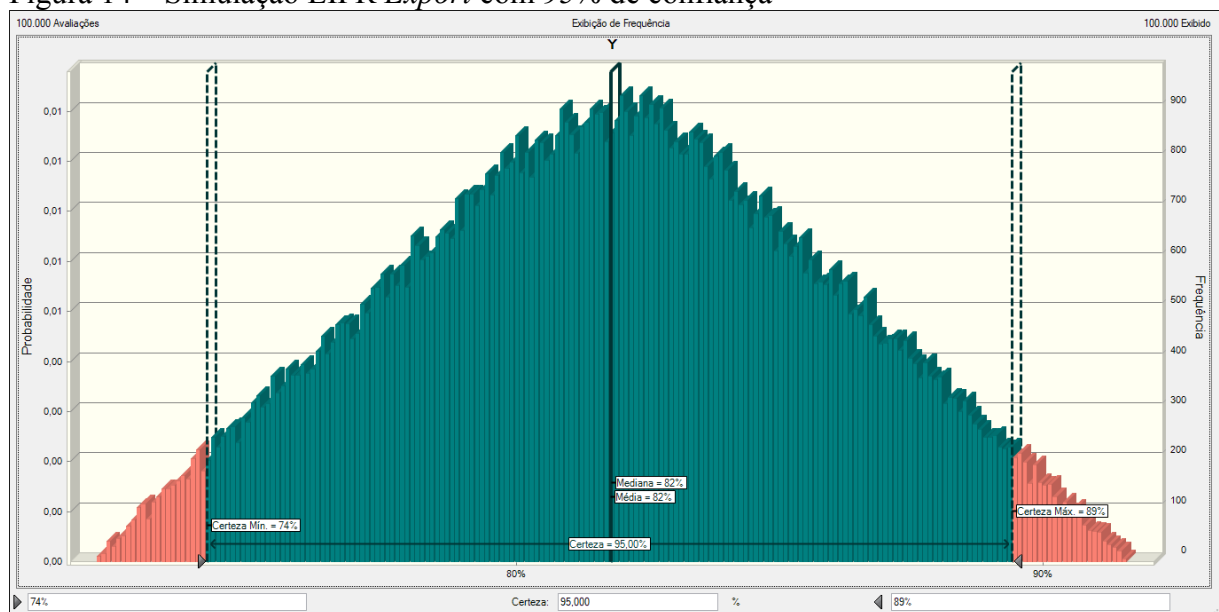
Fonte: Produção do próprio autor

A simulação foi aplicada calculando-se a média das simulações dos LIFR *Export* da Tabela 9 e dos LIFR *Export* Normalizados da Tabela 10, por meio da distribuição Uniforme.

Foram simuladas 100.000 rodadas utilizando 95% de confiança. Com estes parâmetros, a simulação variou entre 74% e 89% (Figura 14).


Visando a meta deste KPI, analisou-se qual seria o nível de confiança para que a métrica atinja no mínimo 95%. Como pode-se ver na Figura 15, não existe a probabilidade de atingir a métrica de 95%, uma vez que todos os valores simulados ficaram abaixo deste valor.

Figura 14 – Simulação LIFR *Export* com 95% de confiança



Fonte: Produção do próprio autor

Figura 15 – Simulação LIFR *Export* definindo a meta de no mínimo 95%



Fonte: Produção do próprio autor

3.3 DISCUSSÃO DOS RESULTADOS

A simulação de 100.000 valores do UTS, com 95% de confiança, resultou na média de 4% (Figura 8). A meta deste KPI é estar abaixo de 7%, e segundo estas simulações, a probabilidade de isso ocorrer é de 91,48%.

Levando em consideração que a média dos 30 valores foi de 4,3%, e que 16,6% destes valores não atingiram a meta, pode-se afirmar que a simulação Monte Carlo se encaixa neste contexto e poderia auxiliar na análise deste KPI. Porém, a probabilidade de se atingir a meta foi maior na simulação do que na média dos 30 valores coletados.

A performance da simulação do *Kanban Adherence* diferiu do UTS em alguns aspectos. A simulação de 100.000 valores, com 95% de confiança resultou em valores entre 89% e 95% de confiança. O *target* deste KPI é de atingir no mínimo 90%. Com 95% de confiança, a probabilidade deste *target* ser alcançado é de 81,48%.

Levando em consideração que a média dos 27 valores coletados foi de 93%, e que apenas 7,4% destes valores não atingiram a meta, pode-se afirmar que a simulação realizada atingiu valores mais baixos do que os valores coletados, uma vez que há a probabilidade de 18,52% de não atingir o *target*.

A simulação do LIFR *Export* foi mais complexa devido à elevada amplitude que há entre as quantidades de linhas de pedidos dos clientes no decorrer das semanas, fazendo com que o denominador da divisão varie muito e resulte em simulações com valores maiores do que 1.

Algumas alternativas foram implementadas para desviar deste ponto, e a melhor opção encontrada foi a de utilizar a simulação por meio da aplicação VBA, considerando-se todos os valores simulados, incluindo os valores acima de 1, que na média resultam em um valor mais aproximado dos valores coletados.

Ao final das simulações, é possível confirmar que há vantagens em aplicar a SMC na análise de indicadores de desempenho em um contexto sob incerteza, uma vez que os valores simulados se aproximam muito da realidade.

Porém, ainda há muitas outras variáveis, como por exemplo, o nível de inventário e eficiência das máquinas, que influenciam no desempenho destes KPIs, e que não foram incluídas nas simulações. Sendo assim, conclui-se que a SMC de indicadores de desempenho pode ser aplicada para auxiliar na tomada de decisão desde que acompanhada de outros estudos que englobem todas, ou grande parte das variáveis que influenciam no resultado.

4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

4.1 VERIFICAÇÃO DAS QUESTÕES DA PESQUISA E OBJETIVOS

Em conformidade ao objetivo que visa analisar KPIs em um contexto sob incerteza, fundamentou-se teoricamente os temas: indicadores de desempenho e Simulação Monte Carlo. Com isto, evidenciou-se que a simulação se encaixa neste contexto à medida que pode realizar projeções destes indicadores, propondo aumentar a visibilidade da cadeia e auxiliando gestores nos momentos de tomada de decisão.

No decorrer do trabalho, os indicadores foram selecionados, mapeados, descritos e Simulações Monte Carlo foram realizadas por meio do Software Microsoft Office Excel[®].

Três KPIs foram simulados e analisados, e os resultados mostram que é possível e há vantagens em aplicar a SMC para analisar indicadores de desempenho empresariais em um contexto sob incerteza, por ser mais uma ferramenta para auxiliar e embasar uma tomada de decisão.

Além disto, a SMC provêm uma série de resultados possíveis e probabilidades de ocorrência. No estudo em questão ela pode ser reaplicada semanalmente, a cada novo resultado coletado, alterando os valores de acordo com a curva característica escolhida.

Porém, ressalta-se a desvantagem de não poder utilizar apenas a SMC para a tomada de decisão. No contexto aplicado, é necessário a análise de outros fatores externos, como por exemplo a falta de alguma matéria-prima ou a disponibilidade das máquinas, para a análise completa do cenário e conseqüente tomada de decisão.

4.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS

Como limitação da pesquisa e sugestão de continuidade, identifica-se que é necessário englobar a maior quantidade possível de variáveis na simulação para que a mesma se torne mais confiável para a tomada de decisão baseada em simulações.

REFERÊNCIAS

- ALI, M. et al. Supply chain forecasting when information is not shared. **European Journal of Operational Research**, Amsterdam, v. 260, p. 984-994, 16 Jan 2017.
- BAZRKAR, A.; IRANZADEH, S. Choosing a strategic process in order to apply in Lean Six Sigma methodology for improving its performance using integrative approaches. **Journal of Business and Retail Management Research**, Tabriz, v. 11, n. 4, jul. 2017.
- BERTRAND, J. W. M; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, Eindhoven, v. 22, p. 241-264, 2002.
- BISOGNO, S. et al. Combining modelling and simulation approaches: how to measure performance of business processes. **Business Process Management Journal**, Rome, v. 22, n. 1, p.56-74, jul. 2015.
- 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**, Suffolk, v. 93, n.4, p.271–272, mar. 2017.
- DING, S. et al. A novel scheme for key performance indicator prediction and diagnosis with application to an industrial hot strip mill. **IEE Transactions on Industrial Informatics**, Duisburg, v. 9, n. 4, nov. 2013.
- FALCONI, V. **O Verdadeiro poder**. São Paulo: Indg Tecnologia E Serviços Ltda., 2013
- FERREIRA, P. S. et al. Framework for performance measurement and management in a collaborative business environment. **International Journal of Productivity and Performance Management**, Porto, v. 61, n. 6, p.672-690, maio 2012.
- GONDIM, F. **Indicadores de qualidade como ferramenta para alcançar resultados mais efetivos**. 2016. Disponível em: <https://www.falconi.com/flcn_articles/indicadores-para-resultados-mais-efetivos/>. Acesso em: 02 ago. 2017.
- FU, M.C. Optimization via simulation: a review. **Annals of Operations Research**, Amsterdam, v. 53, p.199-247, 1994.
- GRIGOROUDIS, E.; ORFANOUDAKI, E.; ZOPOUNIDIS, C. Strategic performance measurement in a health care organisation: A multiple criteria approach based on balanced scorecard. **Omega**, Elsevier, v. 40, p. 104-119, 2012.
- HAMOUDA, A. E. The BSCBAS: a balanced Scorecard-based appraisal system for improving the performance of software organizations. **Journal of Software Maintenance and Evolution: research and practice**, Cairo, v. 25, p. 763-780, 2013.
- HAO, H. et al. A data-driven multiplicative fault diagnosis approach for automation processes. **ISA Transactions**, Nova York, v. 53, p. 1436–1445, jan. 2014.

JAHANGIRIAN, M. et al. Key performance indicator for successful simulation projects. **Journal of the Operational Research Society**, Cambridge, p. 1-19, 2017.

KAPLAN, R.S.; NORTON, D.P. The balanced scorecard measures that drive performance. **Harvard Business Review**, Cambridge v. 9, p. 70-71, 1992.

KLEIJNENM J.P.C. **Design and analysis of simulation experiments**. New York: Springer, 2015.

KROESE, D. P.; TAIMRE, T.; BOTEV, Z. I. **Handbook of Monte Carlo methods**. New York: John Wiley & Sons, 2017.

LEE, L. H. et al. Advances in simulation optimization and its applications. **IIE Transactions**, Snyder, v.45, n.7, apr. 2013.

MADIC, M. et al. Analysis of correlations of multiple-performance characteristics for optimization of CO2 laser nitrogen cutting of AISI 304 stainless steel. **Journal of Engineering Science and Technology Review**, Serbia, v. 7, p. 16-21, 2014.

MIRANDA, R. 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**, Itajubá, v. 262, n. 2, p. 673-681 , apr. 2017.

MODAK, M.; PATHAK, K.; GHOSH, K. Performance evaluation of outsourcing decision using a BSC and Fuzzy AHP approach: A case of the Indian coal mining organization. **Resources Policy**, Kahragpur v. 52, p. 181-191, 2017.

MURIANA, C.; PIAZZAA T.; VIZZINI, G. N. A expert system for financial performance assessment of health care structures based on fuzzy sets and KPIs. **Knowledge-Based Systems**, Pittsburgh v.97, p.1-10, jan. 2016.

ROBINSON, S. **Simulation: the practice of model development and use**. Local: John Wiley & Sons, 2004.

RUBINSTEIN, R.; KROESE, D. **Simulation and the Monte Carlo Method**. Local: John Wiley & Sons, nov. 2016.

SCOPUS. **Key Word:** Monte Carlo Simulation. Disponível em: <https://www.scopus.com/term/analyzer.uri?sid=afd521555ad7c779ec4c4bf0b8725e77&origin=resultlist&src=s&s=TITLE-ABS-KEY%28monte+carlo+simulation%29&sort=plf-f&sdt=b&sot=b&sl=37&count=190756&analyzeResults=Analyze+results&txGid=56adef74dc3bae0935d82f134663753>. Acesso em: 10 abr. 2017.

TEE, K. F. et al. Identifying critical performance indicators and suitable partners using a benchmarking template. **International Journal of Productivity and Performance Management**, Wharda, v. 64, n. 3, p.434-450, nov. 2014.

VALLEJO, C.; ROMERO, D.; MOLINA, A. Enterprise integration engineering reference framework and toolbox. **International Journal of Production Research**, Cidade do México, v.50, n.6, p. 1489-1511, jul. 2011.

WAAL, A.; KOURTIT, K. Performance measurement and management in practice: advantages, disadvantages and reasons for use. **International Journal of Productivity and Performance Management**, Amsterdam, v. 62, n. 5, p.446-473, jan. 2013.

WEB OF SCIENCE. **Key word:** KPI. Disponível em: http://apps-webofknowledge.ez87.periodicos.capes.gov.br/CitationReport.do?product=WOS&search_mode=CitationReport&SID=5EhKUDiYhP9On9ip6gU&page=1&cr_pqid=1&viewType=summary&colName=WOS. Acesso em: 15 abr. 2017

WEB OF SCIENCE. **Key word:** KPI e Monte Carlo Simulation. Disponível em: http://apps-webofknowledge.ez87.periodicos.capes.gov.br/CitationReport.do?product=WOS&search_mode=CitationReport&SID=5EhKUDiYhP9On9ip6gU&page=1&cr_pqid=3&viewType=summary&colName=WOS. Acesso em: 15 abr.2017

ZHANG, K. et al. A KPI-based process monitoring and fault detection framework for large-scale processes. **ISA Transactions**, Nova York, v. 68, p. 276–286, feb. 2017.