

**MURILO VIEIRA STRONGOLI**

**Modelos multiobjetivo de análise envoltória de dados na avaliação  
da eficiência de linhas de montagem**

**Murilo Vieira Strongoli**

**Modelos multiobjetivo de análise envoltória de dados na avaliação  
da eficiência de linhas de montagem**

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.

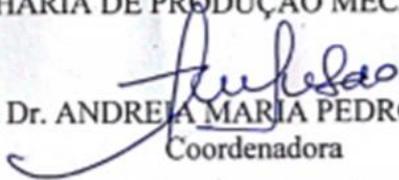
Orientador: Prof. Dr. Aneirson Francisco da Silva

S923m	<p>Strongoli, Murilo Vieira Modelos multiobjetivo de análise envoltória de dados na avaliação da eficiência de linhas de montagem / Murilo Vieira Strongoli. – Guaratinguetá, 2018. 58 f : il. Bibliografia: f. 53-58</p> <p>Trabalho de Graduação em Engenharia de Produção Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2018. Orientador: Prof. Dr. Aneirson Francisco da Silva</p> <p>1. Análise de envoltória de dados 2. Processo decisório por critério múltiplo 3. Desempenho - Medição I. Título.</p> <p style="text-align: right;">CDU 65.012.4</p>
-------	--

**MURILO VIEIRA STRONGOLI**

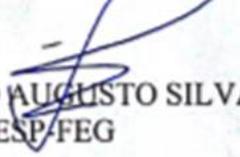
ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO  
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE  
"GRADUADO EM ENGENHARIA DE PRODUÇÃO MECÂNICA"

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

## **DADOS CURRICULARES**

### **MURILO VIEIRA STRONGOLI**

**NASCIMENTO** 02.09.1995 – Piedade / SP

**FILIAÇÃO** Celso Tadeu Reginato Strongoli  
Tania Regina Vieira Strongoli

**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

Agradeço pela minha vida, minha família e meus amigos,  
ao meu orientador, *Prof. Dr. Aneirson Francisco da Silva* que jamais deixou de me incentivar. Sem a sua orientação, dedicação e auxílio, o estudo aqui apresentado seria praticamente impossível.

aos meus pais *Celso e Tania*, que, apesar das dificuldades enfrentadas, sempre incentivaram meus estudos.

à minha namorada, *Angélica*, minha companheira de todas as horas.

aos meus irmãos, *Juliana e Celso*, que estão sempre presentes em minha vida, apesar da distância.

aos funcionários da Faculdade de Engenharia do Campus de Guaratinguetá pela dedicação e alegria no atendimento.

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

Goethe

## RESUMO

Um dos requisitos para que as empresas consigam compreender melhor as necessidades de demanda de mercado é a medida mais detalhada de seu desempenho produtivo. Neste sentido, esse trabalho tem como objetivo medir a eficiência de uma linha de montagem de uma empresa do segmento de autopeças por meio de modelos de Análise Envoltória de Dados Multiobjetivo (MCDEA). Os modelos MCDEA foram modelados em VBA (Excel 2013<sup>®</sup>) e os resultados de eficiência dos diferentes modelos foram comparados com o modelo tradicional de medição de eficiência da empresa, a Eficácia Global do Equipamento (OEE). Por fim, concluiu-se que o modelo que melhor representa a realidade da empresa estudada é o Modelo MCDEA Bi-Objetivo sem peso ótimo.

**PALAVRAS-CHAVE:** Análise envoltória de dados multiobjetivo. Eficácia global do equipamento. MCDEA. OEE. Autopeças. Eficiência. Desempenho.

## **ABSTRACT**

One of the requirements for companies to better understand market demand needs is a detailed measure of their productive performance. In this sense, this work aims to measure the efficiency of an assembly line of a company of the segment of auto parts with Multiple Criteria Data Envelopment Analysis (MCDEA) models. The MCDEA models were modeled in VBA (Excel 2013<sup>®</sup>) and the efficiency results of the different models were compared with the traditional efficiency measurement model of the company, the Overall Equipment Effectiveness (OEE). Finally, it was concluded that the model that best represents the reality of the company studied is the non-epsilon-based weighted Bi-Objective MCDEA Model.

**KEYWORDS:** Multiple criteria data envelopment analysis. Overall equipment effectiveness. MCDEA. OEE. Autoparts. Efficiency. Performance.

## LISTA DE FIGURAS

Figura 1 - Publicações sobre MCDEA .....	16
Figura 2 - Citações sobre MCDEA.....	16
Figura 3 - Áreas de Conhecimento Contempladas pela MCDEA.....	17
Figura 4 - Publicações "Total Productive Maintenance" e "Overall Equipment Effectiveness" .....	17
Figura 5 – Classificação do Trabalho .....	19
Figura 6 – Etapas da Sistemática Proposta.....	20
Figura 7 - Princípios do Lean .....	24
Figura 8 - Primeiro Teste de Levene com OEE nos Parâmetros de Saída .....	44
Figura 9 - Segundo Teste de Levene com OEE nos Parâmetros de Saída .....	45
Figura 10 - Primeiro Teste de Levene sem OEE nos Parâmetros de Saída.....	45
Figura 11 - Segundo Teste de Levene sem OEE nos Parâmetros de Saída.....	46
Figura 12 - Terceiro Teste de Levene sem OEE nos Parâmetros de Saída .....	47

## LISTA DE TABELAS

Tabela 1- Relatório de Citações de Pesquisa na Web of Science e Scopus de 1994 a 2018.....	15
Tabela 2 - Parâmetros de Entrada e Saída das DMUs.....	37
Tabela 3 - Modelos MCDEA e Suas Respectivas Equações.....	38
Tabela 4 – Eficiências de Cada Modelo Utilizando o OEE como Parâmetro de Saída .....	40
Tabela 5 – Eficiências de Cada Modelo sem Utilizar o OEE como Parâmetro de Saída.....	41
Tabela 6 - Resultados do Teste não Paramétrico de Spearman – Modelagem Com OEE .....	43
Tabela 7 - Resultados do Teste não Paramétrico de Spearman – Modelagem Sem OEE.....	43

## LISTA DE QUADROS

Quadro 1 - Classificação das Seis Grandes Perdas .....	25
Quadro 2 - Parâmetros Seleccionados para <i>Input</i> e <i>Output</i> do Modelo .....	34

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>13</b>
1.1	CONTEXTUALIZAÇÃO DA PESQUISA .....	13
1.2	RELEVÂNCIA DA PESQUISA E JUSTIFICATIVA .....	14
1.3	QUESTÕES DE PESQUISA, OBJETIVOS E DELIMITAÇÃO DA PESQUISA .....	18
1.4	MATERIAIS E MÉTODOS.....	19
1.5	ESTRUTURA DO TRABALHO .....	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>23</b>
2.1	PRODUÇÃO ENXUTA.....	23
2.2	EFICÁCIA GLOBAL DO EQUIPAMENTO .....	25
2.3	ANÁLISE ENVOLTÓRIA DE DADOS .....	27
<b>2.3.1</b>	<b>Os modelos clássicos DEA - CCR.....</b>	<b>28</b>
2.4	ANÁLISE ENVOLTÓRIA DE DADOS MULTIOBJETIVO.....	30
<b>2.4.1</b>	<b>Modelo ponderado bi-objetivo (BiO-MCDEA).....</b>	<b>31</b>
<b>2.4.2</b>	<b>Modelo ponderado bi-objetivo estendido .....</b>	<b>31</b>
<b>2.4.3</b>	<b>Modelo de programação por metas combinado com MCDEA.....</b>	<b>32</b>
<b>3</b>	<b>DESCRIÇÃO DO PROBLEMA E MODELAGEM .....</b>	<b>34</b>
3.1	SELEÇÃO DAS DMUS.....	34
3.2	DEFINIÇÃO DAS ENTRADAS E SAÍDAS DA MATRIZ .....	34
3.3	OBTENÇÃO DAS ENTRADAS E SAÍDAS .....	36
3.4	MODELAGEM E SOLUÇÃO DOS MODELOS.....	37
<b>4</b>	<b>DISCUSSÃO DOS RESULTADOS .....</b>	<b>39</b>
4.1	RESULTADOS DAS MODELAGENS.....	39
4.2	RESULTADOS DOS TESTES DE LEVENE E DE CORRELAÇÃO DE SPEARMAN 42	
4.3	DEFINIÇÃO DO CENÁRIO MAIS ADERENTE À REALIDADE DA EMPRESA	47
4.4	IDENTIFICAÇÃO DO MODELO MAIS ADERENTE AO PROBLEMA ESTUDADO 48	
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS .....</b>	<b>49</b>
5.1	RESPOSTAS ÀS QUESTÕES DE PESQUISA E AOS OBJETIVOS .....	49
5.2	RECOMENDAÇÕES PARA FUTURAS PESQUISAS.....	50
	<b>REFERÊNCIAS.....</b>	<b>51</b>

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO DA PESQUISA

A redução dos tempos de produção combinada com a melhoria contínua da qualidade aliada à flexibilização dos processos são quesitos os quais devem estar em constante desenvolvimento em organizações de todos os ramos que buscam se manter competitivas (KHANCHANAPONG et al., 2014).

Esse constante desenvolvimento pressiona as empresas a entenderem melhor as necessidades da demanda do mercado, o qual está em constante mudança, e, também, a medirem de forma mais detalhada seu desempenho produtivo. Para isso, são utilizadas diversas ferramentas da Manufatura Enxuta ou, em inglês, *Lean Manufacturing* (LM) (ESWARAMURTHI; MOHANRAM, 2013).

Dentre as Ferramentas de LM, destaca-se a Eficácia Global do Equipamento ou *Overall Equipment Effectiveness* (OEE), que é um dos métodos da Manutenção Produtiva Total ou *Total Productive Maintenance* (TPM).

O OEE se trata de um amplo conjunto de métricas de desempenho, que tem como objetivo analisar a eficiência dos equipamentos (podendo ser uma única máquina de fabricação ou um sistema integrado). Deste modo, permite aos gerentes entenderem relações de causa e efeito durante os processos de fabricação, porém, trata-se de uma métrica muito simples (FERKO, ZNIDARSIC, 2007).

A fim de tornar as medições de desempenho mais precisas, a partir da década de 2000, há elevados investimentos em sistemas de produção, com o intuito de desenvolver modelos matemáticos que sejam capazes de realizar tais melhorias (LIU, 2008; FERKO, ZNIDARSIC, 2007).

Conforme apontado por Chen e Jia (2017) e Haghghi et al. (2016), existem dois métodos principais de avaliação de desempenho: o primeiro é o método de análise de fronteira estocástica, que é um método de abordagem paramétrico, e outro, que é um método não paramétrico, conhecido como Análise Envoltória de Dados ou *Data Envelopment Analysis* (DEA) (CHARNES et al., 1978).

Na prática, a DEA tem sido considerada como uma ferramenta alternativa para tratar de múltiplos critérios para a avaliação de sistemas produtivos. E, também, é usada para avaliar o desempenho e processos de tomada de decisão (DOTOLI et al., 2015).

Há dois modelos tradicionais de DEA, o modelo DEA - CCR (Charnes et al., 1978), com retorno constante de escala ou (*Constant Return to Scale* - CRS), e o modelo DEA - BCC (Banker et al., 1984), com variáveis retornos de escala ou (*Variable Return To Scale* - VRS).

Ambos podem ser usados para avaliar a eficiência relativa de um conjunto de Unidades de Tomada de Decisão homogêneas ou (*Decision Making Units* - DMUs). Além disso, os modelos DEA não exigem uma forma específica da função de produção e são especialmente adequados para cenários de múltiplas entradas e múltiplas saídas (COOK et al., 2014; OHSATO e TAKAHASHI, 2015).

Deve-se observar que, segundo Banker et al. (1989), os modelos DEA (CCR e BCC) podem apresentar problemas para discriminar as DMUs eficientes e apresentar dispersão de pesos tendenciosas para as variáveis se uma condição específica não for atendida. Essa condição é conhecida como a “Regra de Ouro”, que define a quantidade mínima de DMUs para utilizar esses modelos clássicos. Essa regra determina que o número de DMUs deve ser o maior dentre duas situações: a multiplicação da quantidade de variáveis de entrada pela quantidade de variáveis de saída ou três vezes a quantidade total de variáveis do problema.

Para contornar o problema da baixa discriminação dos modelos DEA (CCR e BCC) que não atendam à regra de ouro, Li e Reeves (1999) propuseram o modelo *Multiple Criteria Data Envelopment Analysis* (MCDEA), o qual considera três funções objetivo a serem minimizadas.

## 1.2 RELEVÂNCIA DA PESQUISA E JUSTIFICATIVA

Ainda como forma de aumentar o poder de discriminação e melhorar a dispersão de pesos na DEA, Bal et al. (2010) desenvolveram modelos de Programação por Metas combinados com a Análise de Envoltória de Dados (*Goal Programming Data Envelopment Analysis* GPDEA). Seus modelos GPDEA (CCR e BCC) foram desenvolvidos como forma de melhorar, também, a dispersão de pesos e poder discriminatório em uma estrutura MCDEA. No entanto, o Modelo Ponderado Bi-Objetivo (BiO-MCDEA), proposto por Ghasemi et al. (2014), destaca que essas alegações eram infundadas e mostra uma alternativa que poderia resolver esses inconvenientes.

Hatami-Marbini e Toloo (2017) desenvolveram um modelo MCDEA ampliado, embasado no modelo de Ghasemi et al. (2014), cujo foco era determinar um limite inferior ideal para pesos de entrada e saída. No entanto, a melhoria do poder de discriminação e a obtenção de uma dispersão mais razoável dos pesos de entrada e saída simultaneamente permanecem um desafio para os modelos DEA e MCDEA (HATAMI-MARBINI e TOLOO, 2017).

Finalmente, Rubem et al. (2017) usaram uma abordagem de Programação de Metas para resolver o modelo WGP-MCDEA (*Weighted Goal Programming MCDEA*). Esses autores comentaram que, em futuras pesquisas, sua intenção é testar numericamente o modelo e usá-lo para alguma aplicação no mundo real.

Como forma de abordar tais lacunas da literatura acerca do tema MCDEA, este trabalho busca testar, com valores reais, os modelos propostos por esses autores e verificar qual desses modelos se mostra mais aderente à realidade da empresa estudada.

Também foi feito um levantamento sobre os principais assuntos abordados por este trabalho nas plataformas *Web of Science* e *Scopus*, pesquisando por títulos e palavras-chave em periódicos, conforme mostra a Tabela 1.

Tabela 1- Relatório de Citações de Pesquisa na Web of Science e Scopus de 1994 a 2018

Item	Palavras-Chave pesquisadas	Publicações	Citações
1	"Data Envelopment Analysis"	11.796	>50.000
2	"Total Productive Maintenance"	299	3.949
3	"Overall Equipment Effectiveness"	267	1.355
4	#2 e #3	71	560
5	"Multiple Criteria Data Envelopment Analysis"	19	419
6	#1 e #2	3	36
7	#1 e #3	2	11
8	#3 e #5	1	2

Fonte: *Web of Science* (2018) e *Scopus* (2018).

A Figura 1 mostra que ao combinar as palavras-chaves: "*Multiple Criteria Data Envelopment Analysis*" ou "*Multi-Criteria Data Envelopment Analysis*" ou "*Multiple Criteria DEA*" foram encontrados apenas 19 trabalhos na base *Web of Science*, e a Figura 2 mostra que vêm crescendo as citações sobre o tema ao longo dos anos.

Figura 1 - Publicações sobre MCDEA

Total de publicações

19 Analisar

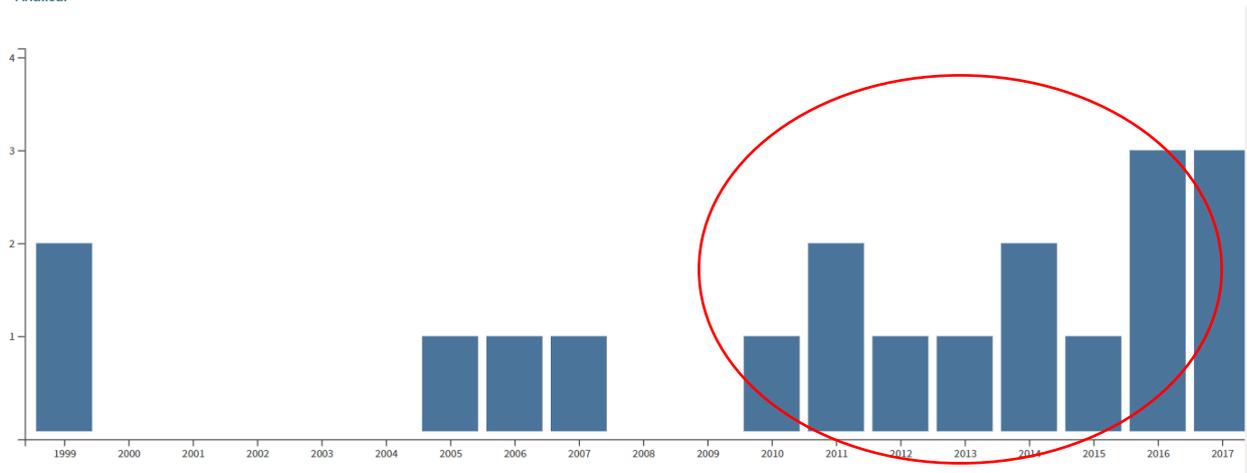
Fonte: Adaptado de *Web of Science* (2018).

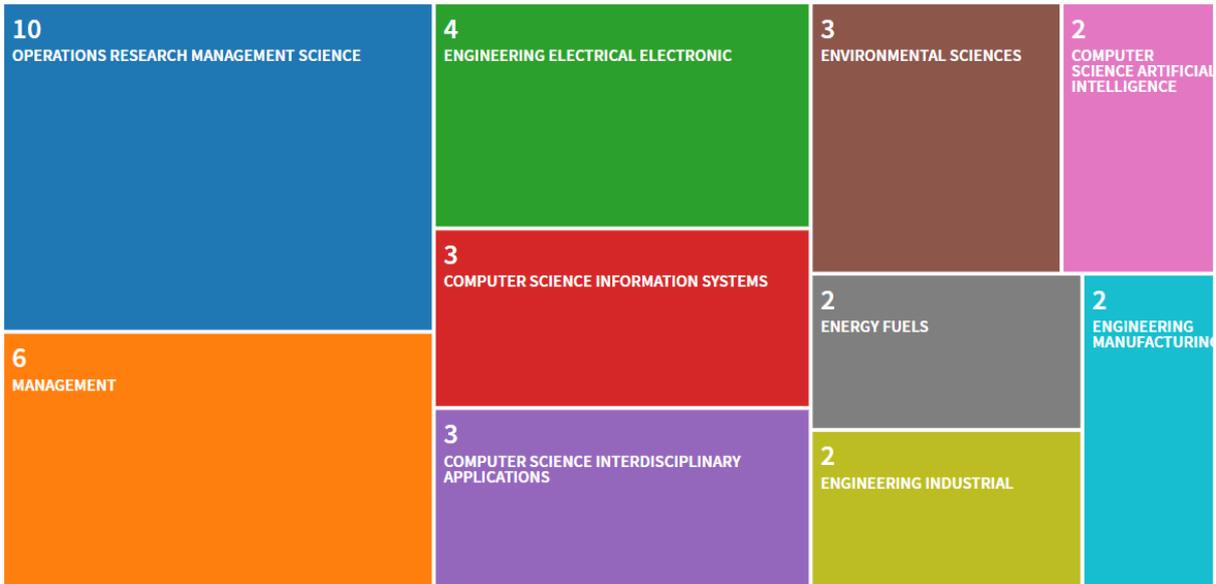
Figura 2 - Citações sobre MCDEA

Número de citações por ano

Fonte: *Web of Science* (2018).

A Figura 3 apresenta as áreas de conhecimento pesquisadas utilizando modelos “*Multiple Criteria Data Envelopment Analysis*” (MCDEA). Áreas como Pesquisa Operacional, Gestão e Engenharia de Manufatura são contempladas por este trabalho.

Figura 3 - Áreas de Conhecimento Contempladas pela MCDEA

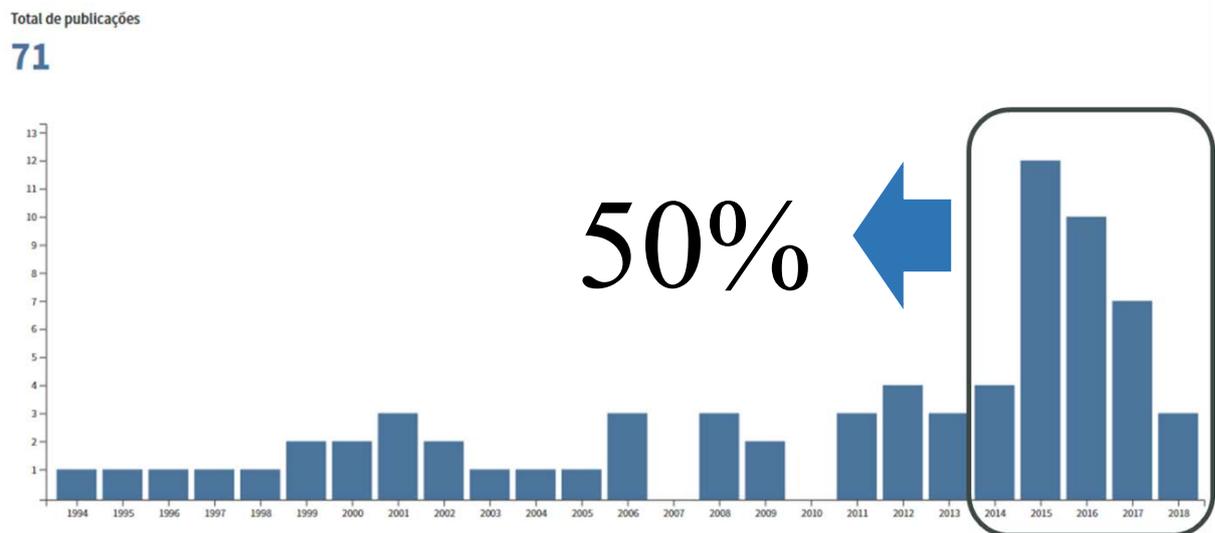


Fonte: *Web of Science* (2018).

Ao se analisarem os resultados de pesquisa relacionados ao OEE da Tabela 1, nota-se que, apesar de não se tratar de um assunto novo na literatura, há muitos estudos envolvendo esse indicador de desempenho a partir da década de 1990.

A Figura 4 mostra que, na plataforma *Web of Science*, quando se combinam as palavras-chave “*Total Productive Maintenance*” e “*Overall Equipment Effectiveness*”, 50% dos trabalhos foram publicados nos últimos 5 anos.

Figura 4 - Publicações "Total Productive Maintenance" e "Overall Equipment Effectiveness"



Fonte: Adaptado de *Web of Science* (2018).

A partir da análise da Figura 4, observa-se que o OEE ainda é um assunto que está em alta na literatura internacional. Isso pode ser explicado com base em Sonmez et al. (2017), que dizem ser necessários outros métodos para complementar o OEE devido às incertezas provenientes de perdas não declaradas.

Em função do contexto apresentado, este trabalho visa contemplar algumas oportunidades referentes à pesquisa sobre MCDEA, a qual apresenta boa tendência de novos estudos, como forma de complementar o OEE, assunto que também está em alta na literatura internacional.

### 1.3 QUESTÕES DE PESQUISA, OBJETIVOS E DELIMITAÇÃO DA PESQUISA

Como indicado pela Tabela 1, a MCDEA combinada com o OEE é um assunto que apresenta poucos estudos registrados na literatura. Dessa forma, com o intuito de contribuir com a literatura existente, este trabalho visa à modelagem, em dois cenários, de diferentes modelos MCDEA que complementem as informações fornecidas pelo OEE. Será analisada a exequibilidade do modelo mais aderente atuar como um novo indicador de desempenho.

Com base no que foi comentado na seção 1.2, o trabalho busca responder às seguintes questões de pesquisa:

- É possível complementar as informações fornecidas pelo OEE com o auxílio de um modelo MCDEA?
- Qual modelo MCDEA proporcionará a melhor análise de eficiência em comparação ao OEE?
- Há vantagens em utilizar essa nova sistemática para medir a eficiência de máquinas industriais em comparação ao método tradicional de cálculo do OEE?

Buscando subsídios para responder às questões de pesquisa enunciadas, este trabalho teve como objetivo geral aplicar modelos Multiobjetivo de Análise Envoltória de Dados para medir a eficiência de linhas de montagem.

Os objetivos específicos foram:

- Modelar e otimizar estes modelos Multiobjetivo em programação VBA (Excel 2013<sup>®</sup>) empregando o algoritmo Simplex.
- Comparar os resultados de eficiência obtidos pelos modelos DEA Multiobjetivo com o método tradicional de cálculo do OEE.

Neste trabalho, serão aplicados modelos Multiobjetivo lineares de DEA em uma empresa do ramo de autopeças, e os resultados dessa aplicação não serão generalizados para outras empresas de outros segmentos.

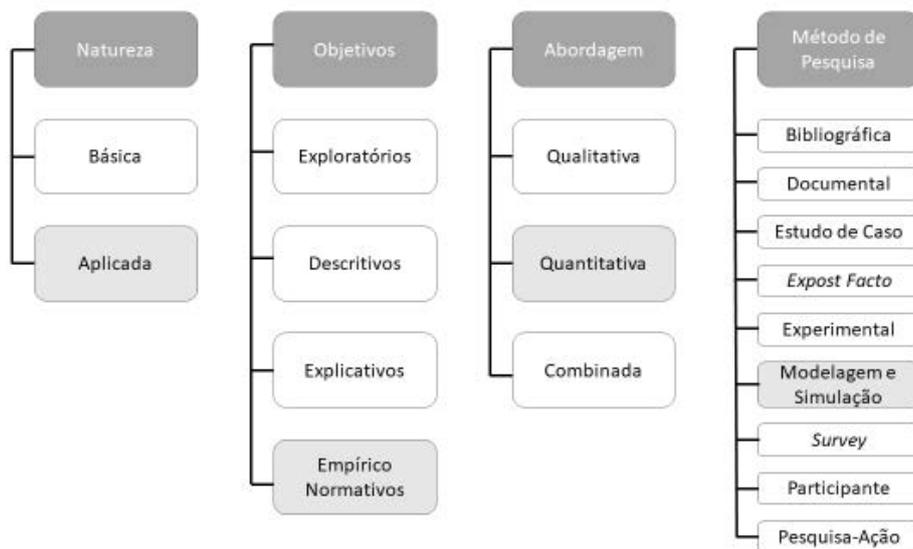
#### 1.4 MATERIAIS E MÉTODOS

Com o estudo bem delimitado e com os objetivos traçados, definiu-se qual seria o procedimento metodológico mais adequado, e quais seriam os materiais necessários para atingi-los.

Com relação aos procedimentos metodológicos, como resumido pela Figura 5, este trabalho pode ser classificado como uma pesquisa aplicada, com objetivos empíricos normativos, uma vez que o modelo desenvolvido favorece a compreensão da realidade por meio dos resultados gerados pela otimização de um modelo.

A abordagem empregada foi a quantitativa, e o método de pesquisa utilizado foi a modelagem e simulação (BERTRAND e FRANSOO, 2002; MIGUEL et al., 2010; BRYMAN e BELL, 2007).

Figura 5 – Classificação do Trabalho



Fonte: adaptado de Bertrand e Fransoo (2002), Miguel et al. (2010) e Bryman e Bell (2007).

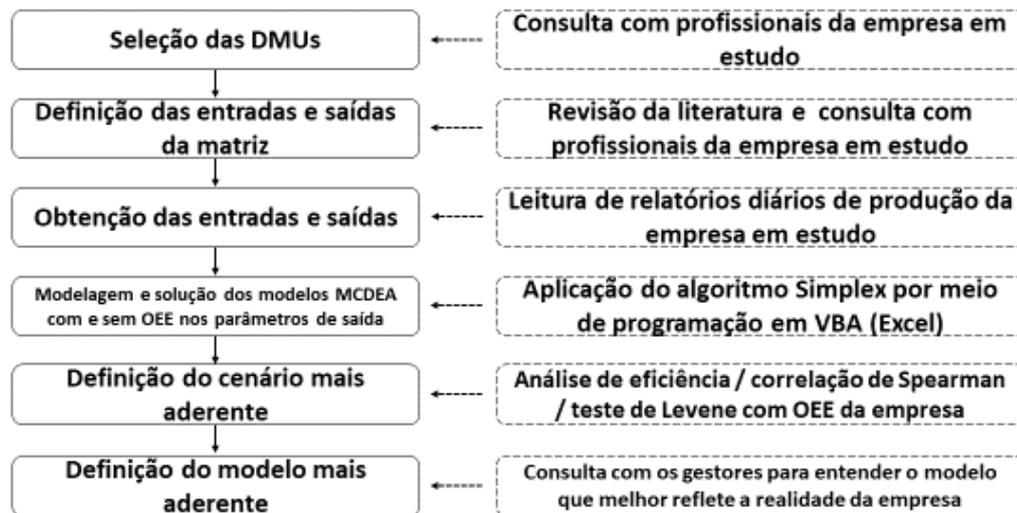
Com relação aos materiais utilizados na pesquisa, a coleta de dados na empresa se deu por meio do preenchimento diário de formulários de produção e de perdas da linha de montagem,

além da consulta do *software* ERP utilizado pela empresa. Para solução do problema, utilizaram-se modelos de Análise Envoltória de Dados Multiobjetivo e programação VBA Excel 2013<sup>®</sup> empregando o algoritmo Simplex (HILLIER e LIEBERMAN, 2010).

Para verificação da aderência das eficiências obtidas pelo modelo com o OEE utilizado pela empresa, aplicou-se o teste de correlação não paramétrico de Spearman (SPEARMAN, 1904) e do teste de Levene (NORDSTOKKE e ZUMBO, 2010), com o auxílio do *software* Minitab17<sup>®</sup>. Para os métodos quantitativos, foi utilizada uma máquina com processador Intel Core i7<sup>®</sup>, com *clock* de 1,9 GHZ e capacidade de 8 GB de memória RAM.

A Figura 6 resume os estágios da sistemática de pesquisa empregada por este trabalho.

Figura 6 – Etapas da Sistemática Proposta



Fonte: Próprio autor (2018).

Passa-se a descrever as etapas do trabalho que constam da Figura 6:

- **Seleção das DMUs:** a partir da consulta com gestores dos setores de planejamento e de montagem da empresa em estudo, a abordagem inicial foi selecionar quais seriam as DMUs mais relevantes a serem estudadas pelo trabalho. Por fim, com o apoio dos gestores, optou-se por analisar apenas uma das linhas de produção, sendo que as diferentes DMUs foram estabelecidas variando-se o turno e a semana de cada uma, ou seja, cada DMU deve ser lida como DMU (Linha, Turno, Semana).

- **Definição das entradas e saídas da matriz:** com as DMUs selecionadas, passou-se para a etapa de definição dos parâmetros de entrada (*input*) e dos parâmetros de saída (*output*), de

forma a contemplar informações que os gestores julgam interessantes do ponto de vista gerencial.

- **Obtenção das entradas e saídas:** essa etapa se deu por meio do preenchimento diário, por parte do funcionário responsável em cada turno, do relatório de produção e de perdas relacionadas à linha de montagem. Além disso, informações como “demanda estimada” e “produção excedente” foram obtidas por meio do *software* ERP da empresa em estudo.

- **Modelagem e Solução dos modelos MCDEA com e sem OEE:** os dados foram organizados em forma de matriz, sendo que os valores registrados nelas são a média de cada variável na semana em questão. Em seguida, realizou-se a modelagem e posterior solução dos modelos em VBA (Excel 2013<sup>®</sup>) em dois cenários: o primeiro contemplando o OEE dos modelos e o segundo retirando o OEE dos parâmetros de saída, com o objetivo de entender qual dos dois cenários reflete melhor a realidade da empresa em estudo.

- **Definição do cenário mais aderente:** nessa etapa, foram aplicados dois testes não paramétricos: o teste de Levene – com o objetivo de averiguar a homogeneidade das variâncias (homocedasticidade) das eficiências dos modelos - e o teste de correlação de Spearman – com o objetivo de entender a correlação entre os resultados dos modelos e do OEE da empresa em ambas as matrizes de resultados de eficiência (com e sem OEE). Além disso, levou-se em conta quais seriam os modelos mais discriminatórios dentro de cada matriz, ou seja, quais modelos apresentaram menor quantidade de DMUs eficientes. Com esses três parâmetros, junto aos gestores da empresa, definiu-se qual o cenário mais aderente (com ou sem o OEE).

- **Definição do modelo mais aderente:** uma vez que o cenário mais aderente foi determinado, com o auxílio dos gestores, foi possível entender qual dos modelos, do cenário mais aderente, reflete melhor a realidade da empresa em estudo.

## 1.5 ESTRUTURA DO TRABALHO

Para facilitar o entendimento, este trabalho foi estruturado de forma a fornecer o embasamento teórico necessário ao leitor para, posteriormente, apresentar a descrição do problema, os resultados e as conclusões. Mais especificamente, a estrutura do trabalho contempla, além deste capítulo, os seguintes Capítulos:

- Capítulo 2 - Fundamentação Teórica – definições acerca da Produção Enxuta (*Lean Manufacturing*), da Eficácia Global do Equipamento (*Overall Equipment Effectiveness* - OEE), da Análise Envoltória de Dados (*Data Envelopment Analysis* - DEA) e dos Modelos de Análise Envoltória de Dados Multiobjetivo (*Multiple Criteria Data Envelopment Analysis* - MCDEA);

- Capítulo 3 - Descrição do problema e modelagem - apresentação do contexto da empresa, do formato dos dados utilizados e das modelagens propostas;
  - Capítulo 4 - Discussão dos Resultados – apresentação dos resultados obtidos e discussão dos mesmos;
  - Capítulo 5 - Conclusão e recomendações para futuras pesquisas.
- Finalmente, apresenta-se a bibliografia consultada para a elaboração deste texto.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 PRODUÇÃO ENXUTA

O *Lean Manufacturing* é uma estratégia gerencial para identificar e eliminar desperdícios a custos reduzidos e avançar em direção à produtividade e excelência (WOMACK et al., 2007). As ferramentas e técnicas *Lean* têm sua origem na Gestão da Qualidade Total ou *Total Quality Management* (TQM). A partir da participação ativa dos funcionários, o *Lean* busca gerar maior satisfação do cliente por meio da melhoria contínua (SPAGNOL et al., 2013).

Ao contrário do que se imagina, as aplicações das teorias *Lean* se estendem para além das áreas fabris. São observadas, por exemplo, aplicações em desenvolvimento de novos produtos (CIARAPICA et al., 2016), em bancos (BORTOLOTTI et al., 2016), em educação (JOHNES et al., 2017) e em saúde, no quesito gestão de hospitais (TEICHGRÄBER, 2012). Essas novas aplicações em diferentes ramos de negócios – públicos ou privados – têm gerado novas denominações para o *Lean*, como *Lean Health Care* e *Lean Office*.

Independentemente da área de aplicação, um ponto crítico relacionado ao pensamento *Lean* é a geração de valor, o qual, por diversas ocasiões, é enxergado pelo cliente somente como redução de custos (HINES et al., 2004). No entanto, o verdadeiro foco deste tipo de abordagem é a eliminação de atividades que não agregam valor ao produto ou serviço e que devem, portanto, ser eliminadas do processo (UGARTE et al., 2016).

Em termos de aplicação, para que o *Lean* seja implementado, são necessárias duas etapas: primeiro, é necessário que se reduza o tempo de espera por meio de um sistema flexível de trabalho, com o auxílio de ferramentas como 5S. Depois, é necessário melhorar e padronizar os processos internos, utilizando ferramentas como SMED (redução do tempo de trocas e *setups*), Jidoka e TPM (KUMAR; KUMAR, 2014).

Os cinco princípios os quais constituem a essência dinâmica do *Lean* estão esquematizados na Figura 7 (TOUSSAINT; BERRY, 2013).

Figura 7 - Princípios do Lean



Fonte: Adaptado de Spagnol et al. (2013).

Utilizam-se diversas ferramentas com o intuito de colocar tais princípios em prática (SPAGNOL et al., 2013). A eliminação de desperdícios e a melhoria contínua são atividades desempenhadas pelas ferramentas *Lean* as quais orientam organizações. (MOURTZIS et al., 2016). Mapeamento de Cadeia de Valores (*Value Stream Mapping* - VSM), 5S, e Eficácia Global do Equipamento (*Overall Equipment Effectiveness* - OEE) são as mais conhecidas (SPAGNOL et al., 2013).

O 5S tem sua origem no Japão e é composto pelas palavras Seiri (Senso de Utilização), Seiton (Senso de Organização), Seisou (Senso de Limpeza), Seiketsu (Senso de Saúde) e Shitsuke (Senso de Autodisciplina). Essa ferramenta pode ser implementada pela organização inteira, pois se trata de uma das mais utilizadas para melhoria de processo e organização (ARUNAGIRI e GNANAVELBABU, 2014).

O VSM, por definição, é o processo de mapeamento de fluxo de informação e material. Tal fluxo deve coordenar desde atividades produtivas até distribuidores e fornecedores, ou seja, toda a cadeia envolvida na entrega de produtos aos clientes (SUNDAR et al., 2014). Durante o mapeamento, são identificadas atividades que não agregam valor ao processo e as mesmas devem ser eliminadas (SPAGNOL et al., 2013).

## 2.2 EFICÁCIA GLOBAL DO EQUIPAMENTO

Ainda dentro do conceito de produção enxuta, a Eficácia Global do Equipamento ou OEE é uma de suas ferramentas que possibilita o melhor cálculo relativo da produção real dentro do tempo previsto, servindo de base para se comparar desempenhos como, por exemplo, resultados de turnos distintos de trabalho. Pode servir, também, para acompanhar a progressão na produção de um determinado produto ao longo do tempo (ARUNAGIRI e GNANAVELBABU, 2014).

Pela definição de Nakajima (1989), há seis grandes perdas que compõe o OEE (Quadro 1). Tais perdas consideram as taxas de disponibilidade, desempenho e qualidade do equipamento, independentemente do foco da aplicação do OEE (AHIRE e RELKAR, 2012).

Quadro 1 - Classificação das Seis Grandes Perdas

<b>Perdas</b>	<b>Definição</b>
Falha equipamento	Perdas em função de falhas. As falhas podem ser esporádicas, com parada de função ou redução de função. Nesses casos, a função do equipamento cai abaixo do nível normal.
Configuração e ajuste	Perdas por parada que acompanham trocas de configuração incluindo ajustes para posicionamento correto.
Paralisação menor e marcha lenta	Perdas que ocorrem quando o equipamento para temporariamente ou trabalha em marcha lenta pela atuação de sensores ou em função de interferência do trabalho.
Redução da velocidade	Perdas vinculadas a velocidade real de operação cair abaixo da velocidade projetada para o equipamento
Defeito/Retrabalho no processo	Perdas em virtude de defeitos e retrabalhos no produto
Redução da produção	Perdas de materiais em virtude das diferenças nos pesos de entrada e saída

Fonte: Eswaramurthi e Mohanram (2013).

O OEE não é capaz de identificar razões específicas pelas quais o equipamento não está operando tão eficientemente quanto era esperado, porém é capaz de identificar as principais perdas que estão afetando o desempenho do equipamento, possibilitando melhorias (ESWARAMURTHI e MOHANRAM, 2013).

No Quadro 1, as primeiras duas perdas se relacionam à disponibilidade do equipamento, as duas do meio se relacionam ao desempenho do equipamento e as duas últimas, à taxa de qualidade do equipamento. O OEE pode ser dividido em três indicadores, disponibilidade, desempenho e qualidade (NAKAJIMA, 1989; WUDHIKARN, 2012), descritos na sequência:

**- Disponibilidade:** trata-se do tempo em que o sistema de produção está disponível para realizar trabalho, sendo que o tempo de sua inatividade pode englobar, por exemplo, falhas no equipamento, requisitos de ajuste (*setup*) ou outros tipos de paradas específicas do sistema de produção em questão. O cálculo de disponibilidade se dá pela equação (1):

$$Disponibilidade = \frac{(Tempo\ disponível - Tempo\ de\ Paradas)}{Tempo\ Disponível} \quad (1)$$

**- Desempenho:** para o bom funcionamento do OEE, é necessário que toda peça a ser produzida pelo sistema de produção possua um tempo padrão. Com esse tempo padrão, é possível prever qual deve ser a produção do sistema em um determinado período de tempo. O índice de desempenho compara justamente a quantidade que deveria ser produzida segundo o tempo padrão com a quantidade realmente produzida pelo sistema, conforme apresentado na equação (2):

$$Desempenho = \frac{Quantidade\ Realmente\ Produzida}{Quantidade\ Segundo\ Tempo\ Padrão} \quad (2)$$

**- Qualidade:** o índice de qualidade compara a quantidade de produtos bons produzidos pelo sistema de produção com a quantidade total produzida pelo mesmo, como apresentado pela equação (3):

$$Qualidade = \frac{(Quantidade\ Produzida - Quantidade\ defeituosa)}{Quantidade\ Produzida} \quad (3)$$

Por fim, o resultado do OEE propriamente dito se dá pela multiplicação desses três indicadores.

Devido à forma como é definido, é comum que haja incertezas relacionadas ao cálculo do OEE, uma vez que o mesmo necessita de grande precisão nas medições de produção e paradas e, geralmente, tais medições são feitas manualmente. Tais incertezas são provenientes de perdas não declaradas, como: pequenas paradas ou paradas de menor velocidade, erros humanos, limitações de medições de instrumentos ou falhas na coleta de dados. Por conta disso, são necessários outros métodos para complementar o OEE (SONMEZ et al., 2017).

### 2.3 ANÁLISE ENVOLTÓRIA DE DADOS

Charnes et al. (1978) propuseram um modelo que ficou conhecido como Análise Envoltória de Dados, ou *Data Envelopment Analysis* (DEA). Tal modelo é utilizado para medir eficiência, a qual é obtida relacionando-se a máxima proporção das saídas com as entradas ponderadas, sujeita à condição de que tal relação seja menor ou igual a uma unidade, conforme equações de (4) a (7), pelo modelo não linear de Programação Fracionária:

$$\max h_0 = \frac{\sum_{r=1}^s u_r y_{r0}}{\sum_{i=1}^m v_i x_{i0}} \quad (4)$$

s.a.:

$$\frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1, j = 1, 2, \dots, n \quad (5)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (6)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (7)$$

Sendo:

$x_{ij}$  a  $i$ -ésima das  $m$  entradas da  $j$ -ésima DMU;

$y_{rj}$  a  $r$ -ésima das  $s$  saídas da  $j$ -ésima DMU;

$u_r \geq 0$  e  $v_i \geq 0$  as variáveis peso das saídas e das entradas, respectivamente, a serem definidas pela otimização do problema.

As entradas  $x_{i0}$  e as saídas  $y_{r0}$  representam os parâmetros da DMU que está sob análise.

A avaliação da eficiência  $h_0$  da DMU sob análise se dá em relação aos dados das demais  $j \in (1, \dots, n)$ . Posterior a isso, a função maximização concede à DMU em análise os pesos  $u_r$ ,  $r \in (1, \dots, s)$  e  $v_i$ ,  $i \in (1, \dots, m)$  mais favoráveis - desde que sejam valores permitidos pelas restrições (CHARNES et al., 1978).

Sueyoshi et al. (2012) comentam que, tanto no âmbito público como no privado, a avaliação de eficiência se dá, de forma geral, pela utilização da DEA. Friesner et al. (2013) comentam em seu trabalho que a DEA é uma ferramenta popular quando se trata de medir eficiência em indústrias. Algumas vantagens em se utilizar a DEA para avaliação de eficiência foram pontuadas pelos mesmos autores:

- Não são necessárias regras rígidas para seleção de dados de entrada e saída para que um modelo DEA funcione adequadamente.
- A DEA se trata de um método não paramétrico, ou seja, é possível relacionar entradas e saídas com diferentes unidades de medidas e/ou escalas;

- A modelagem DEA - quando utilizada com o intuito de estimar a eficiência de DMUs que produzem múltiplas saídas a partir de múltiplas entradas - pode ser considerada simples, se comparada com outros modelos de avaliação de eficiência.

Outras características importantes da modelagem DEA foram pontuadas por Azadeh et al. (2013):

- O método define os melhores parâmetros para as unidades, de modo que nenhuma outra combinação linear dos mesmos será maior que todas as saídas ou menor que todas as entradas;
- Todos os dados são representados em forma de valores;
- DMUs ineficientes adquirem valor menor do que 1, enquanto DMUs eficientes, adquirem valor igual a 1;
- As DMUs ineficientes podem ser facilmente ranqueadas, mas as DMUs eficientes, não.

### 2.3.1 Os modelos clássicos DEA - CCR

Segundo Ferreira e Gomes (2009), os modelos DEA podem ser orientados aos insumos - com o objetivo de reduzir a quantidade de recursos utilizados e manter os resultados obtidos constantes, ou orientados aos produtos - buscando aumentar os valores dos resultados obtidos e mantendo constante a quantidade de recursos utilizados.

Pelas equações de (8) a (12) é formulado um modelo primal orientado ao insumo, também conhecido como modelo multiplicador ou modelo DEA-CCR, com retorno constante de escala e, pelas equações de (13) a (16) é formulado um modelo dual (também conhecido como Modelo do Envelope) orientado à entrada (*input*) (FERREIRA e GOMES, 2009):

Modelo Primal:

$$\max h_0 = \sum_{r=1}^s u_r y_{r0} \quad (8)$$

s.a.:

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (9)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, \quad j = 1, 2, \dots, n \quad (10)$$

$$u_r \geq 0, \quad r = 1, 2, \dots, s \quad (11)$$

$$v_i \geq 0, \quad i = 1, 2, \dots, m \quad (12)$$

Modelo Dual com orientação ao *input*:

$$\min h \quad (13)$$

s.a.:

$$hx_{i0} - \sum_{r=1}^s x_{ij}\lambda_j \geq 0, i = 1, 2, \dots, m \quad (14)$$

$$-y_{r0} + \sum_{r=1}^s y_{rj}\lambda_j \geq 0, j = 1, 2, \dots, n \quad (15)$$

$$\lambda_j \geq 0, r = 1, 2, \dots, s \quad (16)$$

Os  $\lambda_j$ 's representam os alvos e  $x_{ij}$  e  $y_{rj}$ , que devem ser positivos, são as entradas  $i$  e saídas  $r$  da DMU  $j$ , enquanto  $s$  se trata do total de DMUs na amostra.

A identificação de *benchmarkings* de cada DMU é função dos  $\lambda_j$ 's. Um  $\lambda$  igual a zero implica na DMU correspondente não ser *benchmarking* para a DMU em análise (MELLO et al., 2005). As DMUs ineficientes devem tomar como base as DMUs correspondentes como referência e a importância de cada DMU correspondente é diretamente proporcional ao seu  $\lambda$ , ou seja, quanto maior o  $\lambda$ , mais importante a DMU correspondente para a DMU ineficiente. A função *objetivo* ( $h$ ) deve ser minimizada na orientação às entradas, pois se trata da eficiência, e é o valor que deve ser multiplicado pelas entradas de maneira à DMU em análise ficar na fronteira de eficiência.

Uma observação importante acerca dos modelos DEA se trata da condição: para que o modelo DEA seja capaz de discriminar DMUs eficientes adequadamente, é necessário que a regra de ouro de Banker et al. (1989) seja atendida. Essa regra determina que o número de DMUs deve ser maior ou igual a três vezes a soma da quantidade de variáveis ou produto das mesmas. O critério adotado deve ser o que estabelece a maior quantidade de DMUs (vide equação (17)):

$$j \geq 3 * (m + s) \text{ ou } j \geq m * s \quad (17)$$

Sendo:

$j$  a quantidade de DMUs;

$m$  a quantidade de variáveis de entrada; e

$s$  a quantidade de variáveis de saída.

Tal condição muitas vezes pode ser difícil de satisfazer no mundo real. Além disso, existem dois problemas que podem surgir do uso da DEA, de acordo com Li e Reeves (1999):

1) Poder discriminatório fraco, que ocorre quando muitas DMUs são identificadas eficientes

2) Distribuição de peso e irreal, que se refere a uma situação na qual as DMUs podem ser eficientes, mas apresentam altos valores de pesos para uma única saída, ou valores baixos de pesos para uma única entrada.

Em função desses fatores, Li e Reeves (1999) propuseram o primeiro modelo DEA multiobjetivo ou *Multiple Criteria Data Envelopment Analysis* (MCDEA) e, posteriormente, alguns autores propuseram modelos alternativos. Esses trabalhos serão comentados na seção seguinte e, de alguns deles – que foram utilizados na seção 3.5 para modelagem do problema –, também serão apresentadas as equações dos modelos.

## 2.4 ANÁLISE ENVOLTÓRIA DE DADOS MULTIOBJETIVO

O modelo de Li e Reeves (1999) considera três funções *objetivo* a serem minimizadas. Nesse modelo, não é encontrada uma solução ótima, mas é possível gerar soluções não dominadas, deixando à escolha do gestor qual solução se adequa mais a sua realidade. O modelo em questão pode ser descrito por meio das equações de (18) a (26):

$$\min d_0 \text{ ou } \max \sum_{r=1}^s u_r y_{r0} \quad (18)$$

$$\min M \quad (19)$$

$$\min \sum_{j=1}^n d_j \quad (20)$$

s. a.:

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (21)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j \leq 0, j = 1, 2, \dots, n \quad (22)$$

$$M - d_j \geq 0, j = 1, 2, \dots, n \quad (23)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (24)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (25)$$

$$d_j \geq 0, j = 1, 2, \dots, n \quad (26)$$

Sendo:

$d_j$  a ineficiência para  $j$ -ésima DMU;

$M = \text{Max} \{d_j\}$ , ou seja, a variável  $M$  representa o máximo valor de ineficiência; e

$d_0$  a ineficiência para a DMU que está sob análise.

Os outros parâmetros e variáveis são análogos ao modelo apresentado pelas equações de (4) a (7).

Outros modelos, derivados do modelo MCDEA de Li e Reeves (1999), buscam sanar dificuldades encontradas neste. Por exemplo:

- O modelo *Minsum*-CCR tem a característica de considerar apenas uma função *objetivo* ( $\sum_{j=1}^n d_j$ ) (CHEN et al., 2009).

- O modelo *Minmax* considera apenas a variável  $M$  na função *objetivo* (CHEN et al., 2009).

- Bal et al. (2010) propuseram o modelo Programação por Metas e Análise Envoltória de Dados (GPDEA), cujo objetivo era aumentar a discriminação entre as DMUs, e, também, reduzir a dispersão dos pesos.

#### 2.4.1 Modelo ponderado bi-objetivo (BiO-MCDEA)

O modelo BiO-MCDEA, proposto por Ghasemi et al. (2014) e que está equacionado de (27) a (33), tem como principal característica a inclusão de um novo termo na função objetivo do modelo *Minsum*, considerando o máximo desvio ( $M$ ), os pesos ( $w_2$  e  $w_3$ ) na função objetivo e a parametrização ( $\varepsilon$ ) para variáveis  $u_r$  na restrição (31) e  $v_i$  na restrição (32), que permitem, em alguns casos, aumentar a discriminação entre as DMUs:

$$\min h = (w_2 M + w_3 \sum_{j=1}^n d_j) \quad (27)$$

s. a.:

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (28)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j \leq 0, \quad j = 1, 2, \dots, n \quad (29)$$

$$M - d_j \geq 0, \quad j = 1, 2, \dots, n \quad (30)$$

$$u_r \geq \varepsilon, \quad r = 1, 2, \dots, s \quad (31)$$

$$v_i \geq \varepsilon, \quad i = 1, 2, \dots, m \quad (32)$$

$$d_j \geq 0, \quad j = 1, 2, \dots, n \quad (33)$$

Vale ressaltar que, no ano de 2017, Silva et al. (2017) aplicaram uma versão do modelo BiO-MCDEA combinado com o OEE em uma empresa do ramo de autopeças.

#### 2.4.2 Modelo ponderado bi-objetivo estendido

Amin e Toloo (2009) propuseram um modelo que foi denominado pelos autores por *epsilon-based weighted MCDEA*, em que a variável  $\varepsilon$  se trata de uma variável de decisão. Este modelo está apresentado pelas equações de (34) a (38):

$$\varepsilon^* = \max \varepsilon \quad (34)$$

$$\begin{aligned} \text{s.a.:} \\ \sum_{i=1}^m v_i x_{ij} \leq 1, \quad j = 1, 2, \dots, n \end{aligned} \quad (35)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, \quad j = 1, 2, \dots, n \quad (36)$$

$$\varepsilon - u_r \leq 0, \quad r = 1, 2, \dots, s \quad (37)$$

$$\varepsilon - v_i \leq 0, \quad i = 1, 2, \dots, m \quad (38)$$

O modelo equacionado de (39) a (45) foi proposto por Hatami-Marbini et al. (2017), e seu objetivo é validar o modelo proposto por Amin e Toloo (2009).

$$w(\varepsilon) = \min w_1(2d_0) + w_2M + w_3 \sum_{j=1}^n (j \neq 0) d_j \quad (39)$$

$$\begin{aligned} \text{s.a.:} \\ \sum_{i=1}^m v_i x_{i0} = 1 \end{aligned} \quad (40)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j \leq 0, \quad j = 1, 2, \dots, n \quad (41)$$

$$M - d_j \geq 0, \quad j = 1, 2, \dots, n \quad (42)$$

$$u_r \geq \varepsilon, \quad r = 1, 2, \dots, s \quad (43)$$

$$v_i \geq \varepsilon, \quad i = 1, 2, \dots, m \quad (44)$$

$$d_j \geq 0, \quad j = 1, 2, \dots, n \quad (45)$$

Sendo  $\varepsilon$  o máximo valor de *épsilon*.

### 2.4.3 Modelo de programação por metas combinado com MCDEA

Com o objetivo de resolver o MCDEA por meio de um modelo de Programação por Metas com Pesos ou *Weighted Goal Programming WGP*, proposto inicialmente por Bal et al. (2010), o qual apresentou equívocos comprovados por Ghasemi et al. (2014), Rubem et al. (2017) apresentaram um modelo WGP-MCDEA-CCR corrigindo cinco inconsistências do modelo original de Bal et al. (2010), conforme equacionado de (46) a (55):

$$\min a = \{ \lambda_1 d_1^+ + \lambda_2 d_2^+ + \lambda_3 d_3^+ \} \quad (46)$$

s.a.:

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (47)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + d_j = 0, j = 1, 2, \dots, n \quad (48)$$

$$M - d_j \geq 0, j = 1, 2, \dots, n \quad (49)$$

$$d_0 + d_1^- - d_1^+ \leq g_1 \quad (50)$$

$$M + d_2^- - d_2^+ \leq g_2 \quad (51)$$

$$\sum_{j=1}^n d_j + d_3^- - d_3^+ \leq g_3 \quad (52)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (53)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (54)$$

$$d_j, d_1^-, d_1^+, d_2^-, d_2^+, d_3^-, d_3^+ \geq 0, j = 1, 2, \dots, n \quad (55)$$

Sendo  $\lambda_1, \lambda_2$  e  $\lambda_3$  os pesos associados a cada termo da função objetivo e  $g_1, g_2$  e  $g_3$  as metas associadas a cada objetivo analisado e, por fim,  $d_1^-, d_1^+, d_2^-, d_2^+, d_3^-$  e  $d_3^+$  as variáveis auxiliares de desvio associadas a realização de cada meta. Esses autores não testaram esse modelo com valores do mundo real, deixando como sugestão para futuras pesquisas que este modelo seja aplicado em problemas reais.

### 3 DESCRIÇÃO DO PROBLEMA E MODELAGEM

#### 3.1 SELEÇÃO DAS DMUS

Obedecendo à sistemática de pesquisa resumida pela Figura 6, a seleção das DMUs foi a primeira etapa realizada. Tal etapa se deu por meio da consulta com os gestores da empresa e com a consulta à literatura e o que se decidiu foi que as DMUs seriam discriminadas conforme três critérios: linha, turno e semana. Foi considerada apenas uma linha, dois turnos de produção e 17 semanas, totalizando 34 DMUs, conforme mostrado na Tabela 2, encontrada na seção 3.3.

#### 3.2 DEFINIÇÃO DAS ENTRADAS E SAÍDAS DA MATRIZ

Dando sequência à sistemática descrita pela Figura 6, a etapa seguinte foi a definição das entradas e saídas da matriz. Decidiu-se, com base na literatura existente e na consulta com os gestores da empresa, que seria interessante adotar 10 parâmetros, sendo 7 de entrada ( $X$ ) e 3, de saída ( $Y$ ), conforme Quadro 2:

Quadro 2 - Parâmetros Seleccionados para *Input* e *Output* do Modelo

Parâmetros	Descrição do parâmetro	[Unidade]
$X_1$	Tempo disponível no turno	[horas]
$X_2$	Tempo médio produzido no turno ( <i>standard</i> )	[horas]
$X_3$	Média de paradas por troca de modelo ( <i>setup</i> )	[horas]
$X_4$	Média de outras paradas	[horas]
$X_5$	Média de mão-de-obra	[pessoas]
$X_6$	Retrabalho	[unidade]
$X_7$	Demanda estimada	[unidade]
$Y_1$	Produção excedente	[%]
$Y_2$	Volume produzido	[quantidade]
$Y_3$	OEE	[%]

Fonte: Próprio autor (2018).

Na sequência estão as descrições das variáveis de entrada e de saída dos modelos:

$X_1$ : horas disponíveis por turno no período. Parâmetro importante para a gerência à medida que pode ser aumentado ou diminuído de acordo com a necessidade de produção. Pode haver, por exemplo, diminuição da jornada de trabalho por turno e aumento de um turno, de forma que a produção se dê, praticamente, nas 24 horas do dia.

$X_2$ : horas produzidas conforme *standards* das peças. Cada produto tem um tempo padrão (*standard*), que deve ser o menor tempo possível de produção daquele produto, e o parâmetro  $X_2$  se trata de soma de todos esses tempos de produção no turno em questão.

$X_3$ : trata-se da quantidade média de horas perdidas em função de trocas de modelo. No caso da linha de montagem estudada, há grupos de produtos com o mesmo tempo padrão ( $X_2$ ). Quando um grupo de menor tempo padrão é sequenciado para produção depois de um grupo de maior tempo padrão, perde-se tempo por *setup*, pois o produto com menor tempo padrão acaba tendo seu tempo de produção aumentado, igualando-se ao tempo de produção do produto de maior tempo padrão.

$X_4$ : parâmetro relacionado a outras paradas de produção. Suas causas são variadas, podendo englobar paradas por falha de abastecimento de peças, falha de abastecimento de elementos de fixação ou quebra de máquina-ferramenta, por exemplo.

$X_5$ : parâmetro relacionado à quantidade de pessoas trabalhando na linha de produção por turno. Sua importância é grande, à medida que possibilita à gerência variar a quantidade de mão-de-obra na linha de montagem caso haja necessidade de aumentar ou diminuir a produção.

$X_6$ : parâmetro que representa as peças as quais não estão dentro dos padrões de qualidade estipulados pela empresa. Trata-se, portanto, de um *output* indesejado que foi considerado como um *input* no modelo. Isso aconteceu pois, segundo Anvari et al. (2014), assume-se que os *inputs* devam ser minimizados ou os *outputs* maximizados para medir a eficiência. Segundo Ignatius et al. (2016), em modelos CRS (ou seja, com retorno constante de escala), autores modelam *outputs* indesejados como *inputs*.

$X_7$ : trata-se de um parâmetro relacionado à quantidade esperada de produção para a semana. É uma informação relacionada ao planejamento, e seu valor pode implicar em variações em outros parâmetros (a produção esperada para a semana seguinte ser muito menor do que a da semana atual pode implicar, por exemplo, na diminuição do tempo disponível por turno ou, ainda, na diminuição de mão-de-obra por turno. Essa mão-de-obra excedente pode ser deslocada para realizar outras atividades na empresa).

$Y_1$ : este *output* deve ser gerenciado com cautela. O ideal é que este valor esteja dentro de um intervalo determinado. Valores muito baixos desse parâmetro implicam em grandes perdas por *set-up* (uma vez que o sequenciador tem que alterar a sequência de produção a todo o

momento para atender às variações na demanda), enquanto valores muito altos desse parâmetro implicam em grandes áreas de estoque de produto acabado.

$Y_2$ : variável de grande importância para a gerência. Como se trata de volume produzido, quanto maior, melhor. Possibilita uma análise rápida sobre a eficiência de produção.

$Y_3$ : o OEE possibilita, como o parâmetro  $Y_2$ , uma análise rápida sobre a eficiência da linha de montagem. A forma de cálculo desse parâmetro está descrita na seção 2.2.

### 3.3 OBTENÇÃO DAS ENTRADAS E SAÍDAS

Com os parâmetros decididos, passou-se para a coleta de dados na linha de montagem. Essa coleta se deu por meio do preenchimento diário do relatório de produção e perdas da linha. Vale ressaltar que informações como “demanda estimada” e “produção excedente” foram obtidas por meio do *software* ERP da empresa em estudo. Os dados coletados foram multiplicados por um fator constante de forma a preservar os dados da empresa e não alterar o resultado das modelagens. Esses dados modificados estão expressos na Tabela 2.

Tabela 2 - Parâmetros de Entrada e Saída das DMUs

DMU's/Variáveis	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$Y_1$	$Y_2$	$Y_3$
1, 1, 1	8,8	7,2	0,06	0,47	30,2	0,0	68,4	95,1%	55,4	81,7%
1, 1, 2	8,8	7,4	0,07	0,11	29	0,0	72,0	97,6%	59,2	84,1%
1, 1, 3	8,8	6,2	0,06	0,16	29	0,0	70,8	88,7%	48,8	70,0%
1, 1, 4	9,0	7,5	0,06	0,12	29	0,2	71,5	122,9%	57,5	82,2%
1, 1, 5	9,6	8,3	0,06	0,12	29	0,5	67,5	124,8%	62,4	85,6%
1, 1, 6	9,6	7,9	0,08	0,13	28,6	0,0	69,0	116,1%	61,6	81,8%
1, 1, 7	9,6	8,2	0,06	0,13	28,5	0,6	69,5	92,0%	61	83,7%
1, 1, 8	9,7	8,6	0,06	0,09	27,7	2,2	69,7	112,3%	62	84,7%
1, 1, 9	9,7	8,8	0,06	0,10	29	4,3	65,6	116,0%	64,5	86,0%
1, 1, 10	9,7	8,6	0,08	0,11	32,2	10,0	69,9	108,6%	68,7	77,6%
1, 1, 11	9,6	8,5	0,06	0,10	34	3,7	70,5	80,7%	74	80,1%
1, 1, 12	9,8	8,6	0,07	0,12	33	0,0	68,8	72,0%	73,5	85,2%
1, 1, 13	9,3	8,4	0,07	0,14	34	2,6	69,3	91,5%	71	84,7%
1, 1, 14	9,6	8,0	0,06	0,11	33,4	0,6	71,0	77,2%	72	82,9%
1, 1, 15	9,6	8,7	0,05	0,09	34	1,8	71,5	70,4%	74,4	87,5%
1, 1, 16	9,2	7,7	0,06	0,09	34	1,4	69,8	53,5%	70,6	81,4%
1, 1, 17	8,8	7,6	0,07	0,11	36,8	2,2	69,0	84,5%	68	82,1%
1, 2, 1	8,4	7,5	0,05	0,11	30,5	1,6	68,4	95,1%	54,3	85,2%
1, 2, 2	8,4	7,7	0,05	0,08	28,8	6,5	72,0	97,6%	57,6	80,8%
1, 2, 3	8,4	7,5	0,06	0,14	28,8	1,8	70,8	88,7%	57,3	85,1%
1, 2, 4	8,8	7,7	0,05	0,14	29	2,8	71,5	122,9%	56,4	83,1%
1, 2, 5	9,0	7,8	0,05	0,13	28,5	0,2	67,5	124,8%	57	85,8%
1, 2, 6	9,0	7,8	0,06	0,13	28,8	3,8	69,0	116,1%	58	79,9%
1, 2, 7	9,1	7,9	0,06	0,12	28,75	1,0	69,5	92,0%	60	85,9%
1, 2, 8	9,2	8,5	0,06	0,09	27,67	2,5	69,7	112,3%	60,2	88,5%
1, 2, 9	9,2	8,3	0,06	0,14	29,33	6,8	65,6	116,0%	63,3	83,6%
1, 2, 10	9,2	8,1	0,08	0,11	33,17	13,5	69,9	108,6%	70	70,6%
1, 2, 11	9,2	7,6	0,06	0,10	32,2	8,0	70,5	80,7%	63,4	75,8%
1, 2, 12	9,3	7,6	0,05	0,13	33,8	5,8	68,8	72,0%	63,8	75,4%
1, 2, 13	9,4	7,2	0,05	0,15	34	6,6	69,3	91,5%	57,25	68,9%
1, 2, 14	9,2	7,8	0,05	0,09	33,33	6,4	71,0	77,2%	71,33	78,5%
1, 2, 15	9,2	7,7	0,05	0,10	34	3,0	71,5	70,4%	75,8	81,4%
1, 2, 16	8,4	7,2	0,06	0,11	34	2,6	69,8	53,5%	62,2	81,1%
1, 2, 17	8,5	6,7	0,06	0,12	36,6	1,8	69,0	84,5%	64	73,4%

Fonte: Próprio autor (2018).

### 3.4 MODELAGEM E SOLUÇÃO DOS MODELOS

O primeiro passo necessário para a modelagem de todos os modelos MCDEA foi a transcrição dos valores da Tabela 2 em uma planilha Excel 2013<sup>®</sup>. Para facilitar o entendimento

de como foi feita a modelagem de cada um dos modelos, a Tabela 3 mostra qual o modelo e quais as equações, descritas na seção 2.4, foram utilizadas para modelagem.

Tabela 3 - Modelos MCDEA e Suas Respectivas Equações

Modelo	Equações
DEA-CRS	18 a 26
BiO-MCDEA	27 a 33
MCDEA-Estendido	34 a 38
BiO-MCDEA-Ótimo	39 a 45
WGP-MCDEA	46 a 55

Fonte: Próprio autor (2018).

A otimização dos modelos foi realizada por meio do algoritmo SIMPLEX, utilizando programação VBA Excel 2013<sup>®</sup>. Como descrito na seção 1.4, para os métodos quantitativos foi utilizada uma máquina com processador Intel Core i7<sup>®</sup>, com *clock* de 1,9 GHZ e capacidade de 8 GB de memória RAM. Cinco segundos é o tempo computacional médio para realização da otimização de cada modelo MCDEA.

Vale ressaltar que a modelagem DEA-CRS respeitou a “Regra de Ouro” de Banker et al. (1989) tanto na matriz com OEE quanto na matriz sem OEE. Essa regra delimita o número mínimo de DMUs necessárias para uma modelagem eficaz. Como no trabalho em questão a matriz com maior número de parâmetros (matriz com OEE) apresenta sete parâmetros de entrada e três parâmetros de saída, segundo essa regra, são necessárias, no mínimo, três vezes a quantidade total de parâmetros no problema (dez), ou seja, seriam necessárias trinta DMUs. No caso apresentado, tem-se trinta e quatro DMUs, satisfazendo a regra para o ambiente mais restrito.

## 4 DISCUSSÃO DOS RESULTADOS

### 4.1 RESULTADOS DAS MODELAGENS

A Tabela 4 e a Tabela 5, respectivamente, com e sem OEE como parâmetro de saída, apresentam a avaliação da eficiência das trinta e quatro DMUs pelos métodos do OEE da empresa, do BiO-MCDEA, do MCDEA-Estendido, do BiO-MCDEA-Ótimo, do WGP-MCDEA e do DEA-CRS. As DMUs eficientes foram destacadas nas Tabelas com seu fundo verde claro, bem como foi incluída, na parte inferior da Tabela (linha “Eficientes”), a soma de DMUs eficientes observadas em cada modelo.

Tabela 4 – Eficiências de Cada Modelo Utilizando o OEE como Parâmetro de Saída

DMUs	DEA-CRS	BiO- MCDEA	MCDEA – Estendido	BiO – MCDEA – Ótimo	WGP – MCDEA	OEE
1	100,0%	88,3%	97,7%	92,8%	82,3%	81,7%
2	100,0%	97,9%	97,9%	94,8%	98,5%	84,1%
3	100,0%	86,6%	86,6%	83,2%	83,9%	70,0%
4	100,0%	95,3%	95,3%	94,1%	97,7%	82,2%
5	100,0%	98,6%	98,6%	100,0%	98,5%	85,6%
6	100,0%	95,6%	95,6%	97,3%	94,6%	81,8%
7	99,3%	95,6%	95,6%	94,8%	94,5%	83,7%
8	100,0%	95,1%	95,3%	95,8%	95,0%	84,7%
9	100,0%	98,6%	98,7%	98,6%	99,7%	86,0%
10	98,2%	90,9%	91,9%	88,8%	94,9%	77,6%
11	100,0%	95,0%	95,2%	94,4%	96,0%	80,1%
12	100,0%	99,3%	99,6%	100,0%	94,7%	85,2%
13	100,0%	98,3%	98,3%	97,0%	100,0%	84,7%
14	100,0%	98,2%	98,5%	97,1%	95,4%	82,9%
15	100,0%	99,6%	99,6%	100,0%	100,0%	87,5%
16	100,0%	98,3%	98,3%	94,4%	93,9%	81,4%
17	100,0%	95,8%	96,5%	93,2%	91,8%	82,1%
18	100,0%	99,4%	99,4%	92,0%	98,3%	85,2%
19	100,0%	92,5%	93,4%	87,6%	96,1%	80,8%
20	100,0%	98,9%	98,9%	93,0%	100,0%	85,1%
21	100,0%	95,0%	95,0%	91,3%	99,7%	83,1%
22	100,0%	100,0%	100,0%	98,5%	100,0%	85,8%
23	97,6%	93,9%	93,9%	91,4%	96,6%	79,9%
24	100,0%	99,2%	99,2%	95,8%	94,8%	85,9%
25	100,0%	98,7%	98,7%	96,7%	99,9%	88,5%
26	100,0%	99,1%	99,1%	95,8%	100,0%	83,6%
27	100,0%	88,6%	88,6%	85,1%	99,5%	70,6%
28	93,6%	91,5%	91,6%	84,5%	90,0%	75,8%
29	92,9%	91,2%	91,4%	86,8%	90,5%	75,4%
30	100,0%	88,2%	89,1%	86,2%	88,4%	68,9%
31	100,0%	95,9%	95,9%	92,1%	96,6%	78,5%
32	100,0%	100,0%	100,0%	98,4%	100,0%	81,4%
33	100,0%	96,2%	96,4%	88,7%	91,7%	81,1%
34	100,0%	91,6%	91,6%	88,8%	97,2%	73,4%
<b>Eficientes</b>	<b>29</b>	<b>2</b>	<b>2</b>	<b>3</b>	<b>5</b>	

Fonte: Próprio autor (2018).

Tabela 5 – Eficiências de Cada Modelo sem Utilizar o OEE como Parâmetro de Saída

DMUs	DEA-CRS	BiO-MCDEA	MCDEA – Estendido	BiO – MCDEA - Ótimo	WGP - MCDEA	OEE
1	100,0%	82,5%	91,0%	99,3%	85,6%	81,7%
2	100,0%	96,5%	96,5%	99,7%	95,8%	84,1%
3	100,0%	81,9%	81,9%	99,3%	90,1%	70,0%
4	100,0%	100,0%	100,0%	99,9%	100,0%	82,2%
5	100,0%	100,0%	100,0%	99,8%	100,0%	85,6%
6	100,0%	97,5%	97,5%	99,7%	100,0%	81,8%
7	97,3%	89,9%	89,9%	99,3%	90,5%	83,7%
8	100,0%	93,7%	95,1%	99,5%	95,4%	84,7%
9	100,0%	97,2%	97,2%	99,6%	97,0%	86,0%
10	98,2%	96,2%	96,2%	99,7%	96,2%	77,6%
11	100,0%	96,8%	96,8%	99,6%	96,2%	80,1%
12	100,0%	94,2%	94,2%	99,4%	97,0%	85,2%
13	100,0%	99,4%	99,4%	99,7%	94,5%	84,7%
14	100,0%	95,6%	95,6%	99,7%	95,7%	82,9%
15	100,0%	95,1%	95,1%	99,4%	94,1%	87,5%
16	100,0%	90,5%	90,5%	99,4%	90,4%	81,4%
17	100,0%	96,1%	97,9%	99,8%	87,0%	82,1%
18	93,6%	92,1%	92,1%	99,4%	90,9%	85,2%
19	100,0%	93,2%	95,3%	99,5%	90,8%	80,8%
20	94,7%	92,8%	94,5%	99,5%	90,2%	85,1%
21	100,0%	99,3%	99,3%	99,8%	97,0%	83,1%
22	100,0%	100,0%	100,0%	99,8%	98,7%	85,8%
23	97,5%	97,0%	97,0%	99,7%	96,1%	79,9%
24	94,9%	92,7%	92,7%	99,4%	92,6%	85,9%
25	100,0%	95,2%	97,2%	99,5%	96,5%	88,5%
26	100,0%	99,2%	99,2%	99,8%	98,9%	83,6%
27	100,0%	100,0%	100,0%	100,0%	100,0%	70,6%
28	92,1%	88,6%	88,6%	99,4%	89,3%	75,8%
29	90,2%	85,9%	86,1%	99,3%	86,6%	75,4%
30	100,0%	93,4%	93,4%	99,9%	95,3%	68,9%
31	100,0%	96,0%	96,0%	99,8%	96,2%	78,5%
32	100,0%	100,0%	100,0%	100,0%	100,0%	81,4%
33	90,3%	87,2%	87,2%	99,3%	86,3%	81,1%
34	100,0%	96,6%	96,9%	100,0%	94,0%	73,4%
<b>Eficientes</b>	<b>25</b>	<b>5</b>	<b>5</b>	<b>3</b>	<b>5</b>	

Fonte: Próprio autor (2018).

Analisando-se apenas os resultados das DMUs eficientes em cada um dos cenários é possível observar que os modelos apresentaram:

- DEA-CRS: 29 DMUs eficientes no cenário de modelagem com o OEE nos parâmetros de saída e 25 DMUs eficientes no cenário de modelagem sem o OEE nos parâmetros de saída.
- BiO-MCDEA: 2 DMUs eficientes no cenário de modelagem com o OEE nos parâmetros de saída e 5 DMUs eficientes no cenário de modelagem sem o OEE nos parâmetros de saída.
- MCDEA-Estendido: 2 DMUs eficientes no cenário de modelagem com o OEE nos parâmetros de saída e 5 DMUs eficientes no cenário de modelagem sem o OEE nos parâmetros de saída.
- BiO-MCDEA-Ótimo: 3 DMUs eficientes no cenário de modelagem com o OEE nos parâmetros de saída e 3 DMUs eficientes no cenário de modelagem sem o OEE nos parâmetros de saída.
- WGP-MCDEA: 5 DMUs eficientes no cenário de modelagem com o OEE nos parâmetros de saída e 5 DMUs eficientes no cenário de modelagem sem o OEE nos parâmetros de saída.

#### 4.2 RESULTADOS DOS TESTES DE LEVENE E DE CORRELAÇÃO DE SPEARMAN

Com os resultados de eficiência em ambos os cenários disponíveis, foi possível testar – por meio dos testes não paramétricos de Levene e de correlação de Spearman – a aderência dos modelos estudados ao OEE da empresa.

Primeiramente, serão apresentados os resultados do teste não paramétrico de correlação de Spearman. Os resultados desse teste são valores compreendidos no intervalo de -1 a +1, onde +1 significa uma correlação idêntica e -1 uma correlação completamente oposta. Uma síntese das interpretações desse teste é descrita a seguir (SPEARMAN, 1904):

- +0,9 a + 1 ou -0,9 a -1 indica uma correlação muito forte.
- +0,7 a +0,9 ou -0,7 a 0,9 indica uma correlação forte.
- +0,5 a +0,7 ou -0,5 a -0,7 indica uma correlação moderada.
- +0,3 a 0,5 ou -0,3 a -0,5 indica uma correlação fraca.
- 0 a +0,3 ou 0 a -0,3 indica uma correlação desprezível.

No Minitab17, *software* utilizado para realizar tal teste, os valores de correlação são mostrados na linha superior dos elementos da matriz. A linha inferior dos elementos da matriz, por sua vez, diz respeito à significância estatística do teste (valor-p), ou seja, se o valor-p da linha inferior for menor do que 5% ou 0,05, significa que, ao nível de confiança de 95%, esse teste é significativo.

Os resultados do teste não paramétrico de Spearman entre todos os modelos estudados e o OEE da empresa foi realizado por meio do Minitab17<sup>®</sup>. Os resultados foram transcritos em uma planilha Excel 2013<sup>®</sup>, com o intuito de facilitar sua visualização. O teste com o OEE nos parâmetros de saída está apresentado na Tabela 6 e o teste sem o OEE como parâmetro de saída está apresentado na Tabela 7.

Tabela 6 - Resultados do Teste não Paramétrico de Spearman – Modelagem Com OEE

	DEA - CRS	BiO - MCDEA	MCDEA - Estendido	BiO - MCDEA - Ótimo	WGP - MCDEA
BiO - MCDEA	0,553 0,001				
MCDEA - Estendido	0,604 0,000	0,953 0,000			
BiO - MCDEA - Ótimo	0,413 0,015	0,778 0,000	0,808 0,000		
WGP - MCDEA	0,401 0,019	0,617 0,000	0,533 0,001	0,480 0,004	
OEE	0,538 0,001	0,802 0,000	0,821 0,000	0,793 0,000	0,525 0,001

Fonte: adaptado de Minitab17<sup>®</sup> em Excel 2013<sup>®</sup> (2018).

Tabela 7 - Resultados do Teste não Paramétrico de Spearman – Modelagem Sem OEE

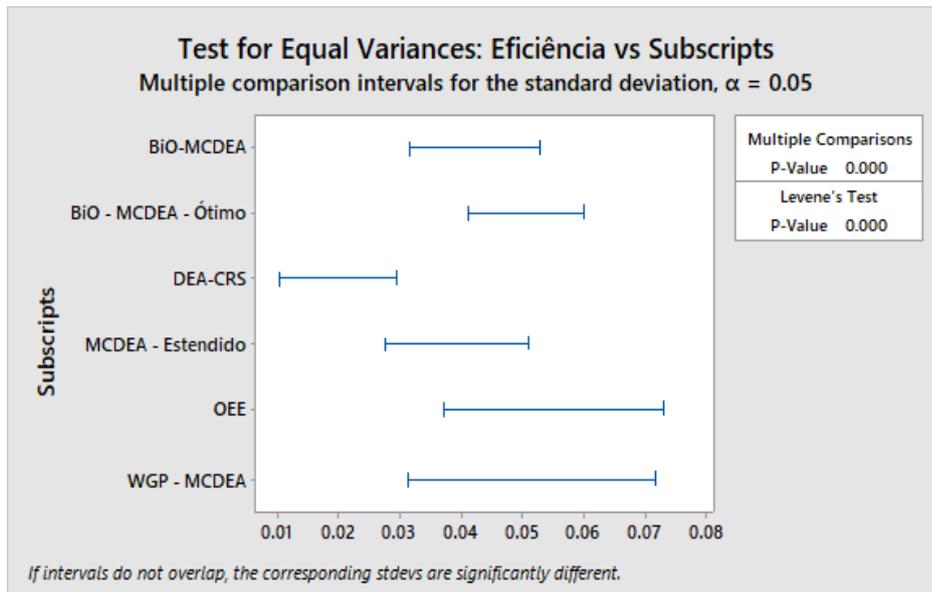
	DEA - CRS	BiO - MCDEA	MCDEA - Estendido	BiO - MCDEA - Ótimo	WGP - MCDEA
BiO - MCDEA	0,362 0,035				
MCDEA - Estendido	0,409 0,016	0,968 0,000			
BiO - MCDEA - Ótimo	0,352 0,041	0,871 0,000	0,865 0,000		
WGP - MCDEA	0,307 0,077	0,860 0,000	0,799 0,000	0,693 0,000	
OEE	0,142 0,423	0,173 0,327	0,222 0,207	-0,105 0,556	0,226 0,200

Fonte: adaptado de Minitab17<sup>®</sup> em Excel 2013<sup>®</sup> (2018).

Com relação ao teste de Levene, seu objetivo foi validar a hipótese de que os modelos estudados, estatisticamente, geram a mesma dispersão de peso em relação ao OEE da empresa objeto de estudo. Todos os testes de Levene apresentados neste trabalho foram realizados para um nível de significância  $\alpha = 5\%$  (NORDSTOKKE e ZUMBO, 2010).

Primeiramente, serão apresentados os resultados do Teste de Levene para o cenário das modelagens com o OEE nos parâmetros de saída. O primeiro teste está expresso na Figura 8.

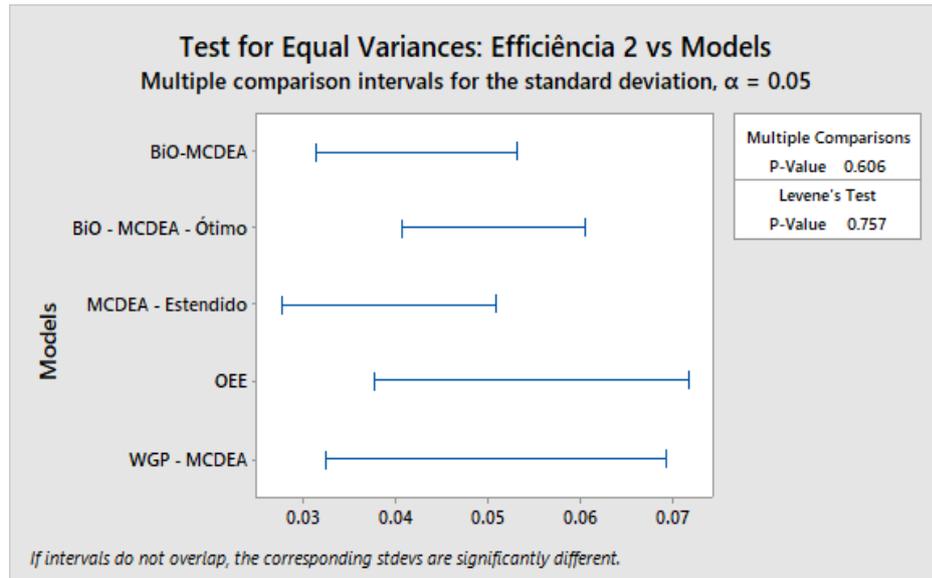
Figura 8 - Primeiro Teste de Levene com OEE nos Parâmetros de Saída



Fonte: Minitab17® (2018).

O resultado do teste apresentado na Figura 8 foi de que há diferença em relação às variâncias dos resultados (teste de Levene com valor menor do que 0,05 ou 5%). No entanto, ao se analisar o gráfico, observa-se que a variância do modelo DEA-CRS está deslocada em relação à variância dos outros modelos. A Figura 9 apresenta um novo teste de Levene retirando o modelo DEA-CRS do teste.

Figura 9 - Segundo Teste de Levene com OEE nos Parâmetros de Saída

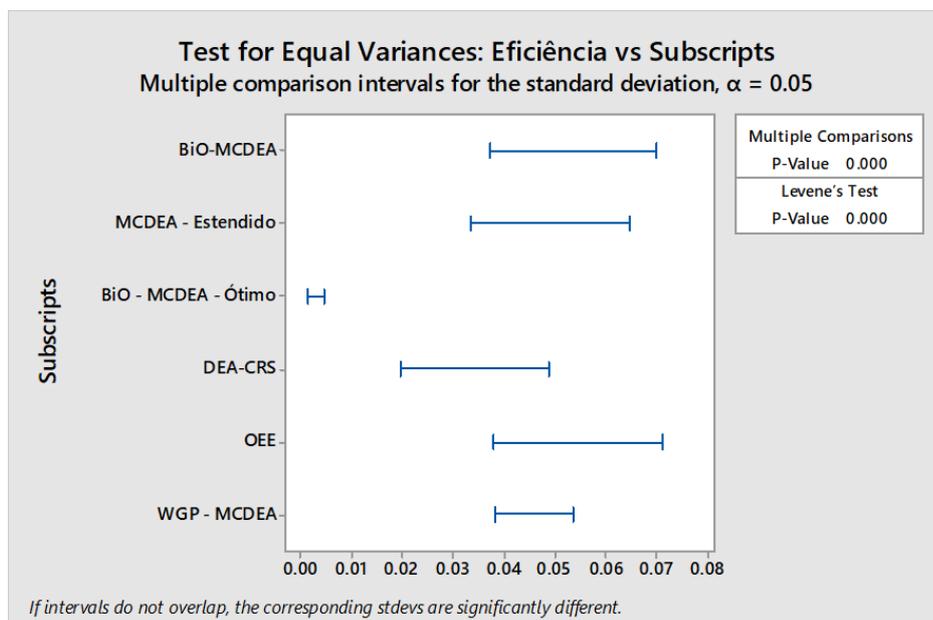


Fonte: Minitab17® (2018).

A Figura 9 permite a conclusão de que, ao nível de 95% de significância, não há diferença significativa entre as variâncias dos modelos BiO-MCDEA, BiO-MCDEA-Ótimo, MCDEA-Estendido e WGP-MCDEA com o OEE da empresa no cenário com o OEE nos parâmetros de saída.

Será feita, agora, uma análise do teste de Levene para o cenário sem o OEE nos parâmetros de saída. O primeiro teste está ilustrado na Figura 10.

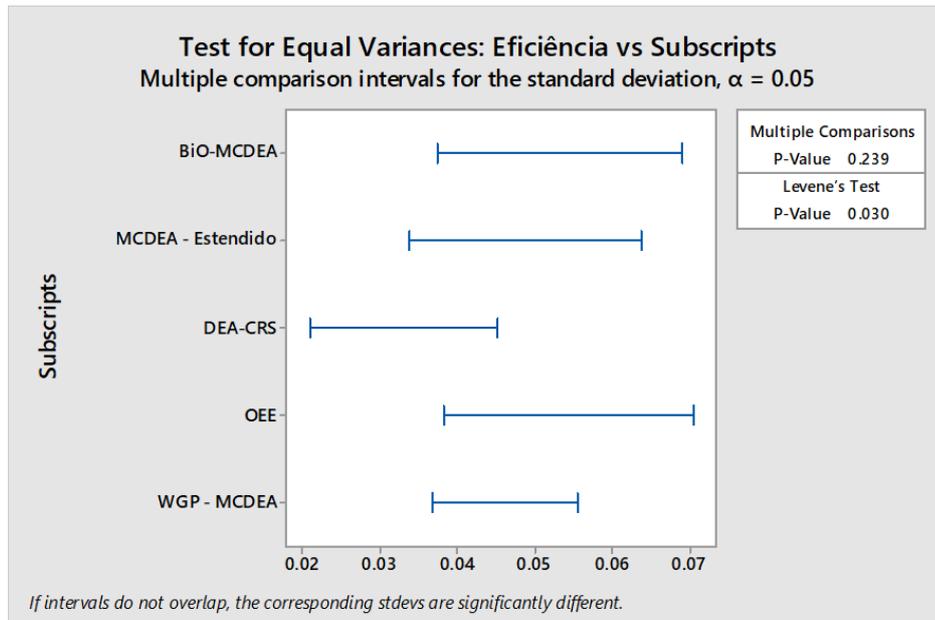
Figura 10 - Primeiro Teste de Levene sem OEE nos Parâmetros de Saída



Fonte: Minitab17® (2018).

O resultado apresentado na Figura 10 foi de que há diferença em relação às variâncias dos resultados (teste de Levene com valor menor do que 0,05 ou 5%). No entanto, a Figura 10 ilustra que o modelo BiO-MCDEA-Ótimo apresenta seu resultado de variância deslocado em relação aos demais. Um novo teste de Levene foi realizado sem esse modelo (Figura 11).

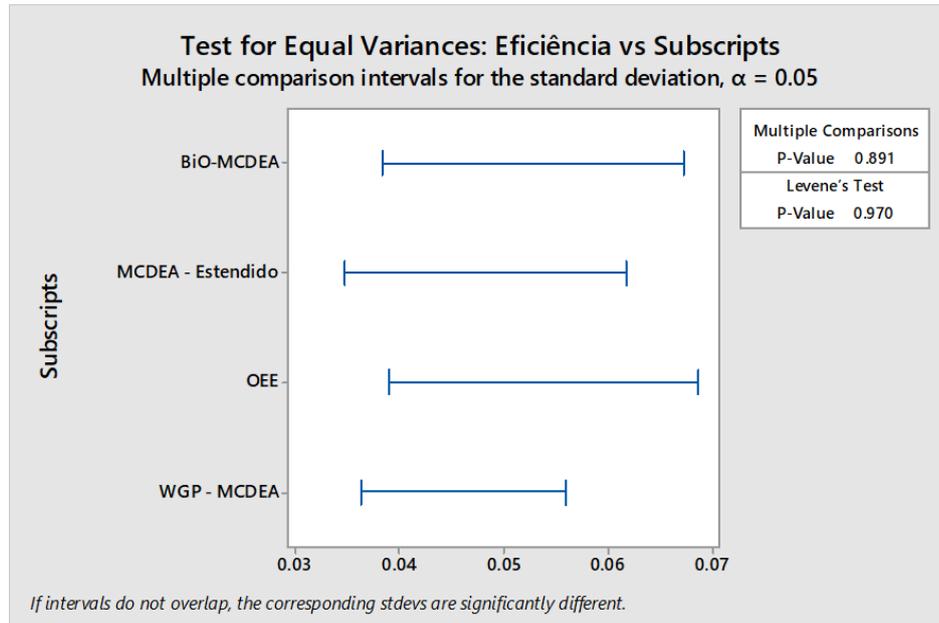
Figura 11 - Segundo Teste de Levene sem OEE nos Parâmetros de Saída



Fonte: Minitab17® (2018).

O resultado do teste apresentado na Figura 11 foi de que há diferença em relação às variâncias dos resultados (teste de Levene com valor menor do que 0,05 ou 5%). No entanto, o gráfico ilustra que o modelo DEA-CRS apresenta seu resultado de variância deslocado em relação aos demais. Um novo teste de Levene foi realizado retirando esse modelo do teste (Figura 12).

Figura 12 - Terceiro Teste de Levene sem OEE nos Parâmetros de Saída



Fonte: Minitab17® (2018).

A Figura 12 permite a conclusão de que, ao nível de 95% de significância, não há diferença significativa entre as variâncias dos modelos BiO-MCDEA, MCDEA-Estendido e WGP-MCDEA com o OEE da empresa no cenário sem o OEE nos parâmetros de saída.

#### 4.3 DEFINIÇÃO DO CENÁRIO MAIS ADERENTE À REALIDADE DA EMPRESA

A partir da análise da Tabela 4 e da Tabela 5, é possível concluir que, do ponto de vista da discriminação dos modelos (entende-se modelos mais discriminantes como sendo os que apresentam menos DMUs eficientes), o modelo DEA-CRS se mostrou mais discriminante no cenário sem o OEE presente nos parâmetros de saída, enquanto os modelos BiO-MCDEA e MCDEA-Estendido se mostraram mais discriminantes no cenário com o OEE presente nos parâmetros de saída. Um resultado igual de discriminação foi apresentado pelos modelos BiO-MCDEA-Ótimo e WGP-MCDEA.

Comparando-se a Tabela 6 e a Tabela 7, observa-se que, em todos os modelos estudados, a modelagem com OEE apresentou maior correlação com o próprio OEE do que a modelagem sem OEE. Uma vez que o OEE já tem sua eficácia comprovada por conta de anos de uso na empresa estudada, o resultado do teste não paramétrico de Spearman possibilita a inferência de que a modelagem com o OEE nos parâmetros de saída é mais aderente à realidade da empresa em estudo.

Comparando-se a Figura 9 e a Figura 12, observa-se que o cenário com o OEE presente nos parâmetros de saída apresentou mais modelos com homogeneidade de variância em relação ao OEE da empresa.

Esses três resultados foram levados até os gestores da empresa e os mesmos definiram que, principalmente em função do teste não paramétrico de correlação de Spearman, o cenário que melhor reflete a realidade da empresa estudada é o cenário em que o OEE está presente nos parâmetros de saída dos modelos.

#### 4.4 IDENTIFICAÇÃO DO MODELO MAIS ADERENTE AO PROBLEMA ESTUDADO

Uma vez que o cenário mais aderente foi definido como sendo o cenário com OEE nos parâmetros de saída, passou-se a estudar qual dos modelos é o que melhor representa a realidade da empresa em estudo.

Ao se observar a discriminação dos modelos (Tabela 4), conclui-se que os modelos mais discriminantes são o BiO-MCDEA e o MCDEA-Estendido, ambos apresentando duas DMUs eficientes. Vale ressaltar que a menor quantidade de DMUs eficientes é benéfica do ponto de vista gerencial, uma vez que se torna mais fácil a identificação do *benchmarking* para transformar DMUs ineficientes em eficientes.

Com relação ao teste não paramétrico de correlação de Spearman (Tabela 6), é possível concluir que três modelos apresentaram resultado de correlação forte com o OEE da empresa (resultados maiores do que 0,7) e foram significantes estatisticamente (apresentaram valores-p menores do que 5%). Os três modelos em questão foram BiO-MCDEA, BiO-MCDEA-Ótimo e MCDEA-Estendido.

O teste de Levene (Figura 9) ilustrou que, ao nível de 5% de significância, não há diferença significativa entre as variâncias dos modelos BiO-MCDEA, BiO-MCDEA-Ótimo, MCDEA-Estendido e WGP-MCDEA com o OEE.

Essas três informações foram levadas aos gestores da empresa juntamente com os resultados de eficiência das modelagens em comparação com os do OEE (Tabela 4). A conclusão foi que o modelo mais aderente à realidade da empresa é o BiO-MCDEA sem peso ótimo, no cenário com o OEE como parâmetro de saída.

## 5 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

### 5.1 RESPOSTAS ÀS QUESTÕES DE PESQUISA E AOS OBJETIVOS

As questões de pesquisa deste trabalho foram atendidas, à medida que se concluiu, com os gestores da empresa, que os modelos de Análise Envoltória de Dados Multiobjetivo são capazes de complementar as informações fornecidas pelo OEE. Respondendo à segunda questão, referente a qual modelo proporciona a melhor análise de eficiência, concluiu-se que o modelo BiO-MCDEA sem peso ótimo é o mais adequado. Por fim, a última questão, a qual visa entender se há vantagens em utilizar essa nova sistemática para medir a eficiência de máquinas industriais em comparação ao método tradicional de cálculo do OEE, foi definido juntos aos gestores da empresa que o esforço adicional necessário para adquirir as informações para o modelo proposto não compensa o retorno proporcionado por ele.

Os objetivos gerais e específicos foram totalmente atendidos, à medida que foi possível a modelagem de todos os modelos em VBA (Excel 2013<sup>®</sup>), e os resultados das modelagens foram comparados com os do OEE da empresa.

A comparação entre os dois cenários propostos, sendo o primeiro com o OEE como parte dos parâmetros de saída dos modelos e o segundo sem o mesmo, concluiu-se que o primeiro cenário se mostrou mais adequado nos três critérios adotados: discriminação dos modelos, teste de correlação de Spearman e teste de Levene.

Dentro do cenário com o OEE dentro dos parâmetros de saída, em função da discriminação apresentada pelo modelo BiO-MCDEA sem peso ótimo, sua alta correlação com o OEE da empresa, sua significância estatística e sua variância ser semelhante à do OEE da empresa, a conclusão, tomada junto aos gestores da empresa, é a de que ele é o mais adequado para o caso estudado.

Vale ressaltar que o modelo WGP-MCDEA, tido como modelo potencial pela literatura por não haver trabalhos com aplicações reais deste modelo, apresentou correlação fraca com o OEE, tornando esse modelo inviável para descrever a realidade da empresa. Esse resultado mostra que a oportunidade de pesquisa destacada na justificativa do trabalho em relação à aplicação deste modelo não se mostrou eficiente para o caso estudado.

Outra observação relevante é a de que, apesar de a “Regra de Ouro” ter sido respeitada na modelagem, os modelos MCDEA se mostraram mais discriminatórios do que o modelo clássico DEA-CRS, justificando o estudo sobre esse tema.

Por fim, conclui-se que a modelagem de qualquer um dos modelos MCDEA não exige grande esforço computacional, à medida que a máquina utilizada neste estudo pode ser considerada mediana (seus dados estão descritos na seção 1.4) e foi suficiente para processar todas as modelagens em menos de cinco segundos.

## 5.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS

Para futuras pesquisas, recomenda-se que seja feito um estudo agregando incertezas aos modelos MCDEA. Essa adesão pode ser feita, por exemplo, por meio da lógica dos conjuntos *fuzzy*. Esse estudo possibilitaria uma abordagem mais ampla dos dados da empresa estudo de caso, além de possibilitar a comparação entre os resultados das modelagens com e sem incerteza.

Além disso, recomenda-se realizar um novo estudo que possibilite o entendimento do (s) motivo (s) pelo (s) qual (is) o Modelo Ponderado Bi-Objetivo Estendido (MCDEA-Estendido), o qual se trata de uma versão aprimorada do modelo BiO-MCDEA sem peso ótimo, apresentou-se menos aderente à realidade da empresa em estudo quando comparado à versão original do BiO-MCDEA sem peso ótimo.

## REFERÊNCIAS

- AHIRE, C. P.; RELKAR, A. S. Correlating failure mode effect analysis (FMEA) and overall equipment effectiveness (OEE). **Procedia Engineering**, Vellore, v. 38, p. 3482-3486, 2012.
- ARUNAGIRI, P.; GNANAVELBABU, A. Identification of high impact lean production tools in automobile industries using weighted average method. **Procedia Engineering**, Vellore, v. 97, p. 2072-2080, 2014.
- ANVARI, A. et al. An integrated design methodology based on the use of group AHP-DEA approach for measuring lean tools efficiency with undesirable output. **International Journal of Advanced Manufacturing Technology**, London, v. 70, n. 9–12, p. 2169-2186, 2014.
- AZADEH, A.; SHEIKHALISHAHI, M.; KOUSHAN, M. An integrated DEA-fuzzy simulation approach for optimization of operator allocation with learning effects in multi products CMS. **Applied Mathematical Modeling**, Amsterdam, v. 37, p. 9922 -9933, 2013.
- BAL, H.; ORKCU, H. H.; CELENBIOGLU, S. Improving the discrimination power and weights dispersion in the data envelopment analysis. **Computers and Operational Research**, Amsterdam, v. 37, n. 1, p. 99-107, 2010.
- BANKER, R.D.; CHARNES, A.; COOPER, W.W. Some models for estimating technical and scale inefficiency in data envelopment analysis. **Management Science**, Catonsville v. 30, p. 1078-1092, 1984.
- BANKER, R.D. et al. An introduction to data envelopment analysis with some of its models and their uses. **Research in Governmental and Non-Profit Accounting**, Oxford, v. 5, p. 125-163, 1989.
- 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.
- BORTOLOTTI, T.; ROMANO, P. 'Lean first, then automate': a framework for process

improvement in pure service companies. a case study. **Production Planning and Control**, London, v. 23, n. 7, p. 513-522, 2012.

BRYMAN, A.; BELL, E. Business research methods. **Oxford University Press**, New York, v. 3, p. 154-177, 2015.

CHARNES, A.; COOPER, W.W.; RHODES, E. Measuring the efficiency of decision making units. **European Journal of Operational Research**, Amsterdam, v. 2, p. 429-444, 1978.

CHAVES, M.C.D.; De MELLO, J.C.C.B.S.; ANGULO-MEZA, L. Studies of some duality properties in the Li and Reeves model. **Journal Of The Operational Research Society**, Oxford, v. 67, p. 474-482, 2016.

CHEN, L.; JIA, G. Environmental efficiency analysis of china's regional industry: a data envelopment analysis (DEA) based approach. **Journal of Cleaner Production**, Amsterdam, v. 142, p. 846-853, 2017.

CHEN, Y. W.; LARBANI, M.; CHANG, Y., P. Multiobjective data envelopment analysis. **Journal of the Operational Research Society**, Oxford, v. 60, p. 1556-1566, 2009.

CIARAPICA, F. E.; BEVILACQUA, M.; MAZZUTO, G. Performance analysis of new product development projects. **International Journal of Productivity and Performance Management**, Bingley, v. 65, p. 177-206, 2016.

COOK, W.D.; TONE, K.; ZHU, J. Data envelopment analysis: prior to choosing a model. **Omega: The International Journal of Management Science**, Amstedam. v. 44, p. 1-4, 2014.

DEB, K. Nonlinear goal programming using multiobjective genetic algorithms. **Journal of the Operational Research Society**, Oxford, v. 52, p. 291-302, 2001.

DOTOLI, M. et al. A cross-efficiency fuzzy data envelopment analysis technique for performance evaluation of decision making units under uncertainty. **Computers and Industrial Engineering**, New York, v. 79, p. 103-114, 2015.

ESWARAMURTHI, K. G.; MOHANRAM, P. V. Improvement of manufacturing performance measurement system and evaluation of overall resource effectiveness. **American Journal of Applied Sciences**, New York, v. 10, n. 2, p. 131-138, 2013.

EXCEL 2013. **Software de criação de planilhas eletrônicas**. Disponível em < <https://microsoft-excel.softonic.com.br/> >. Acesso em: 07 mar. 2018.

FERKO, R.; ZNIDARSIC, A. Using OEE Approach for Improving Manufacturing Performance. **Informacije MIDE M**, Ljubljana, v. 37, p. 105-111, 2007.

FERREIRA, C. M. C.; GOMES, A. P. **Introdução à análise envoltória de dados: teoria, modelos e aplicações**. 22. ed. Viçosa: UFV, 2009. 389 p.

FRIESNER, D.; MITTELHAMMER, R.; ROSENMAN, R. Inferring the incidence of industry inefficiency from MCDEA estimates. **European Journal of Operational Research**, Amsterdam, v. 224, p. 414-424, 2013.

GHASEMI, M.; IGNATIUS, J.; EMROUZNEJAD, A. A bi-objective weighted model for improving the discrimination power in MCDEA. **European Journal of Operational Research**, Amsterdam, v. 233, p. 640-650, 2014.

HATAMI-MARBINI, A.; TOLOO, M. An extended multiple criteria data envelopment analysis model. **Expert Systems With Applications**, New York, v. 73, p. 201-219, 2017.

HAGHIGHI, S.M.; TORABI, S.A.; GHASEMI, R. An integrated approach for performance evaluation in sustainable supply chain networks (with a case study). **Journal of Cleaner Production**, Amsterdam, v. 137, p. 579-597, 2016.

HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to operations research**. 8. ed. New York: McGraw-Hill, 2010. 1038 p.

HINES, P.; HOLWEG, M.; RICH, N. Learning to evolve. **International Journal of Operations and Production Management**, Bingley, v. 24, p. 994-1011, out. 2004.

- IGNATIUS, J. et al. Carbon efficiency evaluation: an analytical framework using fuzzy DEA. **European Journal of Operational Research**, Amsterdam, v. 253, n. 2, p. 428-440, 2016.
- JOHNES, J.; PORTELA, M.; THANASSOULIS, E. Efficiency in education. **Journal of the Operational Research Society**, Oxford, v. 68, p. 331-338, 2017.
- KUMAR, S. S.; KUMAR, M. P. Cycle time reductin of a truck body assembly in an automobile industry by lean principles. **Procedia Materials Science**, Amsterdam, v. 5, p. 1853-1862, 2014.
- LERTWORASIRKUL, S. Fuzzy data envelopment analysis (DEA): a possibility approach. **Fuzzy Sets and Systems**, Amsterdam, v. 139, n. 2, p. 379-394, 2003.
- LI, X.; REEVES, G.R. A multiple criteria approach to data envelopment analysis. **European Journal of Operational Research**, Amsterdam, v. 115, p. 507-517, 1999.
- LIU, S. A fuzzy DEA / AR approach to the selection of flexible manufacturing systems. **Computers and Industrial Engineering**, New York, v. 54, p. 66-76, 2008.
- KHANCHANAPONG, T. et al. The unique and complementary effects of manufacturing technologies and lean practices on manufacturing operational performance. **International Journal of Production Economics**, Amsterdam, v. 153, p. 191-203, 2014.
- MELLO, J. C. C. B. S. et al. Curso de análise envoltória de dados. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 37., 2005, Gramado. **Anais...** Rio de Janeiro: Sociedade Brasileira de Pesquisa Operacional, 2005. p. 30-37.
- 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 17. **Software estatístico**. Disponível em: < <http://www.minitab.com> >. Acesso em: 17 out. 2018.

MOURTZIS, D.; PAPATHANASIOU, P.; FOTIA, S. Lean rules identification and classification for manufacturing industry. **Procedia CIRP**, Amsterdam, v. 50, p. 198–203, 2016.

NAKAJIMA, S. **An introduction to TPM**. Massachusetts: Productive Press, 1989. 26 p.

NORDSTOKKE, D. W.; ZUMBO, B. D. A new nonparametric Levene test for equal variances. **Psicológica**, Valencia, v. 31, p. 401–430, 2010.

RUBEM, A. P. D.; DE MELLO, J. C. C. B. S.; MEZA, L. A. A goal programming approach to solve the multiple criteria DEA model. **European Journal of Operational Research**, Amsterdam, v. 260, p. 134-139, 2017.

SAN CRISTOBAL, J. R. A multi criteria data envelopment analysis model to evaluate the efficiency of the renewable energy technologies. **Renewable Energy**, Oxford, v. 36, p. 2742-2746, 2011.

SCOPUS. **Base de dados bibliográficos**. Disponível em: < <https://www.scopus.com/> >. Acesso em: 14 mar. 2018.

SILVA, A. F. et al. A bi-objective multiple criteria data envelopment analysis combined with the overall equipment effectiveness: an application in an automotive company. **Journal of Cleaner Production**, Amsterdam, v. 157, p. 278-288, 2017.

SONMEZ, V.; TESTIK, M. C.; TESTIK, O. M. Overall equipment effectiveness when production speeds and stoppage durations are uncertain. **International Journal of Advanced Manufacturing Technology**, London, v. 95, n. 1-4, p. 121-130, 2018.

SPAGNOL, G. S.; LI, L.; NEWBOLD, D. Lean principles in healthcare: an overview of challenges and improvements. **The International Federation of Automatic Control**, Toulouse, v. 46, p. 229-234, 2013.

SPEARMAN, C. The proof and measurement of association between two things. **The American Journal of Psychology**. Champaign, v. 15, p. 72-101, 1904.

SUEYOSHI, T.; GOTO, M. Efficiency-based rank assessment for electric power industry: a combined use of data envelopment analysis (DEA) and DEA-discriminant analysis (DA). **Energy economics**, Guildford, v. 34, p. 634-644, 2012.

SUNDAR, R.; BALAJI, A. N.; SATHEESHKUMAR, R. M. A review on lean manufacturing implementation techniques. In: GLOBAL CONGRESS ON MANUFACTURING AND MANAGEMENT, 12., 2014, Vellore. **Proceedings...** Vellore: Manufacturing and Management, 2014. p. 1875-1885.

TAKAHASHI, M.; OHSATO, S. Management efficiency in japanese regional banks: a network DEA. **Procedia: Social and Behavioral Sciences**, Amsterdam, v. 172, p. 511-518, 2015.

TEICHGRÄBER, U. K.; DE BUCOURT, M. Applying value stream mapping techniques to eliminate non-value-added waste for the procurement of endovascular stents. **European Journal of Radiology**, Amsterdam, v. 81, p. 47-52, 2012.

TOUSSAINT, J. S.; BERRY, L. L. The promise of lean in health care. **Mayo Clinic Proceedings**, Rochester, v. 88, n. January, p. 74-82, 2013.

TSAROUHAS, P.H. Evaluation of overall equipment effectiveness in the beverage industry: a case study. **International Journal of Production Research**, London, v. 51, p. 515-523, 2013.

UGARTE, G. M.; GOLDEN, J. S.; DOOLEY, K. J. Lean versus green: the impact of lean logistics on greenhouse gas emissions in consumer goods supply chains. **Journal of Purchasing and Supply Management**, New York, v. 22, p. 98-109, 2016.

VERMA, M.K.; MUKHERJEE, V.; YADAV, V. K. Greenfield distribution network expansion strategy with hierarchical GA and MCDEA under uncertainty. **International Journal of Electrical Power and Energy Systems**, Oxford, v. 79, p. 245-252, 2016.

WEB OF SCIENCE. **Base de dados bibliográficos.** Disponível em: < <https://login.webofknowledge.com/> >. Acesso em: 14 mar. 2018.

WOMACK, J.; JONES, D.; ROOS, D. **The machine that changed the world**: the story of lean production. 1 ed. New York: Free Press, 2007. 352 p.

WUDHIKARN, R. Improving overall equipment cost loss adding cost of quality. **International Journal of Production Research**, London, v. 50, p. 3434-3449, 2012.

ZHAO, M.Y.; CHENG, C.T.; CHAU, K.W., LI, G. Multiple criteria data envelopment analysis for full ranking units associated to environment impact assessment. **International Journal of Environment and Pollution**, Geneva, v. 28, p. 448-464, 2006.