UNIVERSIDADE FEDERAL DE ITAJUBÁ PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Redução do espaço de busca em problemas de Otimização via Simulação utilizando Análise Envoltória de Dados e Arranjos Ortogonais de Taguchi

Rafael de Carvalho Miranda

UNIVERSIDADE FEDERAL DE ITAJUBÁ PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Rafael de Carvalho Miranda

Redução do espaço de busca em problemas de Otimização via Simulação utilizando Análise Envoltória de Dados e Arranjos Ortogonais de Taguchi

Tese submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Doutor em Ciências em Engenharia de Produção.

Área de Concentração: Engenharia de Produção

Orientador: Prof. Dr. José Arnaldo Barra Montevechi

UNIVERSIDADE FEDERAL DE ITAJUBÁ PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Rafael de Carvalho Miranda

Redução do espaço de busca em problemas de Otimização via Simulação utilizando Análise Envoltória de Dados e Arranjos Ortogonais de Taguchi

Tese aprovada por banca examinadora em 28 de abril de 2015, conferindo ao autor o título de *Doutor em Ciências em Engenharia de Produção*.

Banca examinadora:

Prof. Dr. José Arnaldo Barra Montevechi (Orientador)

Prof. Dr. Fernando Augusto Silva Marins (UNESP)

Prof. Dr. Aneirson Francisco da Silva (UNESP)

Prof. Dr. Alexandre Ferreira de Pinho (UNIFEI)

Prof. Dr. Fabiano Leal (UNIFEI)

Prof. Dr. Fábio Favaretto (UNIFEI)

Prof. Dr. José Henrique de Freitas Gomes (UNIFEI)

Prof. Dr. Luiz Gonzaga Mariano de Sousa (UNIFEI)

Itajubá 2015

DEDICATÓRIA

A Deus, princípio e fim de todas as coisas, em especial a meus avós, meus pais, Jonas Olinto Miranda e Maria Aparecida de Carvalho Miranda, e à minha esposa, Alexandra.

AGRADECIMENTOS

A meus pais, Jonas Olinto Miranda e Maria Aparecida de Carvalho Miranda, por todo apoio e ensinamentos durante toda minha vida.

A minha esposa, Alexandra, pela paciência, compreensão nos momentos de ausência e por sempre estar a meu lado.

Ao professor José Arnaldo Barra Montevechi pela orientação desse trabalho e por toda amizade, auxílio e empenho ao longo de meu doutorado.

Aos professores e amigos, Aneirson Francisco da Silva e Fernando Augusto Silva Marins, por toda amizade e parcerias realizadas.

Ao professor Leonardo Chwif pelas contribuições realizadas a esta tese.

Ao professor Carlos Mello, por todo auxílio prestado como coordenador do programa de Pós Graduação em Engenharia de Produção.

Aos professores e amigos, Luiz Gonzaga, Alaor Campos e Carlos Sanches, por toda amizade e apoio.

Aos professores do Núcleo de Estudos Avançados para Auxílio à Decisão (NEAAD), Alexandre Pinho, André Medeiros, Fabiano Leal, Fábio Favaretto, José Hamilton, José Henrique, José Antonio de Queiroz e Josiane Lima.

A todos os meus amigos, em especial Aline, David, Eliza, Fernanda, Luiz Gustavo, Mona Liza, Rafael Florêncio, Tábata, Thiago Buselato, Paulo Campos, Paulo Rotela, Rogério e Ubirajara por sempre estarem a meu lado no que fosse preciso.

A todos os funcionários da UNIFEI, que direta ou indiretamente ajudaram nesse trabalho.

A CAPES, CNPq e à FAPEMIG pelo apoio e incentivo à pesquisa brasileira, em especial a essa.

Por fim, agradeço a Universidade Federal de Itajubá, a quem sempre terei uma dívida de gratidão eterna.

A todos vocês, meu muito obrigado!

EPÍGRAFE

"Se cheguei até aqui foi porque me apoiei no ombro dos gigantes."

Isaac Newton

RESUMO

O desenvolvimento de diversas metaheurísticas possibilitaram o uso da otimização em ambientes de simulação a eventos discretos. No entanto, este campo de pesquisa ainda é pouco utilizado, principalmente, em função do tempo necessário para a convergência desses algoritmos. Nesse sentido, a otimização via simulação é influenciada pela complexidade do modelo de simulação, pelo número de variáveis de decisão e por seus limites de variação. Neste contexto, este trabalho propõe um método capaz de identificar os melhores limites de variação, para cada variável de decisão, em um problema de otimização via simulação, proporcionando uma redução do tempo computacional, ao mesmo tempo em que permite alcançar soluções de elevada qualidade (soluções ótimas ou estatisticamente iguais a ela). Para isso, o método proposto combina a simulação a eventos discretos, arranjos ortogonais de Taguchi e a análise de supereficiência desenvolvida no modelo DEA BCC. Neste método, o espaço de busca do problema de otimização via simulação é representado por meio de um arranjo ortogonal de Taguchi. Para gerar as saídas do modelo DEA BCC, executou-se a simulação do arranjo ortogonal (cenários) e posteriormente a análise de supereficiência. Com base nestes resultados, os cenários são ordenados, sendo adotados como novos limites do problema de otimização os valores das variáveis dos dois cenários de maior supereficiência. Para validar o método proposto, foram utilizados quinze objetos de estudo. Os casos representam problemas complexos de empresas de manufatura e da área hospitalar. Dessa forma, sua eficácia pode ser verificada, uma vez que permitiu reduções médias de 97% no espaço de busca, e de 42% no tempo computacional necessário para se obter uma solução. Além disso, para quatro dos casos estudados, foi realizada a comparação entre o resultado ótimo obtido com a simulação de toda região de solução, e o resultado da otimização realizada no espaço de busca reduzido. Pode-se concluir, com um nível de 95% de confiança, que as respostas obtidas foram estatisticamente iguais.

Palavras Chaves: Simulação a eventos discretos; Otimização via simulação; DEA BCC; Supereficiência; Arranjos ortogonais de Taguchi.

ABSTRACT

The development of various meta-heuristics allowed for the optimization in discrete event simulation environments. Nevertheless, this research area is still underexplored, mainly in respect to the time needed for the convergence of these algorithms. In this sense, simulationbased optimization is influenced by the complexity of the simulation model, the number of variables of the decision, and by their ranges of variation. In this context, this paper proposes a method capable of identifying the best ranges for each decision variable, within simulationbased optimization problems, providing a reduction of computational cost, at the same time it allows to achieve high quality solutions (optimal solutions or statistically equal to it). The proposed method combines discrete-event simulation, Taguchi's orthogonal arrays, and analysis of super-efficiency in DEA BCC model. The Taguchi's orthogonal arrays are used to generate scenarios to be simulated; the analysis of super-efficiency is applied in a DEA BCC model to rank the scenarios; and the values of the variables of the two scenarios that presented the highest values of super-efficiency are adopted as a new range of the optimization problem. To illustrate its use and advantages, the method was applied in fifteen real cases associated to complex problems within manufacturing and medical area. Thereby its effectiveness can be verified, since it permitted average reductions of 97% in the search space and average reductions of 42% in the computational time needed to obtain a solution. Additionally, for four of the cases studied, it was performed comparison between results obtained from the optimization being made in the complete solutions set, and results from the optimization being made in the reduced search space generated by the method proposed here. It can be concluded with a 95% level of confidence that the responses obtained were statistically equal.

Keywords: Discrete-events simulation; Simulation optimization; DEA BCC; Superefficiency; Taguchi's orthogonal arrays.

LISTA DE FIGURAS

Figura 2.1 - Modelo de simulação	27
Figura 2.2 - Funcionamento da OvS	30
Figura 2.3 - Princípio de funcionamento de um modulo de otimização integrado à SED	31
Figura 2.4 - Métodos de OvS para variáveis contínuas	33
Figura 2.5 - Métodos de OvS para variáveis discretas	34
Figura 2.6 - Curva de um processo de produção	40
Figura 2.7 - Alcance da fronteira de eficiência	40
Figura 2.8 - Retornos crescentes, constantes e decrescentes de escala	41
Figura 3.1 - Classificação da pesquisa segundo a proposta de Miguel et al. (2010)	55
Figura 3.2 - Estrutura lógica da abordagem quantitativa	58
Figura 4.1 - Estrutura do método proposto para redução do espaço de busca em problema	as de
OvS	63
Figura 5.1 - Comparação dos resultados para o primeiro objeto de estudo	70
Figura 5.2 - Comparação dos resultados para o segundo objeto de estudo	74
Figura 5.3 - Comparação dos resultados para o terceiro objeto de estudo	78
Figura 5.4 - Comparação dos resultados para o quarto objeto de estudo	82
Figura 5.5 - Comparação dos resultados para o quinto objeto de estudo	86
Figura 5.6 - Comparação dos resultados para o sexto objeto de estudo	90
Figura 5.7 - Comparação dos resultados para o sétimo objeto de estudo	94
Figura 5.8 - Comparação dos resultados para o oitavo objeto de estudo	97
Figura 5.9 - Comparação dos resultados para o nono objeto de estudo	101
Figura 5.10 - Comparação dos resultados para o décimo objeto de estudo	104
Figura 5.11 - Comparação dos resultados para o décimo primeiro objeto de estudo	107
Figura 5.12 - Comparação dos resultados para o décimo segundo objeto de estudo	110
Figura 5.13 - Comparação dos resultados para o décimo terceiro objeto de estudo	113
Figura 5.14 - Comparação dos resultados para o décimo quarto objeto de estudo	116
Figura 5.15 - Comparação dos resultados para o décimo quinto objeto de estudo	120
Figura A.1 - Interface gráfica do software SimRunner®	146
Figura C.1 - Modelo conceitual para o primeiro objeto de estudo	148
Figura C.2 - Modelo conceitual para o segundo objeto de estudo	149
Figura C.3 - Modelo conceitual para o terceiro objeto de estudo	150

Figura C.4 - Modelo conceitual para o quarto objeto de estudo	.151
Figura C.5 - Modelo conceitual para o quinto objeto de estudo	.152
Figura C.6 - Modelo conceitual para o sexto objeto de estudo	.153
Figura C.7 - Modelo conceitual para o sétimo objeto de estudo	.154
Figura C.8 - Modelo conceitual para o oitavo objeto de estudo	.155
Figura C.9 - Modelo conceitual para o nono e décimo objeto de estudo	.156
Figura C.10 - Modelo conceitual para o décimo primeiro objeto de estudo	.157
Figura C.11 - Modelo conceitual para os objetos de estudo 12, 13, 14 e 15	.158
Figura D.1 - Tela do modelo computacional para o primeiro objeto de estudo	.159
Figura D.2 - Tela do modelo computacional para o segundo objeto de estudo	.159
Figura D.3 - Tela do modelo computacional para o terceiro objeto de estudo	.159
Figura D.4 - Tela do modelo computacional para o quarto objeto de estudo	.160
Figura D.5 - Tela do modelo computacional para o quinto objeto de estudo	.160
Figura D.6 - Tela do modelo computacional para o sexto objeto de estudo	.160
Figura D.7 - Tela do modelo computacional para o sétimo objeto de estudo	.161
Figura D.8 - Tela do Modelo computacional para o oitavo objeto de estudo	.161
Figura D.9 - Tela do Modelo computacional para o nono e décimo objetos de estudo	.161
Figura D.10 - Tela do modelo computacional para o décimo primeiro objeto de estudo	.162
Figura D.11 - Tela do modelo computacional para o objetos de estudo 12, 13, 14 e 15	.162

LISTA DE TABELAS

Tabela 2.1 - Análise bibliométrica: número de trabalhos publicados por palavra-chave	.21
Tabela 2.2 - Análise bibliométrica: número de trabalhos publicados por conjunto de palavra	ıs-
chave	.22
Tabela 2.3 - <i>Softwares</i> de Otimização via Simulação	.36
Tabela 2.4 - Arranjo Ortogonal L8 (2 ⁷)	.49
Tabela 2.5 - Arranjo Ortogonal L9 (3 ⁴)	.49
Tabela 2.6 - Arranjo Ortogonal L27 (3 ⁷)	.50
Tabela 2.7 - Arranjos Ortogonais padrão	.51
Tabela 2.8 - Arranjo Ortogonal de Taguchi e fatorial completo	.52
Tabela 2.9A - Matriz de seleção dos Arranjos Ortogonais	.52
Tabela 2.9B - Matriz de seleção dos Arranjos Ortogonais (Continuação)	.53
Tabela 2.10 - Arranjo Ortogonal L8 com 4 fatores e 2 níveis	.53
Tabela 5.1 - Variáveis de decisão, tipo e limites para o primeiro objeto de estudo	.66
Tabela 5.2 - Matriz experimental e resultados obtidos para o primeiro objeto de estudo	.67
Tabela 5.3 - Variáveis de decisão, tipo e novos limites para o primeiro objeto de estudo	.68
Tabela 5.4 - Resultados da otimização para o primeiro objeto de estudo	.68
Tabela 5.5 - Resultados dos testes estatísticos para o primeiro objeto de estudo	.69
Tabela 5.6 - Variáveis de decisão, tipo e limites para o segundo objeto de estudo	.71
Tabela 5.7 - Matriz experimental e resultados obtidos para o segundo objeto de estudo	.72
Tabela 5.8 - Variáveis de decisão, tipo e novos limites para o segundo objeto de estudo	.72
Tabela 5.9 - Resultados da otimização para o segundo objeto de estudo	.73
Tabela 5.10 - Variáveis de decisão, tipo e limites para o terceiro objeto de estudo	.75
Tabela 5.11 - Matriz experimental e resultados obtidos para o terceiro objeto de estudo	.76
Tabela 5.12 - Variáveis de decisão, tipo e novos limites para o terceiro objeto de estudo	.76
Tabela 5.13 - Resultados da otimização para o terceiro objeto de estudo	.77
Tabela 5.14 - Variáveis de decisão, tipo e limites para o quarto objeto de estudo	.79
Tabela 5.15 - Matriz experimental e resultados obtidos para o quarto objeto de estudo	.80
Tabela 5.16 - Variáveis de decisão, tipo e novos limites para o quarto objeto de estudo	.80
Tabela 5.17 - Resultados da otimização para o quarto objeto de estudo	.81
Tabela 5.18 - Variáveis de decisão, tipo e limites para o quinto objeto de estudo	.83
Tabela 5.19 - Matriz experimental e resultados obtidos para o quinto objeto de estudo	.84

Tabela 5.20 - Variáveis de decisão, tipo e novos limites para o quinto objeto de estudo84
Tabela 5.21 - Resultados da otimização para o quinto objeto de estudo
Tabela 5.22 - Resultados dos testes estatísticos para o quinto objeto de estudo
Tabela 5.23 - Variáveis de decisão, tipo e limites para o sexto objeto de estudo87
Tabela 5.24A - Matriz experimental e resultados obtidos para o sexto objeto de estudo88
Tabela 5.24B - Matriz experimental e resultados obtidos para o sexto objeto de estudo
(continuação)
Tabela 5.25 - Variáveis de decisão, tipo e novos limites para o sexto objeto de estudo89
Tabela 5.26 - Resultados da otimização para o sexto objeto de estudo90
Tabela 5.27 - Resultados dos testes estatísticos
Tabela 5.28 - Variáveis de decisão, tipo e limites para o sétimo objeto de estudo91
Tabela 5.29 - Matriz experimental e resultados obtidos para o sétimo objeto de estudo92
Tabela 5.30 - Variáveis de decisão, tipo e novos limites para o sétimo objeto de estudo93
Tabela 5.31 - Resultados da otimização para o sétimo objeto de estudo
Tabela 5.32 - Resultados dos testes estatísticos para o sétimo objeto de estudo94
Tabela 5.33 - Variáveis de decisão, tipo e limites para o oitavo objeto de estudo95
Tabela 5.34A - Matriz experimental e resultados obtidos para o oitavo objeto de estudo95
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)
Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)

Tabela 5.49 - Matriz experimental e resultados obtidos para o décimo primeiro objeto de
estudo
Tabela 5.50 - Variáveis de decisão, tipo e novos limites para o décimo primeiro objeto de
estudo106
Tabela 5.51 - Resultados da otimização para o décimo primeiro objeto de estudo106
Tabela 5.52 - Resultados dos testes estatísticos para o décimo primeiro objeto de estudo106
Tabela 5.53 - Variáveis de decisão, tipo e limites para o décimo segundo objeto de estudo. 107
Tabela 5.54 - Matriz experimental e resultados obtidos para o décimo segundo objeto de
estudo
Tabela 5.55 - Variáveis de decisão, tipo e novos limites para o décimo segundo objeto de
estudo109
Tabela 5.56 - Resultados da otimização para o décimo segundo objeto de estudo109
Tabela 5.57 - Resultados dos testes estatísticos para o décimo segundo objeto de estudo 109
Tabela 5.58 - Matriz experimental e resultados obtidos para o décimo terceiro objeto de
estudo111
Tabela 5.59 - Variáveis de decisão, tipo e novos limites para o décimo terceiro objeto de
estudo111
Tabela 5.60 - Resultados da otimização para o décimo terceiro objeto de estudo112
Tabela 5.61 - Resultados dos testes estatísticos para o décimo terceiro objeto de estudo 112
Tabela 5.62 - Matriz experimental e resultados obtidos para o décimo quarto objeto de estudo
114
Tabela 5.63 - Variáveis de decisão, tipo e novos limites para o décimo quarto objeto de estudo
115
Tabela 5.64 - Resultados da otimização para o décimo quarto objeto de estudo115
Tabela 5.65 - Resultados dos testes estatísticos para o décimo quarto objeto de estudo 116
Tabela 5.66A - Matriz experimental e resultados obtidos para o décimo quinto objeto de
estudo117
Tabela 5.66B - Matriz experimental e resultados obtidos para o décimo quinto objeto de
estudo (continuação)
Tabela 5.67 - Variáveis de decisão, tipo e novos limites para o décimo quinto objeto de estudo
118
Tabela 5.68 - Resultados da otimização para o décimo quinto objeto de estudo119
Tabela 5.69 - Resultados dos testes estatísticos para o décimo quinto objeto de estudo 119

Tabela 5.70 - Comparação dos resultados para o primeiro objeto de estudo com o ótimo
global
Tabela 5.71 - Testes estatísticos para o primeiro objeto de estudo em comparação com o
ótimo global
Tabela 5.72 - Comparação dos resultados para o segundo objeto de estudo com o ótimo global
Tabela 5.73 - Comparação dos resultados para o terceiro objeto de estudo com o ótimo global
Tabela 5.74 - Comparação dos resultados para o décimo objeto de estudo com o ótimo global
Tabela 5.75 - Testes estatísticos para o décimo objeto de estudo em comparação com o ótimo
global
Tabela 5.76 – Tempo estimado para execução de todo espaço de busca para os demais
objetos de estudo
Tabela 5.77 - Resultados das reduções do espaço de busca e do tempo computacional126
Tabela B.1 - Simbologia utilizada na técnica IDEF-SIM

LISTA DE ABREVIATURAS

ABS Agent-Based Simulation (Simulação Baseada em Agentes)

AG Algoritmo Genético

AO Arranjos Ortogonais de Taguchi

DEA Data Envelopment Analysis (Análise Envoltória de Dados)

DEA BCC Análise envoltória de dados com retornos variáveis de escala

DEA CCR Análise envoltória de dados com retornos constantes de escala

DMU Decision Making Unit (Unidade Tomadora de Decisão)

DOE Design of Experiments (Delineamento de Experimentos)

OvS Otimização via Simulação

PL Programação Linear

PO Pesquisa Operacional

SED Simulação a Eventos Discretos

WIP Work in process

WSC Winter Simulation Conference

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Objetivos geral e específicos	17
1.2 Condições de contorno da pesquisa	18
1.3 Estrutura da tese	19
2. FUNDAMENTAÇÃO TEÓRICA	20
2.1 Considerações iniciais	20
2.2 Contribuição científica e tecnológica	20
2.3 Simulação a eventos discretos	23
2.3.1 Introdução à simulação	23
2.3.2 Vantagens e desvantagens da simulação	25
2.4 Otimização via Simulação	27
2.4.1 Simulação combinada à Otimização	27
2.4.2 Princípios de funcionamento da Otimização via Simulação	30
2.4.3 Métodos de Otimização via Simulação	32
2.4.4 Softwares de Otimização via Simulação	34
2.4.5 Procedimento para Otimização via Simulação	36
2.5 Introdução à Análise Envoltória de Dados (DEA)	37
2.5.1 Conceitos básicos da Análise Envoltória de Dados (DEA)	38
2.5.2 Modelos DEA	41
2.5.2.1 Modelo DEA com retornos constantes de escala (DEA CCR)	42
2.5.2.2 Modelo DEA com retornos variáveis de escala (DEA BCC)	44
2.5.3 Métodos para ranqueamento e aumento de discriminação de DMUs em 1	modelos
DEA	46
2.6 Arranjos Ortogonais de Taguchi	48
2.6.1 Seleção do Arranjo Ortogonal	52
3. MÉTODO DE PESQUISA	55
3.1 Considerações iniciais	55
3.2 Classificação da pesquisa	55
3.3 Método de pesquisa quantitativo: experimentação	56
3.4 Etapas da pesquisa	58

	3.5 Aplicação das etapas da pesquisa	.59
4.	MÉTODO PROPOSTO PARA REDUÇÃO DO ESPAÇO DE BUSCA	.60
	4.1 Considerações iniciais	.60
	4.2 Técnicas utilizadas para proposição do método proposto e premissas assumidas	.60
	4.3 Método proposto para redução do espaço de busca em problemas de Otimização via	
	Simulação	.62
5.	APLICAÇÃO DO MÉTODO PROPOSTO	.64
	5.1 Considerações iniciais	.64
	5.2 Primeira classe de problemas de OvS	.65
	5.2.1 Primeiro objeto de estudo	.65
	5.2.1 Segundo objeto de estudo	.70
	5.3 Segunda classe de problemas de OvS	.74
	5.3.1 Terceiro objeto de estudo	.74
	5.3.2 Quarto objeto de estudo	.78
	5.3.3 Quinto objeto de estudo	.82
	5.4 Terceira classe de problemas de OvS	.87
	5.4.1 Sexto objeto de estudo	.87
	5.4.2 Sétimo objeto de estudo	.91
	5.4.3 Oitavo objeto de estudo	.94
	5.5 Quarta classe de problemas de OvS	.98
	5.5.1 Nono objeto de estudo	.98
	5.5.2 Décimo objeto de estudo	101
	5.5.3 Décimo primeiro objeto de estudo.	104
	5.6 Quinta classe de problemas de OvS	107
	5.6.1 Décimo segundo objeto de estudo	107
	5.6.2 Décimo terceiro objeto de estudo	110
	5.6.3 Décimo quarto objeto de estudo	113
	5.6.4 Décimo quinto objeto de estudo	117
	5.7 Comparação dos resultados obtidos com o ótimo global	120
	5.7.1 Primeiro objeto de estudo	121
	5.7.2 Segundo objeto de estudo	122
	5.7.3 Terceiro objeto de estudo	123
	5.7.4 Décimo objeto de estudo	124
	5.7.5 Demais objetos de estudo	125

5.8 Considerações finais	126
6. CONCLUSÃO	128
6.1 Verificação dos objetivos específicos	128
6.2 Considerações finais	129
6.3 Sugestões para trabalhos futuros	132
REFERÊNCIAS BIBLIOGRÁFICAS	133
ANEXO A - ProModel® e SimRunner®	144
ANEXO B - Símbolos IDEF-SIM	147
ANEXO C - Modelos conceituais em IDEF-SIM	148
ANEXO D - Modelos computacionais	159
ANEXO E - Formulação matemática dos modelos dos objetos de estudo	163
ANEXO F - Programação do modelo DEA BCC em GAMS	175
APÊNDICE - Artigos publicados em congressos e periódicos	183

1. INTRODUÇÃO

A maioria dos problemas associados com a otimização de sistemas reais, como em sistemas de manufatura, sistemas logísticos, gestão financeira, sistemas de transporte, dentre outros, são complexos demais para serem modelados analiticamente. Isso se deve principalmente a alta variabilidade desses sistemas, a sua dinâmica não linear, ao tamanho desses problemas, e a possibilidade da ocorrência de múltiplos objetivos. Nesse sentido, a Simulação a Eventos Discretos (SED) tem sido uma ferramenta útil para avaliar o desempenho de tais sistemas (LEE *et al.*, 2008).

A SED vem sendo utilizada de forma crescente, há mais de 40 anos, para apoiar à tomada de decisões (BANKS *et al.*, 2009; SARGENT, 2013; LAW, 2007; SIEBERS *et al.* 2010), principalmente, devido à sua versatilidade, flexibilidade e poder de análise (JAHANGIRIAN *et al.*, 2010; RYAN e HEAVEY, 2006). Esta já é apontada como uma das técnicas de pesquisa mais utilizadas em vários setores, permitindo o estudo de sistemas complexos, de forma mais econômica, rápida e flexível que a experimentação direta em sistemas reais, o que consumiria enormes recursos (SHEN e WAN, 2009; SHARDA e BURY, 2011).

Apesar de sua crescente utilização, uma das desvantagens da SED é que ela fornece apenas estimativas estatísticas e não resultados exatos, gerando uma alternativa ótima para um dado problema, apenas se algum método de otimização for utilizado acoplado ao módulo de simulação (STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014; HILLIER e LIEBERMAN, 2010).

Sem o uso conjunto de uma ferramenta de otimização, um analista teria de simular várias configurações do sistema real em busca daquela que apresente o melhor desempenho, o que muitas vezes são insuficientes do ponto de vista da otimização (LAW e MCCOMAS, 2002; LEE *et al.*, 2008). Sendo assim, para Lee *et al.* (2008) uma abordagem que integre simulação e otimização é muitas vezes necessária.

De modo a contornar esta limitação, surge o conceito da Otimização via Simulação (OvS) (FU *et al.*, 2000), sendo utilizado de forma crescente a partir da década de 90, devido principalmente a pacotes de simulação que já possuem rotinas de otimização integradas (FU, 2002, FU *et al.*, 2000, BANKS *et al.*, 2009).

Apesar dos avanços ocorridos nos *softwares* de otimização para modelos de simulação, uma crítica comum a estes pacotes comerciais é que, ao manipularem mais de uma variável de entrada, tais *softwares* tornam-se muito lentos (APRIL *et al.*, 2003; BANKS, 2001;

HARREL, GHOSH e BOWDEN, 2004; MIRANDA *et al.*, 2014; STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014).

Nesse mesmo sentido, para Pinho *et al.* (2012), Wu *et al.* (2009), Jia *et al.* (2007), April *et al.* (2003) e Banks (2001), a grande limitação da OvS, está no número de variáveis a serem otimizadas, sendo o desempenho da otimização reduzido drasticamente quando um modelo com muitas variáveis é otimizado.

Além disso, para Hillier e Lieberman (2010), apesar dos grandes avanços nos *softwares*, a simulação ainda pode ser considerada uma forma de tomada de decisão relativamente lenta e custosa no estudo de sistemas estocásticos complexos. Para tais sistemas, normalmente se requer grandes despesas e tempo para análise e programação, além de considerável tempo de processamento computacional.

Dessa forma, segundo Cabrera *et al.* (2012), a Busca Exaustiva pode ser usada para problemas de natureza discreta e combinatória, como são na maioria dos casos os problemas de OvS. No entanto, a fim de determinar a melhor solução, pode ser necessário testar cada possível solução para um problema e verificar se esta satisfaz suas restrições. Isso eleva o tempo computacional, sendo diretamente proporcional ao número de possíveis soluções, o que pode levar a uma explosão combinatória, para os casos em que os limites de variação das variáveis de decisão possuem grande amplitude.

Este problema é agravado quando o analista avalia múltiplos objetivos. Para Siegmund *et al.* (2012), problemas de OvS multiobjetivos são, em muitos casos, difíceis de resolver, devido ao grande número de simulações que são necessárias, a fim de encontrar um conjunto diversificado de soluções ótimas.

De modo a contornar este problema, vários estudos tem se concentrado em desenvolver métodos de otimização ou aprimorar metaheurísticas que aumentem a eficiência do processo de OvS (BACHELET e YON, 2007; JACOBSON e MCLAY, 2009; KESKIN, 2010; LEE *et al.*, 2008; LIN, SIR e PASUPATHY, 2013; MIRANDA, 2012; PINHO *et al.*, 2012, SIEGMUND *et al.*, 2012; WILLIS e JONES, 2008; YANG, 2009), buscando boas soluções em um tempo computacional aceitável. Porém, poucos estudos se destacam em limitar o espaço de busca dos problemas de OvS, trabalhando apenas com as variáveis de maior significância e com a melhor faixa de valores para cada variável.

Dentro do contexto apresentado, essa tese foi desenvolvida visando eliminar essa lacuna presente na literatura, sendo motivada pela seguinte questão de pesquisa:

Como reduzir o espaço de busca de um problema de OvS, de forma que o novo espaço de busca contemple a solução ótima e permita reduzir o tempo computacional do processo de

otimização?

Para responder à questão de pesquisa, essa tese propõe um método que integra os Arranjos Ortogonais de Taguchi - AO (TAGUCHI, 1987), a Simulação a Eventos Discretos – SED (BANKS *et al.*, 2009) e a Análise Envoltória de Dados com retornos variáveis de escala – DEA BCC (BANKER, CHARNES e COOPER, 1984) associada ao conceito da Supereficiência (ANDERSEN e PETERSEN, 1993).

Os Arranjos Ortogonais de Taguchi (AO) são empregados, nesta tese, para uma préavaliação do espaço de busca do problema de OvS, uma vez que estes arranjos permitem a geração de uma matriz experimental mais diversificada que outras estratégias fatoriais, frequentemente empregadas na literatura. De fato, segundo Ross (1996), a vantagem da utilização dos AO consiste na capacidade de se avaliar vários fatores em vários níveis, com um número mínimo de testes.

Em relação à Análise Envoltória de Dados (DEA), esta consiste em uma metodologia não paramétrica criada por Charnes, Cooper e Rhodes (1978), para mensuração comparativa da eficiência de unidades tomadoras de decisão - DMUs (COOK e SEIFORD, 2009). A DEA permite identificar as DMUs que sejam referências para as demais analisadas, formando uma fronteira de eficiência. Devido às características dos problemas de OvS foi utilizado nesta tese, o modelo DEA BCC (BANKER, CHARNES e COOPER, 1984).

Os modelos DEA clássicos consideram as DMUs com índices de eficiência iguais a um, como sendo eficientes, e as DMUs com índices de eficiência menores que um, como ineficientes. No entanto, várias DMUs podem possuir índices de eficiência iguais a um. Neste caso, como forma de lidar com essa limitação Andersen e Petersen (1993) propuseram o conceito da Supereficiência. Este método promove uma alteração na formulação do modelo DEA BCC, permitindo que as DMUs eficientes possuam índices de eficiência superiores a um, permitindo assim, ranquear as DMUs mais eficientes.

Dessa forma, com base nesse *ranking* de supereficiência, torna-se possível reduzir o espaço de busca do problema por meio da identificação dos cenários mais eficientes do AO, incrementando, dessa forma, a eficiência do processo de OvS.

1.1 Objetivos geral e específicos

O objetivo geral deste trabalho é desenvolver um método que permita reduzir o espaço de busca em problemas de Otimização via Simulação, limitando dentro dessa nova região de busca, soluções que contemplem a solução ótima ou soluções estatisticamente iguais a ela.

Com isso, espera-se diminuir o tempo computacional envolvido no processo de OvS.

Como objetivos específicos desta pesquisa, tem-se:

- Desenvolver o método de otimização, integrando os arranjos ortogonais de Taguchi, a simulação a eventos discretos e a DEA BCC aliada ao conceito da supereficiência;
- Aplicar o método desenvolvido em modelos de SED, a fim de validar sua aplicabilidade, por meio da comparação dos resultados encontrados pelo método proposto com os resultados encontrados a partir de um software comercial de OvS;
- Quantificar as reduções do espaço de busca e do tempo computacional alcançados com a aplicação do método;
- Comparar os resultados encontrados na aplicação do método com os resultados encontrados com a simulação de todo o espaço de busca (ótimo global).

1.2 Condições de contorno da pesquisa

O método proposto para a redução do espaço de busca em problemas de OvS desenvolvido nesta tese, se aplica a modelos de SED, cujas variáveis de decisão (variáveis de entrada) sejam do tipo: discretas, determinísticas e inteiras.

Este fato é justificado uma vez que, para Nelson (2010), as variáveis de decisão em muitos problemas de OvS, são naturalmente discretas. No entanto, apesar deste fato, segundo o autor, a literatura oferece mais destaque para problemas de OvS com variáveis do tipo contínuas. Ainda em relação a esse fato, Swisher *et al.* (2004) realizaram uma *survey* sobre a OvS com variáveis discretas e apontaram, que a maioria dos trabalhos até então publicados focavam problemas com variáveis contínuas. Nesse sentido, Hong e Nelson (2006) enfatizam que o interesse das pesquisas em OvS tem mudado dos estudos com variáveis contínuas para problemas com variáveis discretas.

Os resultados alcançados com a aplicação do método são restritos a aplicações em modelos de SED, relacionados à alocação de recursos na área de manufatura e médica, na qual a simulação é amplamente utilizada para apoio à tomada de decisão (JAHANGIRIAN *et al.*, 2010). Problemas envolvendo a definição do número de pessoas e equipamentos para aumento de desempenho são destacados por Law (2007), como uma importante classe de problemas para a SED.

Destaca-se também, que todos os modelos de simulação utilizados nesta tese foram construídos com o simulador *ProModel*® e otimizados com o otimizador *SimRunner*®. Maiores detalhes sobre esses *softwares* podem ser obtidos no Anexo A desta tese. Dessa

forma, os resultados alcançados com a aplicação do método proposto são válidos para otimizadores baseados em algoritmos genéticos ou estratégias evolutivas, assim como o otimizador comercial *SimRunner*®.

Por fim, cabe ressaltar que não faz parte do escopo desta tese abordar a eficiência de heurísticas e métodos de otimização para problemas de OvS. Também não faz parte desta pesquisa avaliar técnicas de otimização que possibilitem aumentar a eficiência do processo de OvS.

1.3 Estrutura da tese

A presente tese encontra-se estruturada em mais cinco capítulos.

O Capítulo 2 apresenta a fundamentação teórica que alicerça o trabalho, bem como a contribuição científica e tecnológica do trabalho desenvolvido, evidenciada por meio de uma análise bibliométrica. Buscou-se, neste capítulo, sumarizar o que há de mais recente na literatura sobre Simulação a Eventos Discretos, Otimização via Simulação, DEA e os Arranjos Ortogonais de Taguchi. Para tal, uma revisão de literatura foi realizada, contemplando, principalmente, periódicos internacionais e nacionais, artigos de congressos, livros, teses e dissertações.

O Capítulo 3 apresenta o método de pesquisa utilizado nesta tese e a classificação da pesquisa. Também é descrita a estrutura lógica para a condução de uma pesquisa quantitativa.

O Capítulo 4 apresenta o método proposto para redução do espaço de busca para um problema de OvS. Todas as ferramentas utilizadas para sua proposição, bem como os passos necessários ao seu emprego são apresentados. Neste capítulo, também são expostas as premissas consideradas para sua proposição.

O Capítulo 5 aplica o método desenvolvido em quinze modelos de SED, e compara os resultados encontrados com os resultados da otimização sem a aplicação do método. Neste capítulo, também é apresentada a comparação dos resultados encontrados a partir da aplicação do método proposto nesta tese, com os resultados ótimos globais dos problemas de OvS para quatro objetos de estudos.

Por fim, o Capítulo 6 encerra o trabalho, apresentando as principais conclusões obtidas, verifica se os objetivos propostos foram cumpridos e propõe sugestões para trabalhos futuros, sendo seguido das referências, anexos e apêndices.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações iniciais

Este capítulo apresenta o referencial teórico que suporta esta tese. Sumariza-se aqui o estado da arte em SED, OvS, DEA e Arranjos Ortogonais de Taguchi (AO). Para tal, uma revisão de literatura foi realizada abrangendo principalmente, periódicos internacionais e nacionais, artigos de congressos, livros, teses e dissertações.

Antes de iniciar a fundamentação teórica, um estudo bibliométrico foi conduzido em seis importantes bases de dados internacionais, como forma de assegurar o ineditismo da proposta apresentada nessa tese, bem como destacar sua contribuição científica e tecnológica.

A fundamentação teórica se iniciou pela apresentação dos principais conceitos relacionados à SED, destacando principalmente suas vantagens e desvantagens, como importante ferramenta de apoio a tomada de decisão.

No que diz respeito à OvS, foram explorados: os principais conceitos para otimização mono e multiobjetivo, seu princípio de funcionamento, as principais técnicas e procedimentos de otimização, os principais *softwares* de otimização existentes no mercado, e, por fim, o método para utilização da OvS.

Em relação à DEA, foram apresentados seus principais conceitos, os modelos clássicos com retornos constante de escala (DEA CCR) e com retornos variáveis de escala (DEA BCC), e os principais métodos para aumento de discriminação de DMUs (*Decision Making Units*).

Por fim, esse capítulo é encerrado com os AO, com a apresentação de seus principais conceitos e tipos de arranjos.

2.2 Contribuição científica e tecnológica

De forma a comprovar a relevância do trabalho e comprovar sua contribuição científica e tecnológica para o campo de pesquisa, uma análise bibliométrica foi realizada, focando os três principais temas desta tese: a Otimização via Simulação, a DEA e os Arranjos Ortogonais de Taguchi.

A análise bibliométrica foi realizada no dia 06/01/2014, abrangendo trabalhos disponíveis nas seguintes bases de dados: *Scopus, Emerald, ISI Web of Knowledge, Taylor & Francis, Palgrave e Scielo*. Para Herculano e Norberto (2012), as bases utilizadas são constituídas de importantes periódicos multidisciplinares e reconhecidos internacionalmente. Estes autores destacam a abrangência da base *Scopus*, como a maior base de dados de artigos

e resumos. Os autores destacam, ainda, a base *Scielo*, como um importante repositório de dados de países ibero-americanos, entre eles, o Brasil.

Na análise bibliométrica, buscou-se pelas três principais palavras-chave deste trabalho e suas variações. O termo *Simulation Optimization* é um dos mais comuns em trabalhos presentes na literatura, no entanto, os termos *Simulation via Optimization* e *Simulation based Optimization*, também são encontradas. Desta forma, todos estes termos fizeram parte da análise bibliométrica. O mesmo ocorreu com os Arranjos Ortogonais de Taguchi, no qual se procurou pelos termos: *Taguchi Arrays*, *Taguchi Methods*, *Taguchi's Orthogonal Arrays* e *Orthogonal Arrays*. Em relação à DEA, foram realizadas buscas, tanto pela sigla DEA, como pela expressão *Data Envelopment Analysis*. A busca realizada na base de dados *Scielo* foi realizada, tanto com termos em língua inglesa, como em língua portuguesa.

Na análise bibliométrica, foram realizadas buscas pelas palavras em separado, bem como estas palavras em associação. Não se especificou o período da busca, de modo que, a análise foi conduzida a partir de artigos e livros disponíveis nas bases de dados, de 06/01/2014 até onde houvesse registros. Com isso, foi possível quantificar o número de trabalhos publicados por base de dados. Os resultados encontrados por palavras-chave são apresentados na Tabela 2.1.

Simulation Optimization Taguchi Arrays ou ou Simulation via Taguchi Methods ou DEA ou Data Taguchi Orthogonal Optimization ou Base de dados Envelopment Simulation based Arrays ou Orthogonal Analysis Optimization ou Simulação Arrays ou Arranjos via otimização ortogonais de Taguchi 10969 Scopus 53077 69 101 1174 218 Emerald ISI Web of Knowledge 1271 9427 11 Taylor & Francis 849 7343 1 37 Palgrave 168 1 37 8 Scielo 0

Tabela 2.1 - Análise bibliométrica: número de trabalhos publicados por palavra-chave

Pode-se constatar uma grande quantidade de trabalhos que abordam os temas de pesquisa desta tese, quando analisados em separado. Com destaque para pesquisas envolvendo a DEA, seguido pela OvS, e por fim, trabalhos que abordam os Arranjos de Taguchi.

Cabe destacar que, nem todos os trabalhos mencionados como sendo de OvS, abordam problemas de otimização de modelos de SED, uma vez que tal expressão é comum à otimização de outros tipos de simulação.

Ao se procurar pelas três palavras-chave em conjunto, refinando a busca por aparições no título, resumo e palavras-chave das obras, em nenhuma das seis bases de dados foram encontrados trabalhos, que como esta tese, combinam estes três campos de pesquisa.

Quando esta busca é realizada, sem limitação de local onde a palavra buscada pode aparecer, 11 artigos foram encontrados na *Scopus*, um na *Emerald* e um na base de dados *Palgrave*. Estes resultados podem ser visualizados na Tabela 2.2.

Tabela 2.2 - Análise bibliométrica: número de trabalhos publicados por conjunto de palavras-chave

Base de dados	Simulation Optimization + DEA + Taguchi Arrays (Título, resumo, palavras chave)	Simulation Optimization + DEA + Taguchi Arrays (Todos os campos)
Scopus	0	11
Emerald	0	1
ISI Web of Knowledge	0	0
Taylor & Francis	0	0
Palgrave	0	1
Scielo	0	0

Dos 11 artigos encontrados na *Scopus*, os trabalhos de Al-Refaie *et al.* (2014), Ismail, Thorwarth e Arisha (2014) e Azadeh e Alem (2010) fazem uso da SED e da DEA para análise de eficiência de cenários, visando a identificação dos cenários eficientes. Lin, Sir e Pasupathy (2013) propõem um método de OvS baseado em algoritmos genéticos (AG), que faz uso da DEA para definição dos parâmetros do AG. Azadeh *et al.* (2009) trabalham com a simulação de Monte Carlo e DEA. Nestes cinco trabalhos, o termo "Arranjo de Taguchi" aparece apenas nas referências bibliográficas. Os demais trabalhos encontrados na análise bibliométrica desta base de dados (IÇ, 2014; GHOSH, CHAKRABORTY e DAN, 2012; IÇ, 2012; BEHZADIAN *et al.*, 2012; AZADNIA *et al.*, 2011; ALEM *et al.*, 2009) fazem menções aos termos da pesquisa, sem que apresentem qualquer ligação entre si.

No artigo encontrado na *Emerald*, Sipahi e Timor (2010) fazem uma discussão sobre os métodos *Analytic Hierarchy Process* (AHP) e *Analytic Network Process* (ANP). Os termos pesquisados aparecem no texto sem qualquer ligação entre eles. O trabalho de Muñoz-Seca e Riverola (2004), disponível na base *Palgrave*, é um livro, que aborda a gestão do conhecimento como forma de impulsionar o desenvolvimento de uma empresa. Assim como no caso anterior, os termos buscados aparecem sem nenhuma relação entre si. Como pode ser observado, com base na análise bibliométrica realizada em seis grandes bases de dados, nenhum trabalho encontrado se aproxima dos objetivos propostos nesta tese.

Mesmo quando se analisam trabalhos disponíveis na literatura, combinando dois dos temas de pesquisa aqui explorados, estes se diferenciam da abordagem aqui proposta. O foco principal destes trabalhos é a análise de eficiência dos cenários desenvolvidos via arranjos de Taguchi (AZADEH *et al.*, 2013) ou a aplicação do Método de Taguchi para otimização em conjunto com a simulação (KUO, YANG e HUANG, 2008), não trabalhando com a redução do espaço de busca em problemas de OvS, fato este que comprova seu ineditismo.

Assim, pode-se destacar como contribuições de caráter científico e tecnológico desta tese, a integração do Arranjo de Taguchi com a DEA e com a OvS, propiciando uma redução substancial, tanto no espaço de busca, como no tempo computacional necessário para a solução de problemas reais, complexos e de grande porte.

2.3 Simulação a eventos discretos

2.3.1 Introdução à simulação

Segundo Gagliardi, Renaud e Ruiz (2014), a modelagem de sistemas reais é complexa demais para ser avaliada apenas por modelos analíticos. Para superar essa barreira, analistas assumem simplificações da realidade. No entanto, o fato da maioria destes sistemas serem estocásticos, faz com que a utilização de modelos puramente analíticos seja um grande problema. Nestes casos, os autores recomendam o uso da SED.

Para Banks *et al.* (2009), a SED pode ser definida como sendo a imitação de um processo ou sistema do mundo real, observado com o passar do tempo. A simulação envolve a geração de uma história artificial do sistema, e a observação dessa história para se fazer inferências a respeito das características da operação do sistema real representado. Ainda segundo o autor, o comportamento do sistema é avaliado com o passar do tempo, com o auxílio de um modelo computacional, que uma vez validado permite responder a inúmeras perguntas do tipo: "What if?".

O avanço da SED sempre esteve associado ao avanço da computação (JENKINS e RICE, 2009). Durante as décadas de 50 e 60, os primeiros modelos de simulação foram criados, utilizando linguagens de programação gerais (JENKINS e RICE, 2009), que depois evoluíram, ao longo dessas décadas, para linguagens de programação voltadas à simulação (PIDD, 2004). Para Kelton, Sadowski e Sturrock (2007), durante essas décadas, a simulação era uma ferramenta cara e especializada, sendo utilizada principalmente por grandes corporações.

Ainda segundo o autor, a SED, tal como é conhecida e utilizada hoje, iniciou-se nas décadas de 70 e 80, tendo nesse período passado a fazer parte dos cursos de Engenharia de Produção e Pesquisa Operacional.

Para Banks *et al.* (2009), a utilização da simulação passa realmente a crescer, a partir da década de 1990, com o surgimento dos *softwares* de simulação com interfaces gráficas com o usuário, cuja disseminação foi facilitada com a introdução dos computadores pessoais. É nesse período também, que Kelton, Sadowski e Sturrock (2007) destacam que várias empresas, de diferentes portes, passaram a utilizar a SED desde os primeiros estágios de seus projetos.

Segundo Montevechi *et al.* (2010) e Besseris (2012), a necessidade de se incrementar o desempenho da indústria, associada a busca constante pela redução de custos, estimulou a utilização da SED nas empresas modernas.

Para Ingals (2013), a SED é uma poderosa ferramenta de apoio à tomada de decisão, se compreendida e utilizada de forma correta. Siebers *et al.* (2010) destacam que nas últimas quatro décadas, a utilização da SED foi uma das principais ferramentas empregadas em Pesquisa Operacional.

Dengiz e Belgin (2014) enfatizam que, a simulação serve como uma poderosa ferramenta para solução de problemas enfrentados em sistemas estocásticos, ao mesmo tempo em que permite investigar o comportamento de diferentes problemas reais, de modo a operacionalizar a tomada de decisão sobre várias condições.

Segundo Banks *et al.* (2009), com a evolução dos estudos na área, a SED vem sendo cada vez mais utilizada, e os benefícios obtidos por ela tem gerado impactos nos mais diferentes sistemas. Ainda segundo Hillier e Lieberman (2010), a popularidade da SED cresce continuamente. Tal fato é corroborado por Robinson *et al.* (2014), que consideram que na última década ocorreu um interesse crescente pelo uso da SED como uma ferramenta para facilitar a modelagem de sistemas complexos reais.

Para Hillier e Lieberman (2010), devido à diversidade de aplicações, é difícil enumerar todas as áreas nas quais a SED vem sendo utilizada. Nesse sentido, Banks *et al.* (2009) e Hillier e Lieberman (2010) destacam as seguintes aplicações mais comuns para a SED, tomando por base as publicações de artigos no *Winter Simulation Conference* (WSC): aplicações em manufatura, gerenciamento de projetos, logística, *supply chain* e redes de distribuição, modelagem de transporte e tráfego, construção civil, gestão de estoques, análise de riscos, aplicações médicas, aplicações militares e aplicações nas mais diversas áreas de

serviços, tais como: serviços governamentais, bancos, hotelaria, restaurantes, instituições educacionais, entre outros.

No Workshop de PO realizado pela Sociedade de Pesquisa Operacional do Reino Unido em 2010 (SW10), Sibers et al. (2010) provocaram uma discussão sobre o tema: Discrete-event simulation is dead, long live agent-based simulation!, que posteriormente foi publicado na forma de um artigo no Journal of Simulation. Neste trabalho, os autores chamam a atenção de uma nova modalidade de simulação, a Simulação Baseada em Agentes ou Agent-Based Simulation (ABS). Apesar do título provocador do trabalho, os autores apresentam a ABS, como uma ferramenta promissora, com grande campo de aplicação, mas que ainda é pouco utilizada e explorada em PO e com poucas publicações relacionadas a sua utilização.

De forma a se contrapor a discussão proposta por Sibers *et al.* (2010), Brailsford (2014) respondeu a provocação colocada por aqueles autores com o artigo: *Discrete-event simulation is alive and kicking!*, publicada no mesmo *Journal of Simulation*. Para o autor a suposição da morte da SED é exagerada, e ressalta que vários dos benefícios alcançados com a ABS podem ser reproduzidos, sem grandes problemas, com a tradicional SED.

2.3.2 Vantagens e desvantagens da simulação

Para Chwif e Medina (2010), devido à grande complexidade dos sistemas reais, ocasionada pela natureza dinâmica e aleatória destes sistemas, uma das maiores vantagens da SED é a sua capacidade de reproduzir, em um modelo computacional, o mesmo comportamento que o sistema teria, caso estivesse submetido às mesmas condições.

Nesse mesmo sentido, para Bateman *et al.* (2013), a simulação permite determinar, com auxílio de um modelo do sistema real, como um sistema responderá a mudanças em sua estrutura, ambiente ou condições de contorno.

Law e Kelton (2000) destacam como uma das maiores vantagens do uso da simulação, a capacidade da SED prover, aos tomadores de decisão, uma visão completa de todo o sistema produtivo, facilitando a tomada de decisão e a implementação de ações.

Law (2009) chama a atenção da SED ser uma alternativa à experimentação real, evitando os custos necessários com a implementação no chão de fábrica, além dos custos ocasionados pela interrupção do fluxo produtivo.

Banks *et al.* (2009) consideram inúmeras vantagens proporcionadas pela simulação, embora ressaltem que a SED também traga algumas desvantagens. Estes autores destacam as seguintes vantagens com a utilização da SED:

- Definições de *layouts*, projetos de equipamentos e sistemas de transportes podem ser testados com auxílio da SED, sem a necessidade de recursos ou compra de equipamentos;
- A SED permite visualizar as interações entre variáveis e a importância de seus efeitos para o sistema como um todo;
- Gargalos produtivos podem ser identificados e analisados;
- A SED permite localizar onde o estoque em processo e materiais que estão em excesso se encontram no sistema;
- A SED facilita a compreensão de como opera todo o sistema simulado, ao invés de apenas visualizar como operam suas partes;
- A SED permite responder questões do tipo "What if", o que é útil na proposição de novos sistemas.

Apesar das vantagens apresentadas, Banks *et al.* (2009) e Law e Kelton (2000) destacam algumas desvantagens de seu uso. Dentre elas:

- A modelagem computacional de um sistema real por um modelo de SED, geralmente é cara e consome tempo para ser desenvolvida;
- É necessário, por parte do modelador ou analista de simulação, que este seja treinado em um simulador ou que conheça alguma linguagem de programação;
- Os resultados alcançados com o modelo de simulação podem ser difíceis de serem interpretados, principalmente devido a seu caráter estocástico;
- Existe a necessidade que o modelo computacional seja validado, caso contrário, as informações que forem provenientes deste não terão usabilidade;
- Cada rodada de um modelo de simulação produz apenas estimativas de uma dada saída do modelo. Dessa forma, serão necessárias várias replicações para cada conjunto de parâmetros, de modo que os resultados possam ser interpretados corretamente;
- A simulação pode ser utilizada de forma equivocada, quando uma solução analítica para um dado problema é possível ou até mesmo preferível.

Carson (2004) destaca, ainda, que o tempo dísponivel para a condução de um projeto de simulação pode não ser suficiente para a elaboração de um estudo confiável, fazendo com que os tomadores de decisão tomem conclusões equivocadas, com base em um modelo incorreto.

2.4 Otimização via Simulação

2.4.1 Simulação combinada à Otimização

Para Dengiz e Belgin (2014), a concorrência mundial faz com que as empresas tenham que encontrar novas maneiras de produzir produtos de forma mais rápida, mais barata e mais eficiente. Nesse sentido, o uso da simulação permite investigar o comportamento destes sistemas e os efeitos de fatores sobre seu desempenho. No entanto, sem a utilização da otimização associada à simulação, abordagens experimentais baseadas em tentativa e erro, elevam o tempo computacional necessário para se identificar uma solução, o que pode ser agravado com a complexidade do sistema simulado.

Segundo Swisher *et al.* (2000), Fu (2002), Ólafsson e Kim (2002) e Eskandari *et al.* (2011), pode-se definir a Otimização via Simulação como o processo de procurar o melhor conjunto de soluções para um modelo de simulação, ou seja, seus parâmetros ou variáveis de entrada, de forma a otimizar as saídas do modelo.

Para Carson e Maria (1997), um modelo de simulação geralmente inclui n variáveis de entrada $(x_1, x_2, ..., x_n)$ e m variáveis de saída $(f_1(x), f_2(x), ..., f_m(x))$ ou $(y_1, y_2, ..., y_m)$ (Figura 2.1).

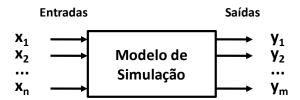


Figura 2.1 - Modelo de simulação Fonte: Adaptado de Carson e Maria (1997)

Para Harrel *et al.* (2002), o uso da otimização visa responder perguntas do tipo: Quais os ajustes ótimos das variáveis de entrada $(x_1, x_2,..., x_n)$ que maximizam (ou minimizam) uma ou mais variáveis de saída $(y_1, y_2, ..., y_m)$ no modelo de simulação? Nesse caso, com a utilização da OvS, visa-se encontrar um valor ótimo, que maximize ou minimize uma determinada saída do modelo.

Chwif e Medina (2010) destacam como vantagem da OvS, o fato de se ter um procedimento sistemático para a otimização de variáveis, evitando o método de tentativa e erro. Ainda para os autores, com a integração alcançada pela OvS, a simulação passa a ser uma geradora de soluções e não apenas uma avaliadora de possíveis soluções para o problema.

Para Swisher *et al.* (2000), os parâmetros de entrada de um modelo de simulação podem ser tanto discretos como contínuos, ou até mesmo uma mistura dos dois. Sendo que os tipos

de parâmetros de entradas, bem como suas faixas de variação, influenciarão na região de busca e no método de otimização a ser empregado. Entretanto, conforme comentado por Nelson (2010), a maioria das variáveis de decisão em problemas de OvS são discretas, havendo uma carência por trabalhos na literatura com estas características.

Fu (1994) define um problema de OvS, com um único objetivo, como sendo (Eq. 2.1):

$$\min f(\theta) \tag{2.1}$$

Sujeito a: $\theta \in \Theta$

sendo $f(\theta) = E[\psi(\theta, \omega)]$ o valor esperado do desempenho do sistema, estimado a partir de amostras do modelo de simulação; e $\psi_j(\theta, \omega)$ valores de desempenho observados segundo parâmetros de entrada discretos ou contínuos, pertencentes a um conjunto viável Θ .

Apesar de a literatura dar maior destaque à OvS com um único objetivo (WILLIS e JONES, 2008), Jones *et al.* (2002) comentam, que usualmente os problemas do mundo real possuem múltiplos objetivos (DEB, 2001), que em geral são conflitantes entre si. Estes autores destacam ainda que, além da complexidade de resolução natural associada à otimização multiobjetivo, em um problema real, deve-se levar em consideração uma possível aleatoriedade nos dados de entrada, o que torna esta tarefa difícil de ser realizada (JONES *et al.*, 2002).

Para Steponavičė, Ruuska e Miettinen (2014), um problema de otimização multiobjetivo pode ser formulado como sendo (Eq. 2.2):

$$\min_{\mathbf{x}} E\{f(\phi(\mathbf{x}, \boldsymbol{\omega}))\}$$
 (2.2)

Sujeito a: $x \in S$

sendo que $E\{\cdot\}$ indica o valor esperado, f é o valor do vetor da função objetivo, ϕ é o modelo estocástico, x é o vetor decisão, ω é um vetor randômico que representa a estocasticidade no modelo, e S é o conjunto viável.

Em problemas de OvS, um modelo estocástico ϕ é resolvido por simulação e suas saídas geram uma amostra que é utilizada em (2.2). Desta forma, a função objetivo f é avaliada pelo valor médio desta amostra. Assim, o problema (Eq. 2.2) pode ser reescrito na forma (Eq. 2.3) (STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014):

$$\min_{\mathbf{x}} \frac{1}{N} \sum_{i=1}^{N} f(\phi_i(\mathbf{x})) \tag{2.3}$$

Sujeito a: $x \in S$

sendo que, para todo $x \in S$, $\phi_i(x)$ indica a saída da *i*-ésima simulação (ou replicação) e N é o número de replicações. Para Steponavičė, Ruuska e Miettinen (2014), problemas como estes são conhecidos por problemas de otimização *black-box*, porque as saídas do modelo de simulação $\phi_i(x)$ não são conhecidas de uma forma fechada, mas devem ser obtidas numericamente para cada $x \in S$.

Kleijnen, Beers e Nieuwenhuyse (2010) reconhecem os problemas de OvS como sendo, em geral, problemas de difícil solução ou *NP-Hard* (ALLAOUI e ARTIBA, 2004). Estes autores apresentam como desvantagens de sua utilização, o fato das saídas dos modelos de SED serem provenientes de funções implícitas e expostas a ruídos, bem como, dependendo do número de variáveis de entradas no modelo de simulação e de seus intervalos de variação, o processo de otimização pode se tornar complexo, devido às exigências computacionais e ao tempo envolvido para convergência.

Nesse mesmo sentindo, Steponavičė, Ruuska e Miettinen (2014) destacam os seguintes desafios computacionais para OvS:

- Tempo computacional: na OvS a função objetivo e as restrições não dependem apenas das variáveis de decisão, mas também, indiretamente do modelo de simulação. Dessa forma, para se avaliar uma dada configuração para o sistema, o modelo de simulação deve ser executado, podendo levar de alguns minutos, há alguns dias ou até mesmo semanas para se obter uma dada resposta. Esse tempo é diretamente proporcional ao número de vezes que o otimizador precisa avaliar a função objetivo e suas restrições. Dessa forma, o tempo computacional é um importante fator limitador para a OvS (STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014);
- Conflito de objetivos: com múltiplos objetivos, a identificação da melhor solução requer a participação do tomador de decisão e o devido apoio metodológico para se explorar as diversas possíveis soluções Pareto-ótimas (STEPONAVIČE, RUUSKA e MIETTINEN, 2014);
- Modelos *Black Box*: a não possibilidade de se definir funções objetivos e restrições, faz com que o problema de OvS passe a ser tratado como um problema de otimização global. Esse fato eleva o tempo computacional e limita o tamanho do problema de OvS. Felizmente são raros os casos onde se busca um ótimo global, na maioria dos casos, uma melhora considerável é aceitável (STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014);

• Estocasticidade: em muitos problemas reais de OvS, o sistema é modelado por meio de um processo estocástico. Nesses casos, as saídas do modelo de simulação passam a ser um vetor aleatório, com uma distribuição de probabilidade desconhecida. As saídas do modelo podem ser obtidas por meio da simulação, embora o seu tempo computacional aumente com o tamanho da amostra a ser simulada e com o número de replicações realizadas. Outro fato a se destacar é que, a menos que o tamanho da amostra seja suficientemente grande, a amostragem introduz ruídos para os valores da função objetivo e restrições, que dependem de alguma estatística de saída do modelo simulado (STEPONAVIČĖ, RUUSKA e MIETTINEN, 2014).

2.4.2 Princípios de funcionamento da Otimização via Simulação

Para Fu (2002), o funcionamento de um procedimento de OvS que opera em paralelo a um *software* de SED pode ser dividido em duas etapas. A primeira consiste em gerar as possíveis candidatas a solução para o problema. Já a segunda consiste em avaliar as soluções, estimando seus resultados. A Figura 2.2 exemplifica a visão de Fu (2002) sobre o funcionamento da OvS.

Segundo o autor, a OvS concentra-se na primeira etapa, tratando o modelo de simulação como apenas um gerador de funções. Nesse sentido, a maior parte dos cálculos realizados é despendida na estimativa de $f(\theta)$ para cada valor de θ . Sendo um dos principais determinantes do tempo computacional da OvS, o número de replicações necessárias para estimar $f(\theta)$.

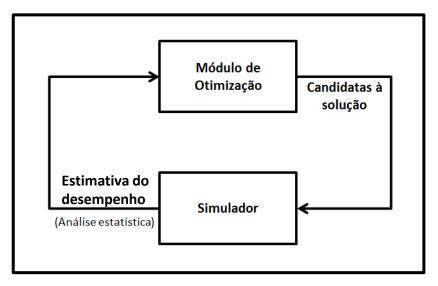


Figura 2.2 - Funcionamento da OvS

Fonte: adaptado de Fu (2002)

A abordagem genérica apresentada por Fu (2002) é expandida por Law (2007), para um módulo de OvS baseado em algoritmos evolutivos e algoritmos genéticos (Figura 2.3). Para Chwif e Medina (2010), esses métodos de otimização são os mais utilizados nos *softwares* comerciais.

Segundo Law (2007), o módulo de otimização do *software* envia ao modelo de simulação as configurações iniciais do sistema (valores iniciais para as variáveis de decisão). O modelo de simulação então, executa as condições especificadas pelo módulo de otimização, avaliando e armazenando a(s) estatística(s) da(s) variável(s) de saída(s) que se pretende otimizar.

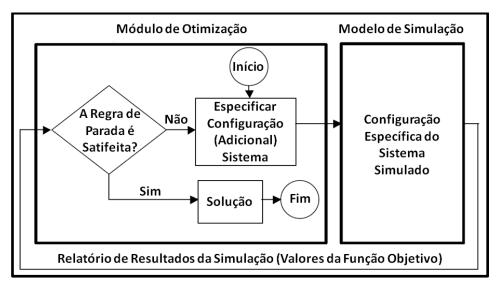


Figura 2.3 - Princípio de funcionamento de um modulo de otimização integrado à SED Fonte: Adaptado de Law (2007)

Estes resultados são repassados para o módulo de otimização, que dessa forma, usa seu algoritmo de busca, para gerar configurações adicionais para o problema de OvS. Todo o processo é repetido, enquanto todas as restrições do sistema são satisfeitas, até que o critério de parada do módulo de otimização seja alcançado.

Segundo Hicks (2006), os critérios de parada são abordagens que delimitam o número de buscas depois que certo número de configurações é concluído. Para Yang, Kuo e Cho (2007) existem vários critérios de parada, um deles parte do princípio que, quando várias gerações consecutivas alcançam a mesma solução, a busca por novas soluções deve ser interrompida. Outro critério utilizado interrompe a busca quando a melhoria na qualidade da solução torna-se insignificante. Estes autores destacam ainda, um critério baseado no número máximo de simulações que podem ser executadas.

Para Wang e Schonfeld (2006), não existem garantias, na maioria dos casos, que os resultados encontrados com um procedimento de OvS sejam ótimos. Estes resultados dependem do método de otimização empregado e de suas configurações, tais como: opções, parâmetros e tolerâncias assumidas. Um bom *software* de OvS pode alcançar soluções próximas à ideal, ainda que, para estes autores, a diferença entre o ótimo global e a solução apresentada pelo *software* é normalmente insignificante, considerando a otimização de um modelo de simulação estocástico.

Cabe ressaltar, que existem outras técnicas de otimização que possuem princípios de funcionamento diferentes dos apresentados nas Figuras 2.2 e 2.3, tais como a Metamodelagem (BARTON e MECKESHEIMER, 2006) e a Metodologia de Superfície de Resposta (MYERS, MONTGOMERY e ANDERSON-COOK, 2009). Em ambas estas técnicas, um modelo matemático simplificado (metamodelo), que represente o modelo de simulação, é desenvolvido e, posteriormente, otimizado, não se encaixando, dessa forma, no princípio de funcionamento apresentado nesta seção.

2.4.3 Métodos de Otimização via Simulação

Segundo Bettonvil, Castillo e Kleijnen (2009) existem na literatura diversos métodos disponíveis para resolução de problemas, como os apresentados nas Eqs. (2.1) e (2.2), porém, infelizmente, alguns desses métodos não garantem que a solução encontrada seja uma solução ótima.

Para Rosen, Harmonosky e Traband (2007), o método de otimização aplicável para o problema de OvS dependerá do sistema simulado, se este é composto por variáveis contínuas, discretas ou por ambas.

Swisher *et al.* (2000) destacam que o conjunto de viabilidade de um problema de OvS é infinito, se as variáveis de entrada são contínuas. Neste caso, os métodos utilizados para otimização são baseados em métodos gradientes (RAO, 2009) ou abordagens não gradientes, tais como: o método de Nelder-Mead (NELDER e MEAD, 1965) e o método de Hooke e Jeeves (HOOKE e JEEVES, 1961).

Ainda segundo o autor, se as variáveis de entrada são discretas, o conjunto de viabilidade de um problema de OvS é finito. Neste caso, se o conjunto de viabilidade é pequeno, métodos de *Ranking* e Seleção (R&S) e procedimentos de múltiplas comparações (SWISHER e JACOBSON, 1999) são os mais apropriados para otimização. No caso do conjunto de viabilidade ser muito grande, técnicas como: *simulated annealing* (AARTS,

KORST e MICHIELS, 2005), busca tabu (GLOVER, LAGUNA e MARTÍ, 2005), algoritmos genéticos (HOLLAND, 1992) ou outras metaheurísticas (RAO, 2009) são os mais indicados.

Kuo, Yang e Huang (2008) destacam o uso da metamodelagem como forma de se otimizar um modelo de SED. O metamodelo de simulação é um modelo matemático mais simples, que se aproxima do modelo de simulação (BARTON e MECKESHEIMER, 2006).

A otimização de um modelo de SED, por metamodelo, ocorre em três etapas. Primeiro, o modelo que se pretende otimizar é utilizado para gerar um conjunto de dados que contenha a variável de saída que se pretende otimizar. Posteriormente, com auxilio de técnicas de metamodelagem, como regressão ou redes neurais, o metamodelo é gerado. Por fim, este metamodelo é otimizado (KUO, YANG e HUANG, 2008).

Ammeri *et al.* (2010) classificam os métodos para OvS em dois grandes grupos. Um grupo de métodos para otimização com variáveis de decisão discretas e outro para variáveis de decisão do tipo contínuas. As Figuras 2.4 e 2.5, apresentam, respectivamente, os métodos de otimização indicados para cada problema de OvS.

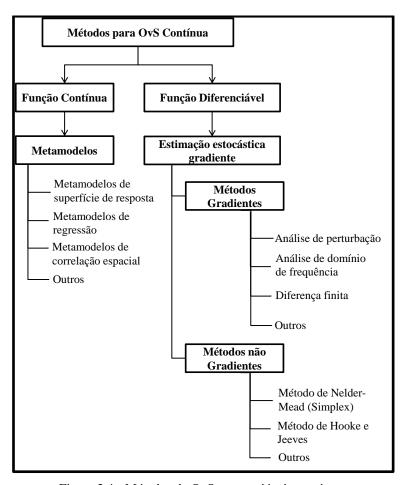


Figura 2.4 - Métodos de OvS para variáveis contínuas

Fonte: Adaptado de Ammeri et al. (2010)

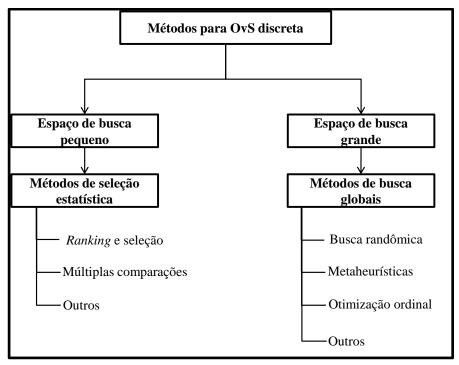


Figura 2.5 - Métodos de OvS para variáveis discretas Fonte: Adaptado de Ammeri *et al.* (2010)

2.4.4 Softwares de Otimização via Simulação

Para Fu (2002), uma das interfaces mais bem-sucedidas entre a Pesquisa Operacional e a Computação tem sido o desenvolvimento de *softwares* de SED. Várias técnicas de otimização tem sido integradas a simulação, principalmente por meio de simuladores comerciais. Hoje, a inclusão de rotinas de otimização tornou-se comum à maioria dos pacotes de SED.

No entanto, a comunidade científica foi relutante em utilizar ferramentas de otimização integradas a simulação. Isso pode ser comprovado, segundo Fu *et al.* (2000), pelo fato que a primeira vez que tal tema surgiu em dois dos mais renomados livros de simulação, Law e Kelton (2000) e Banks *et al.* (2000), se deu no final do século XX.

April *et al.* (2005) afirmam que a resistência da comunidade científica começou a diminuir com o início das pesquisas na área de metaheurísticas, em conjunto com o avanço dos métodos de análise estatística.

Azadeh, Tabatabaee e Maghsoudi (2009) consideram a OvS como uma das tecnologias mais importantes que surgiram nos últimos anos. E ressaltam que em metodologias anteriores, à integração da otimização com a simulação, exigiam a realização de mudanças em modelos de simulação, que em muitos casos eram complexas, difíceis e não economicamente viáveis, principalmente, para problemas com um grande número de variáveis de decisão.

Para Fu *et al.* (2000), o objetivo da inclusão de módulos de otimização em simuladores, visa alcançar soluções melhoradas para os parâmetros de entrada do sistema, na busca por incrementar seu desempenho. No entanto, para a grande maioria dos otimizadores comerciais, o analista de simulação não tem como saber se um ponto de ótimo foi realmente atingido.

Nesse sentido, para Banks *et al.* (2009), a existência de variabilidade na amostragem dos dados de entrada, muitas vezes obriga a OvS a possuir heurísticas de busca robustas e poderosas. Assim, várias heurísticas têm sido desenvolvidas para problemas de otimização que, apesar de não garantirem encontrar a melhor solução, mostram-se eficientes em problemas práticos complexos (BANKS *et al.*, 2009; PINHO *et al.*, 2012).

Para Harrel *et al.* (2002), o progresso no desenvolvimento de ferramentas computacionais foi especialmente lento no campo da OvS. Nesse sentido, o uso de técnicas computacionais tradicionais para OvS fez com que sua utilização fosse particularizada, principalmente no meio acadêmico. Isso vem sendo resolvido com a inserção de novas técnicas de otimização, como as metaheurísticas.

Law (2007) destaca as seguintes características como desejáveis para um pacote de OvS:

- O software deve fornecer informações aos usuários, tanto durante o processo de otimização, quanto após a otimização;
- É importante que o software permita que restrições e variáveis de decisão, possam ser adicionadas ao processo de otimização;
- Regras de paradas devem ser incluídas nos pacotes de otimização;
- É importante que o software forneça para cada solução um intervalo de confiança;
- É desejável que os *softwares* de simulação, que possuem módulos de otimização integrados, retornem às suas configurações originais após o término da otimização;
- Como boa parte dos problemas de OvS necessitam da realização de réplicas, é mandatório que os softwares permitam sua execução.

Para Martins *et al.* (2013), apesar da integração recente entre otimização e simulação, a inclusão de técnicas de otimização em simuladores comerciais contribuiu para aumentar a popularidade da OvS, tendo estes *softwares* se mostrado bastante eficazes para solução de inúmeros problemas. A Tabela 2.3 agrupa os principais *softwares* comerciais de otimização existentes no mercado (ESKANDARI *et al.*, 2011; FU, 2002; LAW, 2007; LAW e

MCCOMAS, 2002), assim como os pacotes de simulação aos quais estão integrados e as técnicas de otimização utilizadas por esses pacotes.

Software de Otimização Pacote de simulação Técnica de otimização Extend Optimizer® **Extend®** Estratégias Evolutivas Arena®, Flexsim®, Micro Saint®, Busca Scatter, Busca Tabu e OptQuest® ProModel®, Quest®, Simprocess®, Simul8® Redes Neurais Estratégias Evolutivas e SimRunner® MedModel®, ProModel®, ServiceModel® Algoritmos Genéticos Simulated Anneling e Busca Witness Optimizer® Witness® Tabu Estratégias Evolutivas e WizardGA® Tecnomatix Plant Simulation® Algoritmos Genéticos

Tabela 2.3 - Softwares de Otimização via Simulação

Fonte: Adaptado de Eskandari et al. (2011), Fu (2002), Law (2007), Law e McComas (2002).

Estes *softwares* utilizam diferentes técnicas de otimização, dentre elas destacam-se: Estratégias Evolutivas (COELLO, LAMONT, VAN VELDHUIZEN, 2007), Algoritmos Genéticos (HOLLAND, 1992), Busca *Scatter* (MARTÍ, LAGUNA e GLOVER, 2006), Busca Tabu (GLOVER, LAGUNA e MARTÍ, 2005), Redes Neurais (RIPLEY, 1996) e a *Simulated Anneling* (AARTS, KORST e MICHIELS, 2005).

Para Pinho *et al.* (2012), em se tratando de rotinas de otimização baseadas em metaheurísticas, a utilização de algoritmos evolutivos predominam, sendo que dentre eles, um dos mais importante é o Algoritmo Genético (AG).

Para Damaso e Garcia (2009), o uso de técnicas evolutivas é justificada para problemas de otimização combinatória, como são os problemas de OvS. Nesse caso, as combinações de variáveis de entrada são testadas, a fim de se encontrar o resultado de saída mais desejável para o problema (HARREL, GHOSH e BOWDEN, 2004).

2.4.5 Procedimento para Otimização via Simulação

A grande maioria dos procedimentos para emprego da OvS partem de um modelo computacional já existente, verificado e validado. Harrel, Ghosh e Bowden (2004) propõem uma sequência de passos para utilização do *SimRunner*®. Apesar de definida para este otimizador, o método proposto por Harrel, Ghosh e Bowden (2004), devido a seu caráter generalista, pode ser estendido e aplicado a outros *softwares* de otimização.

Harrel, Ghosh e Bowden (2004) propõem cinco passos para utilização de um otimizador:

• 1º. Passo: Definir as variáveis de decisão que irão afetar as saídas do modelo de SED.

Estas variáveis terão seus valores alterados pelo otimizador a cada rodada de simulação;

- 2º. Passo: Para cada variável de decisão, definir o tipo da variável (real ou inteira) e seus limites inferiores e superiores. O algoritmo buscará soluções compreendidas entre os limites especificados, respeitando o tipo de variável. Quanto maior o número de variáveis e os limites definidos, maior a dificuldade e o tempo consumido para identificar a solução ótima;
- 3º. Passo: Definir a função objetivo para avaliar as soluções testadas pelo algoritmo.
 Embora apresentada como uma terceira etapa do método, a função objetivo poderia ser estabelecida durante a fase de projeto do estudo de simulação. Esta função objetivo não necessariamente precisa ser uma equação, podendo ser, uma variável de saída do modelo simulado;
- 4º. Passo: Selecionar os parâmetros de otimização do otimizador. Parâmetros como: perfis de otimização, critérios de parada, precisão requerida, tamanho da população, nível de significância, número de replicações, dentre outros, devem ser especificados no otimizador;
- 5°. Passo: Após a conclusão da busca, um analista deve estudar as soluções encontradas, uma vez que, além da melhor solução encontrada, o algoritmo apresenta várias outras soluções competitivas.

2.5 Introdução à Análise Envoltória de Dados (DEA)

Para Liu *et al.* (2013), a Análise Envoltória de Dados ou *Data Envelopment Analysis* (DEA) é um método não paramétrico de medição de eficiência produtiva, para operações com múltiplos insumos e múltiplos produtos. Não exigindo, dessa forma, a determinação de relações funcionais entre produtos e insumos, e não se restringindo a medidas únicas entre estes (FERREIRA e GOMES, 2012).

Segundo Ferreira e Gomes (2012), a DEA teve seus primórdios na Teoria da Produção Microeconômica, fomentada a partir do século XIX, com a obra *Der Isolierte Staat*, do alemão Johann-Heinrich von Thünen. Esta obra foi uma das primeiras a formular a Teoria da Produtividade Marginal. Outros trabalhos, que se seguiram a este, tentaram definir conceitos e medidas do melhor uso dos fatores de produção (máquinas, pessoas, equipamentos matérias-primas, energia, *etc.*).

Na década de 50, o trabalho de Farrel (1957) influenciou de forma significativa a proposição da DEA. Farrel (1957) desenvolveu métodos mais robustos para avaliar a

produtividade, por meio dos conceitos de análise de atividades. Segundo o autor, tentativas de avaliar a produtividade resultavam em medidas extremamente restritivas, uma vez que não conseguiam combinar múltiplos insumos em um único medidor de eficiência.

Segundo Saurin *et al.* (2013), o propósito do trabalho de Farrel (1957) era desenvolver uma métrica de eficiência capaz de levar em consideração todos os insumos de uma empresa, e mostrar como isto poderia ser realizado na prática, por meio de uma função de produção.

Com base no trabalho de Farrel (1957) e em suas limitações, a DEA é proposta no final da década de 70, na tese de doutorado de Rhodes (1978). Orientado pelo professor William W. Cooper, o trabalho buscou desenvolver um método para comparar a eficiência de escolas públicas para alunos carentes, que participavam do programa *Follow Through*, comparando escolas que participavam desse programa com escolas que não participavam (COOPER, SEIFORD e TONE, 2007).

Segundo Ferreira e Gomes (2012), o objetivo deste trabalho era estimar a eficiência técnica relativa entre as escolas, levando em consideração vários insumos e produtos, sem que houvesse a necessidade de convertê-los em um padrão e sem estabelecer ponderações arbitrárias. Dessa forma, a busca de uma conceituação precisa de medidas de eficiência econômica levou ao desenvolvimento da DEA, publicada no trabalho de Charnes, Cooper e Rhodes (1978).

Segundo Cook e Seiford (2009), a DEA consiste em uma metodologia não-paramétrica para mensuração comparativa da eficiência de Unidades Tomadoras de Decisão (*Decision Making Units* - DMUs). Outro fato que merece destaque é a possibilidade de existir incomensurabilidade (diferentes unidades de medida) entre os elementos das matrizes de entradas e saídas, o que é contornado com o uso da DEA. Assim, a DEA fornece uma metodologia que permite identificar as DMUs que sejam referências (*benchmarking*) para as demais analisadas, formando uma fronteira de eficiência.

2.5.1 Conceitos básicos da Análise Envoltória de Dados (DEA)

Para Mariano, Almeida e Rabelatto (2006), um dos primeiros conceitos a serem discutidos para uma correta compreensão da DEA, diz respeito às organizações analisadas para o cálculo de eficiência. Denominada, segundo Cook e Seiford (2009), de Unidades Tomadoras de Decisão ou *Decision Making Units* (DMUs).

Para Cooper, Seiford e Tone (2007), uma DMU é considerada como a entidade responsável pela conversão de insumos em produtos, cujos desempenhos são avaliados. Em aplicações gerenciais, uma DMU pode incluir bancos, lojas de departamentos, supermercados,

fabricantes de automóveis, hospitais, escolas, bibliotecas, entre outros.

Para Mariano, Almeida e Rabelatto (2006), uma das formas para avaliar o desempenho de uma DMU é relacionar os insumos e produtos de cada DMU analisada. Cooper, Seiford e Tone (2007) relacionam insumos e produtos por meio da equação (Eq. 2.4):

$$Produtividade = \frac{produção (outputs)}{insumos (inputs)}$$
(2.4)

Para Ferreira e Gomes (2012), a produtividade está relacionada à forma de utilização de recursos para realizar a produção. Este conceito sugere que o insumo esteja sendo utilizado da melhor maneira possível. Segundo estes autores, para a DEA, a utilização de insumos, além do necessário, é denominada folga.

Para Cooper, Seiford e Tone (2007), a utilização de abordagens clássicas de medidas de produtividades é limitada, quando múltiplos *inputs* e *outputs* devem ser levados em consideração.

Outro importante conceito, diz respeito à eficiência. Para Mariano, Almeida e Rabelatto (2006), a eficiência de uma DMU é definida como a divisão entre um indicador de desempenho e o seu correspondente máximo. Com base nisso, a eficiência de uma DMU pode ser calculada como sendo (Eq. 2.5):

$$Eficiência = \frac{P}{P_{max}}$$
 (2.5)

sendo:

- P = Produtividade atual da DMU;
- P_{max} = Produtividade máxima que pode ser alcançada por essa DMU.

Para os autores, a eficiência sempre estará entre 0 e 1. A partir deste conceito, é possível calcular a eficiência absoluta e a eficiência relativa. Na eficiência absoluta, o valor de P_{max} é um valor teórico e inatingível, enquanto que na eficiência relativa, P_{max} é a produtividade da DMU mais eficiente. Caso a eficiência seja igual a 1, a DMU é eficiente, caso ela seja menor que 1, essa DMU é ineficiente.

Mello *et al.* (2005) exemplificam graficamente, os conceitos da produtividade e da eficiência, por meio da Figura 2.6. Na figura, o eixo *X* representa os Recursos ou Insumos,

enquanto o eixo *Y* representa a Produção. A curva S (em preto) é denominada Fronteira de Eficiência, e representa o valor máximo produzido para um dado valor de insumo. A região situada abaixo da curva S é chamada de Conjunto Viável de Produção.

Ainda na Figura 2.6, o autor destaca que as unidades C e B são eficientes, uma vez que ambas se encontram na fronteira de eficiência. No entanto, a unidade C é mais produtiva, visto que o coeficiente angular da reta OC (em azul) é maior que o coeficiente angular da reta OB (em verde). Nesse sentido, a unidade A, situada abaixo da fronteira de eficiência, não é nem produtiva, nem eficiente.

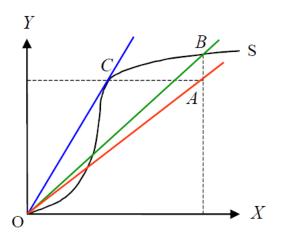


Figura 2.6 - Curva de um processo de produção Fonte: Mello *et al.* (2005)

Para Mello *et al.* (2005) existem duas formas de uma DMU não eficiente se tornar eficiente. A primeira é denominada de orientação a *inputs*, nela reduzem-se os recursos, mantendo-se constante os produtos. A segunda forma é denominada de orientação a *outputs*, na qual se mantêm constantes os recursos, enquanto se aumenta a produção. Os autores exemplificam as orientações a *inputs* e *outputs* por meio da Figura 2.7.

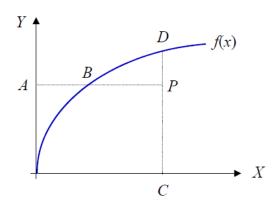


Figura 2.7 - Alcance da fronteira de eficiência Fonte: Mello *et al.* (2005)

Considerando a DMU P, situada abaixo da fronteira de eficiência definida por f(x) (em azul), esta precisa se deslocar até B, reduzindo recursos para ser tornar eficiente (orientação a *inputs*), ou se deslocar até D, aumentando a produção e mantendo constante os recursos (orientação a *outputs*).

Cooper, Seiford e Tone (2007) chamam atenção para uma terceira orientação, que combina ambas as orientações apresentadas por Mello *et al.* (2005), que pode ser representada pelos modelos Aditivos (*Additive models*) ou baseados em folgas (*Slack Based Measure*). Estes modelos buscam estabelecer um acordo entre as duas perspectivas, em que ao mesmo tempo que se busca reduzir insumos, busca-se aumentar os produtos (SANTOS, MARINS e SALOMON, 2011).

Neste caso, tomando por base o exemplo da Figura 2.7, utilizando esta terceira orientação, a DMU P se deslocaria para fronteira de eficiência, se situando entre as DMUs B e D.

2.5.2 Modelos DEA

Para Santos (2010), a DEA calcula a eficiência relativa de um conjunto de DMUs, a partir da fronteira de eficiência obtida para este conjunto. Desta forma, o que irá guiar a escolha do modelo matemático DEA mais apropriado, se dá em função do formato da fronteira de eficiência e do retorno de escala considerado.

O conceito de retornos de escala pode ser exemplificado a partir do conceito da isoquanta. A isoquanta permite representar todas as possíveis combinações de dois insumos que resultam no mesmo valor de produção (PINDYCK e RUBINFELD, 2002). Na Figura 2.8, sendo x_1 produtos e x_2 insumos, os valores associadas às isoquanta, resultam no mesmo volume de produção.

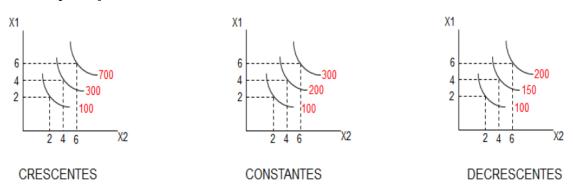


Figura 2.8 - Retornos crescentes, constantes e decrescentes de escala Fonte: Adaptado de Pindyck e Rubinfeld (2002)

Para o caso de retornos crescentes de escala, ao se dobrar o número de insumos, mais que se dobra o valor da produção. Retornos constantes de escala significam que, quando se dobra a quantidade de insumos, a produção também dobra, ou seja, é mantida uma mesma proporção. Por fim, quando o retorno é decrescente, ao se dobrar a quantidade de insumos, a produção cresce, porém de forma menor, que no caso de retornos constantes de escala (PINDYCK e RUBINFELD, 2002).

Existem dois modelos DEA que se destacam na literatura: os modelos DEA CCR e BCC (ANGULO-MEZA *et al.*, 2007). O modelo DEA CCR é assim denominado em referência ao trabalho pioneiro de Charnes, Cooper e Rhodes (1978) e admite retornos constantes de escala, por isso também denominado de DEA CRS (*constant returns to scale*). O modelo DEA BCC é assim denominado em referência ao trabalho de Banker, Charnes e Cooper (1984), que admite retornos variáveis de escalas, por isso, também denominado de DEA VRS (*variable returns to scale*). Para Martić, Novaković e Baggia (2009), o modelo DEA BCC é a principal extensão do modelo DEA CCR.

2.5.2.1 Modelo DEA com retornos constantes de escala (DEA CCR)

Para Mello *et al.* (2005), o modelo DEA CCR (CHARNES, COOPER e RHODES, 1978), é um modelo não-paramétrico, que constrói uma superfície de eficiência linear, por partes, envolvendo os dados em análise. Este modelo trabalha com retornos constantes de escala, ou seja, uma variação nos valores de insumos (*inputs*) produzirá uma variação proporcional nos produtos (*outputs*).

Na DEA, a eficiência relativa de uma DMU é igual à razão da soma ponderada dos *outputs* e a soma ponderada dos *inputs*, sendo que os pesos de ambos são selecionados de forma a maximizar a eficiência da DMU, que está sendo analisada. Neste modelo, deve-se atender à restrição de que o conjunto de pesos para cada DMU deve ser também possível para todas as outras, de forma que as DMUs não apresentem eficiência superior a 1 (CHARNES, COOPER e RHODES, 1978).

Desta forma, os pesos para as variáveis de entrada e saída do modelo podem ser obtidos a partir da solução do modelo de Programação Fracionária, dado por (Eq. 2.6) - (Eq. 2.9):

$$w_{O} = \max \frac{\sum_{i=1}^{S} u_{i} \cdot y_{i}}{\sum_{i=1}^{m} \sum_{j=1}^{N} v_{i} \cdot x_{i}}$$

$$(2.6)$$

Sujeito a:

$$\frac{\sum_{r=1}^{s} u_r y_{rj}}{\sum_{i=1}^{m} v_i x_{ij}} \le 1, \quad j = 1, 2, ..., n$$
(2.7)

$$u_r \ge 0, \quad r = 1, 2, ..., s.$$
 (2.8)

$$v_i \ge 0, \quad i = 1, 2, ..., m.$$
 (2.9)

sendo w_o é a eficiência relativa da DMU que está sendo analisada, conhecida por DMU₀; y_{r0} e x_{io} são os dados de saídas e entradas para a DMU₀; j o índice da DMU, j=1,...,n; r é o índice das saídas, com r=1,...,s; i é o índice das entradas, i=1,...,m; y_{rj} é o valor da r-ésima saída para a j-ésima DMU; x_{ij} é o valor da i-ésima entrada para a j-ésima DMU; u_r é o peso associado a r-ésima saída; v_i é o peso associado a i-ésima entrada.

Caso w_o seja igual a 1 (w_o =1), a DMU $_0$ é considerada eficiente, quando comparada às demais unidades analisadas no modelo; se w_o for menor que 1 (w_o <1), então esta DMU é considerada ineficiente (CHARNES, COOPER e RHODES, 1978).

O modelo expresso pelas Eqs. (2.6) - (2.9) não é linear, podendo ter múltiplas soluções, porém, este pode ser linearizado, gerando o modelo DEA CCR (CHARNES, COOPER e RHODES, 1978). Este modelo é conhecido como modelo dos multiplicadores com orientação ao *input*, Eqs. (2.10) - (2.14):

$$\max w_o = \sum_{r=1}^{s} u_r . y_{r0}$$
 (2.10)

Sujeito a:

$$\sum_{i=1}^{m} v_i x_{io} = 1 (2.11)$$

$$\sum_{r=1}^{s} u_r y_{rj} - \sum_{i=1}^{m} v_i x_{ij} \le 0, \quad j = 1, 2, ..., n$$
(2.12)

$$u_r \ge 0, \quad r = 1, 2, \dots, s$$
 (2.13)

$$v_i \ge 0, \quad i = 1, 2, ..., m$$
 (2.14)

Charnes, Cooper e Rhodes (1978) apresentam a formulação dual do problema de programação linear como o problema do envelope, este modelo é representado pelas Eqs. (2.15) - (2.18). Este modelo é conhecido como modelo do envelope com orientação ao *input*.

$$Min h_0 (2.15)$$

Sujeito a:

$$h_0 x_{i0} - \sum_{j=1}^{n} x_{ij} \lambda_j \ge 0, i = 1, 2, ..., m$$
 (2.16)

$$-y_{r0} + \sum_{j=1}^{n} y_{rj} \lambda_j \ge 0, r = 1, 2, \dots, s$$
 (2.17)

$$\lambda_j \ge 0, \qquad \qquad j = 1, 2, \dots, n \tag{2.18}$$

sendo h_0 o coeficiente de utilização dos recursos, medida pela qual busca-se a eficiência igual a 1/h; λ_j a contribuição da DMU_j na formação do alvo da DMU₀, também chamado de coeficiente de importância relativa para a DMU₀, sendo o alvo definido como a coordenada de valores de *outputs* que as unidades ineficientes passariam a ter ao atingir a fronteira eficiente. Os demais índices são análogos aos índices do modelo descrito pelas equações (3.10) - (3.14).

Para Mello *et al.* (2005), a função objetivo representa a eficiência, que é o valor que deve ser multiplicado por todos os *inputs*, de forma a obter valores que coloquem a DMU na fronteira eficiente, ou seja, provoca decréscimo no valor dos *inputs*. O primeiro conjunto de restrições garante que essa redução em cada um dos *inputs*, não ultrapasse a fronteira definida pelas DMUs eficientes. O segundo grupo de restrições garante que a redução nos *inputs* não altere o nível atual dos *outputs* da DMU. Enquanto, no modelo dos multiplicadores, os pesos são as variáveis de decisões, no modelo do envelope são h_0 e λ_j 's.

2.5.2.2 Modelo DEA com retornos variáveis de escala (DEA BCC)

Para Angulo-Meza *et al.* (2007), o modelo BCC, proposto por Banker, Charnes e Cooper (1984), considera situações de eficiência de produção com retornos variáveis de escala, não assumindo uma relação de proporcionalidade entre *inputs* e *outputs*, como é feito no modelo original proposto por Charnes, Cooper e Rhodes (1978). Desta forma, o modelo BCC é indicado quando ocorrem retornos variáveis de escala, sejam eles crescentes ou decrescentes.

O modelo DEA BCC com orientação a *inputs* (BANKER, CHARNES e COOPER, 1984), com retornos variáveis de escalas, pode ser expresso pelas Eqs. (2.19) - (2.24). Este modelo é conhecido como o modelo dos multiplicadores com orientação ao *input*.

$$\max w_o = \sum_{r=1}^{s} u_r \cdot y_{r0} + c_0 \tag{2.19}$$

Sujeito a:

$$\sum_{i=1}^{m} v_i x_{io} = 1 {(2.20)}$$

$$\sum_{r=1}^{s} u_r y_{rj} - \sum_{i=1}^{m} v_i x_{ij} + c_0 \le 0, \qquad j = 1, 2, ..., n$$
(2.21)

$$u_r \ge 0,$$
 $r = 1, 2, ..., s$ (2.22)

$$v_i \ge 0,$$
 $i = 1, 2, ..., m$ (2.23)

$$c_0$$
 livre (2.24)

A principal diferença no modelo DEA BCC para o DEA CCR é a adição da variável c_0 (livre) que indica os retornos variáveis de escala. Neste modelo, c_0 é conhecido como fator de escala. Banker, Charnes e Cooper (1984) comentam que uma DMU considerada eficiente no modelo CCR, também o será no modelo de BCC, mas o contrário não necessariamente ocorre.

As Eqs. (2.25) - (2.29) representam a formulação dual do problema de programação linear do modelo DEA BCC, representado pelas Eqs. (2.19) - (2.24). Este é o modelo do envelope com orientação ao *input*.

$$Min h_0 (2.25)$$

Sujeito a:

$$h_0 x_{i0} - \sum_{j=1}^{n} x_{ij} \lambda_j \ge 0, \quad i = 1, 2, ..., m$$
 (2.26)

$$-y_{r0} + \sum_{j=1}^{n} y_{rj} \lambda_j \ge 0, r = 1, 2, \dots, s$$
 (2.27)

$$\sum_{j=1}^{n} \lambda_j = 1 \tag{2.28}$$

$$\lambda_j \ge 0, \qquad j = 1, 2, \dots, n \tag{2.29}$$

Cooper, Seiford e Tone (2007) chamam a atenção para a necessidade de uma quantidade mínima de DMUs, a serem analisadas em um modelo DEA tradicional (CCR e BCC). Nesse sentido, Banker *et al.* (1989) estabeleceram uma regra conhecida como *Golden Rule*, para que os modelos clássicos DEA pudessem ser aplicados sem gerar o problema de baixa discriminação das DMUs. Esta regra diz que para aplicar estes modelos, o número de DMUs deve ser de no mínimo três vezes a soma do número de variáveis (*inputs* + *outputs*) ou igual ao produto destas variáveis (*inputs* x *outputs*), sendo adotado o critério que conduzir a maior quantidade de DMUs.

Caso o número de DMUs não atenda a essa regra, várias DMUs poderão ser consideradas eficientes, quando verdadeiramente não são (COOPER, SEIFORD e TONE, 2007).

2.5.3 Métodos para ranqueamento e aumento de discriminação de DMUs em modelos DEA

Para Adler, Friedman e Sinuany-Stern (2002), muitos trabalhos adaptaram os modelos clássicos DEA, para lidar com problemas que ocorrem na prática. Uma dessas adaptações diz respeito à necessidade de discriminação das DMUs.

Para Lins e Angulo-Meza (2000), o objetivo da DEA é avaliar a eficiência de DMUs. Para realizar esta avaliação, a DEA faz uso da Programação Linear (PL), objetivando maximizar a eficiência, enquanto se atende determinadas restrições. Nesse sentido, os modelos clássicos DEA consideram as DMUs com $w_0 = 1$, como sendo eficientes, e as DMUs com $w_0 < 1$, ineficientes (CHARNES, COOPER e RHODES, 1978; BANKER, CHARNES e COOPER, 1984).

Para Angulo-Meza e Cunha (2006), por se tratar de um problema de PL, este permitirá que cada DMU dê pesos maiores às variáveis que tenham níveis de *outputs* maiores (no caso de *inputs*, níveis menores) e darão pesos menores ou nulos as variáveis que lhe sejam desfavoráveis. Isto resulta que os pesos utilizados por diferentes DMUs, para cada variável, podem variar amplamente, fazendo com que várias DMUs sejam consideradas eficientes (ANGULO-MEZA, 1998). Nesse caso, não se consegue discriminar bem estas DMUs. Tal fato é mais crítico, quando o número de DMUs é pequeno, fazendo com que várias DMUs sejam consideradas eficientes, quando na verdade são ineficientes (COOPER, SEIFORD e TONE, 2007).

No entanto, muitas vezes, os tomadores de decisão estão interessados em um *ranking* completo das DMUs, a fim de poderem refinar a avaliação destas unidades (ADLER, FRIEDMAN e SINUANY-STERN, 2002).

Lotfi *et al.* (2013), em um trabalho de revisão sobre modelos de *ranking* em DEA, apresentam os modelos mais utilizados na literatura para classificação de DMUs, como sendo:

- Eficiência cruzada;
- Métodos baseados em encontrar pesos ótimos para o modelo DEA;
- Supereficiência;
- Métodos de benchmarking;

- Métodos que fazem uso de ferramentas estatísticas;
- Abordagem multiobjetivo.

Para Lotfi *et al.* (2013), outros métodos são encontrados na literatura, apesar de serem pouco explorados. Bal, Örkcü e Çelebioğlu (2010) destacam como principais modelos para melhorar a discriminação das DMUs, os modelos de avaliação cruzada, supereficiência e a abordagem multiobjetivo.

O modelo de avaliação cruzada foi criado por Sexton (1986) e estendido por Doyle e Green (1994). Este modelo preconiza a avaliação de conjunto, ou seja, as DMUs envolvidas na análise de eficiência, primeiro têm uma avaliação própria, tal como nos modelos DEA clássicos, porém, também são avaliados pelas outras DMUs, por meio dos pesos ótimos dados pelo modelo. Assim, os pesos para o cálculo do índice de eficiência de cada DMU são determinados, e esses pesos são utilizados para determinar os índices de eficiência das outras DMUs (LETA *et al.*, 2005), sendo a média de todas essas eficiências, a eficiência cruzada da DMU em análise (ANGULO-MEZA e CUNHA, 2006).

Os modelos baseados em abordagens multiobjetivo, tal como os modelos desenvolvidos por Li e Reeves (1999) e Bal, Örkcü e Çelebioğlu (2010), permitem um aumento de discriminação das DMUs, quando o número de DMUs é menor em comparação com o número total de entradas e saídas, fazendo com que os modelos clássicos identifiquem muitas DMUs como sendo eficientes. Estes modelos evitam uma ponderação excessiva dos pesos do modelo DEA (ANGULO-MEZA e LINS, 2002).

Nesta tese será utilizado o método da Supereficiência proposto por Andersen e Petersen (1993). Para que a Supereficiência possa ser empregada no modelo DEA BCC, Andersen e Petersen (1993) sugerem retirar a restrição (Eq. 2.21) do modelo, assim a DMU analisada poderá alcançar índices maiores que 1, o que facilitará a elaboração de um *ranking* de eficiência, mesmo para as DMUS que originalmente tinham $w_0 = 1$.

Uma das vantagens desse método é que apenas as DMUs eficientes sofrem alteração no valor da eficiência, que neste caso será sempre maior ou igual a 1, permitindo o *ranking* das DMUs. Já as DMUs que forem ineficientes na análise tradicional, ao realizar a análise de supereficiência, apresentarão o mesmo grau de ineficiência apresentada na análise tradicional. Outra vantagem da análise da Supereficiência é o fato da mesma não agregar maiores complexidades computacionais ao problema.

2.6 Arranjos Ortogonais de Taguchi

Ballantyne *et al.* (2008) apontam que o processo de otimização de sistemas complexos, que possuem muitas variáveis de entrada com vários níveis, pode consumir muito tempo e recursos durante seu processamento. Nesse sentido, para sistemas com poucos níveis, Antony (2006) recomenda o uso de estratégias fatoriais, como os fatoriais completos ou fracionados, que trabalham tipicamente com dois níveis: um baixo e um alto (MONTEGOMERY, 2005).

No entanto, para processos complexos envolvendo quatro ou mais fatores, com três ou mais níveis, abordagens como estas exigiriam um número elevado de experimentos para poderem ser utilizadas (ANTONY, 2006). Uma abordagem alternativa é a utilização dos Arranjos Ortogonais de Taguchi (AO) (TAGUCHI, 1987), que reduzem o número de experimentos necessários e permitem a análise dos fatores de maior importância.

Para Roos (1996), os arranjos ortogonais foram desenvolvidos por volta de 1897, sendo pouco explorados até a Segunda Guerra Mundial, quando passaram a ser empregados por Plackett e Burman. Para o autor, o fato de um arranjo ser ortogonal está relacionado a possibilidade de todos os fatores serem avaliados independentemente um do outro, ou seja, o efeito de um fator não influencia na estimativa do efeito de outro fator.

Para Maghsoodloo *et al.* (2004), Dr. Genichi Taguchi (Guru da Qualidade Japonesa) introduziu os arranjos ortogonais de Taguchi como parte de seus estudos (ANTONY, 2006), embora boa parte destes arranjos sejam baseados em projetos fatorais fracionados. Para o autor, uma das principais contribuições de Taguchi foi o de simplificar a prática do projeto de experimentos (DOE).

Taguchi, Chowdhury e Wu (2005) definem arranjo ortogonal como uma matriz de números dispostos em linhas e colunas, de tal modo que cada par de colunas é ortogonal ao outro. Quando utilizado em um experimento, cada linha representa uma situação experimental, e cada coluna representa um fator específico ou uma determinada condição que pode ser alterada. Para os autores, a matriz é chamada ortogonal, porque os efeitos dos vários fatores podem ser separados uns dos outros.

A vantagem da utilização dos arranjos ortogonais consiste na capacidade de se avaliar vários fatores com um número mínimo de experimentações. De fato, este arranjo permite considerar k fatores com n níveis cada, testando todos os níveis de cada fator de uma maneira balanceada (ROSS, 1996).

Nesses arranjos, o número de experimentos necessários é reconhecido pelo índice que acompanha a letra "L" de *Latin Square* (ROY, 2010). Um experimento L8, por exemplo,

significa um experimento com oito experimentos, sem considerar replicações (ROSS, 1996).

Para Roy (2010), além da notação apresentada por Ross (1996), os arranjos ortogonais costumam apresentar outras notações que indicam o número de fatores envolvidos em cada arranjo. Por exemplo, o AO L8 (2⁷) prevê a realização de 8 experimentos em 7 colunas, sendo cada coluna a combinação de 2 níveis. Esse arranjo pode ser visualizado na Tabela 2.4.

Experimento	A	В	C	D	E	F	G
1	1	1	1	1	1	1	1
2	1	1	1	2	2	2	2
3	1	2	2	1	1	2	2
4	1	2	2	2	2	1	1
5	2	1	2	1	2	1	2
6	2	1	2	2	1	2	1
7	2	2	1	1	2	2	1
8	2	2	1	2	1	1	2

Tabela 2.4 - Arranjo Ortogonal L8 (2⁷)

De acordo com Montgomery (2005), alguns dos arranjos de Taguchi são formas de fatoriais fracionários. Além disso, em algumas aplicações, dependendo do número de fatores e experimentos escolhidos, o arranjo pode ser saturado, não permitindo a análise de interações entre os fatores.

Phadke (1989) apresenta o arranjo ortogonal L9 (3⁴) com 4 fatores e 3 níveis, proposto por Taguchi e Wu (1979). Este arranjo é apresentado na Tabela 2.5.

Experimento	A	В	C	D
1	1	1	1	1
2	1	2	2	2
3	1	3	3	3
4	2	1	2	3
5	2	2	3	1
6	2	3	1	2
7	3	1	3	2
8	3	2	1	3
9	3	3	2	1

Tabela 2.5 - Arranjo Ortogonal L9 (3⁴)

Segundo Phadke (1989), as colunas dessa matriz experimental são mutuamente ortogonais. A ortogonalidade é interpretada no sentido de que a combinação de qualquer par de colunas, ocorrem todas as combinações dos níveis dos fatores e ocorrem em um número igual de vezes. Por isso este arranjo é chamado de balanceado, implicando assim em sua ortogonalidade (ROY, 2010).

No exemplo apresentado na Tabela 2.5, para cada par de colunas, existem 3 x 3 = 9 possíveis combinações de níveis de fatores, e cada combinação ocorre precisamente uma única vez. Para as colunas 1 e 2, as nove possíveis combinações de níveis de fatores, ou seja, as combinações (1,1), (1,2), (1,3), (2,1), (2,2), (2,3), (3,1), (3,2) e (3,3), ocorrem nos experimentos (ou linhas) 1, 2, 3, 4, 5, 6, 7, 8 e 9, respectivamente (PHADKE, 1989).

Para Costa (2008), o objetivo básico da utilização dos arranjos ortogonais é obter o máximo de informações sobre as variáveis, sobre seus efeitos na resposta e sobre suas eventuais inter-relações, ao menor custo possível. Neste sentido, às vezes o custo de se levar adiante um experimento fatorial torna-se muito alto, devido ao grande número de combinações existentes entre as variáveis.

Por exemplo, para se analisar o efeito de sete variáveis em três níveis, com um experimento fatorial completo, seriam necessários $3^7 = 2.187$ experimentos. Utilizando um Arranjo Ortogonal de Taguchi, por exemplo, o L27 (3^7) (Tabela 2.6), a quantidade de experimentos é reduzido para 27 (COSTA, 2008).

				rtogonai L27			
Experimento	A	В	C	D	E	F	G
1	1	1	1	1	1	1	1
2	1	1	1	1	2	2	2
3	1	1	1	1	3	3	3
4	1	2	2	2	1	1	1
5	1	2	2	2	2	2	2
6	1	2	2	2	3	3	3
7	1	3	3	3	1	1	1
8	1	3	3	3	2	2	2
9	1	3	3	3	3	3	3
10	2	1	2	3	1	2	3
11	2	1	2	3	2	3	1
12	2	1	2	3	3	1	2
13	2	2	3	1	1	2	3
14	2	2	3	1	2	3	1
15	2	2	3	1	3	1	2
16	2	3	1	2	1	2	3
17	2	3	1	2	2	3	1
18	2	3	1	2	3	1	2
19	3	1	3	2	1	3	2
20	3	1	3	2	2	1	3
21	3	1	3	2	3	2	1
22	3	2	1	3	1	3	2
23	3	2	1	3	2	1	3
24	3	2	1	3	3	2	1
25	3	3	2	1	1	3	2
26	3	3	2	1	2	1	3
27	3	3	2	1	3	2	1

Tabela 2.6 - Arranjo Ortogonal L27 (3⁷)

Taguchi (1987) definiu 18 arrajos ortogonais básicos, que são conhecidos como arranjos ortogonais padrões. Na Tabela 2.7 são apresentados os 18 arrajos ortogonais padrões. Para cada AO apresentado, são indicados o número de experimentos a serem realizados, o número máximo de fatores e o número máximo de colunas por níveis.

Assim, o AO L4(2³) prevê a realização de quatro experimentos com três fatores com dois níveis cada. O AO L18(2¹3³) possui 18 experimentos, sendo a matriz experimental composta de uma coluna com dois níveis e sete colunas com três níveis. Na Tabela 2.7 podese observar que quando existem duas matrizes com o mesmo número de experimentos, o segundo arranjo é apresentado com um apóstrofo. Assim, as duas matrizes com 36 experimentos são referidos como L36 e L'36 (PHADKE, 1989).

Tabela 2.7 - Arranjos Ortogonais padrão

Arranjo ortogonal	Número de experimentos	Número Máximo de fatores –		Número Máximo de colunas com os seguintes níveis				
	experimentos	uc latores =	2	3	4	5		
L4	4	3	3	-	-	-		
L8	8	7	7	-	-	-		
L9	9	4	-	4	-	-		
L12	12	11	11	-	-	-		
L16	16	15	15	-	-	-		
L´16	16	5	-	-	5	-		
L18	18	8	1	7	-	-		
L25	25	6	-	-	-	6		
L27	27	13	-	13	-	-		
L32	32	31	31	-	-	-		
L′32	32	10	1	-	9	-		
L36	36	23	11	12	-	-		
L′36	36	16	3	13	-	-		
L50	50	12	1	-	-	11		
L54	54	26	1	25	-	-		
L64	64	63	63	-	-	-		
L'64	64	21	-	-	21	-		
L81	81	40	-	40	-	-		

Neste trabalho os arranjos de Taguchi serão empregados para uma pré-avaliação do espaço de busca de problemas de OvS, uma vez que estes arranjos permitem a geração de uma matriz experimental mais diversificada que outras estratégias experimentais (ANTONY, 2006). Como exemplo, a Tabela 2.8 apresenta a matriz experimental para um arranjo ortogonal de Taguchi L16(2⁴) e um Fatorial Completo para 4 fatores (A, B, C, D) e 2 níveis (1, 4).

Como pode-se verificar na Tabela 2.8, o AO L16(4⁴) explora todos os quatro níveis para os quatro fatores, representando a região experimental de forma mais diversificada, enquanto a matriz experimental do fatorial completo trabalha com apenas dois níveis para cada fator.

Experimentos	Arranjo	Ortogona	l de Taguch	i (L16 (4 ⁴))		Fatorial Completo (2 ⁴)			
Experimentos	A	В	С	D	A	В	С	D	
1	1	1	1	1	1	1	1	1	
2	1	2	2	2	4	1	1	1	
3	1	3	3	3	1	4	1	1	
4	1	4	4	4	4	4	1	1	
5	2	1	2	3	1	1	4	1	
6	2	2	1	4	4	1	4	1	
7	2	3	4	1	1	4	4	1	
8	2	4	3	2	4	4	4	1	
9	3	1	3	4	1	1	1	4	
10	3	2	4	3	4	1	1	4	
11	3	3	1	2	1	4	1	4	
12	3	4	2	1	4	4	1	4	
13	4	1	4	2	1	1	4	4	
14	4	2	3	1	4	1	4	4	
15	4	3	2	4	1	4	4	4	
16	4	4	1	3	4	4	4	4	

Tabela 2.8 - Arranjo Ortogonal de Taguchi e fatorial completo

A discussão a respeito do poder de análise de ambos os planejamentos fatoriais foge do escopo deste trabalho, uma vez que apenas as matrizes experimentais serão utilizadas para representação da região experimental do problema de OvS, realização da simulação e análise de eficiência.

2.6.1 Seleção do Arranjo Ortogonal

Para Bolboacă e Jäntschi (2007), a escolha da matriz ortogonal adequada para um determinado problema de interesse é a principal dificuldade do método de Taguchi. Os principais AO disponíveis na literatura são disponibilizados nas Tabelas 2.9A e 2.9B.

No. de Níveis	Número de Fatores														
No. de Niveis	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
2	L4	L4	L8	L8	L8	L8	L12	L12	L12	L12	L16	L16	L16	L16	L32
3	L9	L9	L9	L18	L18	L18	L18	L27	L27	L27	L27	L27	L36	L36	L36
4	L16	L16	L16	L16	L32	L32	L32	L32	L32						
5	L25	L25	L25	L25	L25	L50	L50	L50	L50	L50	L50				

Tabela 2.9A - Matriz de seleção dos Arranjos Ortogonais

No. de Níveis		Número de Fatores													
	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
2	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32	L32
3	L36	L36	L36	L36	L36	L36	L36								
4															
5															

Tabela 2.9B - Matriz de seleção dos Arranjos Ortogonais (Continuação)

Definido o número de fatores e níveis que serão utilizados, o AO adequado pode ser selecionado. Usando a matriz de seleção apresentada na Tabela 2.9, para selecionar o arranjo correto, basta que se encontre a coluna que possui o número de fatores envolvidos no problema (número de variáveis de decisão), seguido da linha que representa a quantidade de níveis (limite de variação de cada variável). A intercessão entre a linha e a coluna resultará no AO a ser utilizado. Este é representado pela letra "L", seguido de um número, que representa a quantidade de experimentos a serem realizados (ROSS, 1996).

Definido o arranjo ortogonal, a matriz experimental que o representa pode ser gerada e os experimentos realizados. Como exemplo, para um experimento com 4 fatores e 2 níveis, o AO recomendado pela Tabela 2.9 é o arranjo L8. A matriz experimental que representa este arranjo é apresentada na Tabela 2.10

		Fat	ores	
Experimentos	A	В	C	D
1	1	1	1	1
2	1	1	2	2
3	1	2	1	2
4	1	2	2	1
5	2	1	1	2
6	2	1	2	1
7	2	2	1	1
8	2	2	2	2

Tabela 2.10 - Arranjo Ortogonal L8 com 4 fatores e 2 níveis

Existem na literatura diversos trabalhos que apresentam as matrizes experimentais dos arranjos apresentados na Tabela 2.9, bem como vários *softwares* que permitem a seleção e geração do AO desejado.

Para Hedayat, Sloane e Stufken (1999), a literatura aborda muitos AO padrões, como os apresentados na Tabela 2.9, no entanto, um sistema completo que inclua todas as possibilidades de matrizes ortogonais, mesmo para um pequeno número de experimentos, não são explorados.

Nesse sentido, trabalhos como o de Bolboacă e Jäntschi (2007) desenvolvem outros AO, além dos padrões já apresentados, trabalhando com níveis e parâmetros superiores aos comumente empregados, aumentando assim, a diversidade de AO disponíveis para experimentação.

Para Sloane e Stufken (1996), em muitos trabalhos clássicos envolvendo AO, todos os fatores possuem o mesmo número de níveis, sendo denominados de arranjos puros ou de níveis fixos. No entanto, para os autores, em muitas aplicações na realidade, torna-se necessário que os fatores possuam diferentes níveis.

De forma a atender tais situações, AO de níveis misto ou assimétricos podem ser gerados utilizando o método da substituição expansiva (HEDAYAT, SLOANE e STUFKEN, 1999) ou a abordagem *mixed spreads* (RAINS, SLOANE e STUFKEN, 2002), que permitem a utilização de diferentes níveis em um AO.

Nesse sentido, para Sloane e Stufken (1996), a Programação Linear (2009) pode ser empregada na geração de matrizes ortogonais de nível fixo, que vão além dos arranjos padrões apresentados na Tabela 2.9.

3. MÉTODO DE PESQUISA

3.1 Considerações iniciais

Este capítulo apresenta a classificação da presente pesquisa, quanto a sua natureza, abordagem, objetivos e ao método de pesquisa. Em relação ao método de pesquisa são apresentadas suas principais características. Apresentam-se também, as etapas da pesquisa quantitativa, segundo a abordagem de Bryman (1989), e como se dará sua aplicação neste trabalho.

3.2 Classificação da pesquisa

A Figura 3.1 apresenta a classificação da pesquisa segundo a proposta de Miguel *et al.* (2010).

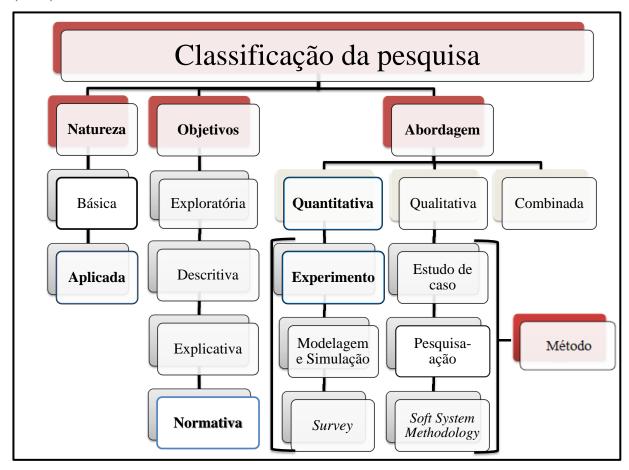


Figura 3.1 - Classificação da pesquisa segundo a proposta de Miguel et al. (2010)

Quanto à natureza, esta pesquisa pode ser classificada como aplicada, uma vez que, segundo Appolinário (2006), ela possui objetivos práticos, ou seja, que os resultados

alcançados com sua realização sejam aplicados ou utilizados para a solução de problemas reais.

Quanto à abordagem, pode-se classificar este trabalho como uma pesquisa baseada em modelagem quantitativa. Esta classificação é atribuída às pesquisas, nas quais modelos de relações causais entre variáveis de controle e variáveis de desempenho são desenvolvidos, analisados ou testados e se alteram sobre um domínio específico (BERTRAND e FRANSOO, 2002).

Quanto aos objetivos, Bertrand e Fransoo (2002) classificam as pesquisas quantitativas, em duas classes: as pesquisas axiomáticas e as pesquisas empíricas.

Nas pesquisas axiomáticas, a principal preocupação do pesquisador é a obtenção de soluções dentro de um modelo definido. A pesquisa axiomática produz conhecimento sobre o comportamento de certas variáveis, e também pode produzir conhecimento sobre como manipular algumas variáveis no modelo.

Já na pesquisa empírica, a principal preocupação do pesquisador é assegurar que existe uma adequação entre o modelo desenvolvido e o sistema real. Neste tipo de pesquisa, os resultados teóricos são aplicados em processos reais.

Para o caso específico dessa tese, como o objetivo se concentra no desenvolvimento de um método para redução do espaço de busca em problemas reais de OvS, pode-se concluir que a classificação mais adequada para esta pesquisa é a empírica.

Em uma classificação mais ampla, Bertrand e Fransoo (2002) classificam as pesquisas empíricas em duas classes:

- Empírica Descritiva: objetiva criar um modelo que descreva adequadamente as relações causais que podem existir na realidade, levando à compreensão dos processos atuais;
- Empírica Normativa: está interessada, principalmente, no desenvolvimento de políticas, estratégias e ações para melhorar um sistema real.

Partindo dessa classificação mais ampla, pode-se classificar esta pesquisa como tendo objetivos empíricos normativos. Uma vez que, neste trabalho, busca-se melhorar uma situação real, ao desenvolver um método que propiciará incrementar o desempenho do processo de OvS.

Por fim, optou-se pela utilização da experimentação como método de pesquisa para condução do trabalho a ser desenvolvido. Este método é apresentado nas próximas seções.

3.3 Método de pesquisa quantitativo: experimentação

Para Bertrand e Fransoo (2002), a modelagem quantitativa tem sido a base da maioria

dos estudos em Pesquisa Operacional. Inicialmente, a modelagem quantitativa foi orientada para solução de problemas reais, ao invés de servir para o desenvolvimento de conhecimento científico. Porém, com o passar do tempo, esse fato se alterou, e a necessidade de desenvolver uma teoria explicativa e preditiva sobre os processos operacionais, tornou-se necessária.

Para Gressler (2004), a abordagem quantitativa é amplamente utilizada, visando garantir resultados precisos, de modo a evitar interpretações dúbias ou distorções na análise dos dados. Deste modo, esta abordagem é caracterizada pela formulação de hipóteses, definição de variáveis, coleta de dados e pela realização de testes estatísticos.

Ainda, segundo a autora, a abordagem quantitativa estabelece relações de causa e efeito por meio de hipóteses, permitindo a análise matemática destas, a partir de dados estatísticos, comprovações e testes. Esta abordagem valoriza a experiência, verificação, controle e a neutralidade do pesquisador, permitindo construir uma realidade, por meio de fatos que podem ser observados, e em geral, quantificados.

Para Martins (2012), em Engenharia de Produção existem quatro métodos de pesquisa mais apropriados para a condução de uma pesquisa quantitativa: a Pesquisa de Avaliação (*Survey*), a Modelagem/Simulação, a Experimentação e o Quase-Experimento.

Na Experimentação ou Pesquisa Experimental são conduzidos experimentos, de maneira a testar relações de causas e efeitos entre as variáveis estabelecidas no estudo, operacionalizadas por meio das hipóteses. Isso é realizado com a manipulação pelo pesquisador das variáveis independentes, por meio da alteração dos níveis definidos para cada uma dessas variáveis e observando o efeito dessa variação no resultado das variáveis dependentes (MARTINS, 2012).

Segundo Kidder (2004), na experimentação se estuda a relação entre dois tipos de variáveis: as independentes e as dependentes. As variáveis independentes estão relacionadas às causas, enquanto as variáveis dependentes relacionam-se aos efeitos.

Para Bryman (1989), a experimentação conquistou uma notável importância em pesquisas organizacionais, devido a dois fatos. Primeiro, por este método de pesquisa permitir que o pesquisador possa tirar fortes conclusões sobre relações de causalidade. O segundo fato relaciona-se a facilidade do pesquisador que utiliza planejamentos experimentais encontra para estabelecer relações de causa e efeito.

Segundo Martins (1998), nessa abordagem é crítica a necessidade de controle para demonstração das relações de causa e efeito, pois somente exercendo controle sobre as variáveis se torna possível experimentar alternativas, verificando o efeito das variáveis independentes sobre as dependentes. Tal fato leva a experimentação a ter forte validade

interna, ou seja, quando o experimento está apto a concluir que a variável independente realmente afeta a variável dependente (BRYMAN, 1989).

No entanto, o mesmo fato que faz a experimentação possuir forte validade interna, prejudica sua validação externa, que segundo Gressler (2004), está ligada a abrangência da generalização dos resultados alcançados com o trabalho. Quanto mais condições se diferirem da situação real, mais difícil será de se generalizar os resultados, e menor será a sua validade externa (KIDDER, 2004).

3.4 Etapas da pesquisa

Bryman (1989) destaca a seguinte estrutura lógica (Figura 3.2), para a condução de uma pesquisa baseada em uma abordagem quantitativa.

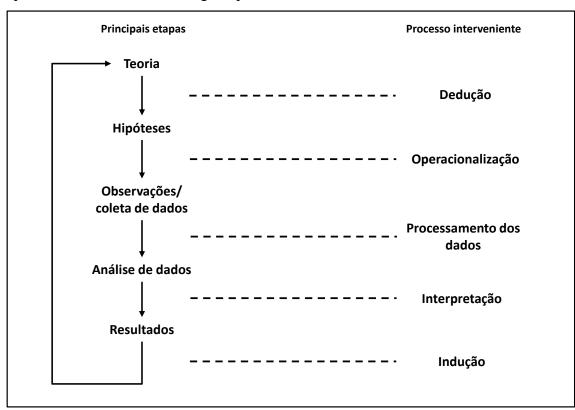


Figura 3.2 - Estrutura lógica da abordagem quantitativa Fonte: Bryman (1989)

Para Martins (2012), na abordagem quantitativa, tudo é iniciado a partir da definição do problema de pesquisa. Neste caso, o pesquisador, com a utilização da teoria, deve tentar explicar e prever o problema estudado. Com auxílio da teoria, hipóteses devem ser definidas para solucionar o problema de pesquisa, e posteriormente, estas deverão ser testadas.

De modo a tornar possível o teste das hipóteses propostas, variáveis que as representem devem ser definidas e mensuradas. A partir daí, dados deverão ser coletados, para

posteriormente serem analisados. Em muitos casos, testes estatísticos são utilizados como forma de testar as hipóteses definidas. A análise dos dados e posterior interpretação dos resultados fornecem uma base para indução dos resultados encontrados, permitindo modificar a teoria disponível ou confirmá-la.

Segundo Martins (2012), as fases iniciais da pesquisa quantitativa (Figura 3.2) são as mais longas e complexas de serem realizadas, uma vez que, todo o delineamento da pesquisa acontece nestas etapas. Para o autor, a análise dos dados, geralmente auxiliada pela estatística, e as conclusões são mais fáceis de serem realizadas pelo pesquisador.

3.5 Aplicação das etapas da pesquisa

Seguindo a abordagem proposta por Bryman (1989), para um estudo quantitativo, a teoria que suportará a aplicação do método, foi desenvolvida ao logo de todo o Capítulo 2, focando o problema de pesquisa apresentado no Capítulo 1 e os principais conceitos e técnicas relacionados à proposição do método desenvolvido nesta tese.

Delineado o problema de pesquisa, e as principais ferramentas necessárias a proposição do método, são apresentadas, com base na revisão da teoria, as premissas assumidas neste trabalho, que permitiram propor o método para redução do espaço de busca em problemas de OvS (Capítulo 4).

Na terceira etapa da abordagem, tendo por base a teoria e as premissas assumidas, é proposta a estrutura do método (Capítulo 4) e este é aplicado na otimização de modelos de simulação (Capítulo 5), sendo seus resultados armazenados para comparações.

Na etapa de análise de dados, os resultados são comparados em duas situações, permitindo a validação do método. No Capítulo 5, os dados provenientes da aplicação do método são comparados com os resultados da otimização sem sua aplicação. Posteriormente, essa comparação é realizada entre os dados da aplicação do método e o resultado ótimo global. A realização destas comparações permitiu que o método fosse validado, para as condições de contorno estabelecidas nessa tese.

Por fim, de posse dos resultados da análise dos dados, as principais conclusões alcançadas serão apresentadas no Capítulo 6, permitindo expandir a teoria existente sobre os temas pesquisados.

4. MÉTODO PROPOSTO PARA REDUÇÃO DO ESPAÇO DE BUSCA

4.1 Considerações iniciais

Este capítulo apresenta o método para redução do espaço de busca para problemas de OvS proposto nesta tese. Para tal, são apresentadas as quatro técnicas empregadas no método, e as etapas necessárias a sua aplicação. São apresentadas também neste capítulo, as premissas assumidas para o desenvolvimento deste trabalho, bem como as condições de contorno necessárias a aplicação deste. Dessa forma, este capítulo cumprirá a segunda etapa do método proposto por Bryman (1989) e iniciará sua terceira etapa, que será finalizada no próximo capítulo.

4.2 Técnicas utilizadas para proposição do método proposto e premissas assumidas

O método proposto nesta tese, para redução do espaço de busca para problemas de OvS, faz uso de quatro técnicas amplamente discutidas e utilizadas na literatura. São elas:

- A Simulação a Eventos Discretos (SED), para construção dos modelos de simulação, execução dos experimentos da matriz experimental, geração dos *outputs* a serem analisados pela DEA e execução da otimização em conjunto com a ferramenta de OvS;
- A Análise Envoltória de Dados com retornos variáveis de escala (DEA BCC), para análise de supereficiência de cada um dos cenários gerados e classificação das DMUs mais eficientes;
- Os Arranjos Ortogonais de Taguchi (AO), para elaboração da matriz experimental e geração dos cenários; e
- A Otimização via Simulação (OvS) para se buscar as melhores configurações para um sistema modelado.

Esse método tem por premissas, que a utilização do AO permite representar a região experimental do problema de OvS, com o menor número de cenários possíveis. E que, com a aplicação da DEA BCC neste arranjo, torna-se possível limitar o espaço de busca deste problema, por meio do *ranking* das DMUs mais eficientes. Isso permitirá, que a região de

busca do problema de OvS, seja reduzido. Dessa forma, o método de otimização empregado, poderá se concentrar nessa região limitada, onde se espera que a melhor solução para o problema de otimização se encontrará.

Por focar uma região menor do espaço de busca total, espera-se que o tempo computacional necessário para que o otimizador chegue a uma solução, seja menor, ao mesmo tempo em que se espera alcançar uma solução estatisticamente igual ao problema original, sem a redução do espaço de busca.

Optou-se nesse trabalho, pela utilização dos Arranjos Ortogonais de Taguchi, por essa estratégia experimental permitir trabalhar com fatores em vários níveis (ROSS, 1996), ao contrário de estratégias fatoriais clássicas, como planejamentos fatoriais completos, fracionários e arranjos de Plackett-Burman, que trabalham com apenas dois níveis (MONTGOMERY, 2005).

Dessa forma, com o uso dos AO, a matriz experimental a ser ensaiada via simulação será mais diversificada, podendo assim representar de forma mais ampla a região de busca do problema de OvS.

Com relação ao modelo DEA escolhido, para os objetivos desta tese, o modelo DEA com retornos variáveis de escala (BCC), se mostrou o mais indicado, principalmente devido a natureza estocástica e não linear da SED (WENG *et al.*, 2011). Soma-se a isso, o fato dos variados tipos de entradas e saídas de um modelo de simulação, tenderem a possuir retornos de escala diferentes, fato este que impediria o uso do modelo DEA CCR, que preconiza como propriedade principal a proporcionalidade entre *inputs* e *outputs* na fronteira (MELLO *et al.*, 2005), o que não é comum em modelos de SED.

Complementarmente, segundo Cooper, Sieford e Tone (2007), o modelo DEA BCC é invariante a transformações lineares, enquanto o modelo CCR não é. Outro fato relevante está na possibilidade de trabalhar com dados que apresentem valores negativos, o que pode ocorrer em modelos de simulação estocásticos como, por exemplo, no caso de uma variável associada ao lucro, que pode vir a ser negativa, no caso de prejuízo. A solução proposta na literatura (DYSON *et al.*, 2001) para esse caso é somar um valor positivo aos valores de entrada e/ou saída de cada DMU. Essa abordagem só pode ser utilizada em modelos DEA BCC, pois os modelos CCR são invariantes a translação.

Ainda, segundo Azadeh *et al.* (2011), quando os dados de saída de um modelo encontram-se na forma de índices, como é o caso de valores médios utilizados em simulação, o modelo DEA BCC é o mais indicado.

Por fim, cabe ressaltar que o modelo DEA BCC utilizado neste trabalho possui

orientação a *inputs*. Tal fato é justificado, segundo Silveira (2011), uma vez que, ao se considerar um *output* indesejável como *input*, como por exemplo, custos de produção, refugo ou estoque em processamento, pode ocorrer uma variação ilimitada deste *output*, neste caso o ideal é aplicar a orientação a *inputs*.

Ainda, segundo Figueiredo e Mello (2009), em um modelo DEA BCC com orientação a *inputs*, o índice de eficiência não se altera se um valor positivo for somado a todos os *outputs*, solução essa adotada caso o *output* seja negativo. Tais observações justificam a escolha da orientação a *inputs* para o modelo utilizado neste trabalho.

4.3 Método proposto para redução do espaço de busca em problemas de Otimização via Simulação

Definidas as ferramentas que compõe o método para redução do espaço de busca em problemas de OvS, e as premissas assumidas com seu desenvolvimento, pode-se apresentar as etapas de sua aplicação.

Antes, cabe destacar que a aplicação do método parte do pressuposto que o modelo de simulação, que se deseja otimizar, encontra-se construído, verificado e validado (Passo 0), e que as variáveis de decisão do problema sejam todas do tipo inteiras.

Os passos para a aplicação do método são os seguintes:

- **Passo 1:** Determinar as variáveis de decisão do problema de OvS $(x_1, x_2, x_3, ..., x_n)$ e os limites de variação para cada variável (Limite inferior $\leq x_i \leq$ Limite superior, com $1 \leq i \leq n$);
- **Passo 2:** Determinar as variáveis de saída que serão otimizadas: minimização e/ou maximização de uma ou mais variáveis de saída $(y_1, y_2, y_3, ..., y_m)$;
- **Passo 3:** Selecionar o Arranjo Ortogonal de Taguchi que melhor se adequa ao problema estudado (L4, L9, L12, L16, L25, L32, L54,). Esse arranjo deve ser definido levando-se em consideração o número de variáveis de decisão e seus limites de variação; e deve atender ao número mínimo de DMUs necessários para serem analisados pelo modelo DEA BCC, de forma a atender a regra básica proposta por Banker *et al.* (1989).
- **Passo 4:** Gerar a matriz experimental que represente o Arranjo Ortogonal de Taguchi escolhido no passo anterior;
- **Passo 5:** Executar os experimentos no simulador, seguindo a matriz experimental desenvolvida. Os dados resultantes desta etapa deverão ser armazenados para fins de análise;
- **Passo 6:** Determinar a supereficiência de cada cenário, por meio da aplicação do modelo DEA BCC nos resultados simulados. Neste caso, considerar cada linha da matriz

experimental com seu resultado simulado como uma DMU;

Passo 7: Com base nos resultados da aplicação do modelo de supereficiência (DEA BCC), ranquear as DMUs;

Passo 8: Baseando-se nas 2 DMUs mais eficientes, definir uma nova faixa de variação para cada variável de decisão, retirando do processo de otimização aquelas variáveis cujos valores em ambas as DMUs mais eficientes forem iguais, sendo este valor adotado para aquela variável:

Passo 9: Otimizar o modelo de simulação, utilizando a nova faixa de variação para cada variável de decisão.

A Figura 4.1 apresenta a estrutura do método para redução do espaço de busca em problemas de OvS desenvolvido nesta tese. Na Figura 4.1, as atividades estabelecidas à direita do fluxo principal (Passos 0, 5 e 9) são realizadas no simulador ou pelo módulo de otimização acoplado ao simulador.

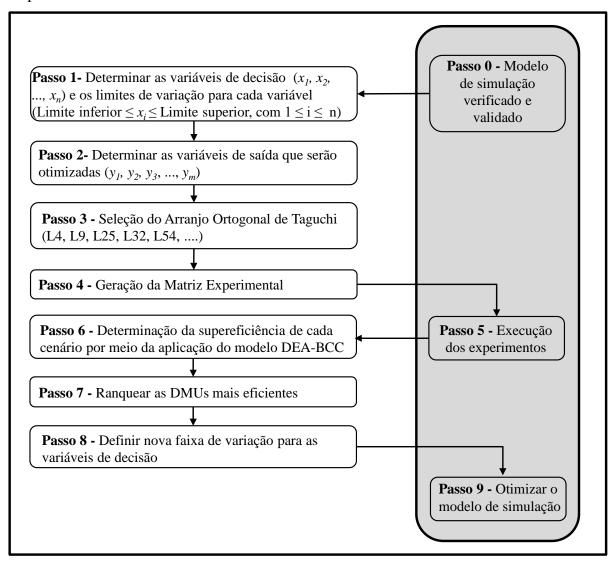


Figura 4.1 - Estrutura do método proposto para redução do espaço de busca em problemas de OvS

5. APLICAÇÃO DO MÉTODO PROPOSTO

5.1 Considerações iniciais

Nesta seção serão descritas aplicações do método proposto em modelos de simulação, bem como serão feitas análises dos resultados obtidos que validaram o procedimento e mostraram seu potencial de uso na melhoria do desempenho da OvS.

Segundo Ahuja, Magnanti e Orlin (1993), a literatura destaca três abordagens básicas para medir o desempenho de um método: a análise empírica, cujo objetivo é estimar como o método se comporta na prática, testando seu desempenho na aplicação de algumas classes de problemas; a análise média, em que o objetivo é estimar o número médio de passos do método; e a análise do pior caso, que torna possível analisar os limites do método na análise do pior caso.

Para esta tese, optou-se pelo uso da análise empírica, uma vez que se deseja conhecer o comportamento e eficiência do método proposto em problemas de OvS que visem a alocação de recursos.

Para aplicação do método de otimização foram utilizados quinze modelos de simulação, que se enquadraram em cinco classes de problemas de OvS, sendo elas:

- **Primeira classe de problemas de OvS:** modelos de simulação com número de níveis iguais por variável de decisão, contemplando problemas de OvS mono-objetivos;
- Segunda classe de problemas de OvS: modelos de simulação com número de níveis iguais por variável de decisão, contemplando problemas de OvS multiobjetivos;
- **Terceira classe de problemas de OvS:** modelos de simulação com número de níveis diferentes por variável de decisão, contemplando problemas de OvS mono-objetivos;
- Quarta classe de problemas de OvS: modelos de simulação em que o número de níveis e a quantidade de variáveis de decisão mudam, mantendo o mesmo modelo de simulação;
- Quinta classe de problemas de OvS: modelos de simulação em que o número de níveis e o número de variáveis de saída mudam, mantendo o mesmo modelo de simulação.

A seleção desses quinze modelos se deve ao fato, de se adequarem as condições de contorno estabelecidas para aplicação do método aqui desenvolvido, e por sua

disponibilidade, contemplando casos teóricos presentes na literatura e problemas reais do grupo de pesquisa do pesquisador.

Os quinze casos apresentados exemplificam a utilização do método para redução do espaço de busca. Ressalta-se, que o método aqui desenvolvido pode ser aplicado a qualquer problema de OvS, desde que estes apresentem as mesmas condições de contorno já destacadas neste trabalho.

Após a aplicação do método, os resultados alcançados serão discutidos, comparando o resultado da otimização com a aplicação do método proposto, e sem a aplicação do método desenvolvido. Dos quinze objetos de estudo, quatro terão todo o seu espaço de busca simulado, para realização da comparação do resultado ótimo global com o resultado encontrado com o método proposto. Com isso, pretende-se validar as premissas assumidas, quando da proposição do método desenvolvido nesta tese. Devido a limitações de ordem computacional, a simulação de todo o espaço de busca para os demais objetos de estudo se mostrou inviável.

Desta forma, neste capítulo encerra-se a terceira etapa do método de Bryman (1989), iniciada no capítulo anterior, bem como é iniciada e finalizada a quarta etapa do método com a realização da análise dos dados.

5.2 Primeira classe de problemas de OvS

5.2.1 Primeiro objeto de estudo

O primeiro objeto de estudo representa uma célula de produção de uma empresa brasileira do setor de telecomunicações. A empresa em questão produz *transponders* que são vendidos a vários países. Todas as etapas de verificação e validação do modelo de simulação foram empregadas, de forma que o modelo representa de forma adequada o sistema que se busca otimizar. No Anexo C é apresentado o modelo conceitual para este objeto de estudo, bem como para os demais casos testados nesta tese, realizado segundo a técnica de modelagem IDEF-SIM (LEAL, ALMEIDA e MONTEVECHI, 2008). A simbologia desta técnica de modelagem é apresentada no Anexo B.

Para o objeto de estudo apresentado, foram definidas como variáveis de decisão: o número de bancadas dos tipos 1 e 2, denotados por x_1 e x_2 , e o número de funcionários dos tipos 1, 2 e 3, denotados por x_3 , x_4 e x_5 . Definiu-se que as variáveis de decisão seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 5. A Tabela 5.1 apresenta essas informações.

	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Número de bancadas do tipo 1	Inteira	1	5
x_2	Número de bancadas do tipo 2	Inteira	1	5
x_3	Número de operadores do tipo 1	Inteira	1	5
x_4	Número de operadores do tipo 2	Inteira	1	5
x_5	Número de operadores do tipo 3	Inteira	1	5

Tabela 5.1 - Variáveis de decisão, tipo e limites para o primeiro objeto de estudo

O relacionamento das variáveis de decisão junto ao sistema simulado deste objeto de estudo, bem como dos demais casos, tratados nesta tese, podem ser verificados nos modelos conceituais presentes no Anexo C. Apresenta-se também, no Anexo D, a visualização gráfica dos modelos de simulação utilizados.

O objetivo da otimização foi encontrar a melhor combinação das variáveis de decisão, de forma a maximizar a produção total, denotada por y_1 . No Anexo E são apresentadas as formulações matemáticas referentes a todos os problemas de OvS apresentados nesta tese.

Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 3.125 cenários possíveis (5⁵) para a busca da melhor configuração.

Considerando a quantidade de variáveis de decisão e a variação dos níveis de cada variável, optou-se por um arranjo ortogonal L25. Este arranjo prevê a realização de 25 experimentos, o que atende a regra mínima do número de DMUs ser igual ou superior a 3 vezes o número total de variáveis de entrada e saída (BANKER *et al.*, 1989; COOPER, SEIFORD e TONE, 2007). Para o objeto de estudo em questão, seriam necessários, no mínimo, 18 DMUs.

Com o arranjo definido, foi gerada a matriz experimental apresentada na Tabela 5.2. Os cenários na matriz experimental foram simulados no *ProModel*®. Trinta replicações para cada cenário, referentes a um mês de operação da célula de produção, foram simuladas e os dados referentes a cada variável de saída foram armazenados para o cálculo da supereficiência. As trinta replicações garantiram um nível de precisão aceitável pelos tomadores de decisão, bem como permitiram a utilização de testes paramétricos, como o Teste T, para comparação das respostas, visto que tais testes exigem no mínimo 30 amostras para sua utilização.

As simulações dos 25 cenários e suas replicações foram realizadas em um computador com processador *Intel* (*Core 2 Duo*) 1.58 *GHZ*, 2*GB* de *RAM* e sistema operacional *Windows*, plataforma 64 *bits*, e consumiram pouco menos de 25 minutos. Os resultados encontrados são apresentados na Tabela 5.2. Os dados analisados referem-se à média de 30 replicações para cada cenário.

Para o cálculo da supereficiência com o modelo DEA BCC, relacionada a cada DMU, foi utilizado o *software The General Algebraic Modeling* - GAMS (GAMS, 2013), versão 22.8.1. A programação do modelo utilizado neste objeto de estudo é apresentada no Anexo F. Com estes resultados pode-se relacionar a cada cenário o valor da supereficiência da DMU.

Pelos valores de supereficiência (Tabela 5.2) foi possível ranquear as DMUs mais eficientes. Para este objeto de estudo, a DMU 17 foi a mais eficiente, seguida pela DMU 1. Ambas as DMUs encontram-se destacadas na Tabela 5.2.

Tabela 5.2 - Matriz experimental e resultados obtidos para o primeiro objeto de estudo

	Vai	riáve	is de	Dec	isão	Variáveis de Saída	G # 10 1	
DMU	x_1	x_2	x_3	x_4	<i>x</i> ₅	<i>y</i> ₁ (un)	Supereficiência	Ranking
1	1	1	1	1	1	853,77	2,000	2
2	1	2	2	2	2	1.392,97	1,630	6
3	1	3	3	3	3	1.391,40	1,000	18
4	1	4	4	4	4	1.393,53	1,370	8
5	1	5	5	5	5	1.392,97	1,000	18
6	2	1	2	3	4	1.252,93	1,159	15
7	2	2	3	4	5	1.394,50	1,085	16
8	2	3	4	5	1	1.393,47	1,278	10
9	2	4	5	1	2	851,73	1,000	18
10	2	5	1	2	3	1.136,77	1,218	13
11	3	1	3	5	2	1.394,30	1,345	9
12	3	2	4	1	3	851,57	1,000	18
13	3	3	5	2	4	1.396,43	1,875	4
14	3	4	1	3	5	1.125,00	1,000	18
15	3	5	2	4	1	1.393,43	1,529	7
16	4	1	4	2	5	1.395,57	1,917	3
17	4	2	5	3	1	1.395,43	2,989	1
18	4	3	1	4	2	1.121,83	1,182	14
19	4	4	2	5	3	1.394,90	1,687	5
20	4	5	3	1	4	847,63	1,000	18
21	5	1	5	4	3	1.394,83	1,039	17
22	5	2	1	5	4	1.152,07	1,244	11
23	5	3	2	1	5	852,07	1,000	18
24	5	4	3	2	1	1.306,07	1,224	12
25	5	5	4	3	2	1.389,67	0,790	25

Com a identificação destas duas DMUs mais eficientes, um novo intervalo para cada variável de decisão pode ser redefinido, permitindo assim, a redução do espaço de busca do processo de otimização.

Ainda analisando a Tabela 5.2, pode-se verificar que a variável x_5 apresentou o mesmo valor nas DMUs mais eficientes, tendo, portanto, seu valor definido em $x_5 = 1$, reduzindo o

número de variáveis do problema de 5 para 4. Os novos intervalos de variação para as outras variáveis de decisão são apresentados na Tabela 5.3.

Tabela 5.3 - Variáveis de decisão, tipo e novos limites para o primeiro objeto de estudo

	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Número de bancadas do tipo 1	Inteira	1	4
x_2	Número de bancadas do tipo 2	Inteira	1	2
x_3	Número de operadores do tipo 1	Inteira	1	5
x_4	Número de operadores do tipo 2	Inteira	1	3

Com a redução do intervalo de variação de cada variável de decisão, o espaço de busca para a melhor solução foi reduzido de 3.125 para 120, uma redução de aproximadamente 96,2%. Para testar a eficiência desta proposta, um otimizador comercial foi empregado.

Para este trabalho foi utilizado o *software SimRunner*®, apresentado e discutido no Anexo A. De modo a não comprometer os resultados e a comparação realizada, para todos os casos onde este *software* foi empregado, utilizaram-se suas configurações padrões, definido como: perfil moderado e com taxa de convergência igual a 0,01% (SIMRUNNER USER GUIDE, 2002).

Para comprovar a eficiência da nova região de busca do problema de otimização, o SimRunner® foi configurado para realizar a otimização do modelo de simulação, objetivando maximizar a produção total na célula (y_1) , segundo a nova faixa de variação, definida com a utilização do método proposto (Tabela 5.3).

De modo a confirmar os resultados obtidos com a otimização com o espaço de busca reduzido, o otimizador foi configurado nas mesmas condições, e com os mesmos objetivos, porém com a variação original para as variáveis de decisão (Tabela 5.1), ou seja, com o intervalo de variação de 1 a 5 para todas as variáveis de decisão. Os resultados encontrados em ambas as otimizações podem ser vistos na Tabela 5.4.

Tabela 5.4 - Resultados da otimização para o primeiro objeto de estudo

Variáveis de Decisão	So	olução
variaveis de Decisao	Novos Limites	Limites Originais
x_1	3	1
x_2	2	5
x_3	4	4
x_4	3	4
x_5	1	5
Variáveis de Saída	Res	spostas
y_1	1397	1398
Intervalo de confiança para y ₁ (95%)	(1393-1400)	(1394-1401)

As respostas apresentadas pelo otimizador, para as variáveis de decisão, só foram iguais para a variável $x_3 = 4$. Já para as demais variáveis de decisão, o otimizador encontrou valores diferentes, sendo que, para o problema com os intervalos originais, as respostas apresentadas indicam a necessidade de um número maior de funcionários e equipamentos, a exceção da variável x_1 .

Devido ao caráter estocástico de um modelo de SED, uma comparação baseada apenas no valor médio encontrado para uma solução seria incorreto (CHWIF e MEDINA, 2010). Dessa forma, optou-se pela realização de testes estatísticos, de forma a comprovar a igualdade das respostas encontradas.

De posse dos resultados das 30 replicações encontradas para cada uma das soluções apresentadas na Tabela 5.4, foi conduzido um teste de normalidade de Anderson-Darling, em que se constatou a normalidade de ambas as amostras de dados. Na sequência, foi conduzido um teste de igualdade de variâncias (Teste F), constatando que ambas as amostras possuem a mesma variância (p-value = 0,804). Por fim, de modo a comprovar a igualdade dos resultados, foi realizado um Teste T (p-value = 0,726).

Como o *p-value* deste teste foi superior ao nível de significância adotado ($\alpha = 0.05$), pode-se concluir estatisticamente que ambas as soluções encontradas para o total produzido (y_1) são estatisticamente iguais. Os resultados dos testes realizados são apresentados na Tabela 5.5.

Tabela 5.5 - Resultados dos testes estatísticos para o primeiro objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com novos limites	0,408	0.004	0.726
Solução com limites originais	0,978	0,804	0,726

O otimizador comercial realizou 69 experimentos antes de convergir para o problema de otimização com o novo intervalo definido pelo método, o que equivale a 57,5% da área experimental reduzida (120 cenários), consumindo 2,4 horas. Já para o problema otimizado com o intervalo original, o otimizador realizou 243 experimentos, o que equivale a pouco mais de 7,7% de toda área experimental original (3.125 cenários), consumindo aproximadamente 8 horas.

A Figura 5.1 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido. São apresentados o tempo necessário para a convergência do otimizador, a resposta encontrada para o total produzido (y_1) e o número de experimentos necessários para se alcançar a resposta.

Em relação ao tempo necessário para convergência do otimizador, e ao número de experimentos realizados, para o espaço de busca reduzido, foram somados os valores gastos (tempo e experimentos) com a simulação dos 25 cenários do AO e com a aplicação da DEA. Mesmo neste caso, a aplicação do método mostrou-se vantajosa, pois alcançou a mesma resposta para o total produzido, e reduziu o tempo total para convergência do otimizador em aproximadamente 65%, além de promover uma redução do número de experimentos em aproximadamente 61%.

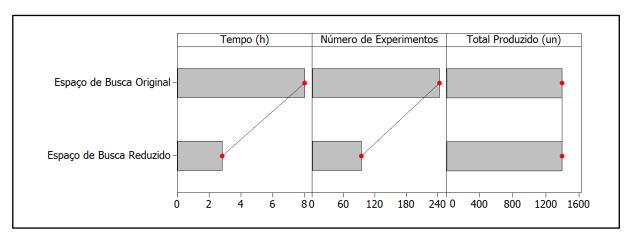


Figura 5.1 - Comparação dos resultados para o primeiro objeto de estudo

Vale ressaltar, que o tempo envolvido para execução das demais etapas do método é consideravelmente pequeno, quando comparado aos tempos para simulação dos cenários do arranjo ortogonal e otimização. Desta forma, tais tempos não foram acrescentados neste estudo.

5.2.1 Segundo objeto de estudo

O segundo objeto de estudo deste trabalho é uma Unidade de Processamento de Roupas (UPR) de um hospital paulista. A unidade é responsável pelo fornecimento e manutenção de roupas utilizadas por pacientes, médicos e enfermeiras de todos os setores que atendem os pacientes. Todas as etapas de verificação e validação do modelo de simulação foram empregadas, de forma que o modelo representa de forma adequada o sistema ao qual se procura otimizar.

Para o objeto de estudo apresentado, foram definidas como variáveis de decisão: o número de lavadoras (x_1) , o número de centrifugas (x_2) , o número de secadoras (x_3) , o número de operadores da área contaminada (x_4) e o número de funcionários da área não contaminada (x_5) , os quais desempenham atividades diferenciadas na célula modelada.

Foi definido que as variáveis de decisão seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 5. A Tabela 5.6 apresenta essas informações.

O objetivo da otimização foi encontrar a melhor combinação das variáveis de decisão de forma a maximizar o total de roupas lavadas (y_1) , em uma semana na lavanderia. Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 3.125 cenários possíveis para a busca da melhor configuração.

Variável Tipo **Limite Inferior Limite Superior** Número de lavadoras Inteira Número de centrífugas Inteira 5 1 5 Número de secadoras Inteira 1 x_3 5 Número de operadores área contaminada Inteira 1 Número de operadores área não contaminada Inteira

Tabela 5.6 - Variáveis de decisão, tipo e limites para o segundo objeto de estudo

Considerando a quantidade de variáveis de decisão e a variação dos níveis de cada variável, optou-se por um arranjo ortogonal L25. Este arranjo prevê a realização de 25 experimentos, o que atende a regra mínima do número de DMUs, que para este objeto de estudo deveria ser superior a 18 DMUs.

Com o arranjo definido, foi gerada a matriz experimental, apresentada na Tabela 5.7. Os cenários na matriz experimental foram simulados no *ProModel*®. Foram simuladas 30 replicações para cada cenário, referentes a uma semana de operação da unidade de processamento de roupas, e os dados referentes a cada variável de saída foram armazenados para o cálculo da supereficiência.

As simulações dos 25 cenários, e suas replicações, consumiram pouco menos de cinco minutos. Os resultados encontram-se apresentados na Tabela 5.7. Os dados analisados referem-se às médias das 30 replicações.

Para o cálculo da supereficiência relacionada a cada DMU com o modelo DEA BCC usou-se o *software* GAMS. Com estes resultados, pode-se relacionar a cada cenário o valor da supereficiência da DMU. Estes valores encontram-se dispostos na Tabela 5.7.

De posse dos valores de supereficiência (Tabela 5.7) foi possível ranquear as DMUs mais eficientes, podendo ser constatado que a DMU 23 é a mais eficiente seguida da DMU 14. Ambas as DMUs encontram-se destacadas na Tabela 5.7.

Com a identificação das DMUs mais eficientes, um novo intervalo para cada variável de decisão pode ser redefinido, permitindo assim, a redução do espaço de busca do processo de otimização.

Ainda da análise da Tabela 5.7, pode-se verificar que a variável x_5 apresentou o mesmo valor nas DMUs mais eficientes tendo, portanto, seu valor definido em $x_5 = 5$, reduzindo o número de variáveis do problema de 5 para 4. Os novos intervalos para as demais variáveis de decisão estão na Tabela 5.8.

Tabela 5.7 - Matriz experimental e resultados obtidos para o segundo objeto de estudo

DMU	Vai	riáve	is de	Dec	isão	Variável de Saída	Supereficiência	Dankina
DMU	x_1	x_2	x_3	x_4	x_5	$y_1(Kg)$	Superenciencia	Kanking
1	1	1	1	1	1	2958,00	2,000	3
2	1	2	2	2	2	2984,00	1,000	19
3	1	3	3	3	3	3013,00	1,008	18
4	1	4	4	4	4	2990,00	1,000	19
5	1	5	5	5	5	3012,00	1,000	19
6	2	1	2	3	4	5294,00	1,453	8
7	2	2	3	4	5	5325,00	1,459	7
8	2	3	4	5	1	4573,00	1,296	12
9	2	4	5	1	2	5300,00	1,442	10
10	2	5	1	2	3	5294,00	1,445	9
11	3	1	3	5	2	5275,00	1,460	6
12	3	2	4	1	3	5326,00	1,586	5
13	3	3	5	2	4	5313,00	0,813	25
14	3	4	1	3	5	5329,00	2,029	2
15	3	5	2	4	1	4519,00	1,234	16
16	4	1	4	2	5	5315,00	1,656	4
17	4	2	5	3	1	4530,00	1,248	15
18	4	3	1	4	2	5286,00	1,399	11
19	4	4	2	5	3	5295,00	0,814	24
20	4	5	3	1	4	5288,00	1,000	19
21	5	1	5	4	3	5249,00	1,000	19
22	5	2	1	5	4	5287,00	1,250	14
23	5	3	2	1	5	5328,00	2,333	1
24	5	4	3	2	1	4535,00	1,254	13
25	5	5	4	3	2	5304,00	1,103	17

Com a redução do intervalo de variação de cada variável de decisão, o espaço de busca para a melhor solução foi reduzido de 3.125 para 36, uma redução de aproximadamente 98,85%. Para testar a eficiência desta proposta de redução do espaço de busca, o *SimRunner*® foi utilizado.

Tabela 5.8 - Variáveis de decisão, tipo e novos limites para o segundo objeto de estudo

	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Número de lavadoras	Inteira	3	5
x_2	Número de centrífugas	Inteira	3	4
x_3	Número de secadoras	Inteira	1	2
x_4	Número de funcionários área contaminada	Inteira	1	3

Para comprovar a eficiência da nova região de busca, o SimRunner® foi configurado para realizar a otimização do modelo de simulação, objetivando maximizar o total de roupas lavadas (y_1) na lavanderia hospitalar, segundo o novo intervalo de variação, definido com a utilização do método proposto.

De modo a confirmar os resultados obtidos com a primeira otimização, o otimizador foi configurado nas mesmas condições e com os mesmos objetivos, porém com a variação original para as variáveis de decisão (Tabela 5.6), ou seja, com o intervalo de variação de 1 a 5 para todas as variáveis de decisão. Os resultados encontrados na otimização com a redução do espaço experimental, e segundo o problema original podem ser vistos na Tabela 5.9.

Vouióvois do Dosisão	Solução				
Variáveis de Decisão	Novos Limites	Limites Originais			
x_1	5	5			
x_2	4	4			
x_3	1	1			
x_4	1	1			
x_5	5	5			
Variáveis de Saída	Res	spostas			
<i>y</i> ₁	5.363	5.363			
ntervalo de confiança para y_1 (95%)	(5.319-5.406)	(5.319-5.406)			

Tabela 5.9 - Resultados da otimização para o segundo objeto de estudo

Tanto para o caso com o intervalo reduzido, como para o caso com o intervalo original, o otimizador encontrou a mesma solução para o problema de maximização do total de roupas lavadas na unidade de processamento (y_1) . As diferenças verificadas na otimização destes dois problemas foi quanto ao número de experimentos exigidos para se alcançar a solução, e quanto ao tempo necessário. Observou-se que o tempo computacional na solução dos problemas foi proporcionalmente maior para o caso em que o intervalo original foi utilizado.

O otimizador realizou 33 experimentos antes de convergir para o problema de otimização com o espaço de busca reduzido, o que equivale a aproximadamente 92% de toda a área experimental reduzida (36 cenários), consumindo 6,5 minutos. Já para o problema otimizado com o intervalo original, o otimizador realizou 165 experimentos, o que equivale a pouco mais de 5% de toda área experimental original (3.125 cenários), consumindo para tal, aproximadamente 33 minutos.

A Figura 5.2 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido. São apresentados o

tempo necessário para a convergência do otimizador, o número de experimentos necessários para se alcançar a resposta e o resultado encontrado para o total produzido. A aplicação do método proposto reduziu o tempo total para convergência do otimizador, em aproximadamente 65,45%, além de promover uma redução do número de experimentos em aproximadamente 64,50%, alcançando as mesmas soluções.

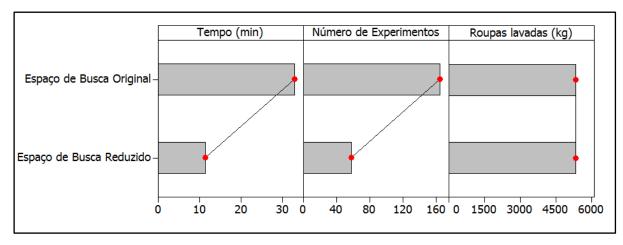


Figura 5.2 - Comparação dos resultados para o segundo objeto de estudo

5.3 Segunda classe de problemas de OvS

5.3.1 Terceiro objeto de estudo

O terceiro objeto de estudo representa uma célula de produção de uma empresa multinacional do setor automobilístico. A célula em questão é responsável pela produção de componentes automotivos, sendo estes produtos vendidos, tanto para o mercado nacional, como para exportação.

Todas as etapas de verificação e validação do modelo de simulação foram empregadas, de forma que o modelo representa adequadamente o sistema que se procura otimizar.

Para esse objeto de estudo foram definidas como variáveis de decisão o número de operadores dos tipos 1, 2 e 3 (x_1 , x_2 e x_3), o número de máquinas do tipo 1-4 (x_4), o número de máquinas do tipo 3 (x_5) e o número de fornos do tipo 1 (x_6). As máquinas foram escolhidas em função de serem os gargalos da célula de produção. Todas as variáveis foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 4, a exceção do número de fornos que varia de 1 a 2, conforme exposto na Tabela 5.10.

O objetivo da otimização foi encontrar a melhor combinação das variáveis de decisão de forma a maximizar a produção total na célula (y_1) , e minimizar o total de refugo (y_2) . Para o problema em questão, o espaço de busca pela melhor solução consiste em 2.048 cenários.

Cabe destacar, que a princípio, por ser uma técnica não-paramétrica, a DEA não requer uma investigação do relacionamento estatístico entre as variáveis de saída e as de entrada, como por exemplo, se existe correlação entre as variáveis de entrada e/ou saída.

		•	•	•
-	Variáveis de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número operadores do tipo 1	Inteira	1	4
x_2	Número operadores do tipo 2	Inteira	1	4
x_3	Número operadores do tipo 3	Inteira	1	4
x_4	Número de máquinas do tipo 1-4	Inteira	1	4
x_5	Número de máquinas do tipo 3	Inteira	1	4
x_6	Número de fornos do tipo 1	Inteira	1	2

Tabela 5.10 - Variáveis de decisão, tipo e limites para o terceiro objeto de estudo

Para este problema optou-se por um arranjo ortogonal misto L32, que atende a necessidade do número mínimo de DMUs. Para este objeto de estudo são necessárias, no mínimo 24 DMUs. A matriz experimental deste problema é apresentada na Tabela 5.11.

Foram simuladas 30 replicações de cada cenário, referentes a um mês de produção, e os dados referentes a cada variável de saída foram armazenados para o cálculo da supereficiência. O tempo computacional foi de aproximadamente sete minutos para o processamento dos 32 cenários, com 30 replicações cada.

Os resultados encontrados para as variáveis de saída y_1 e y_2 encontram-se apresentados na Tabela 5.11. Com os dados referentes às simulações, passou-se ao cálculo da supereficiência de cada cenário.

Uma vez que a variável de saída refugo (y_2) é uma variável do tipo que quanto menor melhor, existem três possibilidades para sua correta utilização no cálculo da eficiência (DYSON *et al.*, 2001): considerar o valor inverso do refugo, subtrair um número de valor suficientemente grande dos valores do refugo, ou considerar o refugo como sendo uma variável de entrada. Neste trabalho, optou-se pela terceira opção que é tratar a variável de saída refugo (y_2) como sendo uma variável de entrada, e calcular a supereficiência, por meio do modelo DEA BCC.

Pela análise da supereficiência (Tabela 5.11) foi possível ranquear as DMUs mais eficientes. A DMU 15 foi a mais eficiente dentre as 32, sendo seguida pela DMU 10. Ambas as DMUs encontram-se destacadas na Tabela 5.11.

Uma vez definidas as duas DMUs mais eficientes, pode-se definir a nova faixa de variação para cada variável de decisão. A variável x_6 teve seu valor fixado em 1, uma vez que nas duas DMUs mais eficientes, esta variável teve esse mesmo valor. Os novos intervalos de variação para cada variável de decisão podem ser vistos na Tabela 5.12.

Tabela 5.11 - Matriz experimental e resultados obtidos para o terceiro objeto de estudo

DMI		Variá	veis (le De	cisão		Variáveis	de Saída	C	D
DMU -	x_1	x_2	x_3	x_4	<i>x</i> ₅	x_6	<i>y</i> ₁ (un)	<i>y</i> ₂ (un)	– Supereficiência	Ranking
1	1	1	1	1	1	1	377.866,67	366,67	1,667	3
2	1	2	2	2	2	1	396.500,00	516,67	1,087	14
3	1	3	3	3	3	1	406.466,67	450,00	1,021	16
4	1	4	4	4	4	1	416.433,33	450,00	1,353	5
5	2	1	1	2	2	1	403.433,33	500,00	1,312	6
6	2	2	2	1	1	1	390.866,67	416,67	1,118	13
7	2	3	3	4	4	1	434.633,33	583,33	1,200	9
8	2	4	4	3	3	1	434.633,33	533,33	1,151	11
9	3	1	2	3	4	1	404.733,33	483,33	1,038	15
10	3	2	1	4	3	1	427.700,00	533,33	1,767	2
11	3	3	4	1	2	1	422.066,67	500,00	1,192	10
12	3	4	3	2	1	1	433.766,67	466,67	1,301	7
13	4	1	2	4	3	1	415.566,67	566,67	1,471	4
14	4	2	1	3	4	1	422.933,33	466,67	1,138	12
15	4	3	4	2	1	1	441.566,67	666,67	19,000	1
16	4	4	3	1	2	1	424.666,67	533,33	1,245	8
17	1	1	4	1	4	2	303.766,67	516,67	1,000	17
18	1	2	3	2	3	2	284.266,67	450,00	1,000	17
19	1	3	2	3	2	2	262.166,67	633,33	1,000	17
20	1	4	1	4	1	2	270.400,00	600,00	1,000	17
21	2	1	4	2	3	2	370.066,67	600,00	1,000	17
22	2	2	3	1	4	2	257.833,33	383,33	1,000	17
23	2	3	2	4	1	2	335.833,33	550,00	1,000	17
24	2	4	1	3	2	2	347.100,00	450,00	1,000	17
25	3	1	3	3	1	2	347.100,00	383,33	1,000	17
26	3	2	4	4	2	2	390.000,00	416,67	0,932	24
27	3	3	1	1	3	2	333.666,67	366,67	1,000	17
28	3	4	2	2	4	2	340.600,00	566,67	0,647	25
29	4	1	3	4	2	2	345.366,67	550,00	1,000	17
30	4	2	4	3	1	2	375.266,67	650,00	1,000	17
31	4	3	1	2	4	2	376.133,33	366,67	1,000	17
32	4	4	2	1	3	2	309.400,00	433,33	1,000	17

Tabela 5.12 - Variáveis de decisão, tipo e novos limites para o terceiro objeto de estudo

	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Número operadores do tipo 1	Inteira	3	4
x_2	Número operadores do tipo 2	Inteira	2	3
x_3	Número operadores do tipo 3	Inteira	1	4
x_4	Número de máquinas do tipo 1_4	Inteira	2	4
χ_5	Número de máquinas do tipo 3	Inteira	1	3

Com a redução do intervalo de variação para cada variável, o espaço de busca foi reduzido de 2.048 cenários para 144, uma redução de aproximadamente 93% do espaço de busca original. Novamente o *SimRunner*® foi utilizado para otimização do modelo de

simulação. Os mesmos parâmetros utilizados no otimizador, para os casos anteriores, foram mantidos na realização das otimizações.

O *SimRunner*® permite realizar otimizações com múltiplos objetivos, aglutinando as variáveis que se deseja otimizar em uma única função objetivo (SIMRUNNER USER GUIDE, 2002). De modo a não interferir nos resultados encontrados, o método de aglutinação utilizado pelo *software* foi utilizado para todos os casos de otimização com mais de um objetivo.

Os resultados obtidos com os novos intervalos de variação (Tabela 5.12) e com os intervalos originais (Tabela 5.10) são apresentados na Tabela 5.13.

Vaniénsia da Dasia	Solução			
Variáveis de Decisão	Novos Limites	Limites Originais		
x_1	4	4		
x_2	3	3		
x_3	4	4		
x_4	3	3		
x_5	2	2		
x_6	1	1		
Variáveis de Saída	Res	postas		
ν.	451 100	451 100		

Tabela 5.13 - Resultados da otimização para o terceiro objeto de estudo

 yariaveis de Saida
 Respostas

 y_1 451.100
 451.100

 Intervalo de Confiança para y_1 (95%) (447.691-454.509) (447.691-454.509)
 y_2 517
 517

 Intervalo de Confiança para y_2 (95%) (324-710) (324-710)
 (324-710)

Tanto para o caso com o intervalo reduzido, como para o caso com o intervalo original, o otimizador encontrou a mesma solução para os problemas de maximização do total produzido (y_1) e, também, para o problema de minimização do refugo (y_2) . As diferenças verificadas na solução destes dois problemas foi quanto ao número de experimentos exigidos para se alcançar a solução, e quanto ao tempo necessário. Observou-se que o tempo computacional na solução dos problemas foi maior para o caso em que o intervalo original foi utilizado.

Para o problema com o intervalo de variação reduzido, o otimizador realizou 76 experimentos antes de convergir, o que equivale a 53% desta área experimental (144 cenários), consumindo cerca de 19 minutos. Já para o problema otimizado com os limites originais, o otimizador realizou 158 experimentos, o que equivale a pouco mais de 7% de toda área experimental original (2.048 cenários), consumindo para tal, 41 minutos.

A Figura 5.3 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido. São apresentados o tempo necessário para a convergência do otimizador, o número de experimentos necessários para se alcançar as respostas, as soluções encontradas para o total produzido (y_1) e refugo (y_2) . A aplicação do método proposto reduziu o tempo total para convergência do otimizador em aproximadamente 31,60%, reduziu o número de experimentos em aproximadamente 35,30%, ao mesmo tempo, que encontrou as mesmas respostas para y_1 e y_2 .

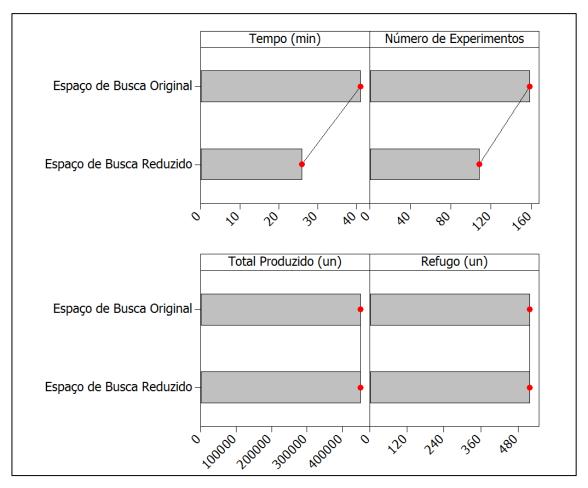


Figura 5.3 - Comparação dos resultados para o terceiro objeto de estudo

5.3.2 Quarto objeto de estudo

O quarto objeto de estudo foi desenvolvido em uma empresa do setor automobilístico. A célula modelada representa uma célula de produção de uma empresa multinacional fabricante de autopeças. O sistema é formado por duas unidades produtivas, com o mesmo conjunto de máquinas e operadores, desempenhando as mesmas funções. Todas as etapas de verificação e validação do modelo de simulação foram empregadas, de forma que o modelo representa de forma adequada o sistema que se busca otimizar.

Para esse objeto de estudo foram definidas como variáveis de decisão: o número de operadores de retífica (x_1 e x_3), o número de operadores de lapidadora (x_2 e x_4) e o número de retíficas na célula (x_5 e x_6). Todas as variáveis foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 5, conforme apresentado na Tabela 5.14.

Variável de Decisão Tipo **Limite Inferior Limite Superior** Número operadores na retífica 1 Inteira Número operadores na lapidadora 1 Inteira 5 x_2 5 Número operadores na retífica 2 Inteira x_3 5 Número operadores na lapidadora 2 Inteira x_4 5 Número de retíficas do tipo 1 Inteira χ_5 Número de retíficas do tipo 2 Inteira

Tabela 5.14 - Variáveis de decisão, tipo e limites para o quarto objeto de estudo

O objetivo da otimização foi encontrar a melhor combinação das variáveis de decisão, de forma a maximizar a produção total na célula (y_1) , e minimizar o custo de produção (y_2) . Para o problema em questão, o espaço de busca pela melhor solução possui 15.625 cenários.

Mais uma vez, devido ao número de variáveis de decisão e seus limites de variação, optou-se por um arranjo ortogonal L25, que atende a necessidade do número mínimo de DMUs. Para este objeto de estudo seriam necessárias no mínimo 24 DMUs. A matriz experimental deste problema é apresentada na Tabela 5.15.

Foram simuladas 30 replicações de cada cenário, referentes a um mês de produção, e os dados referentes a cada variável de saída foram armazenados para o cálculo da supereficiência. O tempo computacional foi de aproximadamente três horas para o processamento dos 25 cenários, com 30 replicações cada um.

Os resultados encontrados para as variáveis de saída y_1 e y_2 encontram-se apresentados na Tabela 5.15. Com os dados referentes às simulações, passou-se ao cálculo da supereficiência de cada cenário.

Pela análise da supereficiência (Tabela 5.15) foi possível ranquear as DMUs mais eficientes. A DMU 20 foi a mais eficiente dentre as 25, sendo seguida pela DMU 1. Ambas as DMUs encontram-se destacadas na Tabela 5.15.

Tabela 5.15 - Matriz experimental e resultados obtidos para o quarto objeto de estudo

DMI		Variá	veis (de De	cisão		Variávei	s de Saída	C	D L.:
DMU -	x_1	x_2	<i>x</i> ₃	<i>x</i> ₄	<i>x</i> ₅	x_6	<i>y</i> ₁ (un)	y ₂ (R\$)	- Supereficiência	Ranking
1	1	1	1	1	1	1	189.800,00	84.470,00	2,000	2
2	1	2	2	2	2	2	256.533,33	148.980,00	1,096	22
3	1	3	3	3	3	3	299.000,00	209.850,00	1,150	17
4	1	4	4	4	4	4	308.966,67	265.845,00	1,101	21
5	1	5	5	5	5	5	309.400,00	320.410,00	1,014	25
6	2	1	2	3	4	5	286.000,00	185.900,00	1,435	6
7	2	2	3	4	5	1	230.533,33	224.580,00	1,043	23
8	2	3	4	5	1	2	239.633,33	272.945,00	1,210	13
9	2	4	5	1	2	3	289.033,33	209.855,00	1,115	20
10	2	5	1	2	3	4	327.600,00	145.140,00	1,273	10
11	3	1	3	5	2	4	234.000,00	250.100,00	1,027	24
12	3	2	4	1	3	5	351.433,33	197.215,00	1,466	5
13	3	3	5	2	4	1	258.700,00	230.305,00	1,172	16
14	3	4	1	3	5	2	368.766,67	176.315,00	1,615	3
15	3	5	2	4	1	3	245.266,67	204.790,00	1,195	15
16	4	1	4	2	5	3	280.800,00	211.620,00	1,230	12
17	4	2	5	3	1	4	262.166,67	255.825,00	1,370	8
18	4	3	1	4	2	5	318.066,67	193.710,00	1,391	7
19	4	4	2	5	3	1	242.233,33	229.335,00	1,134	18
20	4	5	3	1	4	2	388.266,67	180.740,00	15,857	1
21	5	1	5	4	3	2	269.533,33	281.930,00	1,201	14
22	5	2	1	5	4	3	360.100,00	225.015,00	1,610	4
23	5	3	2	1	5	4	365.733,33	155.360,00	1,349	9
24	5	4	3	2	1	5	241.366,67	183.705,00	1,116	19
25	5	5	4	3	2	1	256.966,67	233.045,00	1,238	11

Uma vez definidas as duas DMUs mais eficientes, pode-se definir a nova faixa de variação para cada variável de decisão. A variável x_4 teve seu valor fixado em um, uma vez que nas duas DMUs mais eficientes, esta variável teve esse mesmo valor. Os novos intervalos para cada variável podem ser vistos na Tabela 5.16.

Tabela 5.16 - Variáveis de decisão, tipo e novos limites para o quarto objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número operadores na retífica 1	Inteira	1	4
x_2	Número operadores na lapidadora 1	Inteira	1	5
x_3	Número operadores na retífica 2	Inteira	1	3
x_5	Número de retíficas do tipo 1	Inteira	1	4
x_6	Número de retíficas do tipo 2	Inteira	1	2

Com a redução do intervalo de variação para cada variável, o número de cenários possíveis para otimização caiu de 15.625 para 480, uma redução de 97% no espaço de busca. Novamente, o *SimRunner*® foi utilizado para otimização do modelo de simulação. As

mesmas condições foram garantidas na realização das otimizações. Os resultados obtidos com os novos intervalos de variação (Tabela 5.16) e com os intervalos originais (Tabela 5.14) são apresentados na Tabela 5.17.

Tanto para o caso com o intervalo de variação reduzido, como para o caso com o intervalo original, o otimizador encontrou a mesma solução para os problemas de maximização do total produzido (y_1) e, também, para o problema de minimização dos custos (y_2) . Como no objeto de estudo anterior, as diferenças verificadas na solução destes dois problemas se deram quanto ao número de experimentos exigidos para se alcançar a solução e quanto ao tempo necessário.

Vaniénsia da Dasiaza	Solução			
Variáveis de Decisão	Novos Limites	Limites Originais		
x_1	4	4		
x_2	5	5		
x_3	1	1		
x_4	1	1		
x_5	4	4		
x_6	2	2		
Variávais da Saída	Pas	noctac		

Tabela 5.17 - Resultados da otimização para o quarto objeto de estudo

Variáveis de Saída	Respostas		
<i>y</i> ₁	388.267	388.267	
Intervalo de Confiança para y_1 (95%)	(379.277 - 397.257)	(379.277 - 397.257)	
y_2	130.740,00	130.740,00	
Intervalo de Confiança para y_2 (95%)	(129.391,48-132.088,52)	(129.391,48-132.088,52)	

O otimizador, para o problema de otimização com o espaço de busca reduzido, realizou 108 experimentos antes de convergir, o que equivale a 22,5% da área experimental, consumindo cerca de 45,5 horas. Já para o problema otimizado com o espaço de busca original, o otimizador realizou 186 experimentos, o que equivale a pouco mais de 1% de toda área experimental original, consumindo para tal 78,5 horas.

A Figura 5.4 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido. São apresentados o tempo necessário para a convergência do otimizador, o número de experimentos necessários para se alcançar as respostas e as soluções encontradas para o total produzido (y_1) e custo (y_2) .

A aplicação do método proposto reduziu o tempo total para convergência do otimizador em aproximadamente 38,20% e reduziu o número de experimentos em aproximadamente 28,50%, alcançando respostas idênticas para y_1 e y_2 .

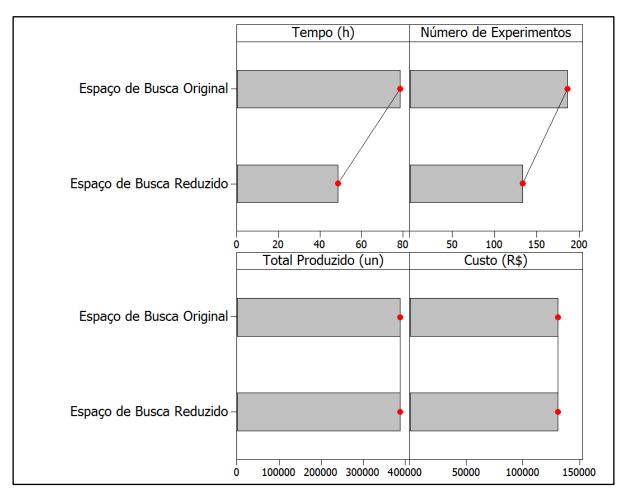


Figura 5.4 - Comparação dos resultados para o quarto objeto de estudo

5.3.3 Quinto objeto de estudo

O quinto objeto de estudo foi desenvolvido em uma empresa produtora de equipamentos de transmissão. A célula modelada corresponde ao controle de qualidade da empresa, sendo responsável pela realização de uma série de testes que irão garantir a aprovação ou reprovação dos equipamentos produzidos. Todas as etapas de verificação e validação deste modelo foram realizadas, de modo que o modelo encontra-se apto a otimização.

Para esse objeto de estudo foram definidas como variáveis de decisão: o número de operadores responsáveis pela realização de testes no controle de qualidade (x_1, x_2) e o número de equipamentos para testes dos tipos 1, 2 e 3 (x_3, x_4, x_5) .

Todas as variáveis de decisão foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 10. A Tabela 5.18 apresenta essas informações.

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores do tipo 1	Inteira	1	10
x_2	Número de operadores do tipo 2	Inteira	1	10
x_3	Número de equipamentos do tipo 1	Inteira	1	10
x_4	Número de equipamentos do tipo 2	Inteira	1	10
x_5	Número de equipamentos de tipo 3	Inteira	1	10

Tabela 5.18 - Variáveis de decisão, tipo e limites para o quinto objeto de estudo

O objetivo da otimização foi encontrar a melhor combinação das variáveis de decisão, de forma a maximizar o total de produtos inspecionados no controle de qualidade (y_1) e o lucro (y_2) ; e minimizar o número de produtos aguardando por inspeção (WIP) (y_3) . Para o problema em questão, considerando o número de variáveis de decisão e sua variação máxima, existe um total de 100.000 cenários possíveis para a busca da melhor configuração.

Considerando a quantidade de variáveis de decisão, a variação dos níveis de cada variável e a regra do número mínimo de DMUs (no mínimo 24 DMUs necessárias), optou-se por um arranjo ortogonal L25.

Como este arranjo trabalha com cinco níveis para cada variável, foi preciso distribuir os dez níveis do problema original nos cinco níveis disponíveis no arranjo, buscando assim, representar a região experimental da forma mais abrangente possível. A distribuição dos níveis por fator pode ser visualizada na matriz experimental apresentada na Tabela 5.19.

Com a matriz experimental definida, foram simulados os 25 cenários do arranjo L25, com 30 replicações, referentes a um mês de operação do controle de qualidade. Os dados referentes a cada variável de saída foram armazenados para o cálculo da supereficiência. Foram gastos cerca de 53 minutos para o processamento dos 25 cenários, considerando todas as replicações realizadas.

Os resultados encontrados para as variáveis de saída y_1 , y_2 e y_3 encontram-se apresentados na Tabela 5.19. Com os dados referentes às simulações, passou-se ao cálculo da supereficiência de cada cenário.

Pela análise da supereficiência foi possível ranquear as DMUs mais eficientes. Para o problema em questão, a DMU 1 é a mais eficiente, seguida da DMU 8. Ambas as DMUs encontram-se destacadas na Tabela 5.19.

A partir da identificação das duas DMUs mais eficientes, foi possível identificar um novo intervalo de variação para cada variável de decisão, onde se espera que um conjunto de soluções melhores para problema esteja contido.

								P O	quinto objeto de es	
DMU	Variáveis de Decisão Variáveis de Saída						a	Dankina		
DMU	x_1	x_2	x_3	x_4	x_5	$y_1(\mathbf{un})$	$y_2(\mathbf{R}\$)$	y_3 (un)	- Supereficiência	Kanking
1	1	1	1	1	1	3985,60	3.952.740,00	216,60	247,074	1
2	1	3	3	3	3	3970,60	3.933.940,00	230,20	1,000	6
3	1	5	5	5	5	3974,60	3.935.260,00	224,60	1,000	6
4	1	8	8	8	8	3974,60	3.926.680,00	224,60	1,000	6
5	1	10	10	10	10	3974,60	3.918.760,00	224,60	1,000	6
6	3	1	3	5	8	3984,60	3.946.150,00	216,60	1,000	6
7	3	3	5	8	10	3979,40	3.935.550,00	221,40	0,333	25
8	3	5	8	10	1	3986,20	3.943.335,00	219,00	4,000	2
9	3	8	10	1	3	3982,40	3.938.340,00	217,60	1,000	6
10	3	10	1	3	5	3975,00	3.927.975,00	230,20	1,000	6
11	5	1	5	10	3	3985,40	3.943.140,00	220,60	1,000	6
12	5	3	8	1	5	3986,40	3.946.285,00	213,20	3,045	3
13	5	5	10	3	8	3975,20	3.928.085,00	226,20	0,333	25
14	5	8	1	5	10	3980,00	3.930.655,00	223,20	1,000	6
15	5	10	3	8	1	3983,40	3.934.765,00	216,40	1,117	5
16	8	1	8	3	10	3985,40	3.935.015,00	220,60	1,000	6
17	8	3	10	5	1	3980,60	3.932.715,00	219,20	1,000	6
18	8	5	1	8	3	3980,00	3.931.500,00	223,20	1,000	6
19	8	8	3	10	5	3975,20	3.920.025,00	226,20	0,333	25
20	8	10	5	1	8	3976,00	3.918.405,00	229,20	1,000	6
21	10	1	10	8	5	3985,40	3.929.905,00	220,60	1,000	6
22	10	3	1	10	8	3977,80	3.921.530,00	221,20	1,000	6
23	10	5	3	1	10	3976,00	3.918.890,00	229,20	1,000	6
24	10	8	5	3	1	3983,40	3.928.575,00	216,40	1,151	4
25	10	10	8	5	3	3975,20	3.913.080,00	226,20	0,333	25

Tabela 5.19 - Matriz experimental e resultados obtidos para o quinto objeto de estudo

Os novos intervalos para cada variável de decisão são apresentados na Tabela 5.20. Destaca-se, que a variável x_5 teve seu valor definido, sendo igual a um, uma vez que esta variável apresentou este valor nas duas DMUs mais eficientes, reduzindo o número de variáveis de decisão para 4.

Com a redução do limite de variação de cada variável de decisão, o espaço de busca para a melhor solução foi reduzido de 100.000, para 1.200, uma redução de 98,80%.

Tabela 5.20 - Variáveis de decisão, tipo e novos limites para o quinto objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de bancadas do tipo 1	Inteira	1	3
x_2	Número de bancadas do tipo 2	Inteira	1	5
x_3	Número de operadores 1	Inteira	1	8
x_4	Número de operadores 2	Inteira	1	10

Para confirmar a eficiência da redução do espaço de busca, o *software SimRunner*® foi utilizado para otimização do modelo. O otimizador foi configurado nas mesmas condições e

com os mesmos objetivos, porém, como nos casos anteriores, duas otimizações foram conduzidas para o mesmo problema, uma com a redução do intervalo de variação (Tabela 5.20), e uma com as condições originais do problema (Tabela 5.18). Os resultados encontrados podem ser visualizados na Tabela 5.21.

Tabela 5.21 - Resultados da otimização para o quinto objeto de estudo

Variáveis de Decisão	Solução		
variaveis de Decisao	Novos Limites	Limites Originais	
x_1	3	3	
x_2	4	1	
x_3	3	4	
x_4	1	4	
χ_5	1	1	
Variáveis de Saída	Res	postas	

Variáveis de Saída	Respostas		
<i>y</i> ₁	3.995	3.988	
Intervalo de Confiança para y_1 (95%)	(3.989-4.001)	(3.983-3.993)	
y_2	3.960.935	3.953.345	
Intervalo de Confiança para y_2 (95%)	(3.954.724 - 3.967.146)	(3.947.280 - 3.959.410)	
y_3	207	214	
Intervalo de Confiança para y ₃ (95%)	(202-212)	(209-219)	

As respostas apresentadas pelo otimizador para as variáveis de decisão só foram iguais para as variáveis x_1 e x_5 . Para as demais variáveis, o otimizador chegou a valores diferentes. Quanto às soluções para y_1 , y_2 e y_3 , com a redução do espaço de busca, o otimizador alcançou resultados melhores estatisticamente para todas as variáveis de saída.

Como apresentado na Tabela 5.22, todos os dados se mostraram normais e apresentaram variâncias estatisticamente iguais, porém os resultados não puderam ser considerados iguais. Desta forma, com a redução do espaço de busca, as soluções encontradas foram melhores, quando comparadas com a otimização contemplando o intervalo original.

Tabela 5.22 - Resultados dos testes estatísticos para o quinto objeto de estudo

	Dados	Teste de Anderson-Darling	Teste F	Teste T	
	Solução com novos limites	0,170	0.502	< 0.000	
<i>y</i> ₁	Solução com limites originais	0,311	0,582	< 0,000	
	Solução com novos limites	0,152	0.436	< 0.000	
y_2	Solução com limites originais	0,570	0,430	< 0,000	
	Solução com novos limites	0,328	0.488	< 0.000	
<i>y</i> ₃	Solução com limites originais	0,356	0,466	< 0,000	

O otimizador realizou 169 experimentos antes de convergir para o problema de otimização com o espaço de busca reduzido, o que equivale a pouco mais de 14% da área

experimental reduzida (1.200 cenários), consumindo para isso pouco mais de 7,4 horas. Já para o problema com o espaço de busca original, o otimizador realizou 261 experimentos, o que equivale a pouco mais de 0,2% de toda área experimental original (100.000 cenários), consumindo para tal, 11,5 horas.

A Figura 5.5 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido. São apresentados o tempo necessário para a convergência do otimizador, o número de experimentos necessários para se alcançar as respostas e as soluções encontradas para o total de produtos inspecionados (y_1) , lucro (y_2) e WIP (y_3) . A aplicação do método proposto reduziu o tempo total para convergência do otimizador em aproximadamente 28%, além de promover uma redução do número de experimentos em aproximadamente 25,7%.

Para este objeto de estudo, as respostas encontradas para y_1 , y_2 e y_3 com a aplicação do método proposto foi melhor estatisticamente, que o resultado alcançado com o espaço de busca original.

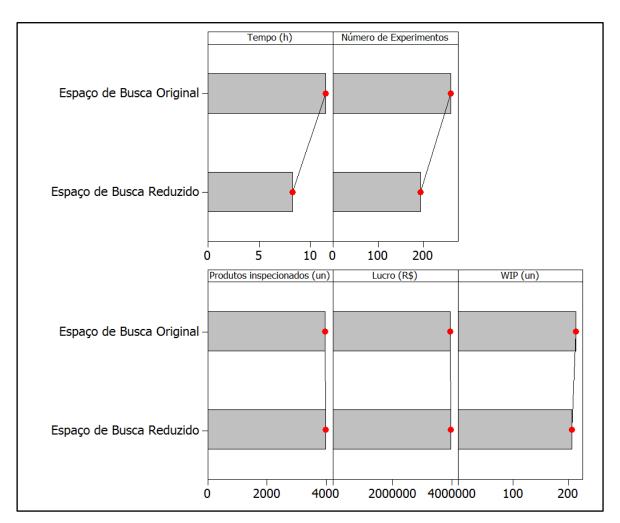


Figura 5.5 - Comparação dos resultados para o quinto objeto de estudo

5.4 Terceira classe de problemas de OvS

5.4.1 Sexto objeto de estudo

O sexto objeto de estudo representa um modelo real de um hospital e foi construído com base no trabalho de Ahmed e Alkhamis (2009). Este objeto de estudo apresenta cinco variáveis de decisão apresentadas na Tabela 5.23. Para esse objeto de estudo buscou-se encontrar a melhor combinação das variáveis de entrada, de modo a otimizar a taxa de atendimento horária de pacientes no hospital (y_1) .

Limite Inferior Variável de Decisão Tipo **Limite Superior** Número de recepcionistas Inteiro 3 x_1 Número de médicos Inteiro 1 4 x_2 5 Número de técnicos de laboratório Inteiro 1 Número de enfermeiras na sala de tratamento 1 6 Inteiro 1 12

Tabela 5.23 - Variáveis de decisão, tipo e limites para o sexto objeto de estudo

Considerando o número de variáveis de decisão e o número de níveis por variável, existe um total de 4.320 cenários para a busca da melhor solução. Devido a amplitude de variação dos níveis das variáveis de decisão envolvidas, optou-se por um arranjo L72.

Seguindo a mesmo orientação do artigo de Ahmed e Alkhamis (2009), cem replicações, referentes a um dia de operação do hospital, foram realizadas para cada configuração do arranjo L72. Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.24A e 5.24B.

A partir do *ranking* de supereficiência (Tabela 5.24), pode-se definir uma nova faixa de variação para cada variável de decisão, com base nas duas DMUs mais eficientes (60 e 5). Estes resultados são apresentados na Tabela 5.25.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 5 para 4, tendo a variável x_4 definida com valor igual a 2. O espaço de busca que era de 4.320 foi reduzido para 200. Uma redução de aproximadamente 95,4%.

Tabela 5.24A - Matriz experimental e resultados obtidos para o sexto objeto de estudo

	Var	iáve	is de	Dec	isão	Variáveis de Saída		
DMU	x_1	x_2	<i>x</i> ₃	x_4	<i>x</i> ₅	<i>y</i> ₁	Supereficiência	Ranking
1	3	1	4	4	1	1,71	1,091	13
2	3	2	5	3	1	2,22	1,000	15
3	2	4	2	6	1	2,41	1,000	15
4	2	1	2	5	1	1,68	1,286	8
5	1	2	1	2	1	2,07	1,683	2
6	1	3	3	1	1	2,35	1,000	15
7	2	4	4	2	2	4,16	0,617	67
8	3	1	2	1	2	2,47	1,000	15
9	1	3	5	6	2	3,98	1,000	15
10	2	4	1	3	2	2,96	1,000	15
11	1	2	3	4	2	3,64	1,000	15
12	3	1	2	5	2	2,44	1,000	15
13	1	4	3	5	3	5,26	1,000	15
14	2	2	5	4	3	4,47	0,696	61
15	1	1	5	1	3	2,66	1,000	15
16	3	4	1	2	3	2,99	1,000	15
17	2	1	2	6	3	2,68	1,000	15
18	3	3	4	3	3	5,11	0,610	69
19	3	3	1	6	4	3,01	1,000	15
20	2	1	3	2	4	2,76	1,000	15
21	3	4	5	5	4	5,71	0,530	72
22	2	2	4	1	4	4,75	1,000	15
23	1	3	2	3	4	4,96	1,000	15
24	1	4	2	4	4	5,00	1,000	15
25	1	2	1	5	5	2,99	1,000	15
26	1	2	4	3	5	4,96	1,000	15
27	3	4	1	6	5	3,05	0,613	68
28	2	3	2	4	5	4,99	0,756	58
29	3	1	5	1	5	2,75	1,000	15
30	2	1	3	2	5	2,75	1,000	15
31	1	4	2	3	6	5,16	1,000	15
32	1	3	4	5	6	5,71	1,000	15
33	2	1	3	4	6	2,70	1,000	15
34	2	2	1	6	6	3,07	1,000	15
35	3	3	1	2	6	3,05	1,000	15
36	3	4	5	1	6	5,66	1,000	15
37	2	1	1	3	7	2,65	1,500	3
38	3	2	5	4	7	5,10	0,573	71
39	1	3	4	6	7	5,72	1,000	15
40	3	3	3	1	7	5,58	1,000	15
41	2	4	5	5	7	5,74	0,674	63
42	1	2	2	2	7	4,71	1,098	12

Tabela 5.24B - Matriz experimental e resultados obtidos para o sexto objeto de estudo (continuação)

DMU	Vai	iáve	is de	Dec	isão	Variáveis de Saída	Supereficiência	D
DNIU	x_1	x_2	x_3	x_4	x_5	y_1	Superenciencia	Kanking
43	3	2	2	5	8	4,80	0,75	59
44	3	2	3	6	8	5,13	0,638	66
45	2	3	4	1	8	5,61	1,000	15
46	2	4	3	3	8	5,73	0,867	53
47	1	1	1	4	8	2,63	1,500	4
48	1	1	5	2	8	2,70	1,000	15
49	2	3	5	3	9	5,75	0,853	54
50	3	2	4	6	9	5,06	0,591	70
51	3	1	4	5	9	2,79	1,000	15
52	1	2	2	2	9	4,72	1,099	11
53	2	3	1	4	9	2,96	1,000	15
54	1	4	3	1	9	5,59	1,000	15
55	3	4	2	4	10	5,07	0,651	65
56	1	1	3	6	10	2,70	1,125	9
57	3	2	3	3	10	5,15	0,692	62
58	2	2	4	5	10	5,06	0,672	64
59	1	4	1	1	10	3,02	1,500	5
60	2	3	5	2	10	5,75	3,211	1
61	2	2	1	1	11	3,03	1,500	6
62	3	3	2	2	11	5,10	0,805	55
63	1	1	5	6	11	2,75	1,000	15
64	1	4	4	4	11	5,73	1,000	15
65	3	1	1	3	11	2,64	1,500	7
66	2	3	3	5	11	5,72	0,757	57
67	2	2	2	1	12	4,73	1,100	10
68	3	3	3	4	12	5,72	0,723	60
69	3	4	4	2	12	5,74	0,761	56
70	2	4	5	6	12	5,75	0,923	52
71	1	1	4	3	12	2,72	1,091	14
72	1	3	1	5	12	2,99	1,000	15

Tabela 5.25 - Variáveis de decisão, tipo e novos limites para o sexto objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de recepcionistas	Inteiro	1	2
x_2	Número de médicos	Inteiro	2	3
x_3	Número de técnicos de laboratório	Inteiro	1	5
x_5	Numero de enfermeiras na sala de emergência	Inteiro	1	10

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador *SimRunner*® foi empregado. Os resultados encontrados são apresentados na Tabela 5.26. O otimizador encontrou valores diferentes para todas as variáveis de decisão, contemplando o espaço de busca original e o espaço de busca reduzido pelo método proposto.

Variáveis de Decisão	Solução			
variaveis de Decisao	Novos limites	Limites Originais		
x_1	2	3		
x_2	3	4		
x_3	4	5		
x_4	2	6		
x_5	10	9		
Variáveis de Saída	Respostas			
<i>y</i> ₁	5,75	5,76		
Intervalo de Confiança para y_1 (95%)	(5,74-5,77)	(5,75-5,78)		

Tabela 5.26 - Resultados da otimização para o sexto objeto de estudo

Em relação a resposta encontrada, em ambos os casos o otimizador encontrou soluções estatisticamente iguais, considerando um nível de confiança de 95%. Como os resultados das cem replicações não se mostraram normais para a solução encontrada, foi utilizado o teste não paramétrico de Mann-Whitney para confirmar que as respostas encontradas eram estatisticamente iguais. Os resultados dos testes estatísticos são apresentados na Tabela 5.27.

Tabela 5.27 - Resultados dos testes estatísticos

Dados	Teste de Anderson-Darling	Mann-Whitney
Solução com novos limites	< 0,005	0.102
Solução com limites originais	< 0,005	0,102

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 25,2 h para convergir, realizando 183 experimentos. Com o espaço de busca reduzido foram gastos 9,6 h para a realização de 73 experimentos. Somando a este valor às 8,5 h para a simulação do arranjo L72, o ganho de tempo computacional foi de 28%. A Figura 5.6 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

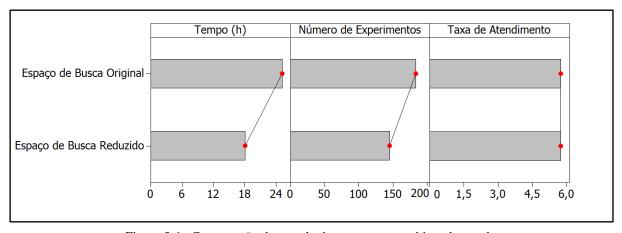


Figura 5.6 - Comparação dos resultados para o sexto objeto de estudo

5.4.2 Sétimo objeto de estudo

O sétimo objeto de estudo representa um modelo real de uma célula de produção de uma empresa do setor de autopeças. Para esse objeto de estudo foram definidas 11 variáveis de decisão, apresentadas na Tabela 5.28. O objetivo da otimização desse modelo foi encontrar a melhor combinação das variáveis de decisão de modo a otimizar o lucro da empresa (y_1) .

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores do tipo1	Inteiro	1	5
x_2	Número de operadores do tipo 2	Inteiro	1	4
x_3	Número de operadores do tipo 3	Inteiro	1	6
x_4	Número de máquinas do tipo 1	Inteiro	1	3
x_5	Número de máquinas do tipo 2	Inteiro	1	3
x_6	Número de máquinas do tipo 3	Inteiro	1	3
x_7	Número de máquinas do tipo 4	Inteiro	1	3
x_8	Número de máquinas do tipo 5	Inteiro	1	4
x_9	Número de máquinas do tipo 6	Inteiro	1	4
x_{10}	Número de máquinas do tipo 7	Inteiro	1	4
x_{11}	Número de máquinas do tipo 8	Inteiro	1	4

Tabela 5.28 - Variáveis de decisão, tipo e limites para o sétimo objeto de estudo

Considerando o número de variáveis de decisão e sua amplitude de variação, existe um total de 2.488.320 possíveis soluções para o problema.

Para este objeto de estudo considerando o numero de variáveis de decisão e o número de níveis por variável, optou-se por um arranjo L36. Foram realizadas 30 replicações para cada cenário compreendendo um mês de produção da célula de fabricação. Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.29.

A partir do *ranking* de supereficiência, pode-se definir uma nova faixa de variação para cada variável de decisão a partir das duas DMUs mais eficientes (16 e 32). Estes resultados são apresentados na Tabela 5.30.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 11 para 8. As variáveis x_4 , x_5 e x_{11} tiveram seus valores definidos como sendo igual a 1. O espaço de busca que era de 2.488.320 foi reduzido para 7.776, uma redução de aproximadamente 99,7%.

Tabela 5.29 - Matriz experimental e resultados obtidos para o sétimo objeto de estudo

				Var	iáve	is d	e Do	ecisá	ão			Variáveis de Saída		
DMU	$\overline{x_1}$	x_2	x_3	x_4	<i>x</i> ₅	x_6	<i>x</i> ₇	<i>x</i> ₈	x_9	x ₁₀	x ₁₁	<i>y</i> ₁ (\$)	Supereficiência	Ranking
1	3	2	1	2	3	1	1	4	2	4	2	10.600,00	1,455	16
2	2	2	2	3	2	3	1	4	4	3	1	-110.500,00	1,304	23
3	3	1	2	1	2	1	2	3	1	4	4	-49.100,00	1,647	10
4	1	4	5	1	2	3	3	4	2	2	4	194.100,00	1,324	22
5	1	1	1	2	3	3	3	2	4	1	4	-108.100,00	1,500	12
6	4	4	2	2	1	2	3	2	1	2	3	-68.500,00	1,119	27
7	3	3	6	1	3	2	1	1	4	2	3	222.400,00	1,438	17
8	5	1	5	3	3	2	2	2	2	2	1	102.000,00	1,250	24
9	5	4	4	3	3	3	1	3	1	3	4	-177.200,00	1,000	31
10	5	4	3	1	1	2	2	4	1	1	2	142.500,00	1,488	14
11	5	2	6	2	2	3	3	3	3	2	4	-410.200,00	0,765	35
12	3	4	3	2	2	3	3	1	2	4	1	34.000,00	1,000	31
13	5	3	1	3	2	1	2	4	4	1	3	1.700,00	1,673	9
14	1	2	4	1	3	2	2	3	2	1	3	161.000,00	1,489	13
15	5	1	6	2	1	1	2	1	2	3	3	293.000,00	1,977	5
16	1	4	6	1	1	1	1	3	4	4	1	335.100,00	7,375	1
17	1	2	5	3	3	1	3	1	1	3	3	46.800,00	1,556	11
18	4	4	4	2	2	1	2	1	3	1	1	308.100,00	2,102	3
19	2	4	6	3	3	3	2	2	3	4	2	-367.200,00	0,733	36
20	2	1	4	2	1	1	1	4	4	2	4	228.700,00	1,419	18
21	4	3	1	1	2	2	1	2	2	3	4	38.500,00	1,400	19
22	5	3	2	1	3	1	3	1	3	4	2	15.400,00	1,467	15
23	2	1	5	2	2	2	1	3	3	4	3	197.700,00	1,106	28
24	1	3	2	2	3	2	2	4	3	3	1	-80.300,00	1,364	20
25	4	3	5	2	1	3	2	3	4	3	2	-200.800,00	1,000	31
26	3	3	4	3	1	3	3	2	1	4	3	-9.500,00	1,000	31
27	2	2	4	1	2	2	3	2	4	3	2	138.400,00	1,012	30
28	1	3	3	2	2	1	1	2	1	2	2	118.900,00	1,785	7
29	4	2	3	3	1	2	2	1	4	4	4	-107.800,00	1,043	29
30	4	1	3	1	3	3	1	4	3	3	3	-62.400,00	1,333	21
31	1	1	2	3	1	3	1	1	2	1	2	-12.600,00	1,796	6
32	2	2	1	1	1	3	2	1	1	2	1	134.800,00	2,248	2
33	3	4	1	3	1	2	3	3	3	2	2	-3.100,00	1,200	26
34	4	1	6	3	2	2	3	4	1	1	1	256.700,00	2,036	4
35	3	2	5	1	1	1	1	2	3	1	1	365.100,00	1,759	8
36	2	3	3	3	3	1	3	3	2	1	4	-7.100,00	1,227	25

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador *SimRunner*® foi empregado, considerando o espaço de busca original e o espaço reduzido pelo método proposto.

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores do tipo 1	Inteiro	1	2
x_2	Número de operadores do tipo 2	Inteiro	2	4
x_3	Número de operadores do tipo 3	Inteiro	1	6
x_6	Número de máquinas do tipo 3	Inteiro	1	3
x_7	Número de máquinas do tipo 4	Inteiro	1	2
x_8	Número de máquinas do tipo 5	Inteiro	1	3
x_9	Número de máquinas do tipo 6	Inteiro	1	4
x_{10}	Número de máquinas do tipo 7	Inteiro	2	4

Tabela 5.30 - Variáveis de decisão, tipo e novos limites para o sétimo objeto de estudo

O otimizador encontrou soluções iguais para as variáveis de decisão x_4 , x_5 e x_6 . Para todas as demais variáveis, os valores encontrados foram diferentes. Estes resultados podem ser observados na Tabela 5.31.

Tabela 5.31 - Resultados da otimização para o sétimo objeto de estudo

Vanidada dada	Solu	ıção		
Variáveis de decisão	Novos limites	Limites originais		
x_1	2	5		
x_2	4	1		
x_3	6	5		
x_4	1	1		
x_5	1	1		
x_6	1	1		
x_7	1	3		
x_8	3	1		
χ_9	4	1		
x_{10}	3	2		
x_{11}	1	4		
Variáveis de saída	Respostas			
<i>y</i> ₁	483.700,00	480.400,00		
Intervalo de Confiança para y_1 (95%)	(454.936,00-512.464,00)	(453.447,00-507.353,00)		

Em relação ao valor encontrado para o lucro, ambas as soluções podem ser consideradas estatisticamente iguais, como pode ser observado por meio da análise estatística da Tabela 5.32.

Uma vez que as soluções encontradas não puderam ser aproximadas por distribuições normais, optou-se pela utilização do teste não-paramétrico de Mann-Whitney, que confirmou a igualdade das soluções encontradas para a variável de saída lucro (y_1) .

Dados	Teste de Anderson-Darling	Teste de Mann-Whitney	
Solução com novos limites	< 0,005	0.002	
Solução com limites originais	< 0,005	0,982	

Tabela 5.32 - Resultados dos testes estatísticos para o sétimo objeto de estudo

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 10,12 h para convergir, realizando 335 experimentos. Com o espaço de busca reduzido foram gastos 5,18 h para a realização de 172 experimentos. Somando a este valor às 0,62 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 42,7%. A Figura 5.7 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

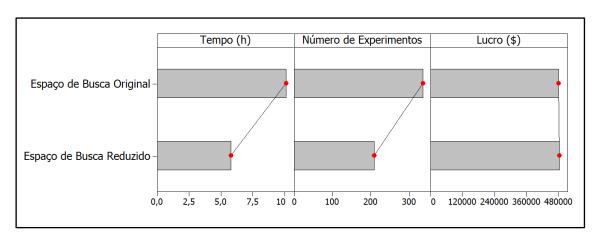


Figura 5.7 - Comparação dos resultados para o sétimo objeto de estudo

5.4.3 Oitavo objeto de estudo

O oitavo objeto de estudo representa um modelo real de uma célula de produção de uma empresa do setor de telecomunicações. Para este objeto de estudo foram definidas 7 variáveis de decisão, apresentadas na Tabela 5.33.

Neste modelo, além das variáveis inteiras representando o número de operadores, bancadas e tamanho dos estoques intermediários, existe uma variável do tipo binária, que ativa (1) ou desativa (0) a realização de uma atividade extra na célula de produção.

O objetivo da otimização deste modelo foi encontrar a melhor combinação das variáveis de decisão de modo a otimizar o lucro da empresa (y_1) .

Considerando o número de variáveis de decisão e sua amplitude de variação existe um total de 127.776 possíveis soluções para o problema. Devido ao número de variáveis de decisão e a variação de níveis para cada variável, optou-se para este objeto de estudo por um

arranjo L36. Foram realizadas 30 replicações para cada cenário compreendendo um mês de produção da célula de produção.

Tabela 5.33 - Variáveis de decisão, tipo e limites para o oitavo objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores	Inteiro	1	3
x_2	Número de bancadas do tipo 1	Inteiro	1	4
x_3	Número de bancadas do tipo 2	Inteiro	1	4
x_4	Atividade Organizar Material	Binário	0	1
x_5	Tamanho do estoque intermediário 1	Inteiro	5	15
x_6	Tamanho do estoque intermediário 2	Inteiro	5	15
x_7	Tamanho do estoque intermediário 3	Inteiro	5	15

Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados nas Tabelas 5.34A e 5.34B.

Tabela 5.34A - Matriz experimental e resultados obtidos para o oitavo objeto de estudo

									•		
DMU		Var	iáve	is d	e De	cisão	0	Variáveis de Saída	Supereficiência	Ranking	
DNIC	x_1	x_2	x_3	x_4	x_5	x_6	x_7	$y_1(\$)$	Superencia	Kunking	
1	3	1	1	0	5	5	5	33.275,00	1,832	2	
2	2	2	3	0	13	9	5	31.345,00	1,149	16	
3	1	3	2	0	9	9	5	11.268,33	1,588	6	
4	2	1	2	0	11	7	13	26.495,00	1,132	18	
5	1	4	3	0	7	11	13	10.085,00	1,039	24	
6	1	2	4	0	5	15	13	7.138,33	1,424	10	
7	3	1	1	0	13	13	7	1.965,00	1,000	25	
8	3	3	3	0	7	11	7	50.511,67	1,763	3	
9	2	2	3	0	15	15	7	30.828,33	0,988	32	
10	2	4	4	0	11	5	9	30.005,00	1,148	17	
11	2	3	2	0	5	13	9	33.481,67	1,226	12	
12	3	2	1	0	9	7	9	45.191,67	1,602	5	
13	1	3	4	0	15	7	11	4.818,33	1,182	15	
14	2	4	3	0	9	11	11	30.561,67	0,945	34	
15	3	4	2	0	13	15	11	51.555,00	1,098	21	
16	3	2	2	0	15	5	15	53.075,00	4,165	1	
17	1	1	3	0	11	13	15	8.165,00	1,500	7	
18	3	3	4	0	7	9	15	37.605,00	0,898	36	
19	2	4	2	1	7	13	5	31.705,00	1,127	19	
20	3	1	4	1	15	11	5	28.241,67	1,000	25	
21	1	3	4	1	11	15	5	5.348,33	1,000	25	
22	2	3	1	1	15	5	13	31.088,33	1,209	14	
23	3	4	4	1	9	13	13	47.698,33	0,915	35	
24	3	3	3	1	13	7	13	50.241,67	0,952	33	

DMU		Var	iáve	is d	e ent	rada	a	Variáveis de saída	Cunavaficiância	Dankina
DNIU	x_1	x_2	x_3	x_4	x_5	x_6	<i>x</i> ₇	<i>y</i> ₁ (\$)	Supereficiência	Ranking
25	1	1	2	1	9	5	7	12.538,33	1,492	9
26	2	2	4	1	7	7	7	32.108,33	1,079	23
27	3	4	2	1	11	9	11	54.068,33	1,645	4
28	1	4	1	1	15	9	9	7.998,33	1,500	8
29	1	2	2	1	13	11	9	9.418,33	1,000	25
30	3	1	3	1	7	15	9	18.461,67	1,000	25
31	1	2	3	1	7	5	11	9.181,67	1,105	20
32	3	2	1	1	11	13	11	45.941,67	1,084	22
33	2	1	1	1	5	9	11	29.418,33	1,247	11
34	1	4	3	1	5	7	15	5.941,67	1,211	13
35	2	1	4	1	13	11	15	20.845,00	1,000	25
36	2	3	1	1	9	15	15	29.218,33	1,000	25

Tabela 5.34B - Matriz experimental e resultados obtidos para o oitavo objeto de estudo (continuação)

A partir do *ranking* de supereficiência, pode-se definir uma nova faixa de variação para cada variável de decisão. Estes resultados são apresentados na Tabela 5.35.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 7 para 4. Para este objeto de estudo a variável x_1 teve seu valor definido como 3, a variável x_4 foi definida como 0 e a variável x_6 foi definida como sendo igual a 5. O espaço de busca que era de 127.776 foi reduzido para 484, uma redução de aproximadamente 99,6%.

Tabela 5.35 - Variáveis de decisão, tipo e novos limites para o oitavo objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_2	Número de bancadas com setup	Inteiro	1	2
x_3	Número de bancadas sem setup	Inteiro	1	2
x_5	Tamanho estoque 1	Inteiro	5	15
x_7	Tamanho estoque 3	Inteiro	5	15

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado, considerando o espaço de busca original e o espaço reduzido pelo método proposto.

O otimizador encontrou soluções iguais para as variáveis de decisão x_1 , x_3 , x_4 , x_5 , x_6 e x_7 . Apenas para a variável de decisão x_2 o valor encontrado foi diferente. Estes resultados podem ser observados na Tabela 5.36.

A partir dos resultados dos testes estatísticos (Tabela 5.37), considerando um nível de confiança de 95%, pode-se concluir que as respostas obtidas para a variável de saída lucro (y_1) foram estatisticamente iguais, considerando ambos os resultados da otimização.

		·					
Variáveis de Decisão	Sol	Solução					
variaveis de Decisao	Novos Limites	Limites Originais					
x_1	3	3					
x_2	2	3					
x_3	2	2					
x_4	0	0					
x_5	7	7					
x_6	5	5					
x_7	6	6					
Variáveis de Saída	Res	postas					
y_1	58.723,33	59.006,67					
Intervalo de Confiança para v. (95%	6) (56.445.00-61.001.00)	(57.129.00-61.884.00					

Tabela 5.36 - Resultados da otimização para o oitavo objeto de estudo

Tabela 5.37 - Resultados dos testes estatísticos para o oitavo objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com novos limites	0,414	0.303	0.845
Solução com limites originais	0,477	0,303	0,843

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 7,46 h para convergir, realizando 172 experimentos. Com o espaço de busca reduzido foram gastos 4,7 h para a realização de 109 experimentos. Somando a este valor às 1,1 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 22,25%. A Figura 5.8 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

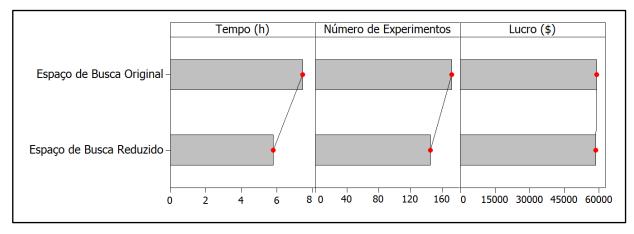


Figura 5.8 - Comparação dos resultados para o oitavo objeto de estudo

5.5 Quarta classe de problemas de OvS

5.5.1 Nono objeto de estudo

O nono objeto de estudo apresentado nesta tese representa uma célula de manufatura, e foi construído com base no trabalho de Law e McCommas (2002) e Eskandari *et al.* (2011). Este modelo possui sete variáveis de decisão, representando o número de máquinas na célula e o tamanho dos estoques intermediários. A Tabela 5.38 apresenta estas informações. O objetivo da otimização foi encontrar a melhor combinação das variáveis de entrada, de modo a otimizar o lucro na célula de produção (*y*₁).

Variável de Decisão Tipo **Limite Inferior Limite Superior** Número de máquinas do tipo 1 Inteiro 1 3 3 Número de máquinas do tipo 2 Inteiro 1 x_2 3 Número de máquinas do tipo 3 Inteiro 1 χ_3 Número de máquinas do tipo 4 Binário 1 3 χ_4 5 15 Tamanho do estoque intermediário 1 Inteiro χ_5 Tamanho do estoque intermediário 2 Inteiro 5 15 Tamanho do estoque intermediário 3 Inteiro 5 15 χ_7

Tabela 5.38 - Variáveis de decisão, tipo e limites para o nono objeto de estudo

Todas as características dos modelos apresentados por Law e McCommas (2002) e Eskandari *et al.* (2011) foram respeitadas para construção do modelo de simulação utilizado neste objeto de estudo, assim como o processo de validação, que pode ser realizado com informações presentes nos trabalhos citados.

Considerando o número de variáveis de decisão e sua amplitude de variação existe um total de 107.811 possíveis soluções para o problema. Para este objeto de estudo optou-se por um arranjo L36.

Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.39. Foram realizadas 30 replicações referentes a um período de 720 horas, com um período de aquecimento de 125 horas (LAW e McCOMMAS, 2002; ESKANDARI *et al.*, 2011).

Tabela 5.39 - Matriz experimental e resultados obtidos para o nono objeto de estudo

		Var	iávo	eis d	e De	cisã	0	Variáveis de Saída		
DMU	$\overline{x_1}$	x_2	x_3	x_4	<i>x</i> ₅	x_6	<i>x</i> ₇	<i>y</i> ₁ (\$)	Supereficiência	Ranking
1	3	3	1	3	13	5	5	208.306,67	1,480	3
2	3	1	3	1	9	7	5	64.446,67	1,222	18
3	1	2	1	2	11	13	5	246.346,67	1,308	11
4	2	3	3	2	13	9	7	534.220,00	1,412	6
5	3	1	3	3	7	13	7	7.600,00	1,049	27
6	1	3	1	1	5	15	7	250.820,00	1,422	5
7	3	1	2	1	7	9	9	87.120,00	1,078	25
8	2	2	1	3	15	9	9	332.093,33	1,094	24
9	1	3	2	1	9	13	9	223.746,67	1,001	29
10	3	2	3	1	11	5	11	296.586,67	1,337	9
11	3	1	1	2	5	7	11	88.973,33	1,364	7
12	2	3	1	3	7	11	11	449.833,33	1,361	8
13	2	1	1	2	9	5	13	111.420,00	1,273	14
14	3	3	3	3	11	11	13	478.626,67	0,873	36
15	1	1	2	3	15	15	13	67.246,67	1,000	30
16	2	2	2	3	13	7	15	315.866,67	0,978	34
17	2	1	2	1	5	11	15	105.446,67	1,273	15
18	3	3	3	1	15	15	15	277.800,00	1,000	30
19	3	3	2	3	5	5	5	561.293,33	2,982	1
20	2	1	3	1	15	11	5	80.786,67	1,154	20
21	2	2	2	2	7	15	5	344.800,00	1,105	22
22	2	1	2	1	11	5	7	113.080,00	1,267	16
23	1	2	2	2	15	7	7	225.380,00	1,244	17
24	3	2	1	3	9	11	7	320.246,67	1,097	23
25	2	3	3	3	11	7	9	505.893,33	1,077	26
26	1	2	3	2	5	11	9	190.933,33	1,165	19
27	3	1	1	2	13	15	9	73.553,33	1,105	21
28	1	3	2	2	9	9	11	201.480,00	1,000	30
29	1	1	2	1	13	13	11	125.086,67	1,500	2
30	2	2	3	3	9	15	11	287.826,67	0,885	35
31	1	3	1	1	7	7	13	252.880,00	1,460	4
32	3	2	3	1	13	9	13	293.020,00	1,000	30
33	2	2	3	3	5	13	13	287.380,00	1,002	28
34	1	2	3	2	7	5	15	196.480,00	1,286	13
35	1	1	1	3	11	9	15	100.186,67	1,333	10
36	3	3	1	2	15	13	15	442.893,33	1,297	12

A partir do *ranking* de supereficiência e definição das duas DMUs mais eficientes (19 e 29), pode-se definir uma nova faixa de variação para cada variável de decisão. Estes resultados são apresentados na Tabela 5.40.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 7 para 6. Para este objeto de estudo a variável x_3 teve seu valor definido como 2. O espaço de busca que era de 107.811 foi reduzido para 15.309, uma

redução de aproximadamente 85,8%.

	Variável	Tipo	Limite Inferior	Limite Superior
x_1	Número de máquinas do tipo 1	Inteiro	1	3
x_2	Número de máquinas do tipo 2	Inteiro	1	3
x_4	Número de máquinas do tipo 4	Inteiro	1	3
x_5	Tamanho do estoque intermediário 1	Inteiro	5	13
x_6	Tamanho do estoque intermediário 2	Inteiro	5	13
x_7	Tamanho do estoque intermediário 3	Inteiro	5	11

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou o mesmo valor para as 5 primeiras variáveis de decisão, tendo encontrado valores diferentes para as variáveis x_6 e x_7 .

Tabela 5.41 - Resultados da otimização para o nono objeto de estudo

Variáveis de Decisão	Solução			
variaveis de Decisao	Novos Limites	Limites Originais		
x_1	3	3		
x_2	3	3		
x_3	2	2		
x_4	2	2		
x_5	9	9		
x_6	9	12		
x_7	8	5		
Variáveis de Saída	Respostas			
<i>y</i> ₁	587.480,00	584.180,00		
Intervalo de Confiança para y_1 (95%)	(583.787,00-591.173,00)	(575.909,00-595.451,00)		

Em relação a solução encontrada para o lucro (y_1) , ambas as soluções puderam ser consideradas estatisticamente iguais, considerando um nível de confiança de 95%. A Tabela 5.42 apresenta os resultados dos testes estatísticos que embasam esta afirmação.

Tabela 5.42 - Resultados dos testes estatísticos para o nono objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com novos limites	0,536	0.233	0.602
Solução com limites originais	0,942	0,233	0,693

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 5,15 h para convergir, realizando 213 experimentos. Com o espaço de busca reduzido foram gastos 3,34 h para a realização de 142 experimentos. Somando a este valor às 0,81 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 19,4%. A Figura 5.9

apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

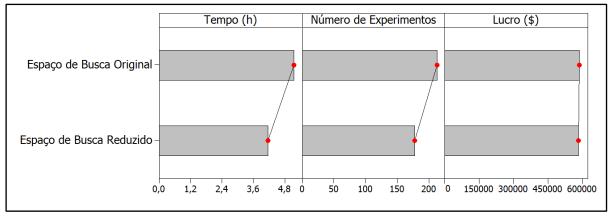


Figura 5.9 - Comparação dos resultados para o nono objeto de estudo

5.5.2 Décimo objeto de estudo

O décimo objeto de estudo representa o mesmo problema do objeto de estudo anterior. No caso anterior, ambas as soluções apontaram os mesmos valores para as variáveis de decisão x_1 , x_2 , x_3 e x_4 , variáveis estas que representavam o número de máquinas na célula de produção. Desta forma, este objeto de estudo investigará as três variáveis de decisão restantes, mantendo os valores das variáveis x_1 , x_2 , x_3 e x_4 nos mesmos valores apresentados na Tabela 5.41.

A Tabela 5.43 apresenta as variáveis de decisão e a amplitude de variação para cada variável. Assim como no caso anterior, o objetivo foi encontrar a melhor combinação das variáveis de decisão de modo a otimizar o lucro na célula de produção (y_1) .

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Tamanho do estoque intermediário 1	Inteiro	5	15
x_2	Tamanho do estoque intermediário 2	Inteiro	5	15
x_3	Tamanho do estoque intermediário 3	Inteiro	5	15

Tabela 5.43 - Variáveis de decisão, tipo e limites para o décimo objeto de estudo

Para este objeto de estudo existe um total de 1.331 possíveis soluções para o problema de OvS. Devido ao nível de variação de cada variável de decisão, optou-se por um arranjo L36. Este arranjo, bem como os resultados simulados e os valores das supereficiência por DMU são apresentados na Tabela 5.44. Assim como no caso anterior foram realizadas 30 replicações referentes a um período de 720 horas, com um período de aquecimento de 125 horas.

Tabela 5.44 - Matriz experimental e resultados obtidos para o décimo objeto de estudo

	Variáveis de Decisão		Decisão	Variáveis de Saída		
DMU	x_1	x_2	<i>x</i> ₃	<i>y</i> ₁ (\$)	Supereficiência	Ranking
1	5	7	5	580.780,00	8,200	1
2	5	13	13	571.220,00	1,000	5
3	5	11	7	578.460,00	1,000	5
4	5	9	9	576.220,00	1,000	5
5	5	15	11	568.680,00	1,000	5
6	5	5	15	574.880,00	1,200	2
7	7	15	5	575.300,00	1,000	5
8	7	7	13	572.600,00	0,797	17
9	7	9	7	576.000,00	0,757	19
10	7	5	9	578.940,00	1,175	4
11	7	13	11	579.080,00	0,714	21
12	7	11	15	567.620,00	0,714	22
13	9	11	5	575.160,00	1,000	5
14	9	5	13	574.980,00	1,000	5
15	9	15	7	575.340,00	0,714	23
16	9	13	9	573.320,00	0,556	30
17	9	7	11	578.500,00	0,757	18
18	9	9	15	570.820,00	0,632	26
19	11	9	5	576.680,00	1,000	5
20	11	15	13	566.960,00	0,455	35
21	11	7	7	577.260,00	0,828	16
22	11	11	9	575.960,00	0,591	28
23	11	5	11	570.540,00	1,000	5
24	11	13	15	568.420,00	0,487	34
25	13	5	5	572.100,00	1,180	3
26	13	9	13	568.800,00	0,591	29
27	13	13	7	567.980,00	0,714	24
28	13	7	9	575.060,00	0,743	20
29	13	11	11	568.520,00	0,551	32
30	13	15	15	568.140,00	0,426	36
31	15	13	5	575.180,00	1,000	5
32	15	11	13	572.700,00	0,516	33
33	15	5	7	579.480,00	1,000	5
34	15	15	9	574.020,00	0,556	31
35	15	9	11	576.220,00	0,600	27
36	15	7	15	569.640,00	0,714	25

A partir do *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (1 e 6), foi possível definir uma nova faixa de variação para cada variável de decisão. Estes resultados são apresentados na Tabela 5.45.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 3 para 2. Para este objeto de estudo a variável x_1 teve seu valor definido como 5. O espaço de busca que era de 1.331 foi reduzido para 33, uma redução de

aproximadamente 97,5%.

Tabela 5.45 - Variáveis de decisão, tipo e novos limites para o décimo objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_2	Tamanho do estoque intermediário 2	Inteiro	5	7
x_3	Tamanho do estoque intermediário 3	Inteiro	5	15

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador *SimRunner*® foi empregado. O otimizador encontrou valores diferentes para as três variáveis de decisão. Sendo que a solução encontrada com a aplicação do método proposto necessitou de um estoque intermediário menor em todos os casos. A Tabela 5.46 apresenta os resultados da otimização.

Tabela 5.46 - Resultados da otimização para o décimo objeto de estudo

Variáveis de Decisão	Solução			
variaveis de Decisao	Novos Limites	Limites Originais		
x_1	5	9		
x_2	6	9		
x_3	5	8		
Variáveis de Saída	Respostas			
<i>y</i> ₁	587.520,00	588.560,00		
Intervalo de Confiança para y_1 (95%)	(575.619,00-597.420,00)	(580.170,00-596.949,00)		

Em relação a solução encontrada para o lucro (y_1) , ambas as soluções puderam ser consideradas estatisticamente iguais, considerando um nível de confiança de 95%. A Tabela 5.47 apresenta os resultados dos testes estatísticos que confirmam esta afirmação.

Tabela 5.47 - Resultados dos testes estatísticos para o décimo objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T	
Solução com novos limites	0,275	0.184	0.669	
Solução com limites originais	0,536	0,184	0,668	

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 4,75 h para convergir, realizando 202 experimentos. Com o espaço de busca reduzido foram gastos 0,7 h para a realização de 30 experimentos. Somando a este valor às 0,72 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 70%.

A Figura 5.10 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

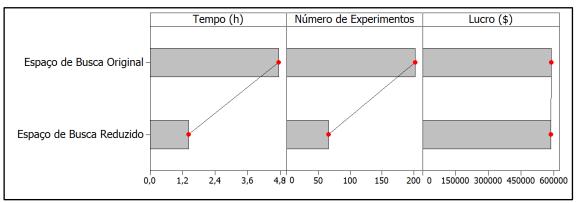


Figura 5.10 - Comparação dos resultados para o décimo objeto de estudo

5.5.3 Décimo primeiro objeto de estudo

O décimo primeiro objeto de estudo também é o mesmo apresentado nos dois casos anteriores. A diferença agora é a adição de uma oitava variável de decisão. Neste modelo foi adicionado um operador responsável pela realização de manutenção nas máquinas presentes na célula.

Este objeto de estudo é apresentado em Law (2007) e foi construído respeitando as informações apresentadas no trabalho.

A Tabela 5.48 apresenta as variáveis de decisão e a amplitude de variação para cada variável. Assim como nos dois casos anteriores, o objetivo da otimização foi encontrar a melhor combinação das variáveis de entrada de modo a otimizar o lucro na célula de produção (y_1) .

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de máquinas do tipo 1	Inteiro	1	3
x_2	Número de máquinas do tipo 2	Inteiro	1	3
x_3	Número de máquinas do tipo 3	Inteiro	1	3
x_4	Número de máquinas do tipo 4	Binário	1	3
x_5	Tamanho do estoque intermediário 1	Inteiro	5	15
x_6	Tamanho do estoque intermediário 2	Inteiro	5	15
x_7	Tamanho do estoque intermediário 3	Inteiro	5	15
x_8	Número de operadores de manutenção	Inteiro	1	2

Tabela 5.48 - Variáveis de decisão, tipo e limites para o décimo primeiro objeto de estudo

Para este objeto de estudo existe um total de 215.622 possíveis soluções para o problema de OvS. Devido ao nível de variação de cada variável de decisão e ao número de variáveis envolvidas neste problema, optou-se por um arranjo L36. Este arranjo, bem como os resultados simulados e os valores das supereficiência por DMU são apresentados na Tabela 5.49. Assim como nos dois casos anteriores, foram realizadas 30 replicações referentes a um

período de 720 horas, com um período de aquecimento de 125 horas.

Tabela 5.49 - Matriz experimental e resultados obtidos para o décimo primeiro objeto de estudo

DMII		V	aria	ávei	s de l	Deci	são		Variáveis de Saída	C	D1 !
DMU	x_1	x_2	x_3	x_4	<i>x</i> ₅	x_6	<i>x</i> ₇	<i>x</i> ₈	<i>y</i> ₁ (\$)	Supereficiência	Ranking
1	1	3	1	3	13	5	5	1	178.553,33	1,526	4
2	3	1	3	1	9	7	5	1	49.480,00	1,350	11
3	1	2	1	2	11	13	5	1	219.193,33	1,266	17
4	3	3	3	3	13	13	15	1	238.746,67	1,000	34
5	3	1	3	3	7	13	7	1	-4.633,33	1,049	32
6	1	3	1	1	5	15	7	1	216.780,00	1,460	7
7	3	1	2	1	7	9	9	1	67.740,00	1,100	28
8	2	2	1	3	15	9	9	1	274.460,00	1,114	26
9	1	3	2	1	9	13	9	1	197.186,67	1,065	31
10	3	2	3	1	11	5	11	1	231.506,67	1,444	8
11	3	1	1	2	5	7	11	1	66.733,33	1,364	10
12	2	3	1	3	7	11	11	1	351.760,00	1,303	14
13	2	1	1	2	9	5	13	1	89.566,67	1,250	18
14	3	3	2	2	11	11	13	1	486.620,00	2,084	2
15	1	1	2	3	15	15	13	1	58.246,67	1,333	12
16	2	2	2	3	13	7	15	1	270.406,67	1,071	30
17	2	1	2	1	5	11	15	1	89.853,33	1,273	16
18	3	3	3	1	15	15	15	1	261.393,33	1,097	29
19	3	3	2	3	5	5	5	2	476.140,00	2,224	1
20	2	1	3	1	15	11	5	2	89.180,00	1,154	24
21	2	2	2	2	7	15	5	2	337.666,67	1,154	25
22	2	1	2	1	11	5	7	2	111.066,67	1,275	15
23	1	2	2	2	15	7	7	2	230.033,33	1,160	22
24	3	2	1	3	9	11	7	2	299.160,00	1,155	23
25	2	3	3	3	11	7	9	2	464.313,33	1,412	9
26	1	2	3	2	5	11	9	2	186.346,67	1,167	21
27	3	1	1	2	13	15	9	2	83.666,67	1,105	27
28	1	3	2	2	9	9	11	2	207.313,33	1,000	34
29	1	1	2	1	13	13	11	2	131.100,00	1,500	5
30	2	2	3	3	9	15	11	2	285.666,67	0,909	36
31	1	3	1	1	7	7	13	2	248.813,33	1,500	6
32	3	2	3	1	13	9	13	2	283.086,67	1,181	20
33	2	2	3	3	5	13	13	2	269.766,67	1,028	33
34	1	2	3	2	7	5	15	2	191.193,33	1,239	19
35	1	1	1	3	11	9	15	2	103.326,67	1,333	13
36	3	3	1	2	15	13	15	2	424.893,33	1,542	3

A partir do *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (14 e 19), foi possível definir uma nova faixa de variação para cada variável de decisão. A Tabela 5.50 apresenta essa nova faixa de variação para cada variável de decisão.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de

decisão foi reduzido de 8 para 5. As variáveis de decisão x_1 e x_2 tiveram seus valores definidos como sendo iguais a 3 e a variável x_3 teve seu valor definido como 2. O espaço de busca que era de 215.622 foi reduzido para 1.764, uma redução de aproximadamente 99,2%.

Tabela 5.50 - Variáveis de decisão, tipo e novos limites para o décimo primeiro objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_4	Número de máquinas do tipo 4	Inteiro	2	3
x_5	Tamanho do estoque intermediário 1	Inteiro	5	11
x_6	Tamanho do estoque intermediário 2	Inteiro	5	11
x_7	Tamanho do estoque intermediário 3	Inteiro	5	13
x_8	Número de operadores de manutenção	Inteiro	1	2

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou valores iguais para as variáveis de decisão x_1 , x_2 , x_3 , x_4 e x_8 . Os valores só divergiram para as três variáveis de decisão que representavam o tamanho dos estoque intermediários. A Tabela 5.51 apresenta os resultados da otimização.

Tabela 5.51 - Resultados da otimização para o décimo primeiro objeto de estudo

Variáveis de Decisão	Solu	ıção	
variaveis de Decisao	Novos Limites	Limites Originais	
x_1	3	3	
x_2	3	3	
x_3	2	2	
x_4	2	2	
x_5	11	15	
x_6	11	15	
x_7	12	15	
x ₈	2	2	
Variáveis de Saída	Resp	ostas	
y_1	552.846,00	556.026,00	
Intervalo de Confiança para (95%)	(542.161,00-563.532,00)	(544.073,00-567.980,00)	

Em relação a solução encontrada para o lucro (y_1) , ambas as soluções puderam ser consideradas estatisticamente iguais, considerando um nível de confiança de 95%. A Tabela 5.52 apresenta os resultados dos testes estatísticos que embasam esta afirmação.

Tabela 5.52 - Resultados dos testes estatísticos para o décimo primeiro objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com novos limites	0,683	0.550	0.697
Solução com limites originais	0,860	0,330	0,687

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 4,72 h para convergir, realizando 186 experimentos. Com o espaço de busca reduzido foram gastos 2,88 h para a realização de 115 experimentos. Somando a este valor às 0,75 h

para a simulação do arranjo L36, o ganho de tempo computacional foi de 23,1%. A Figura 5.11 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

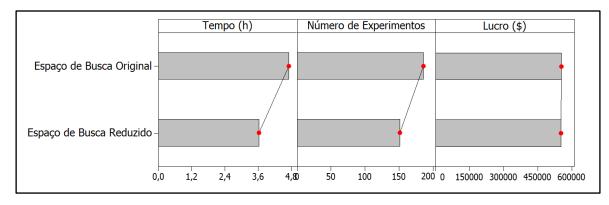


Figura 5.11 - Comparação dos resultados para o décimo primeiro objeto de estudo

5.6 Quinta classe de problemas de OvS

5.6.1 Décimo segundo objeto de estudo

O décimo segundo objeto de estudo representa uma célula de produção de um empresa produtora de componentes automotivos. A Tabela 5.53 apresenta as variáveis de decisão e a amplitude de variação para cada variável. O objetivo da otimização foi encontrar a melhor combinação das variáveis de entrada, de modo a otimizar o total produzido na célula de produção (y_1) .

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores do tipo 1	Inteiro	1	2
x_2	Número de operadores do tipo 2	Inteiro	1	2
x_3	Número de operadores do tipo 3	Inteiro	1	2
x_4	Número de operadores do tipo 4	Inteiro	1	2
x_5	Número de operadores de movimentação	Inteiro	1	5
x_6	Número de máquinas do tipo 1	Inteiro	1	4
x_7	Número de máquinas do tipo 2	Inteiro	1	4
x_8	Número de máquinas do tipo 3	Inteiro	1	4
x_9	Número de máquinas do tipo 4	Inteiro	1	4

Tabela 5.53 - Variáveis de decisão, tipo e limites para o décimo segundo objeto de estudo

Para este objeto de estudo existe um total de 20.480 possíveis soluções para o problema de OvS. Considerando o número de variáveis de decisão e o nível de variação de cada variável, optou-se, para esse objeto de estudo, por um arranjo L32. Foram realizadas 30 replicações para cada cenário compreendendo um mês de produção da célula. Este arranjo,

bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.54.

Tabela 5.54 - Matriz experimental e resultados obtidos para o décimo segundo objeto de estudo

	Variáveis de Decisão						. ~			T7 1/ 1 1 G /3		
DMU										Variáveis de Saída	Supereficiência	Ranking
	x_1	x_2	<i>x</i> ₃	x_4	<i>x</i> ₅	x_6	<i>x</i> ₇	<i>x</i> ₈	<i>x</i> ₉	y ₁ (un)		
1	1	2	1	2	2	3	3	1	1	10.128,00	1,333	14
2	2	1	2	2	1	3	4	2	1	10.769,70	1,408	11
3	1	1	2	1	4	4	3	1	4	10.273,80	1,035	25
4	2	2	1	1	1	1	3	3	4	10.114,30	1,400	12
5	2	2	2	1	3	4	4	1	3	10.273,00	1,022	27
6	1	2	1	1	3	1	2	2	1	10.123,00	1,458	9
7	1	1	2	2	1	1	2	1	2	10.290,00	1,660	4
8	2	2	2	2	1	2	1	1	1	10.266,60	1,625	5
9	2	2	1	2	4	4	1	2	2	10.140,00	1,003	28
10	1	1	1	2	3	3	3	3	1	10.134,10	1,333	15
11	1	1	2	1	1	4	3	2	3	10.400,40	1,354	13
12	2	2	2	2	3	2	3	3	3	14.340,00	1,792	3
13	1	1	1	1	3	2	1	1	2	10.126,50	1,531	8
14	1	2	1	2	4	2	2	2	3	10.140,00	1,002	30
15	1	1	2	2	5	1	1	2	4	13.839,60	2,276	1
16	2	1	1	1	5	2	3	4	1	10.128,40	1,250	19
17	2	1	2	1	4	3	2	3	2	10.426,00	1,025	26
18	2	1	1	1	2	1	4	1	3	10.122,20	1,333	16
19	2	2	2	2	5	4	4	4	2	14.340,50	1,581	6
20	2	1	1	1	2	2	4	2	4	10.123,50	1,000	31
21	2	1	2	2	3	3	2	4	4	13.840,00	1,301	18
22	2	1	1	2	4	1	1	4	3	10.140,00	1,333	17
23	1	2	1	1	1	3	1	4	2	10.114,10	1,545	7
24	1	2	2	1	5	3	1	3	3	10.426,20	1,070	22
25	2	1	2	1	2	4	1	3	1	10.411,10	1,444	10
26	2	2	2	2	2	1	3	2	2	14.336,90	1,994	2
27	1	2	2	1	2	2	2	4	4	10.415,10	1,052	24
28	1	2	2	1	4	1	4	4	1	10.415,40	1,069	23
29	1	1	1	2	2	4	2	4	3	10.140,00	1,143	20
30	2	2	1	1	5	3	2	1	4	10.125,50	1,000	32
31	1	2	1	2	1	4	4	3	4	10.140,00	1,101	21
32	1	1	1	2	5	2	4	3	2	10.140,00	1,003	29
	_	_			_	_	-	_			-,	

Com base no *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (15 e 26), foi possível definir uma nova faixa de variação para cada variável de decisão. A Tabela 5.55 apresenta a nova faixa de variação para cada variável de decisão.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 9 para 5. As variáveis de decisão x_3 , x_4 e x_8 tiveram seus valores definidos como sendo iguais a 2 e a variável x_6 teve seu valor definido como 1. O espaço de

busca que era de 20.480 foi reduzido para 144, uma redução de aproximadamente 99,3%.

Tabela 5.55 - Variáveis de decisão, tipo e novos limites para o décimo segundo objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de operadores do tipo 1	Inteiro	1	2
x_2	Número de operadores do tipo 2	Inteiro	1	2
x_5	Número de operadores de movimentação	Inteiro	2	5
x_7	Número de máquinas do tipo 2	Inteiro	1	3
x_9	Número de máquinas do tipo 4	Inteiro	2	4

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou valores iguais para as variáveis de decisão x_1 , x_2 , x_3 e x_4 . Para as outras cinco variáveis de decisão o otimizador encontrou valores diferentes. A Tabela 5.56 apresenta os resultados da otimização.

Tabela 5.56 - Resultados da otimização para o décimo segundo objeto de estudo

Variáveis de Decisão	Solu	ução
variaveis de Decisao	Novos Limites	Limites Originais
x_1	2	2
x_2	2	2
x_3	2	2
x_4	2	2
x_5	2	5
x_6	1	4
x_7	3	2
x_8	2	4
x_9	3	2
Variáveis de Saída	Resp	oostas
<i>y</i> ₁	14.340,00	14.340,00
Intervalo de Confiança para y_1 (95%)	(14.255,00-14.425,00)	(14.248,00-14.432,00)

Em relação a solução encontrada para o total produzido na célula (y_1) , ambas as soluções puderam ser consideradas estatisticamente iguais, considerando um nível de confiança de 95%. A Tabela 5.57 apresenta os resultados dos testes estatísticos que confirmam esta afirmação.

Tabela 5.57 - Resultados dos testes estatísticos para o décimo segundo objeto de estudo

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com novos limites	0,235	0.145	0.200
Solução com limites originais	0,378	0,145	0,200

Os resultados encontrados foram estatisticamente iguais, considerando um nível de confiança de 95%. Para o caso em que o otimizador utilizou o espaço de busca original, o

SimRunner® gastou 22,67 h para convergir, realizando 140 experimentos. Com o espaço de busca reduzido foram gastos 9,69 h para a realização de 61 experimentos. Somando a este valor, às 2,58 h para a simulação do arranjo L32, o ganho de tempo computacional foi de 45,9%. A Figura 5.12 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

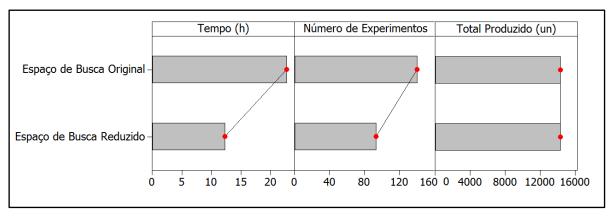


Figura 5.12 - Comparação dos resultados para o décimo segundo objeto de estudo

5.6.2 Décimo terceiro objeto de estudo

O décimo terceiro objeto de estudo é o mesmo do objeto de estudo anterior, possuindo as mesmas variáveis de decisão e a mesma faixa de variação apresentadas na Tabela 5.53.

A diferença deste objeto de estudo é que se busca maximizar o total de peças produzidas (y_1) e minimizar o *work in process* - WIP (y_2) na célula de produção.

Como no caso anterior, existe um total de 20.480 possíveis soluções para o problema de OvS. Optou-se, para esse caso, por um arranjo L36. Foram realizadas 30 replicações para cada cenário compreendendo um mês de produção da célula. Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.58.

Com base no *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (2 e 36), foi possível definir uma nova faixa de variação para cada variável de decisão. A Tabela 5.59 apresenta a nova faixa de variação para cada variável de decisão.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 9 para 5. As variáveis de decisão x_3 e x_4 tiveram seus valores definidos como sendo iguais a 2, já a variável x_1 e x_6 tiveram seus valores definidos como 1 e 3, respectivamente. O espaço de busca que era de 20.480 foi reduzido para 240, uma redução de aproximadamente 98,8%.

Tabela 5.58 - Matriz experimental e resultados obtidos para o décimo terceiro objeto de estudo

DMU		V	ari	ávei	is de	De	cisê	ío		Variáveis	de Saída	Supereficiência	Dankina
DMU	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	$y_1(\mathbf{un})$	$y_2(un)$	Superenciencia	Kanking
1	1	2	1	1	2	3	4	3	1	10.118,00	56.207,20	1,375	15
2	1	1	2	2	1	3	4	2	2	13.836,20	35.767,60	2,719	2
3	2	1	2	1	3	2	3	3	4	10.425,70	54.533,90	1,003	33
4	1	1	1	2	1	1	3	4	2	10.140,00	56.100,00	1,444	14
5	2	1	1	2	2	2	1	3	1	10.134,00	56.121,20	1,552	6
6	1	2	2	1	3	3	1	4	3	10.415,80	54.562,70	1,157	28
7	1	1	1	2	3	4	1	2	3	10.140,00	56.100,00	1,323	19
8	2	2	2	1	1	4	3	2	2	10.402,70	54.654,10	1,200	24
9	2	2	1	1	4	2	3	4	1	10.126,00	56.182,20	1,167	26
10	1	1	1	1	5	4	2	2	1	10.132,30	56.136,00	1,316	20
11	2	2	2	2	1	3	2	2	1	10.768,20	52.632,80	1,314	21
12	2	1	1	2	1	4	2	4	4	10.140,00	56.100,00	1,200	25
13	1	1	2	1	4	3	2	1	3	10.279,60	55.334,90	1,333	18
14	2	2	1	1	3	4	4	1	4	10.123,40	56.190,40	1,000	34
15	1	2	2	1	2	2	4	1	2	10.270,00	55.368,20	1,333	16
16	2	2	1	2	4	4	4	3	3	10.140,00	56.100,00	1,000	34
17	2	1	1	2	5	3	3	1	1	10.130,10	56.159,30	1,500	9
18	1	1	2	1	4	2	4	2	1	10.419,30	54.571,60	1,275	23
19	1	2	1	2	4	1	2	3	4	10.140,00	56.100,00	1,111	29
20	2	1	2	2	1	4	3	3	1	10.763,40	52.660,60	1,333	17
21	2	2	1	1	5	2	2	2	2	10.128,40	56.151,60	1,085	30
22	2	2	2	2	3	2	3	2	4	14.337,90	33.009,60	1,996	4
23	1	1	2	1	1	1	3	3	3	10.400,60	54.655,70	1,528	7
24	2	1	2	1	5	3	1	1	4	10.274,60	55.337,60	1,508	8
25	2	1	2	2	3	1	2	3	1	10.786,60	52.512,80	1,621	5
26	1	2	2	2	5	2	4	4	3	14.339,50	33.003,10	2,008	3
27	1	1	2	1	4	4	1	3	2	10.427,50	54.509,70	1,280	22
28	2	1	2	2	2	1	2	1	3	10.302,40	55.218,20	1,465	12
29	2	2	1	1	3		1	4	3		· · · · · · · · · · · · · · · · · · ·	1,500	10
30	1	1	1	2	4	3	4	4	4		56.100,00	1,000	34
31	1	2	1	2	5	1	1	4	2	10.140,00	56.100,00	1,455	13
32	2	2	1	2	2	1	3	2	4	10.140,00	56.100,00	1,083	31
33	2	2	1	2	1	2	2	3	3	10.109,70	56.259,40	1,159	27
34	2	1	1	1	3	1	4	1	2	10.128,70	56.162,00	1,500	11
35	1	2	2	1	2	4	3	4	2	10.419,10	54.543,90	1,026	32
36	1	2	2	2	5	3	1	3	4	14.128,00	34.166,40	2,893	1

Tabela 5.59 - Variáveis de decisão, tipo e novos limites para o décimo terceiro objeto de estudo

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_2	Número de operadores do tipo 2	Inteiro	1	2
x_5	Número de operadores de movimentação	Inteiro	1	5
x_7	Número de máquinas do tipo 2	Inteiro	1	4
x_8	Número de máquinas do tipo 3	Inteiro	2	3
x_9	Número de máquinas do tipo 4	Inteiro	2	4

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou valores iguais para as variáveis de decisão x_2 , x_3 , x_4 e x_5 . Para as outras cinco variáveis de decisão o otimizador encontrou valores diferentes. A Tabela 5.60 apresenta os resultados da otimização.

Tabela 5.60 - Resultados da otimização para o décimo terceiro objeto de estudo

Vaniávais da Dasisão	Solu	ıção		
Variáveis de Decisão	Novos limites	Limites originais		
x_1	1	2		
x_2	2	2		
x_3	2	2		
x_4	2	2		
x_5	5	5		
x_6	3	4		
x_7	4	3		
x_8	3	4		
x_9	4	3		
Variáveis de Saída	Resp	ostas		
<i>y</i> ₁	14.340,00	14.340,00		
Intervalo de Confiança para y_1 (95%)	(14.247,00-14.443,00)	(14.242,00-14.438,00)		
y_2	33.000,00	33.000,00		
Intervalo de Confiança para y ₂ (95%)	(32.835,00-33.165,00)	(32.928,00-33.172,00)		

As soluções encontradas, tanto para o total produzido na célula (y_1) , quanto para o WIP (y_2) puderam ser consideradas estatisticamente iguais, considerando um nível de confiança de 95%. A Tabela 5.61 apresenta os resultados dos testes estatísticos que confirmam tais afirmações.

Tabela 5.61 - Resultados dos testes estatísticos para o décimo terceiro objeto de estudo

	Dados	Teste de Anderson-Darling	Teste F	Teste T
	Solução com novos limites	0,415	0.214	0.318
y_1	Solução com limites originais	0,278	0,214	0,516
	Solução com novos limites	0,318	0.147	0.232
<i>y</i> ₂	Solução com limites originais	0,159	0,147	0,232

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 27,66 h para convergir, realizando 162 experimentos. Com o espaço de busca reduzido foram gastos 11,98 h para a realização de 71 experimentos. Somando a este valor às 3,2 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 45,10%. A Figura 5.13 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

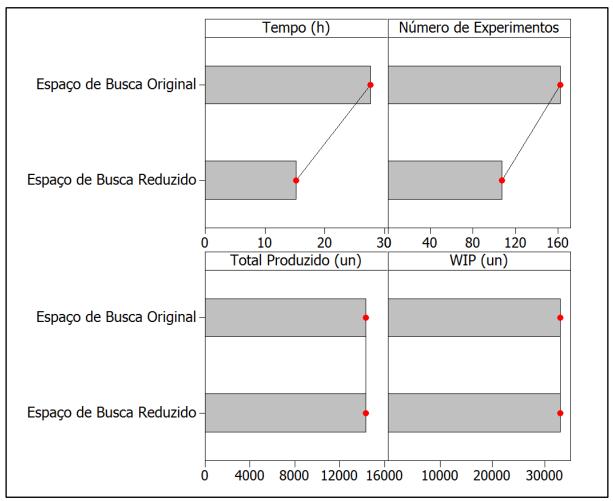


Figura 5.13 - Comparação dos resultados para o décimo terceiro objeto de estudo

5.6.3 Décimo quarto objeto de estudo

O décimo quarto objeto de estudo utilizado nesta tese, é o mesmo dos dois casos apresentados anteriormente, possuindo, portanto, as mesmas variáveis de decisão e a mesma faixa de variação apresentadas na Tabela 5.53.

Neste objeto de estudo, objetiva-se maximizar o total de peças produzidas (y_1) , e minimizar o WIP (y_2) e o custo de fabricação dos produtos (y_3) . Como nos 2 casos anteriores, existe um total de 20.480 possíveis soluções para o problema de OvS. Devido ao número de variáveis e a seus limites de variação, optou-se, para esse caso, por um arranjo L36.

Foram realizadas 30 replicações para cada cenário, compreendendo um mês de operação da célula. Este arranjo, bem como os resultados simulados e os valores das supereficiências por DMU são apresentados na Tabela 5.62.

Tabela 5.62 - Matriz experimental e resultados obtidos para o décimo quarto objeto de estudo

DMI		V	ari	ávei	is de	e De	ecisâ	ío		V	ariáveis de Sa	ída		D 1
DMU	x_1	x_2	x_3	<i>x</i> ₄	<i>x</i> ₅	x_6	x_7	<i>x</i> ₈	<i>x</i> ₉	y ₁ (un)	y ₂ (un)	y ₃ (\$)	- Supereficiência	Kanking
1	1	2	1	1	2	3	4	3	1	10.118,00	56.207,20	36.181,08	1,375	15
2	1	1	2	2	1	3	4	2	2	13.836,20	35.767,60	32.765,14	2,719	2
3	2	1	2	1	3	2	3	3	4	10.425,70	54.533,90	39.280,09	1,003	33
4	1	1	1	2	1	1	3	4	2	10.140,00	56.100,00	33.715,00	1,444	14
5	2	1	1	2	2	2	1	3	1	10.134,00	56.121,20	24.568,18	1,552	6
6	1	2	2	1	3	3	1	4	3	10.415,80	54.562,70	36.134,41	1,157	28
7	1	1	1	2	3	4	1	2	3	10.140,00	56.100,00	32.665,00	1,323	19
8	2	2	2	1	1	4	3	2	2	10.402,70	54.654,10	30.998,12	1,200	24
9	2	2	1	1	4	2	3	4	1	10.126,00	56.182,20	38.177,33	1,167	26
10	1	1	1	1	5	4	2	2	1	10.132,30	56.136,00	33.270,40	1,316	20
11	2	2	2	2	1	3	2	2	1	10.768,20	52.632,80	31.644,92	1,314	21
12	2	1	1	2	1	4	2	4	4	10.140,00	56.100,00	38.815,00	1,200	25
13	1	1	2	1	4	3	2	1	3	10.279,60	55.334,90	33.150,24	1,333	18
14	2	2	1	1	3	4	4	1	4	10.123,40	56.190,40	40.428,56	1,000	34
15	1	2	2	1	2	2	4	1	2	10.270,00	55.368,20	34.005,23	1,333	16
16	2	2	1	2	4	4	4	3	3	10.140,00	56.100,00	44.965,00	1,000	34
17	2	1	1	2	5	3	3	1	1	10.130,10	56.159,30	35.073,90	1,500	9
18	1	1	2	1	4	2	4	2	1	10.419,30	54.571,60	35.435,74	1,275	23
19	1	2	1	2	4	1	2	3	4	10.140,00	56.100,00	37.315,00	1,111	29
20	2	1	2	2	1	4	3	3	1	10.763,40	52.660,60	35.649,09	1,333	17
21	2	2	1	1	5	2	2	2	2	10.128,40	56.151,60	34.922,74	1,085	30
22	2	2	2	2	3	2	3	2	4	14.337,90	33.009,60	35.451,44	1,996	4
23	1	1	2	1	1	1	3	3	3	10.400,60	54.655,70	33.148,36	1,528	7
24	2	1	2	1	5	3	1	1	4	10.274,60	55.337,60	34.700,64	1,508	8
25	2	1	2	2	3	1	2	3	1	10.786,60	52.512,80	32.426,92	1,621	5
26	1	2	2	2	5	2	4	4	3	14.339,50	33.003,10	42.300,47	2,008	3
27	1	1	2	1	4	4	1	3	2	10.427,50	54.509,70	33.976,46	1,280	22
28	2	1	2	2	2	1	2	1	3	10.302,40	55.218,20	30.932,73	1,465	12
29	2	2	1	1	3	1	1	4	3	10.123,40	56.184,10	34.177,62	1,500	10
30	1	1	1	2	4	3	4	4	4	10.140,00	56.100,00	44.715,00	1,000	34
31	1	2	1	2	5	1	1	4	2	10.140,00	56.100,00	35.115,00	1,455	13
32	2	2	1	2	2	1	3	2	4	10.140,00	56.100,00	36.615,00	1,083	31
33	2	2	1	2	1	2	2	3	3	10.109,70	56.259,40	29.788,91	1,159	27
34	2	1	1	1	3	1	4	1	2	10.128,70	56.162,00	33.024,30	1,500	11
35	1	2	2	1	2	4	3	4	2	10.419,10	54.543,90	39.181,59	1,026	32
36	1	2	2	2	5	3	1	3	4	14.128,00	34.166,40	36.324,96	2,893	1

Com base no *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (2 e 36), foi possível definir uma nova faixa de variação para cada variável de decisão. A Tabela 5.63 apresenta a nova faixa de variação para cada variável de decisão.

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_2	Número de operadores do tipo 2	Inteiro	1	2
x_5	Número de operadores de movimentação	Inteiro	1	5
x_7	Número de máquinas do tipo 2	Inteiro	1	4
x_8	Número de máquinas do tipo 3	Inteiro	2	3
x_9	Número de máquinas do tipo 4	Inteiro	2	4

Tabela 5.63 - Variáveis de decisão, tipo e novos limites para o décimo quarto objeto de estudo

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 9 para 5. As variáveis de decisão x_3 e x_4 tiveram seus valores definidos como sendo iguais a 2, já as variáveis x_1 e x_6 tiveram seus valores definidos como 1 e 3, respectivamente. O espaço de busca que era de 20.480 foi reduzido para 240, uma redução de aproximadamente 98,8%.

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou valores iguais para as variáveis de decisão x_1 , x_2 , x_3 , x_4 e x_7 . Para as outras quatro variáveis de decisão, o otimizador encontrou valores diferentes. A Tabela 5.64 apresenta os resultados da otimização.

Tabela 5.64 - Resultados da otimização para o décimo quarto objeto de estudo

Variáveis de Decisão	Solu	ıção		
variaveis de Decisao	Novos Limites	Limites Originais		
x_1	1	1		
x_2	2	2		
x_3	2	2		
x_4	2	2		
x_5	1	3		
x_6	3	1		
x_7	2	2		
x_8	2	3		
x_9	2	3		
Variáveis de Saída	Respostas			
y_1	14.330,00	14.340,00		
Intervalo de Confiança para y_1 (95%)	(14.262,00-14.398,00)	(14.283,00-14.397,00)		
y_2	33.062,00	33.000,00		
Intervalo de Confiança para y ₂ (95%)	(32.928,00-33.196,00)	(32.855,00-33.145,00)		
y_3	28.959,00	28.350,00		
Intervalo de Confiança para y ₃ (95%)	(28.224,00-29.694,00)	(27.400,00-29.308,00)		

Em relação aos valores encontrados para as variáveis de saída, as respostas foram estatisticamente iguais para as três variáveis de saída, considerando um nível de confiança de 95%. A Tabela 5.65 apresenta os resultados dos testes estatísticos que embasam tais afirmações.

	Dados	Teste de Anderson-Darling	Teste F	Teste T	
	Solução com novos limites	0,187	0.254	0.221	
y_1	Solução com limites originais	0,195	0,254	0,321	
	Solução com novos limites	0,121	0.226	0,145	
y_2	Solução com limites originais	0,187	0,336		
	Solução com novos limites	0,139	0.110	0.107	
<i>y</i> ₃	Solução com limites originais	0,165	0,118	0,197	

Tabela 5.65 - Resultados dos testes estatísticos para o décimo quarto objeto de estudo

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 33,77 h para convergir, realizando 189 experimentos. Com o espaço de busca reduzido foram gastos 15,34 h para a realização de 88 experimentos. Somando a este valor as 3,25 h para a simulação do arranjo L36, o ganho de tempo computacional foi de 44,95%. A Figura 5.14 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

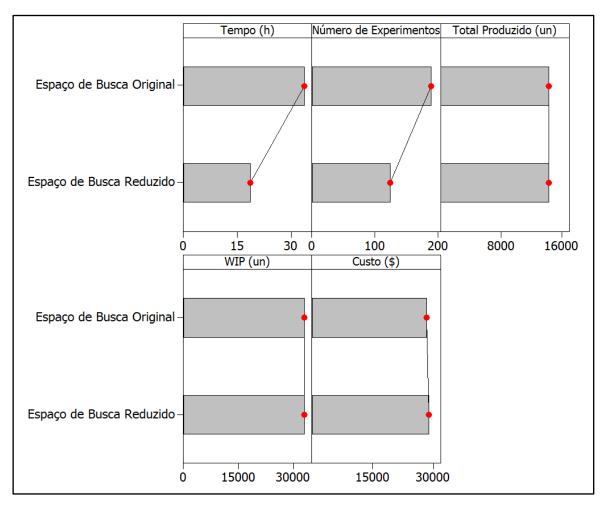


Figura 5.14 - Comparação dos resultados para o décimo quarto objeto de estudo

5.6.4 Décimo quinto objeto de estudo

O décimo quinto objeto de estudo é idêntico aos três objetos de estudo apresentados anteriormente, possuindo as mesmas variáveis de decisão apresentadas na Tabela 5.53, porém, neste caso, o objetivo da otimização é maximizar o total de peças produzidas (y_1) e a produtividade (y_4) ; e minimizar o WIP (y_2) e o custo de fabricação dos produtos (y_3) .

Como nos casos anteriores, existe um total de 20.480 possíveis soluções para o problema de OvS. Optou-se, para esse caso, por um arranjo L42. Foram realizadas 30 replicações referentes a um mês de operação da célula. Este arranjo, bem como os resultados simulados e os valores das supereficiência por DMU são apresentados nas Tabelas 5.66A e 5.66B.

Tabela 5.66A - Matriz experimental e resultados obtidos para o décimo quinto objeto de estudo

		V	ari	ávei	s de	De	cisã	0			Variáveis	s de Saída			
DMU	ν.								r.	<i>y</i> ₁ (un)	$y_2(un)$	$y_3(\$)$	y ₄ (un/op)	Super.	Rank.
							<i>x</i> ₇				-			1.045	22
1	1	2	2	1	2	1	4	2	4		54.576,80	37.486,52	1.302,03	1,045	33
2	2	2	1	1	2	3	1	3	4	10.119,60	56.216,80	34.832,52	1.264,95	1,200	23
3	1	2	1	2	3	3	1	2	2	10.140,00	56.100,00	31.315,00	1.126,67	1,190	24
4	2	1	1	1	3	3	2	4	1	10.126,50	56.169,40	34.575,41	1.265,81	1,333	13
5	1	1	2	1	2	3	2	2	1	10.416,40	54.582,20	29.537,33	1.488,06	1,253	20
6	2	1	2	1	1	2	2	4	4	10.395,40	54.699,60	36.404,94	1.485,06	1,034	34
7	1	2	1	1	5	2	2	3	3	10.123,90	56.179,40	36.976,91	1.012,39	1,087	32
8	2	1	2	1	1	1	1	1	1	10.264,80	55.411,60	23.361,74	1.466,40	1,826	6
9	1	2	2	2	2	1	3	4	3	14.339,70	33.002,40	35.300,36	1.593,30	2,000	4
10	1	2	1	2	1	4	4	3	1	10.115,30	56.224,40	37.283,66	1.445,04	1,400	11
11	1	1	1	2	2	4	4	4	3	10.140,00	56.100,00	41.965,00	1.448,57	1,000	39
12	2	2	2	1	4	4	3	2	3	10.419,90	54.571,80	40.635,77	947,26	1,000	39
13	2	1	1	2	5	4	2	1	1	10.130,80	56.162,50	33.874,38	920,98	1,429	10
14	1	1	2	2	3	4	3	1	4	10.305,80	55.177,10	37.976,57	1.145,09	1,106	30
15	2	2	1	1	4	1	4	4	1	10.126,60	56.160,20	39.374,03	1.012,66	1,286	17
16	1	1	1	1	3	2	4	3	3	10.126,10	56.175,40	37.976,31	1.446,59	1,002	37
17	2	1	1	1	1	2	3	2	2	10.114,80	56.236,00	31.235,40	1.685,80	1,143	27
18	1	2	2	1	5	4	1	2	1	10.427,70	54.491,10	33.123,67	947,97	1,286	18
19	2	1	1	2	5	1	1	2	4	10.140,00	56.100,00	34.415,00	921,82	1,333	14
20	2	1	1	1	4	4	1	2	3	10.126,90	56.176,80	33.876,52	1.125,21	1,250	21
21	1	1	2	1	5	1	4	1	2	10.277,60	55.340,00	35.301,00	1.027,76	1,294	16
22	2	2	2	1	5	3	4	4	2	10.419,40	54.552,10	45.182,82	868,28	1,002	38
23	2	2	2	2	4	1	2	3	4	14.340,00	33.000,00	36.250,00	1.195,00	2,000	3
24	1	1	2	2	1	3	1	4	1	10.769,60	52.637,70	30.545,66	1.538,51	1,523	8
25	1	1	1	2	4	2	1	4	2	10.140,00	56.100,00	33.815,00	1.126,67	1,250	22
26	2	1	2	2	2	4	1	3	2	13.840,00	35.750,00	31.162,50	1.537,78	1,860	5
20 27	2	2	2	2	1	2	2	2	3		33.042,70	30.506,41	1.592,27	4,000	2

DMU		V	ari	ávei	is de	e De	cisã	0			Variáveis	de Saída		Cumon	Dank
DMU	x_1	x_2	x_3	x_4	x_5	x_6	<i>x</i> ₇	x_8	x_9	$y_1(\mathbf{un})$	$y_2(un)$	$y_3(\$)$	<i>y</i> ₄ (un/op)	Super.	Kank.
28	1	1	1	1	4	3	3	1	4	10.126,90	56.171,10	35.825,67	1.265,86	1,286	19
29	2	2	1	2	2	2	1	1	2	10.140,00	56.100,00	28.415,00	1.126,67	1,333	15
30	1	2	2	2	4	3	2	1	2	10.325,20	55.071,30	34.060,70	938,65	1,107	29
31	2	2	2	1	3	4	2	4	2	10.419,90	54.524,70	39.278,71	1.041,99	1,010	35
32	2	2	2	1	2	2	3	1	1	10.268,80	55.382,70	31.457,41	1.140,98	1,004	36
33	1	1	1	1	1	1	3	3	2	10.116,40	56.220,40	30.733,06	2.023,28	205,6	1
34	2	2	1	2	1	3	4	1	3	10.140,00	56.100,00	36.665,00	1.267,50	1,100	31
35	2	1	2	2	3	2	4	2	4	13.840,00	35.750,00	38.162,50	1.384,00	1,338	12
36	1	1	2	2	4	2	4	3	1	10.782,40	52.561,60	38.134,24	1.078,24	1,182	25
37	1	2	1	1	1	4	2	1	4	10.116,40	56.215,20	32.232,28	1.686,07	1,794	7
38	1	2	2	1	3	1	1	1	3	10.273,90	55.367,00	28.655,05	1.141,54	1,459	9
39	1	1	1	2	2	1	2	2	2	10.140,00	56.100,00	29.015,00	1.448,57	1,179	26
40	1	2	1	2	5	2	3	4	4	10.140,00	56.100,00	43.715,00	921,82	1,000	39
41	2	1	2	2	5	3	3	3	3	13.840,00	35.750,00	39.712,50	1.153,33	1,000	39
42	2	2	1	2	3	1	3	3	1	10.128,30	56.167,00	35.275,05	1.012,83	1,117	28

Tabela 5.66B - Matriz experimental e resultados obtidos para o décimo quinto objeto de estudo (continuação)

Com base no *ranking* de supereficiência e com a definição das duas DMUs mais eficientes (27 e 33), foi possível definir uma nova faixa de variação para cada variável de decisão. A Tabela 5.67 apresenta a nova faixa de variação para cada variável de decisão.

Com a aplicação do método para redução do espaço de busca, o número de variáveis de decisão foi reduzido de 9 para 8. A variável de decisão x_5 teve seu valor definido como sendo igual a 1. O espaço de busca que era de 20.480 foi reduzido para 256, uma redução de aproximadamente 98,75%.

	Variável de Decisão	Tipo	Limite Inferior	Limite Superior
x_1	Número de Operadores do tipo 1	Inteiro	1	2
x_2	Número de Operadores do tipo 2	Inteiro	1	2
x_3	Número de Operadores do tipo 3	Inteiro	1	2
x_4	Número de Operadores do tipo 4	Inteiro	1	2
x_6	Número de Máquinas do tipo 1	Inteiro	1	2
x_7	Número de Máquinas do tipo 2	Inteiro	2	3
x_8	Número de Máquinas do tipo 3	Inteiro	2	3
<i>X</i> ₉	Número de Máquinas do tipo 4	Inteiro	2	3

Tabela 5.67 - Variáveis de decisão, tipo e novos limites para o décimo quinto objeto de estudo

De modo a confirmar a eficiência da redução do espaço de busca, o otimizador SimRunner® foi empregado. O otimizador encontrou valores iguais para oito, das nove variáveis de decisão. Apenas para a variável x_7 o otimizador apresentou valores diferentes. Os resultados encontrados são apresentados na Tabela 5.68

Vaniáncia da dacias a	Sol	ıção			
Variáveis de decisão	Novos limites	Limites originais			
x_1	1	1			
x_2	2	2			
x_3	2	2			
x_4	2	2			
x_5	1	1			
x_6	1	1			
x_7	2	1			
x_8	2	2			
x_9	2	2			
Variáveis de saída	Resp	Respostas			
y_1	14.326,00	14.111,00			
ntervalo de Confiança para y ₁ (95%	(14.249,00-14,403,00)	(14.045,00-14.177,00			
y_2	33.072,00	34.268,00			

Tabela 5.68 - Resultados da otimização para o décimo quinto objeto de estudo

Intervalo de Confiança para y_1 (95%) (14.249,00-14,403,00) (14.045,00-14.177,00) y_2 33.072,00 34.268,00 Intervalo de Confiança para y_2 (95%) (32.878,00-33.266,00) (34.062,00-34.474,00) y_3 26.760,00 24.640,00 Intervalo de Confiança para y_3 (95%) (26.606,00-26.914,00) (24.509,00-24.771,00) y_4 1.790,00 1.066,00 Intervalo de Confiança para y_4 (95%) (1.762,00-1,818.00) (1.029,00-1.103,00)

Em relação aos resultados encontrados para as variáveis de saída, estes foram estatisticamente iguais apenas para o total produzido (y_1) , considerando um nível de confiança de 95%.

O otimizador comercial encontrou resultados melhores para WIP (y_2) e produtividade (y_4) , quando da redução do espaço de busca. Já para o custo de produção (y_3) , a solução encontrada contemplando o espaço de busca original foi melhor estatisticamente. A Tabela 5.69 apresenta os resultados dos testes estatísticos que confirmam tais afirmações.

Tabela 5.69 - Resultados dos testes estatísticos para o décimo quinto objeto de estudo

	Dados	Teste de Anderson-Darling	Teste F	Teste T
	Solução com novos limites	0,415	0.254	0,321
<i>y</i> ₁	Solução com limites originais	0,356	0,234	0,321
.,	Solução com novos limites	0,214	< 0.000	< 0,000
<i>y</i> ₂	Solução com limites originais	0,365	< 0,000	
	Solução com novos limites	0,124	. 0 000	< 0,000
У3	Solução com limites originais	0,228	< 0,000	< 0,000
	Solução com novos limites	0,652	< 0.000	< 0,000
У4	Solução com limites originais	0,412	< 0,000	

Para o caso em que o otimizador utilizou o espaço de busca original, o *SimRunner*® gastou 44,38 h para convergir, realizando 256 experimentos. Com o espaço de busca reduzido

foram gastos 15,12 h para a realização de 84 experimentos. Somando a este valor às 4,08 h para a simulação do arranjo L42, o ganho de tempo computacional foi de 56,7%. A Figura 5.15 apresenta os resultados encontrados com a realização da otimização, considerando o espaço de busca original e o espaço de busca reduzido.

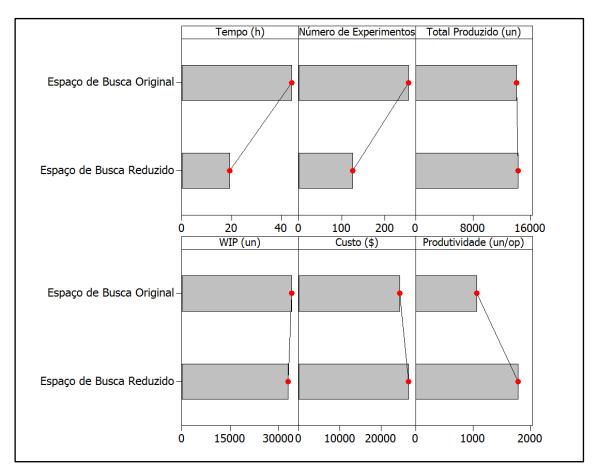


Figura 5.15 - Comparação dos resultados para o décimo quinto objeto de estudo

5.7 Comparação dos resultados obtidos com o ótimo global

Para quatro, dos quinze objetos de estudos utilizados nesta tese, todo o espaço de busca do problema de OvS foi simulado. Dessa forma, para estes quatro casos, foi possível comparar os resultados obtidos com a aplicação do método desenvolvido nesta tese, com a solução ótima global. Para os outros onze objetos de estudo, a comparação da solução obtida com o ótimo global não foi possível de ser realizada, devido a grande quantidade de tempo despendida para a simulação de todo o espaço de busca.

5.7.1 Primeiro objeto de estudo

De modo a validar os resultados alcançados com a aplicação do método proposto nesta tese, para o primeiro objeto de estudo apresentado, foram executados todos os cenários que compõem o espaço de busca do problema de OvS, e compararam-se os resultados alcançados com a aplicação do método proposto.

Para o primeiro objeto de estudo foram executados 3.125 cenários, com 30 replicações cada, totalizando 93.750 simulações realizadas. Desta forma, todo o espaço de busca do problema de OvS foi simulado. Foram gastas, aproximadamente, 106 horas (4,4 dias), para a execução de todos os cenários e suas replicações.

De posse dos resultados de todo o espaço de busca, realizou-se a análise de supereficiência, utilizando o modelo DEA BCC. Dos 3.125 cenários (DMUs), 2.102 foram eficientes, ou seja, de todo o espaço de busca do problema de OvS, 67,3% dos cenários foram eficientes.

Em seguida, realizou-se a comparação no espaço de busca reduzido, alcançado com a aplicação do método proposto. O método proporcionou uma redução do espaço de busca de 3.125 cenários para 120, equivalente a uma redução de aproximadamente 96%. Verificou-se, que dos 120 cenários, presentes no espaço de busca reduzido, 100 foram eficientes, quando analisados todos os 3.125 cenários, o que mostra que a aplicação do método levou a um novo espaço de busca para o problema de OvS, com aproximadamente 83% dos cenários eficientes. Ao se analisar somente o espaço de busca reduzido, com a aplicação do modelo DEA BCC, todos os 120 cenários se mostraram eficientes.

Finalmente, com a simulação de 100% dos cenários possíveis, ou seja, com a simulação de todo o espaço de busca original, o melhor resultado encontrado (ótimo global) dentre os 3.125 cenários foi de 1.399 peças produzidas, sendo o intervalo de confiança de 95%, compreendido entre 1.395 e 1.402 peças.

Observa-se que este resultado é estatisticamente igual, quando comparado por meio de um Teste T, ao obtido pelo procedimento de redução do espaço de busca proposto: 1.397 peças produzidas e intervalo de confiança de 95%, compreendido entre 1.393 e 1.400 peças. Os resultados encontrados para as variáveis de decisão, bem como as soluções do problema de OvS e seu intervalo de confiança, são apresentados na Tabela 5.70. Já os resultados dos testes estatísticos realizados podem ser visualizados na Tabela 5.71.

	Solução					
Variáveis de Decisão	Com a aplicação do método	Com 100% do espaço de busca simulado				
x_1	3	1				
x_2	2	3				
x_3	4	5				
x_4	3	2				
x_5	1	5				
Variáveis de Saída	Respostas					
<i>y</i> ₁	1397	1399				
Intervalo de confiança para y_1 (95%)	(1393-1400)	(1395-1402)				

Tabela 5.70 - Comparação dos resultados para o primeiro objeto de estudo com o ótimo global

Tabela 5.71 - Testes estatísticos para o primeiro objeto de estudo em comparação com o ótimo global

Dados	Teste de Anderson-Darling	Teste F	Teste T
Solução com a aplicação do método	0,408	0.239	0.171
Solução com 100% do espaço de busca simulado	0,886	0,239	0,1/1

5.7.2 Segundo objeto de estudo

Para o segundo objeto de estudo, também foram simulados todos os 3.125 cenários com 30 replicações por cenário, totalizando 93.750 simulações realizadas. Mais uma vez, todo o espaço de busca foi simulado. Para este objeto de estudo foram gastas, aproximadamente, 12 horas para a execução de todos os cenários e suas replicações.

De posse de 100% dos cenários simulados, realizou-se a análise de eficiência utilizando o modelo DEA BCC. Dos 3.125 cenários, 2.125 foram eficientes, ou seja, de todo o espaço de busca do problema de OvS, 68% dos cenários foram eficientes.

Na sequência foi realizada a comparação no espaço de busca reduzido, alcançado com a aplicação do método proposto. O método proporcionou uma redução no espaço de busca, de aproximadamente 98,8%. Reduzindo, os 3.125 cenários originais a 36. Destes 36 cenários, sete foram eficientes, quando analisados dentro do contexto dos 3.125 cenários. Como no caso anterior, ao se analisar somente os 36 cenários do espaço de busca reduzido, todos se mostraram eficientes.

Finalmente, com a simulação de todo o espaço de busca, o melhor resultado encontrado, dentre os 3.125 cenários, foi de 5.363 kg de roupas lavadas, sendo o intervalo de confiança de 95% compreendido entre: 5.319 e 5.406 kg. Esse resultado foi o mesmo encontrado com a aplicação do método proposto nesta tese. Os resultados encontrados para as variáveis de decisão, bem como as soluções do problema de OvS e seu intervalo de confiança, são apresentados na Tabela 5.72.

	Solução		
Variáveis de Decisão	Com a aplicação do método	Com 100% do espaço de busca simulado	
x_1	5	5	
x_2	4 1 1	4 1	
x_3			
x_4		1	
x_5	5	5	
Variáveis de Saída	Respostas		
<i>y</i> ₁	5363	5363	
Intervalo de confiança para y_1 (95%)	(5319-5406)	(5319-5406)	

Tabela 5.72 - Comparação dos resultados para o segundo objeto de estudo com o ótimo global

5.7.3 Terceiro objeto de estudo

Para o terceiro objeto de estudo, foi realizada a simulação dos 2.048 cenários (com 30 replicações), totalizando 61.440 simulações realizadas. Mais uma vez, todo o espaço de busca foi simulado. Para este objeto de estudo foram gastas, aproximadamente, 10 horas para a execução de todos os cenários e suas replicações.

De posse de 100% dos cenários simulados, realizou-se a análise de eficiência utilizando o modelo DEA BCC. Dos 2.048 cenários, 1.805 foram eficientes, ou seja, de todo o espaço de busca do problema de OvS, aproximadamente 88% dos cenários foram eficientes.

Uma vez realizada a análise de eficiência em 100% dos cenários, passou-se a realização desta comparação no espaço de busca reduzido. Para este objeto de estudo, o método proporcionou uma redução no espaço de busca, de aproximadamente 93%. Reduzindo, os 2.048 cenários originais a 144. Dos 144 cenários analisados, todos foram eficientes, quando analisados em conjunto aos 2.048 cenários do espaço de busca, o que mostra que a aplicação do método levou a um novo espaço de busca com 100% dos cenários eficientes. Ao se analisar a eficiência, considerando apenas os 144 cenários, assim como nos casos anteriores todos se mostraram eficientes.

Finalmente, com a geração de 100% dos cenários possíveis, o melhor resultado encontrado foi o mesmo encontrado com a aplicação do método proposto nesta tese: 451.000 peças produzidas, com um intervalo de confiança para a resposta de 95% de 447.691 a 454.509 peças produzidas; e 517 peças refugadas, com um intervalo de confiança de 95% de 324 a 710 peças refugadas. Os resultados encontrados para as variáveis de decisão, bem como as soluções do problema de OvS e seu intervalo de confiança, são apresentados na Tabela 5.73.

	Solução		
Variáveis de Decisão	Com a aplicação do método	Com 100% do espaço de busca simulado	
x_1	4	4	
x_2	3	3 4 3 2	
x_3	4		
x_4	3		
x_5	2		
x_6	1	1	
Variáveis de Saída	Respostas		
<i>y</i> ₁	451.100	451.100	
Intervalo de Confiança para y_1 (95%)	(447.691-454.509)	(447.691-454.509)	
y_2	517	517	
Intervalo de Confiança para y ₂ (95%)	(324-710)	(324-710)	

Tabela 5.73 - Comparação dos resultados para o terceiro objeto de estudo com o ótimo global

5.7.4 Décimo objeto de estudo

Para o décimo objeto de estudo foram simulados todos os 1.331 cenários com 30 replicações por cenário, totalizando 39.930 simulações realizadas. Mais uma vez todo o espaço de busca foi simulado. Para este objeto de estudo foram gastas, aproximadamente, 28 horas para a execução de todos os cenários e suas replicações.

De posse de 100% dos cenários simulados, realizou-se a análise de eficiência utilizando o modelo DEA BCC. Dos 1.331 cenários, 333 foram eficientes, ou seja, de todo o espaço de busca do problema de OvS, 25% dos cenários foram eficientes.

Na sequência foi realizada a comparação no espaço de busca reduzido, alcançado com a aplicação do método proposto. O método proporcionou uma redução no espaço de busca, de aproximadamente 97,5%. Reduzindo, os 1.331 cenários originais a 33. Destes 33 cenários, todos foram eficientes, quando analisados dentro do contexto dos 1.331 cenários. Ao se analisar, somente os 33 cenários do espaço de busca reduzido, da mesma forma, todos se mostraram eficientes.

Finalmente, com a simulação de todo o espaço de busca, o melhor resultado encontrado, dentre todos os cenários, foi de R\$ 588.560,00, sendo o intervalo de confiança de 95% compreendido entre: R\$ 580.170,00 e R\$ 596.949,00. Observa-se que este resultado é estatisticamente igual, quando comparado por meio de um Teste T, ao obtido pelo método de redução do espaço de busca proposto: R\$ 587.520,00 e intervalo de confiança de 95%, compreendido entre R\$ 575.619,00 e R\$ 597.420,00.

Os resultados encontrados para as variáveis de decisão, bem como as soluções do problema de OvS e seu intervalo de confiança, são apresentados na Tabela 5.74. Já os resultados dos testes estatísticos realizados podem ser visualizados na Tabela 5.75.

Tabela 5.74 - Comparação dos resultados para o décimo objeto de estudo com o ótimo global

	Solução		
Variáveis de Decisão	Com a aplicação do método	Com 100% do espaço de busca simulado	
x_1	5	9	
x_2	6	9 8	
x_3	5		
Variáveis de Saída	Respostas		
y_1	587.520,00	588.560,00	
Intervalo de Confiança para y_1 (95%)	(575.619,00-597.420,00)	(580.170,00-596.949,00)	

Tabela 5.75 - Testes estatísticos para o décimo objeto de estudo em comparação com o ótimo global

Dados	Teste de Anderson-Darling	Teste de F	Teste T
Solução com a aplicação do método	0,275	0.184	0,668
Solução com 100% do espaço de busca simulado	0,536	0,184	

5.7.5 Demais objetos de estudo

Para os outros 11 objetos de estudo apresentados nesta tese, a simulação de todo o espaço de busca se tornou inviável, devido ao número excessivo de simulações e ao tempo necessário. A Tabela 5.76 apresenta uma previsão do tempo necessário para a execução de todo o espaço de busca destes objetos de estudo.

Tabela 5.76 – Tempo estimado para execução de todo espaço de busca para os demais objetos de estudo

Objeto de Estudo	Espaço de Busca (No. de Possíveis Soluções)	Tempo Estimado (Dias)	
4	15.625	274,50	
5	100.000	182,45	
6	4.320	21,20	
7	2.488.320	1.785,60	
8	127.776	162,70	
9	107.811	101,07	
11	215.622	187,17	
12	20.480	68,80	
13	20.480	75,85	
14	20.480	77,03	
15	20.480	82,90	

Dessa forma, para estes 11 objetos de estudo não foi possível estabelecer a comparação entre o resultado ótimo global e o resultado encontrado pelo otimizador, com a redução do

espaço de busca, proporcionado pelo método proposto nesta tese.

5.8 Considerações finais

Este capítulo apresentou a aplicação do método de otimização proposto, para redução do espaço de busca, em problemas de OvS. Esta proposta foi aplicada a 15 objetos de estudo, representando problemas de manufatura e da área hospitalar em modelos de SED de complexidade variada. Foram apresentados, tanto problemas de otimização mono-objetivos, como multiobjetivos.

A aplicação do método promoveu reduções do espaço de busca da ordem de 97% em média, tornando o procedimento de OvS mais rápido, em aproximadamente 42%, alcançando soluções estatisticamente iguais ou melhores, quando da otimização sem a aplicação do método. Com isso, pode-se validar a aplicabilidade do método proposto para as condições de contorno estabelecidas nesta tese.

A Tabela 5.77 apresenta os resultados da redução do espaço de busca e da redução do tempo computacional envolvido na otimização de cada objeto de estudo. Na Tabela 5.77, a coluna referente ao "Tempo Método" refere-se a soma dos tempos da simulação do arranjo ortogonal e do otimizador, contemplando o espaço de busca reduzido.

Ob	lasse/ jeto de studo	Espaço de Busca Original	Espaço de Busca Reduzido	Redução Espaço de Busca	Tempo SimRunner® (Espaço de Busca Original)	Tempo Método (Espaço de Busca Reduzido)	Redução Tempo
1	1	3.125	120	96,20%	8,00 h	(2,40 + 0,42) h	64,80%
1	2	3.125	36	98,85%	0,55 h	(0,11+0,08) h	65,45%
2	3	2.048	144	93,00%	0,68 h	(0,32+0,12) h	35,30%
	4	15.625	480	97,00%	78,50 h	(45,50 + 3,00) h	38,20%
	5	100.000	1.200	98,80%	11,50 h	(7,40+0,88) h	28,00%
3	6	4.320	200	95,40%	25,20 h	(9,60+8,5) h	28,00%
	7	2.488.320	7.776	99,70%	10,12 h	(5,18+0,62) h	42,70%
	8	127.776	484	99,60%	7,46 h	(4,70 + 1,10) h	22,25%
4	9	107.811	15.309	85,80%	5,15 h	(3,34 + 0,81) h	19,40%
	10	1.331	33	97,50%	4,75 h	(0,70+0,72) h	70,00%
	11	215.622	1.764	99,20%	4,72 h	(2,88 + 0,75) h	23,10%
5	12	20.480	144	99,30%	22,67 h	(9,69 + 2,58) h	45,90%
	13	20.480	240	98,80%	27,66 h	(11,98 + 3,20) h	45,10%
	14	20.480	240	98,80%	33,77 h	(15,34+3,25) h	44,95%
	15	20.480	256	98,70%	44,38 h	(15,12+4,08) h	56,70%

Tabela 5.77 - Resultados das reduções do espaço de busca e do tempo computacional

Com os resultados encontrados com a simulação de todo o espaço de busca dos problemas de OvS, e posterior comparação com os resultados alcançados com a aplicação do

método, pode-se assumir, que com a aplicação do método desenvolvido nesta tese é possível representar a região de busca de um problema de OvS, por meio de um AO, e com a análise de supereficiência (DEA BCC) nos resultados deste arranjo, reduzir o espaço de busca do problema de OvS.

Isso fará, com que o processo de otimização, realizado por um otimizador, seja mais eficaz, quando comparado a otimização com as condições originais do problema de OvS, uma vez que, ao mesmo tempo em que se terá uma solução estatisticamente igual, isso será alcançado em um tempo menor. Com isso, pode-se, para os casos empregados neste trabalho, validar as premissas assumidas, quando da proposição do método para redução do espaço de busca em problemas de OvS.

Desta forma, este capítulo encerra o passo de análise dos resultados proposto no método de Bryman (1989).

6. CONCLUSÃO

6.1 Verificação dos objetivos específicos

Esta seção apresenta a verificação dos objetivos específicos propostos no Capítulo 1:

1. Desenvolver a estrutura do método de otimização, integrando os arranjos ortogonais de Taguchi, a simulação a eventos discretos e a DEA BCC, aliada ao conceito da supereficiência.

Este objetivo começou a ser delineado a partir do Capítulo 2, com a apresentação do referencial teórico, que suportou a proposição do método, e foi finalizado com a apresentação de sua estrutura no Capítulo 4. Além de apresentar os passos do método proposto, o capítulo apresentou as técnicas empregadas no método, as premissas assumidas para seu desenvolvimento, bem como, as condições de contorno para sua aplicação. Todos os passos e a descrição da estrutura do método proposto, que levaram a atender esse objetivo, podem ser verificados ao longo do Capítulo 4.

2. Aplicar o método desenvolvido em modelos de SED, a fim de validar sua aplicabilidade, por meio da comparação dos resultados encontrados pelo método proposto com os resultados encontrados a partir de um *software* comercial de OvS;

O método desenvolvido foi aplicado em quinze modelos de SED, divididos em cinco classes de problemas, de acordo com a variação dos níveis das variáveis de decisão e com o número de objetivos a serem otimizados. Problemas de diferentes tipos de empresas, com diferentes graus de complexidade, diferentes objetivos e diferentes variáveis de decisão foram utilizados para aplicação e comparação do método proposto, que permitiram sua validação. Foram escolhidos problemas de otimização de empresas de manufatura e ambientes hospitalares, devido a grande utilização da SED nestes setores. A aplicação do método nos modelos de SED pôde ser acompanhada ao longo do Capítulo 5.

Os resultados alcançados com a aplicação do método foram comparados com a otimização, considerando todo o espaço de busca. Foi utilizado o otimizador comercial *SimRunner*®. Desta forma, o otimizador foi empregado, considerando a redução do espaço de busca proporcionado pelo método proposto, e o espaço de busca original do problema de OvS. Os resultados foram comparados em função das respostas encontradas para as variáveis de decisão, solução, tempo para convergência e número de experimentos realizados pelo

otimizador. Em todos os casos, o otimizador encontrou soluções de igual qualidade, ou até mesmo superior, realizando menos experimentos e consumindo menos tempo computacional. Os resultados das comparações são apresentados ao longo do Capítulo 5.

 Quantificar as reduções do espaço de busca e do tempo computacional alcançados com a aplicação do método.

Com a conclusão do objetivo anterior, tornou-se possível quantificar a redução do espaço de busca e a redução do tempo computacional, com o emprego do método desenvolvido nesta tese. A redução do espaço de busca variou de 85,80% a 99,70%, alcançando um valor médio nos 15 objetos de estudo de 97%. Já a redução no tempo computacional variou de 19,40% a 70,00%, reduzindo, em média, 42% o tempo necessário para a convergência do otimizador. Estes resultados, bem como suas discussões podem ser encontrados no Capítulo 5.

4. Comparar os resultados encontrados na aplicação do método com os resultados encontrados com a simulação de todo o espaço de busca (ótimo global).

Para cumprir este objetivo, foram simulados todos os cenários (espaço de busca) dos objetos de estudo 1, 2, 3 e 10. Para os demais objetos de estudo, tal comparação não foi possível, devido ao elevado tempo computacional envolvido, já que, nestes casos seriam necessários vários dias ou até mesmo meses, para que se conseguisse simular todo o espaço de busca dos problemas de OvS. De posse das soluções ótimas, para os problemas de OvS, estes foram comparados com os resultados encontrados com a aplicação do método proposto. Para os quatro objetos de estudo, as soluções encontradas com a aplicação do método foram estatisticamente iguais às soluções ótimas. Este fato permitiu validar a aplicabilidade do método e as premissas assumidas, quando da sua proposição. Toda a comparação, envolvendo os resultados com o espaço de busca reduzido e com os resultados ótimos globais, pode ser encontrada no Capítulo 5.

6.2 Considerações finais

Com o trabalho desenvolvido nesta tese, foi possível propor um método para redução do espaço de busca em problemas de OvS, integrando Simulação a Eventos Discretos, a Análise Envoltória de Dados (DEA BCC), adaptada ao conceito da supereficiência e os Arranjos Ortogonais de Taguchi.

Este método conseguiu alcançar bons resultados na otimização de quinze modelos de SED, mono e multiobjetivos, divididos em cinco classes de problemas. Os quinze objetos de estudo, com diferentes graus de complexidades, abordaram problemas de alocação de recursos nas áreas de manufatura e hospitalar, sendo modelados no simulador *ProModel*®.

Com a aplicação do método nos quinze modelos, conseguiram-se reduções do espaço de busca da ordem de 97%, sem que, com isso, houvesse perda da qualidade das respostas encontradas. Devido às saídas do modelo de simulação serem estocásticas, optou-se por trabalhar com a realização de replicações por cenário simulado, e com a realização de testes estatísticos para comprovação da igualdade das soluções encontradas.

A utilização de um otimizador comercial permitiu comparar, os resultados das otimizações contemplando o espaço de busca original do problema de OvS, com o espaço de busca reduzido, limitado pelo método proposto. Em todos os casos, o otimizador alcançou soluções de igual ou superior qualidade, mostrando que a redução do espaço de busca conduziu a uma região de busca melhor para os problemas de OvS.

Para otimização dos quinze modelos, contemplando a redução do espaço de busca e o espaço de busca original destes problemas, foram gastas mais de 450 horas de tempo computacional.

Outra questão a se destacar, foi que em todos os casos, as reduções de tempo obtidas pelo procedimento de otimização foram significativas para se chegar a uma resposta. Com a aplicação do método ocorreram reduções de tempo de aproximadamente 42% (em média), em comparação com a otimização sem contemplar a redução do espaço de busca.

O método proposto permitiu também, que a região de busca pudesse ser melhor explorada pelo otimizador. Nos quinze objetos de estudo explorados nesta tese, a cobertura da área experimental pelo otimizador, após a redução do espaço de busca, foi significativamente maior, permitindo a obtenção de bons resultados.

De forma a validar a aplicabilidade do método e as premissas assumidas, os resultados encontrados na otimização com o espaço de busca reduzido, foram comparados aos resultados encontrados com a simulação de todo o espaço de busca.

Tal comparação pôde ser feita para quatro, dos quinze modelos de SED otimizados e envolveu a utilização de mais de 150 horas de tempo computacional para o processamento dos espaços de busca. Devido a limitações computacionais, para os demais objetos de estudo, tal comparação não pôde ser realizada. Para estes quatro objetos de estudo foram simulados 100% dos cenários pertencentes ao espaço de busca total, e o ótimo global foi comparado com o resultado encontrado com a utilização do método proposto.

Com esta comparação foi possível comprovar, que o método desenvolvido consegue limitar uma região de busca, que contempla o ótimo global, como no caso do segundo e terceiro objetos de estudo, ou soluções estatisticamente iguais ao ótimo global, como no caso do primeiro e décimo objetos de estudo. Outro fato a se destacar, foi que, quando analisada a eficiência da região de busca limitada pela aplicação do método, todos os cenários se mostraram eficientes para os quatro objetos de estudo.

Adicionalmente, deve-se ressaltar que, por ser uma ferramenta não-paramétrica, a DEA permite trabalhar com dados associados a distribuições de probabilidade diferentes da normal, além de contornar o problema da incomensurabilidade dos elementos envolvidos no problema (unidades de medidas diferentes), quantificando a eficiência de diversos cenários, com diferentes variáveis de entrada e saída. Tal fato permite, que o método desenvolvido nesta tese possa ser aplicado a problemas de OvS, que respeitem as condições de contorno deste trabalho, sem a necessidade de transformações nos dados de entrada e/ou saída.

No que diz respeito à utilização dos arranjos ortogonais de Taguchi para representação do espaço experimental, pode-se afirmar que tal estratégia se mostrou eficaz. Estes permitem trabalhar com vários fatores e níveis, ao contrário de outros métodos de planejamentos experimentais (como fatoriais completos, fracionados e planejamentos compostos central), que trabalham com dois ou três níveis, propiciando, assim uma melhor representação da região experimental.

Cabe destacar, que para o método proposto possa alcançar bons resultados, o AO utilizado deve explorar ao máximo possível, a diversidade de níveis presentes em cada variável de decisão. Quanto mais diversificada for a matriz experimental, maiores as chances de se identificar o intervalo de variação ideal para cada variável de decisão. Esse arranjo escolhido também deverá obedecer a regra do número mínimo de DMUs, proposta por Banker *et al.* (1989).

O método para redução do espaço de busca, proposto nesta tese, se mostrou aplicável a problemas de OvS referentes à alocação de recursos, promovendo reduções de aproximadamente 97% no espaço de busca e reduções médias de tempo de 42%. Tais resultados foram validados com resultados ótimos, alcançados com a simulação de todo o espaço de busca.

Desta forma, este trabalho oferece uma ferramenta capaz de auxiliar analistas de simulação, desde que respeitem as condições de contorno deste trabalho, a reduzir o tempo computacional do processo de OvS, ao mesmo tempo que permite encontrar soluções ótimas.

Vale ainda ressaltar, que novos testes poderão ser realizados com modelos de simulação, contemplando outros tipos de problemas de OvS, de forma a permitir validar sua aplicabilidade para outros tipos de problemas.

6.3 Sugestões para trabalhos futuros

Ao término desta tese, vislumbra-se como possíveis trabalhos futuros:

- Aplicação do método em problemas de OvS com características diferentes dos problemas testados nesta tese, de modo a ampliar a aplicabilidade do método proposto;
- Realizar testes com variáveis do tipo contínuas, no lugar das variáveis discretas, contemplando assim, as principais classes de variáveis de decisão em um problema de OvS;
- Testar o método proposto neste trabalho, utilizando outros otimizadores, que contemplem outros métodos de otimização, além dos algoritmos genéticos e evolucionários;
- Testar modelos DEA-Fuzzy, no lugar do modelo DEA BCC, visando eliminar a necessidade das replicações nos modelos de simulação.
- Testar o modelo GPDEA BCC (BAL, ÖRKCÜ e ÇELEBIOGLU, 2010), no lugar do modelo DEA BCC, uma vez que os modelos GPDEA permitem melhorar a discriminação da DEA, mesmo com um número de DMUs que não atendam o recomendado por Banker et al. (1989);
- Testar modelos GPDEA-Fuzzy, visando eliminar a necessidade de replicações e a necessidade de um número mínimo de DMUs;
- Testar outros arranjos ou estratégias experimentais, que permitam reduzir o número de experimentos necessários, possibilitando uma maior redução do tempo computacional.

Com as sugestões para trabalhos futuros, encerra-se o presente capítulo, cumprindo assim a última etapa do método de pesquisa proposto por Bryman (1989).

REFERÊNCIAS BIBLIOGRÁFICAS

AARTS, E. H. L.; KORST, J.; MICHIELS, W. **Simulated Annealing**. In: BURKE, E. K.; KENDALL, G. (Eds.). Introductory tutorials in optimisation, decision support and search methodologies. Springer, p.187-211, 2005.

ADLER, N.; FRIEDMAN, L.; SINUANY-STERN, Z. Review of ranking methods in the data envelopment analysis context. **European Journal of Operational Research**, v.140, n.2, p.249-265, 2002.

AHMED, M. A.; ALKHAMIS, T. M. Simulation optimization for an emergency department healthcare unit in Kuwait. **European Journal of Operational Research**, v.198, n.3, p.936-942, 2009.

AHUJA, R. K.; MAGNANTI, T. L.; ORLIN, J. B. Network Flows: Theory, Algorithms, and Applications. New Jersey: Upper Saddle River, 1993.

ALEM, S.M.; AZADEH, A.; SHIRKOUHI, S.N.; REZAIE, K. A Decision making methodology for vendor selection problem based on DEA, FDEA and CCDEA models: A simulation analysis. In: Asia International Conference on Modelling and Simulation, **Proceedings...** 2009.

ALLAOUI, H.; ARTIBA, A. Integrating simulation and optimization to schedule a hybrid flow shop with maintenance constraints. **Computers and Industrial Engineering**, v.47, p.431-450, 2004.

AL-REFAIE, A.; FOUAD, R.H.; LI, M.-H.; SHURRAB, M. Applying simulation and DEA to improve performance of emergency department in a Jordanian hospital. **Simulation Modelling Practice and Theory**, v.41, p.59-72, 2014.

AL-TURKI, U. M.; ARIFUSALAM, S.; EL-SELIAMAN, M.; KHAN, M. Resource Allocation, Batching and Dispatching in a Stochastic Flexible Job Shop. **Advanced Materials Research**, v.264, p.1758-1763, 2011.

AMMERI, A.; CHABCHOUB, H.; HACHICHA, W.; MASMOUDI, F. A Comprehensive literature classification of simulation-optimization methods. In: International Conference on Multi Objective Programming and Goal Programming, **Proceedings...** 2010.

ANDERSEN, P.; PETERSEN, N. C. A procedure for ranking efficient units in data envelopment analysis. **Management Science**, v.39, p.1261-1264, 1993.

ANGULO-MEZA, L.; CUNHA, B. T. A avaliação cruzada: uma revisão bibliográfica e implementação computacional. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** Goiânia, 2006.

ANGULO-MEZA, L.; LINS, M. P. E. Review of Methods for Increasing Discrimination in Data Envelopment Analysis. **Annals of Operations Research**, v.116, p.225-242, 2002.

ANGULO-MEZA, L.; MELLO, J. C. C. B. S.; GOMES, E. G.; FERNANDES, A. J. S. Seleção de Variáveis em DEA aplicada a uma análise do mercado de energia elétrica. **Investigação Operacional**, v.27, p.21-36, 2007.

ANGULO-MEZA, L. **Data Envelopment Analysis (DEA) na Determinação da Eficiência dos Programas de Pós-Graduação da COPPE/UFRJ**. 1998. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, RJ, 1998.

- ANTONY, J. Taguchi or classical design of experiments: a perspective from a practitioner. **Sensor Review**, v.26, p.227-230, 2006.
- APPOLINÁRIO, F. **Metodologia da ciência filosofia e prática da pesquisa**. São Paulo: Editora Pioneira Thomson Learning, 2006.
- APRIL, J.; BETTER, M. GLOVER, F.; KELLY, J. P.; LAGUNA, M. Enhancing business process management with simulation optimization. In: Winter Simulation Conference, **Proceedings...** Monterey, CA, USA, 2005.
- APRIL, J.; GLOVER, F.; KELLY, J. P.; LAGUNA, M. Practical introduction to simulation optimization. In: Winter Simulation Conference, **Proceedings...** New Orleans, LA, USA, 2003.
- ARAB, A.; ISMAIL, N.; LEE, L. S. Maintenance scheduling incorporating dynamics of production system and real-time information from workstations. **Journal of Intelligent Manufacturing**, v.24, n.4, p.695-705, 2013.
- AZADEH, A., ALEM, S.M. A flexible deterministic, stochastic and fuzzy Data Envelopment Analysis approach for supply chain risk and vendor selection problem: Simulation analysis. **Expert Systems with Applications,** v.37, n.12, p.7438-7448, 2010.
- AZADEH, A.; ALEM, S. M.; NAZARI-SHIRKOOHI, S.; REZAIE, K. An integrated computer simulation-DEA and its extension models for vendor selection problem. **International Journal of Simulation: Systems, Science and Technology**, v.10, n.3, p. 72-76, 2009.
- AZADEH, A.; MOGHADDAM, M.; ASADZADEH, S. M.; NEGAHBAN, A. An integrated fuzzy simulation-fuzzy data envelopment analysis algorithm for job-shop layout optimization: the case of injection process with ambiguous data. **European Journal of Operational Research**, v.214 p.768-779, 2011.
- AZADEH, A.; SHEIKHALISHAHI, M.; FIROOZI, M.; KHALILI, S. M. An integrated multi-criteria Taguchi computer simulation-DEA approach for optimum maintenance policy and planning by incorporating learning effects. **International Journal of Production Research**, v.51, p.1-12, 2013.
- AZADEH, A.; TABATABAEE, M.; MAGHSOUDI, A. Design of Intelligent Simulation Software with Capability of Optimization. **Australian Journal of Basic and Applied Sciences**, v.3, n.4, p.4478-4483, 2009.
- AZADNIA, A.H., GHADIMI, P., MAT SAMAN, M.Z., WONG, K.Y., SHARIF, S. A Decision making methodology for vendor selection problem based on DEA, FDEA and CCDEA models: A simulation analysis. In: Asia International Conference on Modelling & Simulation, **Proceedings...** 2011.
- BACHELET, B.; YON, L. Model enhancement: Improving theoretical optimization with simulation. **Simulation Modelling Practice and Theory**, v.15, p.703-715, 2007.
- BAL, H.; ÖRKCÜ, H.; ÇELEBIOGLU, S. Improving the discrimination power and weights dispersion in the data envelopment analysis. **Computers & Industrial Engineering**, v.37, p.99-107, 2010.
- BALLANTYNE, K.N.; VAN OORSCHOT, R.A.; MITCHELL R.J. Reduce optimization time and effort: Taguchi experimental design methods, **Forensic Science International: Genetics**, v.1 p.7-8, 2008.

- BANKER, R. D.; CHARNES, A.; COOPER, W. W.; SWARTS, J.; THOMAS, D. A. An Introduction to Data Envelopment Analysis with Some of its Models and Their Uses. **Research in Governmental and Non-Profit Accounting,** v.5, p.125-163, 1989.
- BANKER, R. D.; CHARNES, A.; COOPER, W. W. Some models for estimating technical and scale inefficiencies in Data Envelopment Analysis. **Management Science**, v.30, p.1078-1092, 1984.
- BANKS, J. Panel Session: The Future of Simulation. In: Winter Simulation Conference, **Proceedings...** Arlington, VA, USA, 2001.
- BANKS, J.; CARSON II, J. S.; NELSON, B. L.; NICOL, D. M. **Discrete event system simulation**. 3rd. ed., New Jersey: Prentice-Hall, 2000.
- BANKS, J.; CARSON II, J. S.; NELSON, B. L.; NICOL, D. M. **Discrete-event Simulation**. 5th. ed., New Jersey: Prentice-Hall, 2009.
- BARTON, R.R.; MECKESHEIMER, M. **Metamodel-based simulation optimization**. In: BIRGE, J. R.; LINETSKY, V. (Eds.). Handbooks in operations research and management science, Cap.18, p.535-574, 2006.
- BATEMAN, R. E.; BOWDEN, R. O.; GOGG, T. J.; HARREL, C. R.; MOTT, J. R. A.; MONTEVECHI, J. A. B. Sistemas de simulação: aprimorando processos de logística, serviços e manufatura. Rio de Janeiro: Elsevier, 2013.
- BEHZADIAN, M., KHANMOHAMMADI OTAGHSARA, S., YAZDANI, M., IGNATIUS, J. A state of the art survey of TOPSIS applications. **Expert Systems with Applications**, v.39, n.17, p.13051-13069, 2012.
- BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and Simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v.22, n.2, p.241-264, 2002.
- BESSERIS, G. J. Profiling effects in industrial data mining by non-parametric DOE methods: An application on screening checkweighing systems in packaging operations. **European Journal of Operational Research,** v.1, p.147-161, 2012.
- BETTONVIL, B. W. M.; CASTILLO, E.; KLEIJNEN, J. P. C. Statistical testing of optimality conditions in multiresponse simulation-based optimization. **European Journal of Operational Research**, v.199, n.2, p.448-458, 2009.
- BOLBOACĂ, S.D.; JÄNTSCHI, L. Design of experiments: Useful orthogonal arrays for number of experiments from 4 to 16. **Entropy**, v.9, n.4, p.198-232, 2007.
- BRAILSFORD, S. Discrete-event simulation is alive and kicking! **Journal of Simulation**, v.8, n.1, p.1-8, 2014.
- BRYMAN, A. Research methods and organization studies. Londres: Unwin Hyman, 1989.
- CABRERA, E.; TABOADA, M.; IGLESIAS, M. L.; EPELDE, F.; LUQUE, E. **Simulation Optimization for Healthcare Emergency Departments**. Procedia Computer Science, v.9, p.1464-1473, 2012.
- CARSON, J. S. Introduction to modeling and simulation. In: Winter Simulation Conference, **Proceedings...** Washington, D.C., USA, 2004.
- CARSON, Y.; MARIA, A. Simulation optimization: methods and applications. In: Winter Simulation Conference, **Proceedings...** Atlanta, GA, USA, 1997.

- CHARNES, W. W. COOPER, E. RHODES, Measuring the efficiency of decision making units. **European Journal of Operational Research**, v.2, p.429-444, 1978.
- CHWIF, L.; MEDINA, A. C. Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações. 2ª. ed. São Paulo: Editora dos Autores, 2010.
- CIMINO, A.; LONGO, F.; MIRABELLI, G. A General Simulation Framework for Supply Chain Modeling: State of the Art and Case Study. **International Journal of Computer Science Issues**, v.7, n.3, p.1-9, 2010.
- COELLO, C. A. C.; LAMONT, G.B.; VAN VELDHUIZEN, D. A. **Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation)**. 2nd. ed. New York: Springer, 2007.
- COOK, W. D.; SEIFORD, L. M. Data Envelopment Analysis (DEA) Thirty years on. **European Journal of Operational Research**, v.192, p.1-17, 2009.
- COOPER, W. W.; SIEFORD, L. M.; TONE, K. **Data envelopment analysis: A comprehensive text with models, application, references and DEA-Solver Software**. 2nd. ed. New York: Springer Science + Business Media, 2007.
- COSTA, R. V. P. Otimização da resistência à compressão de pelotas de minério de ferro para redução direta pela aplicação de projeto robusto. 2008. 113 f. Dissertação (Mestrado em Engenharia de Materiais). Universidade Federal de Ouro Preto (UFOP), Ouro Preto, MG, 2008.
- COSTA, R. F. S. Abordagem sistemática para avaliação econômica de cenários para modelos de simulação discreta em manufatura. 2010. 139 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2010.
- DAMASO, V.C.; GARCIA, P.A.A. Testing and preventive maintenance scheduling optimization for aging systems modeled by generalized renewal process. **Pesquisa Operacional**, v.29, p.563-576, 2009.
- DEB, K. Multi-Objective Optimization using Evolutionary Algorithms. Chichester: John Wiley & Sons, 2001.
- DENGIZ, B.; BELGIN, O. Simulation optimization of a multi-stage multi-product paint shop line with Response Surface Methodology. **Simulation: Transactions of the Society for Modeling and Simulation International**, v.90, n.3, p.1-10, 2014.
- DYSON, R. G.; ALLEN, R; CAMANHO, A. S.; PODINOVSKI, V. V.; SARRICO, C. S.; SHALE, E. A. Pitfalls and protocols in DEA. **European Journal of Operational Research**, v.132, p.245-259, 2001.
- DOYLE, J., GREEN, R. Efficiency and cross-efficiency in DEA derivations, meanings and uses. **Journal of the Operational Research Society**, v.45, p.567-578, 1994.
- D'AUDENHOVE, A.D.N.; FUGIHARA, M.K. Aplicações da tecnologia ProModel no Brasil: segmentos que mais utilizam e abrangência do uso. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** 2009.
- ESKANDARI, H.; MAHMOODI, E.; FALLAH, H.; GEIGER, C. D. Performance analysis of comercial simulation-based optimization packages: OptQuest and Witness Optimizer. In: Winter Simulation Conference, **Proceedings...** Phoenix, AZ, USA, 2011.
- FARRELL, Michael J. The measurement of productive efficiency. **Journal of the Royal Statistical Society**, p.253-290, 1957.

- FERREIRA, C. M. C.; GOMES, A. P. Introdução à análise envoltória de dados: teoria, modelos e aplicações. Viçosa: Editora UFV, 2012.
- FIGUEIREDO, D. S. D.; MELLO, J. C. C. B. S. Índice híbrido de eficácia e eficiência para lojas de varejo. **Gestão & Produção**, v.16, n.2, p.286-300, 2009.
- FU, M.C. Optimization for Simulation: Theory vs. Practice. **Journal on Computing**, v.14, n.3, p. 192-215, 2002.
- FU, M. C. Optimization via simulation: A review. **Annals of Operations Research**, v.53, p.199-247, 1994.
- FU, M. C.; ANDRADÓTTIR, S.; CARSON, J. S.; GLOVER, F.; HARRELL, C. R.; HO, Y. C.; KELLY, J. P.; ROBINSON, S. M. Integrating optimization and simulation: research and practice. In: Winter Simulation Conference, **Proceedings...** Orlando, FL, USA, 2000.
- GAGLIARDI, J. P.; RENAUD, J.; RUIZ, A. A simulation modeling framework for multiple-aisle automated storage and retrieval systems. **Journal of Intelligent Manufacturing**, v.25, n.1, p.193-207, 2014.
- GAMS **The General Algebraic Modelling**. Disponível em: http://www.gams.com/>. Acesso em Janeiro de 2013.
- GHOSH, T., CHAKRABORTY, T., DAN, P.K. An effective AHP-based metaheuristic approach to solve supplier selection problem. **International Journal of Procurement Management**, v.5, n.2, p.140-159, 2012.
- GLOVER, F.; LAGUNA, M.; MARTÍ, R. **Principles of Tabu Search**, In: GONZALEZ, T. (Ed), Handbook of Approximation Algorithms and Metaheuristics. Boca Raton: Chapman & Hall/CRC, 2005.
- GRESSLER, L. A. Introdução a Pesquisa: projetos e Relatórios. 2ª.ed. São Paulo: Loyola, 2004.
- HARREL, C. R.; GHOSH, B. K.; BOWDEN, R. **Simulation Using ProModel**. 2^a.ed. New York: McGraw-Hill, 2004.
- HARREL, C. R.; MOTT, J. R. A; BATEMAN, R. E.; BOWDEN, R. G.; GOGG, T. J. **Simulação: otimizando os sistemas**. 2ª.ed. São Paulo: IMAM, 2002.
- HEDAYAT, A.S.; SLOANE, N.J.A.; STUFKEN, J. Orthogonal Arrays: Theory and Applications. New York: Springer-Verlag, 1999.
- HERCULANO, R. D.; NORBERTO, A. M. Q. Scientific research output evaluation of professors of Sao Paulo State University. **Perspectivas em Ciência da Informação**, v.17, n.2, p.57-70, 2012.
- HICKS, C. A Genetic Algorithm tool for optimising cellular or functional layouts in the capital goods industry. **International Journal of Production Economics**, v.104, n.2, p.598-614, 2006.
- HILLIER, F. S.; LIEBERMAN, G. J.; **Introduction to Operations Research**. 9th. ed. New York: McGraw-Hill, 2010.
- HOLLAND, J.H. Adaptation in Natural and Artificial Systems. Cambridge: MIT Press, 1992.
- HONG, L. J.; NELSON, B. L. Discrete optimization via simulation using COMPASS. **Operations Research**, v.54, n.1, p.115-129, 2006.

- HOOKE, R.; JEEVES, T.A. Direct search solution of numerical and statistical problems. **Journal of the Association for Computing Machinery,** v.8, n.2, p.212-229, 1961.
- IÇ, Y.T. A TOPSIS based design of experiment approach to assess company ranking. **Applied Mathematics and Computation**, v.227, p.630-647, 2014.
- IÇ, Y.T. Supplier selection: A hybrid approach using ELECTRE and fuzzy clustering. **Robotics and Computer-Integrated Manufacturing**, v.28, n.2, p.245-256, 2012.
- INGALLS, R. G. Introduction to simulation. In: Winter Simulation Conference, **Proceedings...** Washington, D.C., USA, 2013
- ISMAIL, K., THORWARTH, M., ARISHA, A. Integrated decision support systems for improving emergency department performance in Irish hospitals. **International Journal of Operational Research,** v.19, n.1, p.40-59, 2014.
- JACOBSON, S. H.; MCLAY, L. A. Applying statistical tests to empirically compare tabu search parameters for MAX3-SATISFIABILITY: a case study. **Omega,** v.37 p.522-534, 2009.
- JAHANGIRIAN, M.; ELDABI, T.; NASEER, A.; STERGIOULAS, L. K.; YOUNG, T. Simulation in manufacturing and business: A review. **European Journal of Operational Research**, v.203, n.1, p.1-13, 2010.
- JENKINS, C. M.; RICE, S. V. Resource modeling in discrete-event simulation environments: a fifty-year perspective. In: Winter Simulation Conference, **Proceedings...** Austin, TX, USA, 2009.
- JIA, H.Z.; FUH, J.Y.H.; NEE, A.Y.C.; ZHANG, Y.F. Integration of genetic algorithm and Gantt chart for job shop scheduling in distributed manufacturing systems. **Computers & Industrial Engineering**, v.53, p.313-320, 2007.
- JONES, D. F.; MIRRAZAVI, S. K.; TAMIZ, M. Multi-objective meta-heuristics: an overview of the current state-of-the-art. **European Journal of Operational Research**, v.137, p.1-9, 2002.
- KELTON, W. D.; SADOWSKI, R. P. E.; STURROCK, D. T. **Simulation with Arena**. 4th. ed. New York: McGraw-Hill, 2007.
- KESKIN, B. B.; MELOUK, S. H.; MEYER, I. L. A simulation-optimization approach for integrated sourcing and inventory decisions. **Computers & Operations Research**, v.37, p.1648-1661, 2010.
- KIDDER, L. H. **Métodos de pesquisa nas relações sociais**. 4ª. ed. São Paulo: Editora Pedagógica e Universitária, 2004.
- KLEIJNEN, J. P. C.; VAN BEERS, W.; VAN NIEUWENHUYSE, I. Constrained optimization in simulation: A novel approach. **European Journal of Operational Research**, v.202, n.1, p.164-174, 2010.
- KUO, Y.; YANG, T.; HUANG, G. W. The use of a grey-based Taguchi method for optimizing multi-response simulation problems. **Engineering Optimization**, v.40, n.6, p.517-528, 2008.
- LAW, A. M. How to build valid and credible simulation models. In: Winter Simulation Conference, **Proceedings...** Austin, TX, USA, 2009.
- LAW, A. M. Simulation modeling and analysis. 4th.ed. New York: McGraw-Hill, 2007.

- LAW, A. M.; KELTON, W. D. **Simulation modeling and analysis**. 3rd.ed. New York: McGraw-Hill, 2000.
- LAW, A. M.; MCCOMAS, M. G. Simulation-Based Optimization, In: Winter Simulation Conference, **Proceedings...** San Diego, CA, USA, 2002.
- LEAL, F.; ALMEIDA, D. A.; MONTEVECHI, J. A. B. Uma Proposta de Técnica de Modelagem Conceitual para a Simulação através de elementos do IDEF. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** João Pessoa, PB, 2008.
- LEE, L.H.; CHEW, E. P.; TENG, S.; CHEN, Y. Multi-objective simulation-based evolutionary algorithm for an aircraft spare parts allocation problem. **European Journal of Operational Research**, v.189, p.476-491, 2008.
- LETA, F. R.; MELLO, J. C. C. B. S.; GOMES, E. G.; MEZA, L. A. Métodos de melhora de ordenação em DEA aplicados à avaliação estática de tornos mecânicos. **Investigação Operacional**, v.25, n.2, p.229-242, 2005.
- LI, X.; REEVES, B.G.R. Multiple criteria approach to data envelopment analysis. **European Journal of Operational Research**, v.115, n.3, p.507-517, 1999.
- LIN, R. C.; SIR, M. Y.; PASUPATHY, K. S. Multi-objective simulation optimization using data envelopment analysis and genetic algorithm: Specific application to determining optimal resource levels in surgical services. **Omega**, v.41, p.881-892, 2013.
- LINS, M. P. E.; ANGULO-MEZA, L. A. Análise Envoltória de Dados: e perspectivas de integração no ambiente do Apoio à Decisão. Rio de Janeiro: Editora da COPPE/UFRJ, 2000.
- LIU, J. S., LU, L. Y., LU, W. M.,; LIN, B. J. Data envelopment analysis 1978-2010: A citation-based literature survey. **Omega**, v.41, n.1, p.3-15, 2013.
- LOBÃO, E. C.; PORTO, A. J. V. Evolução das técnicas de simulação. **Produção**, v.9, n.1, p.13-21, 1999.
- LOTFI, F.H., JAHANSHAHLOO, G. R., KHODABAKHSHI, M., ROSTAMY-MALKHLIFEH, M., MOGHADDAS, Z.; VAEZ-GHASEMI, M. A review of ranking models in data envelopment analysis. **Journal of Applied Mathematics**, v.2013, p.1-20, 2013.
- MAGHSOODLOO, S.; OZDEMIR, G.; JORDAN, V.; HUANG, C. H. Strengths and limitations of Taguchi's contributions to quality, manufacturing, and process engineering. **Journal of Manufacturing Systems**, v.23, n.2, p.73-126, 2004.
- MARIANO, E. B.; ALMEIDA, M. R.; REBELATTO, D.A.N. Princípios Básicos para uma proposta de ensino sobre análise por envoltória de dados. In: Congresso Brasileiro de Ensino de Engenharia, **Anais...** Passo Fundo, 2006.
- MARTÍ, R.; LAGUNA, M.; GLOVER, F. Principles of Scatter Search. **European Journal of Operational Research**, v.169, n.2, p.359-372, 2006.
- MARTIĆ, M.; NOVAKOVIĆ, M.; BAGGIA, A. Data Envelopment Analysis-Basic Models and their Utilization. **Organizacija**, v.42, n.2, p.37-43, 2009.
- MARTINS, R. A. **Sistemas de medição de desempenho: um modelo para estruturação do uso**. 1998. Tese (Doutorado). Escola Politécnica da Universidade de São Paulo, São Paulo, 1998.

- MARTINS, M. S. R.; FUCHS, S. C.; PANDO, L. U.; LÜDERS, R.; DELGADO, M. R. PSO with path relinking for resource allocation using simulation optimization. **Computers & Industrial Engineering**, v.65, n.2, p.322-330, 2013.
- MARTINS, R. A. **Abordagens quantitativa e qualitativa**. In: MIGUEL, P. A. C. (Org). Metodologia de pesquisa em engenharia de produção e gestão de operações. Rio de Janeiro: Elsevier, 2012. Cap. 3, p.47-6.
- MELLO, J. C. C. B. S; ANGULO MEZA, L.; GOMES, E. G.; BIONDI NETO, L. Curso de análise de envoltória de dados. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** Gramado, 2005.
- MIGUEL, P. A. C.; FLEURY, A.; MELLO, C. H. P.; NAKANO, D. N.; TURRIONI, J. B.; LEE HO, L.; MORABITO, R.; MARTINS, R. A.; PUREZA, V. **Metodologia de pesquisa em engenharia de produção e gestão de operações.** Rio de Janeiro: Elsevier, 2010.
- MIRANDA, R. C. Algoritmo genético adaptativo para otimização de modelos de simulação a eventos discretos. 2012. 147p. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, 2012.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F.; MARINS, F. A. S. A new approach to reducing search space and increasing efficiency in simulation optimization problems via the Fuzzy-DEA-BCC. **Mathematical Problems in Engineering**, v. 2014, p.1-15, 2014.
- MONTEVECHI, J.A.B.; ALMEIDA FILHO, R. G.; PAIVA, A.P.; COSTA, R.F.S.; MEDEIROS, A.L. Sensitivity analysis in discrete-event simulation using fractional factorial designs. **Journal of Simulation**, v.4, p.128-142, 2010.
- MONTGOMERY, D. C. **Design and Analysis of Experiments**. 6th. ed., New York: Wiley, 2005.
- MUÑOZ-SECA, B.; RIVEROLA, J. **Problem Driven Management: Achieving Improvement in Operations Through Knowledge Management**. London: Palgrave Macmillan, 2004.
- MYERS, R. H.; MONTGOMERY, D. C.; ANDERSON-COOK, C. M. Response surface methodology: process and product optimization using designed experiments. New Jersey: John Wiley & Sons, 2009.
- NELDER, J. A.; MEAD, R. A simplex method for function minimization. **Computer Journal**, v.7, n.4, p. 308-313, 1965.
- NELSON, B. L. **Optimization via simulation over discrete decision variables**, In: HASENBEIN, J. J. (Ed.), Tutorials in operations research: risk and optimization in an uncertain world. Hanover: INFORMS, p.193-207, 2010.
- ÓLAFSSON, S.; KIM, J. Simulation Optimization. In: Winter Simulation Conference, **Proceedings...** San Diego, CA, USA, 2002.
- OLIVEIRA, M. L. M.; MIRANDA, R. C.; MONTEVECHI, J. A. B.; LEAL, F. Desenvolvimento de um projeto de simulação a eventos discretos em uma célula de controle de qualidade de uma empresa de alta tecnologia. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** Bento Gonçalves, RS, 2010.
- PHADKE, M. S. Quality Engineering Using Robust Design. New Jersey: Prentice-Hall, 1989.

- PIDD, M. Computer simulation in management science. 5.ed. Chichester: John Wiley & Sons, 2004.
- PINDYCK, R. S.; RUBINFELD, D. L. Microeconomia. São Paulo: Prentice Hall, 2002.
- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; COSTA, R. F. S.; MIRANDA, R. C.; FRIEND, J. D. (2012). Evaluation of a proposed optimization method for discrete-event simulation models. **Pesquisa Operacional**, v.32, n.3, p.543-560, 2012.
- RAINS, E.M.; SLOANE, N.J.A.; STUFKEN, J. The lattice of N-run orthogonal arrays. **Journal of Statistical Planning and Inference**, v.102, n.2, p.477-500, 2002.
- RAO, S. S. Engineering optimization: theory and practice. John Wiley & Sons, 2009.
- RHODES, E. Data envelopment analysis and related approaches for measuring the efficiency of decision making units with an application to program following through in US education. Thesis. Carnegy Melon University, 1978.
- RIPLEY, B. **Pattern Recognition and Neural Networks**. Cambridge: University Press, 1996.
- ROBINSON, S.; WORTHINGTON, C.; BURGESS, N.; RADNOR, Z. J. Facilitated modelling with discrete-event simulation: Reality or myth? **European Journal of Operational Research**, v.234, n.1, p.231-240, 2014.
- ROSEN, S. L.; HARMONOSKY, C. H.; TRABAND, M. T. Optimization of Systems with Multiple Performance Measures via Simulation: Survey and Recommendations. **Computers and Industrial Engineering**, v.54, p.327-339, 2007.
- ROSS, P. J. Taguchi techniques for quality engineering. New York: McGraw-Hill, 1996.
- ROY, R. K. A primer on the Taguchi method. Dearborn: Society of Manufacturing Engineers, 2010.
- RYAN, J.; HEAVEY, C. Process modeling for simulation. **Computers in Industry**, v.57, n.5, p.437-450, 2006.
- SAIF, A. W. A.; SELIAMAN, M. E.; AHMAD, A. R. Simulation Optimization of a Four-Stage Supply Chain System. **Information and Communication Technologies**, v.2, p.2798-2802, 2006.
- SANDANAYAKE, Y. G.; ODUOZA, C. F.; PROVERBS, D. G. A systematic modelling and simulation approach for JIT performance optimisation. **Robotics and Computer-Integrated Manufacturing**, v.24, n.6, p.735-743, 2008.
- SANTOS, M. A. R. Avaliação do desempenho da saúde pública com aplicação de métodos de auxílio à tomada de decisão e de gestão estratégica. 2010. Dissertação (Mestrado em Engenharia de Produção). Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2010.
- SANTOS, M. A. R.; MARINS, F. A. S.; SALOMON, V. A. P. A Utilização da Função Arbitragem de Nash nos Modelos DEA CCR: Uma abordagem na orientação combinada input/output sob a ótica da Teoria dos Jogos de Barganha. In: Simpósio Brasileiro de Pesquisa Operacional, **Anais...** Ubatuba, 2011.
- SARGENT, R. G. Verification and validation of simulation models. **Journal of Simulation**, v.7, n.1, p.12-24, 2013.
- SAURIN, V.; LOPES, A. L. M.; JÚNIOR, N. C. A. C.; GONÇALVES, C. A. Medidas de eficiência e retorno de investimento: um estudo nas distribuidoras de energia elétrica

- brasileiras com base em Data Envelopment Analysis, Índice de Malmquist e ROI. **Revista de Administração da UFSM**, v.6, n.1, p.25-38, 2013.
- SEXTON, T.R. **The methodology of Data Envelopment Analysis**. In: SILKMAN, R.H. (Ed.), Measuring Efficiency: An Assessment of Data Envelopment Analysis, New Directions for Program Evaluation. San Francisco: Jossey Bass, 1986.
- SHARDA, B.; BURY, S.B. Best practices for effective application of discrete event simulation in the process industries. In: Winter Simulation Conference, **Proceedings...** Phoenix, AZ, USA, 2011.
- SHEN, H. WAN, H. Controlled sequential factorial design for simulation factor screening. **European Journal of Operational Research**, v.198, p.511-519, 2009.
- SIEBERS, P.O.; MACAL, C.M.; GARNETT, J.; BUXTON, D.; PIDD, M. (2010). Discrete-event simulation is dead, long life agent-based simulation! **Journal of Simulation**, v.4, p. 204-210, 2010.
- SIEGMUND, F.; BERNEDIXEN, J.; PEHRSSON, L.; NG, A.H.C.; DEB, K. Reference point-based evolutionary multi-objective optimization for industrial systems simulation. In: Winter Simulation Conference, **Proceedings...** Berlin, GER, 2012.
- SILVEIRA, J. Q. Alocação eficiente de recursos: um modelo DEA paramétrico com retornos variáveis de escala. 2011. 69p. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal Fluminense (UFF), Rio de Janeiro, 2011.
- SIMRUNNER USER GUIDE. ProModel Corporation: Orem, UT. USA. 2002.
- SIPAHI, S.; TIMOR, M. The analytic hierarchy process and analytic network process: an overview of applications. **Management Decision**, v.48, n.5, p.775-808, 2010.
- SLOANE, N.J.A.; STUFKEN, J. A linear programming bound for orthogonal arrays with mixed levels. **Journal of Statistical Planning and Inference**, v.56, p.295-305, 1996.
- STEPONAVIČĖ, I.; RUUSKA, S.; MIETTINEN, K. A solution process for simulation-based multiobjective design optimization with an application in the paper industry. **Computer-Aided Design**, v.47, p.45-58, 2014.
- SWISHER, J. R.; JACOBSON, Sheldon H. A survey of ranking, selection, and multiple comparison procedures for discrete-event simulation. In: Winter Simulation Conference, **Proceedings...** Phoenix, AZ, USA,1999.
- SWISHER, J. R.; HYDEN P. D.; JACOBSON, S. H.; SCHRUBEN, L.W. A survey of recent advances in discrete input parameter discrete-event simulation optimization. **IIE Transactions**, v.36, n.6, p.591-600, 2004.
- SWISHER, J. R.; HYDEN P. D.; JACOBSON, S. H.; SCHRUBEN, L.W. A Survey of Simulation Optimization Techniques and Procedures. In: Winter Simulation Conference, **Proceedings...** Orlando, FL, USA, 2000.
- TAGUCHI, G. System of experimental design: engineering methods to optimize quality and minimize costs. New York: UNIPUB/Kraus International Publications, 1987.
- TAGUCHI, G.; CHOWDHURY, S.; WU, Y. **Taguchi's quality engineering handbook**. New Jersey: John Wiley & Sons, Inc., 2005.
- TAGUCHI, G.; WU, Y. Introduction to Offline Quality Control. Nagoya: Central Japan Quality Control Assoc., 1979.

- WANG, S.; SCHONFELD, P. Genetic Algorithm for Selecting and Scheduling Waterway Projects. In: Nets Symposium, **Proceedings...** Salt Lake City, USA, 2006.
- WENG, S. J., TSAI, B. S., WANG, L. M., CHANG, C. Y., GOTCHER, D. Using simulation and data envelopment analysis in optimal healthcare efficiency allocations. In: Winter Simulation Conference, **Proceedings...** Phoenix, AZ, USA, 2011.
- WILLIS, K.O.; JONES, D.F. Multi-objective simulation optimization through search heuristics and relational database analysis. **Decision Support Systems**, v.46, p.277-286, 2008.
- WU, F.; DANTAN, J.Y.; ETIENNE, A.; SIADAT, A.; MARTIN, P. Improved algorithm for tolerance allocation based on Monte Carlo simulation and discrete optimization. **Computers & Industrial Engineering**, v.56, p.1402-1413, 2009.
- YANG, T. An evolutionary simulation-optimization approach in solving parallel-machine scheduling problems a case study. **Computers & Industrial Engineering,** v.56, p.1126-1136, 2009.
- YANG, T.; KUO, Y.; CHO, C. A genetic algorithms simulation approach for the multiattribute combinatorial dispatching decision problem. **European Journal of Operational Research**, v.176, n. 3, p.1859-1873, 2007.

ANEXO A - ProModel® e SimRunner®

Lobão e Porto (1999) descrevem em seu trabalho a evolução dos pacotes de simulação. Para os autores o desenvolvimento destes simuladores popularizou o uso da simulação, uma vez que, com essa tecnologia não seriam mais necessários especialistas em linguagens de simulação.

Nesse sentido, para d'Audenhove e Fugihara (2009), dentro deste novo contexto de simuladores mais avançados, encontra-se o *software ProModel*®, desenvolvido pela empresa *ProModel Corporation*. Para estes autores, o simulador *ProModel*® encontra-se difundido em várias empresas e universidade no Brasil.

Para Sandanayake, Oduoza e Proverbs (2008), o *ProModel*® é uma ferramenta de simulação que permite modelar vários sistemas, tais como: transportadores, linhas de transferência, sistemas de produção em massa, linhas de montagem, sistemas flexíveis de fabricação, sistemas *Lean*, lojas de departamentos, dentre outros.

Para Saif, Seliaman e Ahmad (2006), este simulador possui uma interface gráfica orientada à modelagem de objetos, combinando uma linguagem geral de simulação, típica de simuladores comerciais.

Ainda, segundo Sandanayake, Oduoza e Proverbs (2008), o *ProModel*® fornece um sistema de modelagem visual, que permite a avaliação das condições operacionais, permitindo a geração de cenários para apoiar e auxiliar a tomada de decisão. Adicionalmente, fornece recursos para a realização de experimentos, replicações, aquisição de dados e cálculos de intervalos de confiança.

A aleatoriedade e a variabilidade de sistemas reais podem ser recriadas no *ProModel*®, por meio da utilização de distribuição de probabilidades, ou diretamente através da importação de dados dos usuários. O simulador permite ainda, importar e exportar dados diretamente para o *Excel*, assim como permite otimizar sistemas modelados com a utilização do otimizador *SimRunner*® (CIMINO, LONGO e MIRABELLI, 2010).

Para Al-Turki *et al.* (2011), enquanto o *ProModel*® é utilizado para construir um modelo de SED, o *SimRunner*® é utilizado para a otimização deste modelo. Segundo Carson e Maria (1997) e Saif, Seliaman e Ahmad (2006), o *SimRunner*® é um pacote de otimização multivariável que testa diferentes combinações de fatores de entrada em busca de condições ótimas de funcionamento para os sistemas simulados.

Segundo Banks *et al.* (2009), o módulo de otimização do *SimRunner*® é baseado em uma metaheurística, baseada em Algoritmo Genético, associada com Estratégias Evolutivas, que é uma variante dos Algoritmos Evolucionários, amplamente utilizada em outros otimizadores comerciais (PINHO *et al.*, 2012). Com sua utilização, a simulação passa a ser uma sofisticada ferramenta para análise a questões *what-if*, além de prover a realização da otimização automaticamente (ARAB, ISMAIL e LEE, 2013). Banks *et al.* (2009) destacam em seu trabalho, a robustez deste otimizador.

Para Arab, Ismail e Lee (2013), a conexão estabelecida com o simulador *ProModel*® via ferramenta *ActiveX* faz com que o *SimRunner*® permita automatizar o processo de otimização, sem a necessidade da interferência humana, economizando tempo. E, embora, o *SimRunner*® não garanta que a solução encontrada seja uma solução ótima, assim como outros *softwares* de otimização baseados em AG, o *software* irá encontrar soluções melhores que aquelas encontradas por meio da tentativa e erro.

Cada projeto de otimização requer a validação do modelo de simulação, um padrão de desempenho (função objetivo) e um grupo de fatores que podem ser alterados, visando à melhoria de desempenho do sistema (SIMRUNNER USER GUIDE, 2002).

Para Miranda (2012), apesar de não ser conhecida a estrutura do algoritmo de otimização do *SimRunner*®, o usuário deve fornecer, por meio da interface gráfica do *software*, alguns parâmetros. O primeiro parâmetro a ser definido é o perfil de otimização. Os perfis estão diretamente relacionados à confiabilidade da solução alcançada pelo otimizador e ao tempo necessário para se encontrar esta solução.

O perfil de otimização é um reflexo do número de soluções possíveis que o *software* irá examinar. O Perfil Cauteloso (*Cautious*) considera um número maior de possíveis soluções para o problema, sendo desta forma, mais completa a busca por melhores soluções. Contudo, o tempo necessário para seu processamento será elevado quando comparado aos outros perfis. O Perfil Agressivo (*Aggressive*) trabalha com uma população pequena de possíveis soluções para o problema, a qual permite convergir para uma solução mais rapidamente, porém a confiabilidade de sua solução será menor se comparada aos demais perfis. Por fim, o Perfil Moderado (*Moderate*) apresenta um equilíbrio entre os perfis Cauteloso e Agressivo (SIMRUNNER USER GUIDE, 2002).

Analisando o *software*, Miranda (2012) chama a atenção para um segundo parâmetro a ser definido pelo usuário: a taxa de convergência. Essa taxa funciona como um critério de parada para o otimizador, controlando quão perto os melhores resultados se encontram do valor médio (SIMRUNNER USER GUIDE, 2002).

Uma vez alcançado o valor da taxa de convergência adotado, o algoritmo para e fornece o melhor resultado encontrado. Um percentual elevado irá parar a busca precocemente, enquanto um valor muito pequeno exigirá um maior gasto de tempo computacional até a convergência (SIMRUNNER USER GUIDE, 2002).

A interface gráfica do *software* com o usuário do *SimRunner*® pode ser visualizada na Figura A.1.

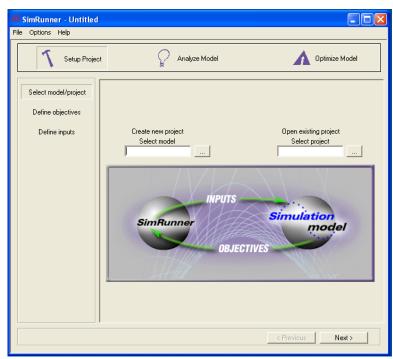


Figura A.1 - Interface gráfica do software SimRunner®

ANEXO B - Símbolos IDEF-SIM

Tabela B.1 - Simbologia utilizada na técnica IDEF-SIM

Elementos	Simbologia	Técnica de origem
Entidade		IDEF3 (modo descrição
		das transições)
Funções		IDEF0
Fluxo da entidade		IDEF0 e IDEF3
Recursos		IDEF0
Controles		IDEF0
Regras para fluxos paralelos e/ou alternativos	& Regra E	IDEF3
	x Regra OU	
	o Regra E/OU	
Movimentação		Fluxograma
Informação explicativa	>	IDEF0 e IDEF3
Fluxo de entrada no sistema modelado	//-	
Ponto final do sistema	•	
Conexão com outra figura		

Fonte: Leal, Almeida e Montevechi (2008)

ANEXO C - Modelos conceituais em IDEF-SIM

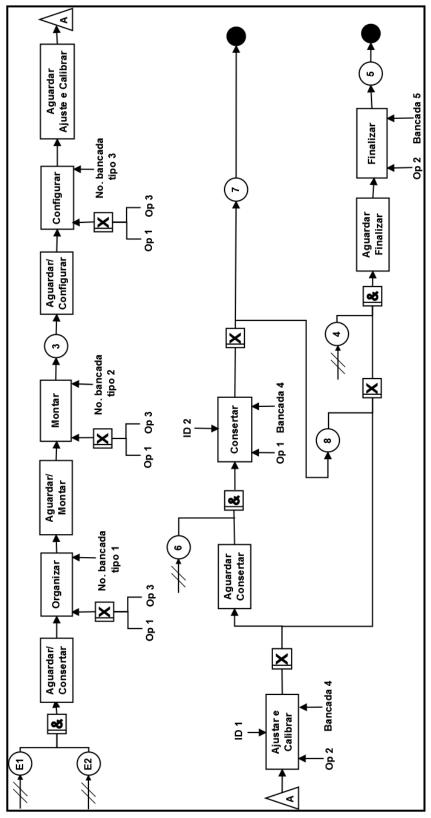


Figura C.1 - Modelo conceitual para o primeiro objeto de estudo Fonte: Adaptado de Costa (2010)

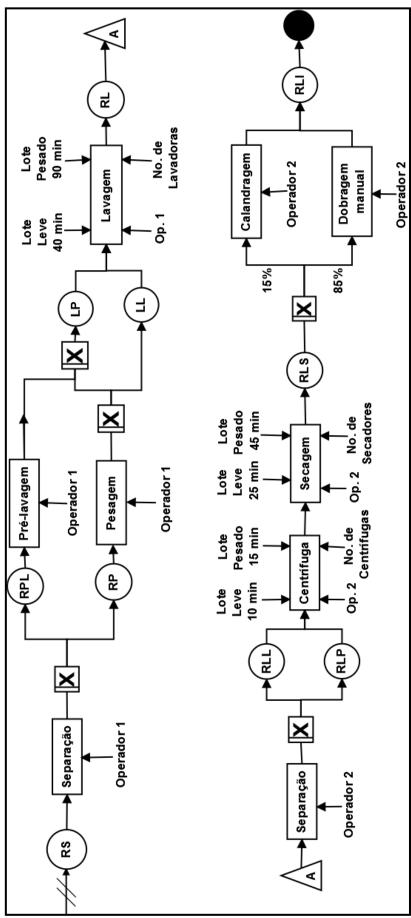


Figura C.2 - Modelo conceitual para o segundo objeto de estudo

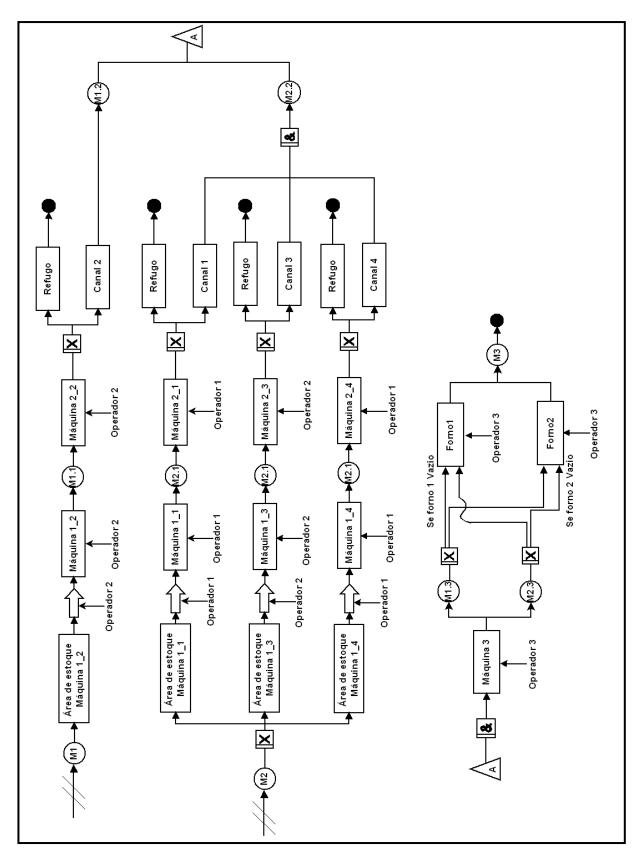


Figura C.3 - Modelo conceitual para o terceiro objeto de estudo

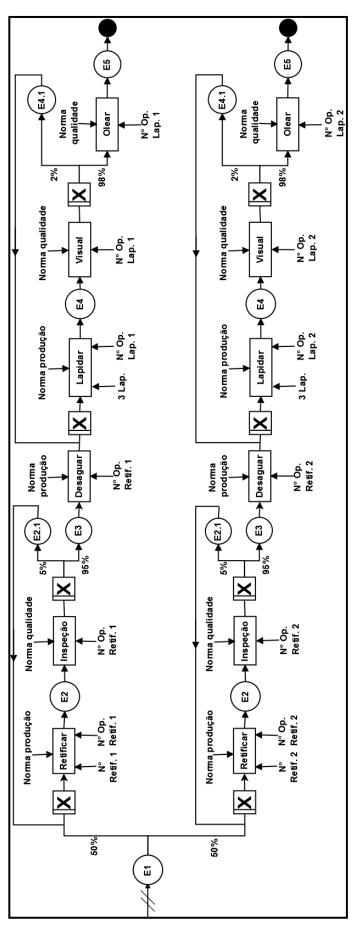


Figura C.4 - Modelo conceitual para o quarto objeto de estudo

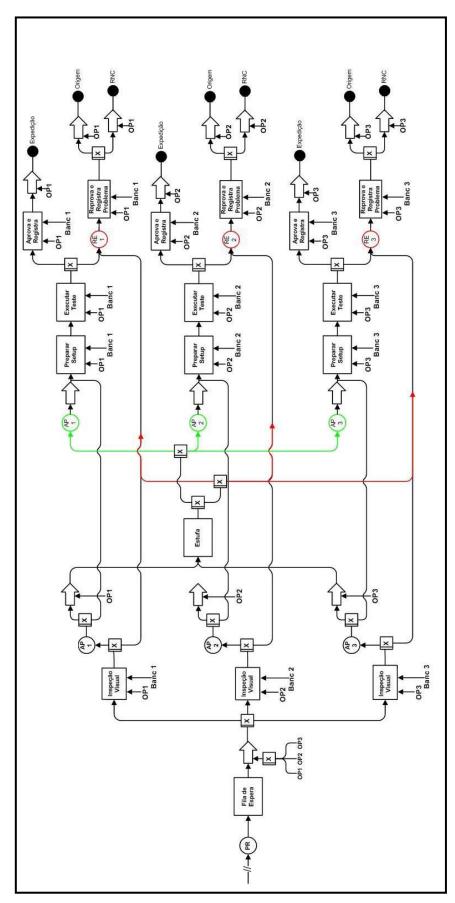


Figura C.5 - Modelo conceitual para o quinto objeto de estudo Fonte: Oliveira *et al.* (2010)

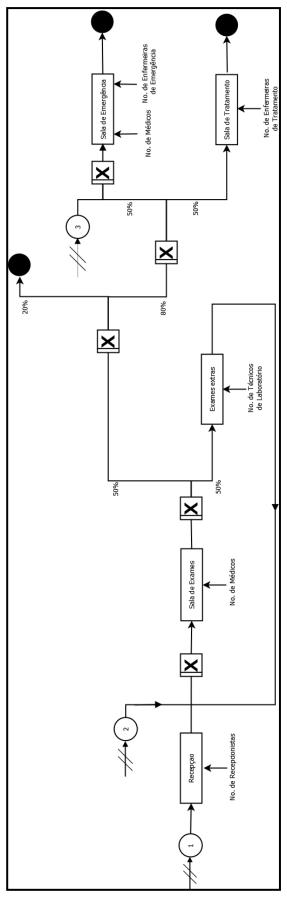


Figura C.6 - Modelo conceitual para o sexto objeto de estudo

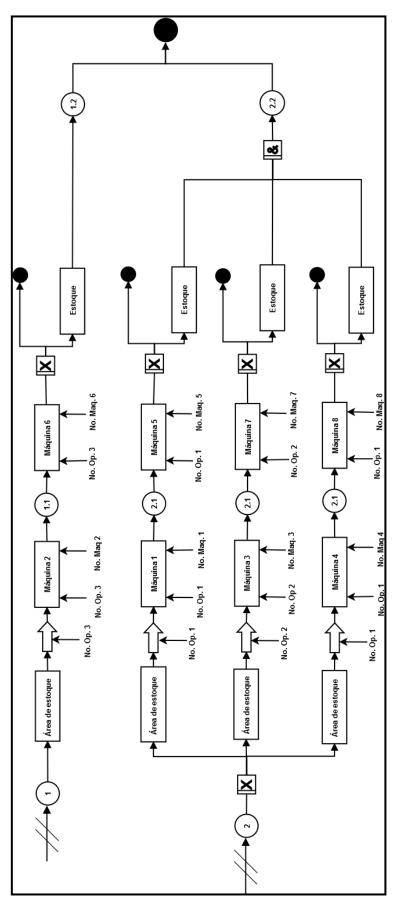


Figura C.7 - Modelo conceitual para o sétimo objeto de estudo

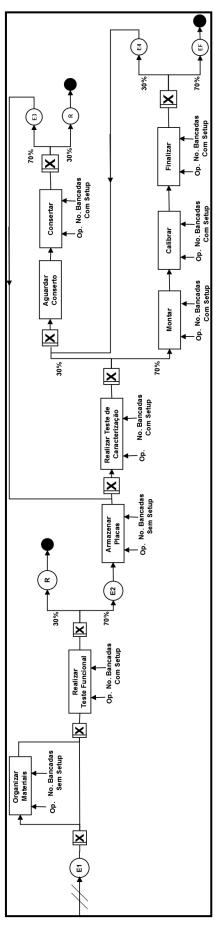


Figura C.8 - Modelo conceitual para o oitavo objeto de estudo

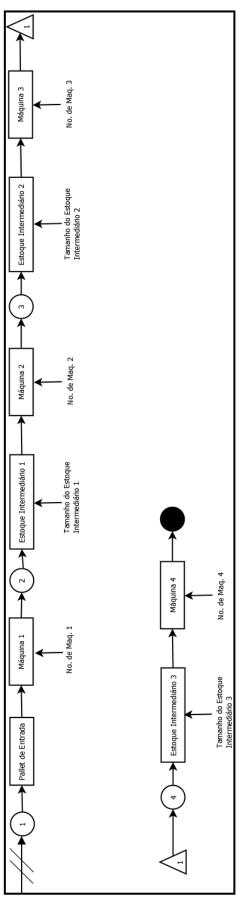


Figura C.9 - Modelo conceitual para o nono e décimo objeto de estudo

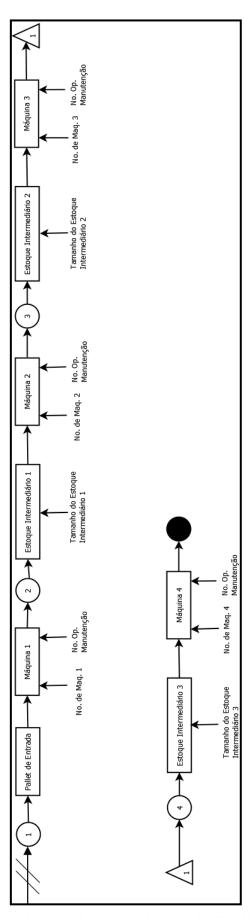


Figura C.10 - Modelo conceitual para o décimo primeiro objeto de estudo

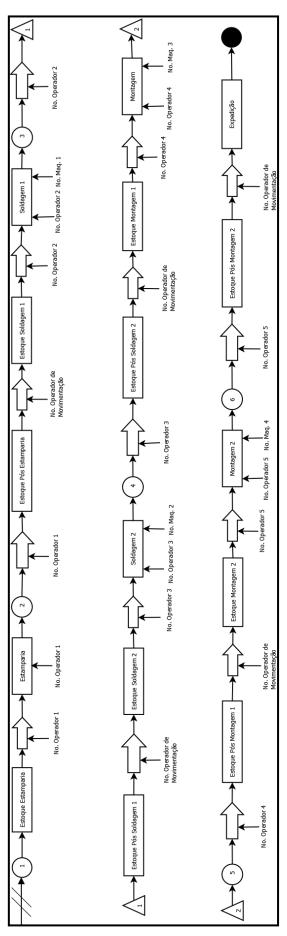


Figura C.11 - Modelo conceitual para os objetos de estudo 12, 13, 14 e 15

ANEXO D - Modelos computacionais

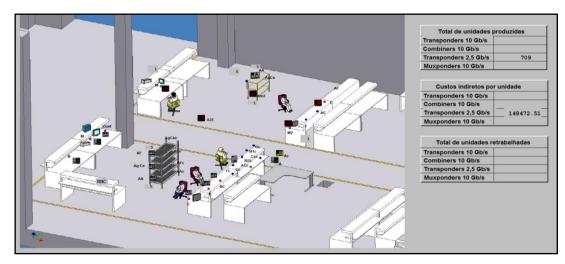


Figura D.1 - Tela do modelo computacional para o primeiro objeto de estudo

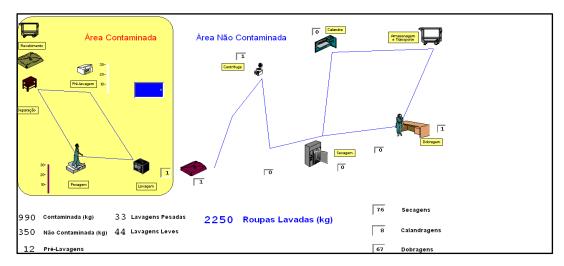


Figura D.2 - Tela do modelo computacional para o segundo objeto de estudo

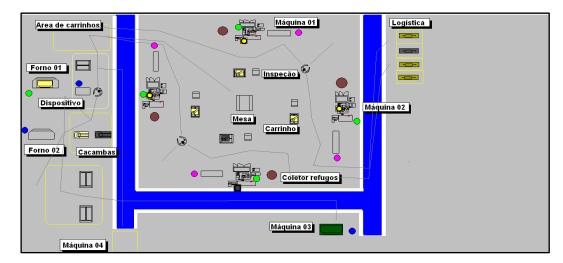


Figura D.3 - Tela do modelo computacional para o terceiro objeto de estudo

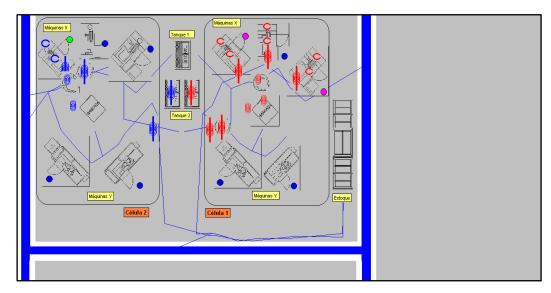


Figura D.4 - Tela do modelo computacional para o quarto objeto de estudo

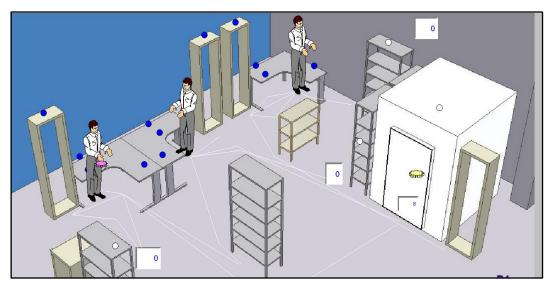


Figura D.5 - Tela do modelo computacional para o quinto objeto de estudo

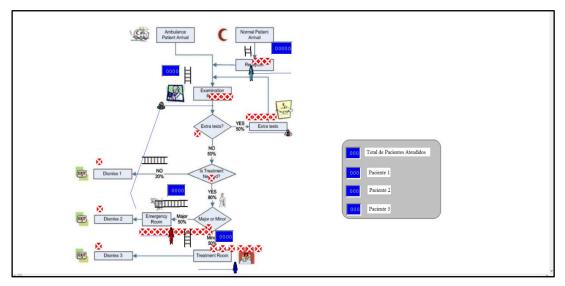


Figura D.6 - Tela do modelo computacional para o sexto objeto de estudo

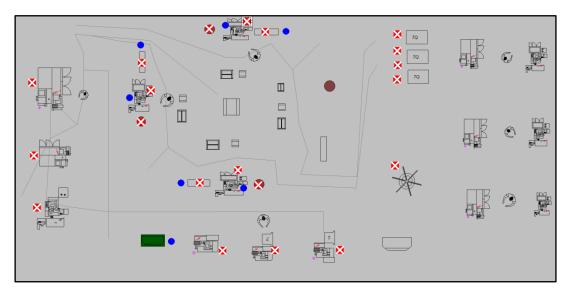


Figura D.7 - Tela do modelo computacional para o sétimo objeto de estudo

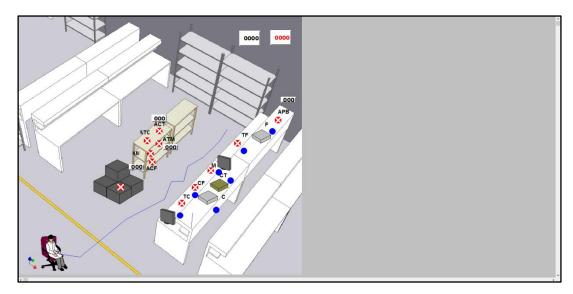


Figura D.8 - Tela do Modelo computacional para o oitavo objeto de estudo

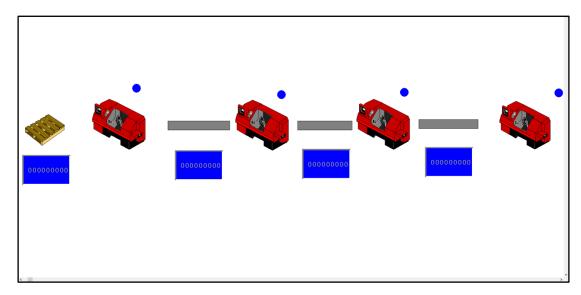


Figura D.9 - Tela do Modelo computacional para o nono e décimo objetos de estudo

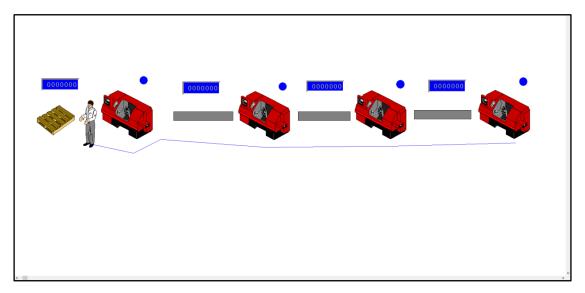


Figura D.10 - Tela do modelo computacional para o décimo primeiro objeto de estudo

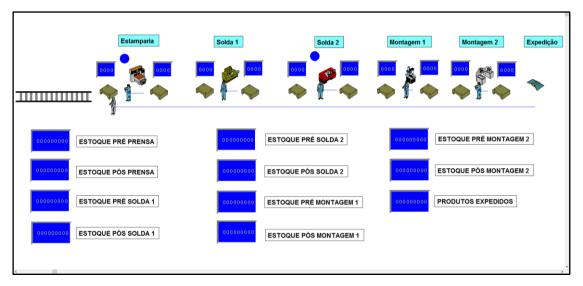


Figura D.11 - Tela do modelo computacional para o objetos de estudo 12, 13, 14 e 15

ANEXO E - Formulação matemática dos modelos dos objetos de estudo

E1. Formulação matemática do primeiro objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ bancadas do tipo 1, bancadas do tipo 2, operadores do tipo 1, operadores do tipo 2, operadores do tipo 3 $\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [5 \ 5 \ 5 \ 5]$.

Variáveis:

 x_i : O quanto utilizar do recurso i.

E: Valor esperado da função objetivo contemplando o total produzido.

f: Valor do vetor função objetivo

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\bigg\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\bigg\} \tag{E.1}$$

Sujeito a:

$$L_i \le x_i \le U_i, \qquad \forall i \in I \tag{E.2}$$

$$x_i \in I, \ \forall i \in I$$
 (E.3)

E.2 Formulação matemática do segundo objeto de estudo

Índices:

i: recursos, $i \in I$, I= {número de lavadoras, número de centrífugas, número de secadoras, número de operadores da área contaminada, número de operadores da área não contaminada}.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [5 5 5 5]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o total de roupas lavadas;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.4}$$

Sujeito a:

$$L_i \le x_i \le U_i, \qquad \forall i \in I \tag{E.5}$$

$$x_i \in I, \ \forall i \in I$$
 (E.6)

E.3 Formulação matemática do terceiro objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de máquinas do tipo 1_4, número de máquinas do tipo 3, número de fornos do tipo 1 $\}$.

m: funções objetivos, $m \in \{1,2\}$.

Parâmetros:

L_i: intervalo mínimo de variação do recurso i, [1 1 1 1 1 1];

 U_i : intervalo máximo de variação do recurso i, $U_i = [4 \ 4 \ 4 \ 4 \ 2]$.

Variáveis:

 x_i : O quanto utilizar do recurso i.

E: Valor esperado das funções objetivos contemplando o total produzido e o total refugado.

f: Valor do vetor das funções objetivos.

 $\tilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.7}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.8)

$$x_i \in I, \ \forall i \in I$$
 (E.9)

$$m \in \{1, 2\} \tag{E.10}$$

E.4 Formulação matemática do quarto objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores na retífica 1, número de operadores na lapidadora 1, número de operadores na retífica 2, número de operadores na lapidadora 2, número de retíficas do tipo 1, número de retíficas do tipo 2 $\}$;

m: funções objetivos, $m \in \{1, 2\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [5 5 5 5 5]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado das funções objetivos contemplando o total produzido e o custo de produção;

f: Valor do vetor das funções objetivos;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.11}$$

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.12)

$$x_i \in I, \ \forall i \in I$$
 (E.13)

$$m \in \{1, 2\} \tag{E.14}$$

E.5 Formulação matemática do quinto objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número operadores do tipo 1, número de operadores do tipo 2, número de equipamentos do tipo 1, número de equipamentos do tipo 2, número de equipamentos do tipo 3 $\}$;

m: funções objetivos, $m \in \{1, 2, 3\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [10 \ 10 \ 10 \ 10]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado das funções objetivos contemplando o total de produtos inspecionados, o lucro e o total de produtos aguardando inspeção;

f: Valor do vetor das funções objetivos;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.15}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.16)

$$x_i \in I, \ \forall i \in I$$
 (E.17)

$$m \in \{1, 2, 3\} \tag{E.18}$$

E.6 Formulação matemática do sexto objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ Número de recepcionistas, Número de médicos, Número de técnicos de laboratório, Número de enfermeiras na sala de tratamento, Numero de enfermeiras na sala de emergência $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [3 \ 4 \ 5 \ 6 \ 12]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando a taxa de atendimento dos pacientes;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.19}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.20)

$$x_i \in I, \ \forall i \in I$$
 (E.21)

E.7 Formulação matemática do sétimo objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4, número de máquinas do tipo 5, número de máquinas do tipo 6, número de máquinas do tipo 7, número de máquinas do tipo 8 $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [5 \ 4 \ 6 \ 3 \ 3 \ 3 \ 4 \ 4 \ 4 \ 4]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o lucro;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\}$$
 (E.22)

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.23)

$$x_i \in I, \ \forall i \in I$$
 (E.24)

E.8 Formulação matemática do oitavo objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores, número de bancadas do tipo 1, número de bancadas do tipo 2, atividade organizar material, tamanho do estoque intermediário 1, tamanho do estoque intermediário 2, tamanho do estoque intermediário 3 $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 0 \ 5 \ 5]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [3 4 4 1 15 15 15]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o lucro;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\}$$
 (E.25)

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.26)

$$x_i \in I, \ \forall i \in I$$
 (E.27)

E.9 Formulação matemática do nono objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4, tamanho do estoque intermediário 1, tamanho do estoque intermediário 2, tamanho do estoque intermediário 3 $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 5 \ 5]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [3 \ 3 \ 3 \ 3 \ 15 \ 15]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o lucro;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.28}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.29)

$$x_i \in I, \ \forall i \in I$$
 (E.30)

E.10 Formulação matemática do décimo objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ tamanho do estoque intermediário 1, tamanho do estoque intermediário 2, tamanho do estoque intermediário 3 $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [5 \ 5]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [15 \ 15 \ 15]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o lucro;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.31}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.32)

$$x_i \in I, \ \forall i \in I$$
 (E.33)

E.11 Formulação matemática do décimo primeiro objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4, tamanho do estoque intermediário 1, tamanho do estoque intermediário 2, tamanho do estoque intermediário 3, número de operadores de manutenção $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 5 \ 5 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [3 \ 3 \ 3 \ 3 \ 15 \ 15 \ 2]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o lucro;

f: Valor do vetor função objetivo;

 $\tilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.34}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.35)

$$x_i \in I, \ \forall i \in I$$
 (E.36)

E.12 Formulação matemática do décimo segundo objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de operadores do tipo 4, número de operadores de movimentação, número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4 $\}$

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [2\ 2\ 2\ 2\ 4\ 4\ 4\ 4]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o total produzido;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\bigg\{f(\widetilde{\phi}(\sum_{i\in I}x_i))\bigg\} \tag{E.37}$$

Sujeito a:

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.38)

$$x_i \in I, \ \forall i \in I$$
 (E.39)

E.13 Formulação matemática do décimo terceiro objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de operadores do tipo 4, número de operadores de movimentação, número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4 $\}$

m: funções objetivos, $m \in \{1,2\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [2\ 2\ 2\ 2\ 4\ 4\ 4\ 4]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o total produzido e o WIP;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.40}$$

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.41)

$$x_i \in I, \ \forall i \in I$$
 (E.42)

$$m \in \{1,2\} \tag{E.43}$$

E.14 Formulação matemática do décimo quarto objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de operadores do tipo 4, número de operadores de movimentação, número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4 $\}$

m: funções objetivos, $m \in \{1,2,3\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [2\ 2\ 2\ 2\ 5\ 4\ 4\ 4\ 4]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o total produzido, o WIP e os custos de produção;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\bigg\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\bigg\} \tag{E.44}$$

$$L_i \le x_i \le U_i, \quad \forall i \in I$$
 (E.45)

$$x_i \in I, \ \forall i \in I$$
 (E.46)

$$m \in \{1,2,3\}$$
 (E.47)

E.15 Formulação matemática do décimo quinto objeto de estudo

Índices:

i: recursos, $i \in I$, $I = \{$ número de operadores do tipo 1, número de operadores do tipo 2, número de operadores do tipo 3, número de operadores do tipo 4, número de operadores de movimentação, número de máquinas do tipo 1, número de máquinas do tipo 2, número de máquinas do tipo 3, número de máquinas do tipo 4 $\}$

m: funções objetivos, $m \in \{1,2,3,4\}$.

Parâmetros:

 L_i : intervalo mínimo de variação do recurso i, $L_i = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$;

 U_i : intervalo máximo de variação do recurso i, $U_i = [2\ 2\ 2\ 2\ 4\ 4\ 4\ 4]$.

Variáveis:

 x_i : O quanto utilizar do recurso i;

E: Valor esperado da função objetivo contemplando o total produzido, o WIP, os custos de produção e a produtividade;

f: Valor do vetor função objetivo;

 $\widetilde{\phi}$: Modelo estocástico representado pelo modelo de simulação.

Modelo:

$$MaxE\left\{f_m(\widetilde{\phi}(\sum_{i\in I}x_i))\right\} \tag{E.48}$$

$$L_i \le x_i \le U_i, \qquad \forall i \in I \tag{E.49}$$

$$x_i \in I, \ \forall i \in I$$
 (E.50)

$$m \in \{1, 2, 3, 4\} \tag{E.51}$$

ANEXO F – Programação do modelo DEA BCC em GAMS

```
set
u saida /Y1/
v entrada /X1*X5/
D M U UNIDADES DE ANÁLISE /1*25/;

option decimals=4, limrow=20,reslim=20;
$CALL GDXXRW.EXE DEABCC.xls par=ENTRADAS rng=A1:Z6

PARAMETER
ENTRADAS (V,DMU);
```

\$GDXIN DEABCC.gdx \$LOAD ENTRADAS \$GDXIN \$CALL GDXXRW.EXE DEABCC.xls par=SAIDAS rng=A9:Z10

PARAMETER

SAIDAS (U, DMU); \$GDXIN DEABCC.gdx \$LOAD SAIDAS \$GDXIN

variable

```
z 1 FUNCAO OBJETIVO PARA DMU1
z 2 FUNCAO OBJETIVO PARA DMU2
z 3 FUNCAO OBJETIVO PARA DMU3
z 4 FUNCAO OBJETIVO PARA DMU4
z 5 FUNCAO OBJETIVO PARA DMU5
z 6 FUNCAO OBJETIVO PARA DMU6
z 7 FUNCAO OBJETIVO PARA DMU7
z 8 FUNCAO OBJETIVO PARA DMU8
z 9 FUNCAO OBJETIVO PARA DMU9
z 10 FUNCAO OBJETIVO PARA DMU10
z 11 FUNCAO OBJETIVO PARA DMU11
z 12 FUNCAO OBJETIVO PARA DMU12
z 13 FUNCAO OBJETIVO PARA DMU13
z 14 FUNCAO OBJETIVO PARA DMU14
z 15 FUNCAO OBJETIVO PARA DMU15
z 16 FUNCAO OBJETIVO PARA DMU16
z 17 FUNCAO OBJETIVO PARA DMU17
z 18 FUNCAO OBJETIVO PARA DMU18
z 19 FUNCAO OBJETIVO PARA DMU19
z 20 FUNCAO OBJETIVO PARA DMU20
z 21 FUNCAO OBJETIVO PARA DMU21
z 22 FUNCAO OBJETIVO PARA DMU22
z 23 FUNCAO OBJETIVO PARA DMU23
z 24 FUNCAO OBJETIVO PARA DMU24
z 25 FUNCAO OBJETIVO PARA DMU25
Y(u) calculo das saídas
X(v) calculo das entradas
co(*) modelo bcc
```

positive variable y, x;

EQUATION

```
funcao 1 calcula a funcao DEA-BCC para DMU1
funcao 2 calcula a funcao DEA-BCC para DMU2
funcao 3 calcula a funcao DEA-BCC para DMU3
funcao 4 calcula a funcao DEA-BCC para DMU4
funcao 5 calcula a funcao DEA-BCC para DMU5
funcao 6 calcula a funcao DEA-BCC para DMU6
funcao 7 calcula a funcao DEA-BCC para DMU7
funcao 8 calcula a funcao DEA-BCC para DMU8
funcao 9 calcula a funcao DEA-BCC para DMU9
funcao 10 calcula a funcao DEA-BCC para DMU10
funcao 11 calcula a funcao DEA-BCC para DMU11
funcao 12 calcula a funcao DEA-BCC para DMU12
funcao 13 calcula a funcao DEA-BCC para DMU13
funcao 14 calcula a funcao DEA-BCC para DMU14
funcao 15 calcula a funcao DEA-BCC para DMU15
funcao 16 calcula a funcao DEA-BCC para DMU16
funcao 17 calcula a funcao DEA-BCC para DMU17
funcao 18 calcula a funcao DEA-BCC para DMU18
funcao 19 calcula a funcao DEA-BCC para DMU19
funcao 20 calcula a funcao DEA-BCC para DMU20
funcao 21 calcula a funcao DEA-BCC para DMU21
funcao 22 calcula a funcao DEA-BCC para DMU22
funcao 23 calcula a funcao DEA-BCC para DMU23
funcao 24 calcula a funcao DEA-BCC para DMU24
funcao 25 calcula a funcao DEA-BCC para DMU25
call(DMU) calculo para saídas-entradas da DMU1
cal2(DMU) calculo para saídas-entradas da DMU2
cal3(DMU) calculo para saídas-entradas da DMU3
cal4(DMU) calculo para saídas-entradas da DMU4
cal5(DMU) calculo para saídas-entradas da DMU5
cal6(DMU) calculo para saídas-entradas da DMU6
cal7(DMU) calculo para saídas-entradas da DMU7
cal8(DMU) calculo para saídas-entradas da DMU8
cal9(DMU) calculo para saídas-entradas da DMU9
cal10(DMU) calculo para saídas-entradas da DMU10
cal11(DMU) calculo para saídas-entradas da DMU11
cal12(DMU) calculo para saídas-entradas da DMU12
cal13(DMU) calculo para saídas-entradas da DMU13
cal14(DMU) calculo para saídas-entradas da DMU14
cal15(DMU) calculo para saídas-entradas da DMU15
cal16(DMU) calculo para saídas-entradas da DMU16
cal17(DMU) calculo para saídas-entradas da DMU17
cal18(DMU) calculo para saídas-entradas da DMU18
cal19(DMU) calculo para saídas-entradas da DMU19
cal20(DMU) calculo para saídas-entradas da DMU20
cal21(DMU) calculo para saídas-entradas da DMU21
cal22(DMU) calculo para saídas-entradas da DMU22
cal23(DMU) calculo para saídas-entradas da DMU23
cal24(DMU) calculo para saídas-entradas da DMU24
cal25(DMU) calculo para saídas-entradas da DMU25
calculo 1 restricao que a soma das entradas para a DMU 1 deve ser igual a 1
calculo 2 restricao que a soma das entradas para a DMU 2 deve ser igual a 1
calculo 3 restricao que a soma das entradas para a DMU 3 deve ser igual a 1
calculo 4 restricao que a soma das entradas para a DMU 4 deve ser igual a 1
calculo 5 restricao que a soma das entradas para a DMU 5 deve ser igual a 1
calculo 6 restricao que a soma das entradas para a DMU 6 deve ser igual a 1
calculo 7 restricao que a soma das entradas para a DMU 7 deve ser igual a 1
calculo 8 restricao que a soma das entradas para a DMU 8 deve ser igual a 1
calculo 9 restricao que a soma das entradas para a DMU 9 deve ser igual a 1
```

```
calculo 10 restricao que a soma das entradas para a DMU 10 deve ser igual a
calculo 11 restricao que a soma das entradas para a DMU 11 deve ser igual a
calculo 12 restricao que a soma das entradas para a DMU 12 deve ser igual a
calculo 13 restricao que a soma das entradas para a DMU 13 deve ser igual a
calculo 14 restricao que a soma das entradas para a DMU 14 deve ser igual a
calculo 15 restricao que a soma das entradas para a DMU 15 deve ser igual a
calculo 16 restricao que a soma das entradas para a DMU 16 deve ser igual a
calculo 17 restricao que a soma das entradas para a DMU 17 deve ser igual a
calculo 18 restricao que a soma das entradas para a DMU 18 deve ser igual a
calculo 19 restricao que a soma das entradas para a DMU 19 deve ser igual a
calculo 20 restricao que a soma das entradas para a DMU 20 deve ser igual a
calculo 21 restricao que a soma das entradas para a DMU 21 deve ser igual a
calculo 22 restricao que a soma das entradas para a DMU 22 deve ser igual a
calculo 23 restricao que a soma das entradas para a DMU 23 deve ser igual a
calculo 24 restricao que a soma das entradas para a DMU 24 deve ser igual a
calculo 25 restricao que a soma das entradas para a DMU 25 deve ser igual a
Funcao1.. Z1 = E = SUM((U), Y(u) *SAIDAS(U, '1')) + co("bcc");
Funcao2.. Z2 = E = SUM((U), Y(u) *SAIDAS(U, '2')) + co("bcc");
Funcao3.. Z3 = E = SUM((U), Y(u) *SAIDAS(U, '3')) + co("bcc");
Funcao4.. Z4 = E = SUM((U), Y(u) *SAIDAS(U, '4')) + co("bcc");
Funcao5.. Z5 = E = SUM((U), Y(u) *SAIDAS(U, '5')) + co("bcc");
Funcao6.. Z6 =E= SUM((U), Y(u)*SAIDAS(U, '6'))+co("bcc");
Funcao7.. Z7 = E = SUM((U), Y(u) *SAIDAS(U, '7')) + co("bcc");
Funcao8.. Z8 = E = SUM((U), Y(u) *SAIDAS(U, '8')) + co("bcc");
Funcao9.. Z9 = E = SUM((U), Y(u) *SAIDAS(U, '9')) + co("bcc");
Funcao10.. Z10 = E = SUM((U), Y(u) *SAIDAS(U, '10')) + co("bcc");
Funcao11.. Z11 = E = SUM((U), Y(u) *SAIDAS(U, '11')) + co("bcc");
Funcao12.. Z12 = E = SUM((U), Y(u) *SAIDAS(U, '12')) + co("bcc");
Funcao13.. Z13 =E= SUM((U), Y(u)*SAIDAS(U, '13'))+co("bcc");
Funcao14.. Z14 =E= SUM((U),Y(u)*SAIDAS(U,'14'))+co("bcc");
Funcao15.. Z15 = E = SUM((U), Y(u) *SAIDAS(U, '15')) + co("bcc");
Funcao16.. Z16 =E= SUM((U),Y(u)*SAIDAS(U,'16'))+co("bcc");
Funcao17.. Z17 = E = SUM((U), Y(u) *SAIDAS(U, '17')) + co("bcc");
Funcao18.. Z18 =E= SUM((U), Y(u)*SAIDAS(U, '18'))+co("bcc");
Funcao19.. Z19 = E = SUM((U), Y(u) *SAIDAS(U, '19')) + co("bcc");
Funcao20.. Z20 = E = SUM((U), Y(u) *SAIDAS(U, '20')) + co("bcc");
Funcao21.. Z21 = E = SUM((U), Y(u) *SAIDAS(U, '21')) + co("bcc");
Funcao22.. Z22 = E = SUM((U), Y(u) *SAIDAS(U, '22')) + co("bcc");
Funcao23.. Z23 = E = SUM((U), Y(u) *SAIDAS(U, '23')) + co("bcc");
Funcao24.. Z24 = E = SUM((U), Y(u) *SAIDAS(U, '24')) + co("bcc");
Funcao25.. Z25 = E = SUM((U), Y(u) *SAIDAS(U, '25')) + co("bcc");
```

```
* BLOCO DE EQUAÇÕES PERTINENTES A SAÍDAS - ENTRADAS= 0
CAL1('1').. SUM((U),Y(u)*SAIDAS(U,'1'))+co("bcc")-
SUM ((V), X(V) *ENTRADAS(V, '1'))=L=0;
CAL2('2').. SUM((U),Y(u)*SAIDAS(U,'2'))-
SUM((V), X(V) *ENTRADAS(V, '2'))+co("bcc")=L=0;
CAL3('3').. SUM((U),Y(u)*SAIDAS(U,'3'))-
SUM((V), X(V) *ENTRADAS(V, '3'))+co("bcc")=L=0;
CAL4('4').. SUM((U),Y(u)*SAIDAS(U,'4'))-
SUM((V),X(V)*ENTRADAS(V,'4'))+co("bcc")=L=0;
CAL5('5').. SUM((U),Y(u)*SAIDAS(U,'5'))+co("bcc")-
SUM((V), X(V) *ENTRADAS(V, '5'))=L=0;
CAL6('6').. SUM((U),Y(u)*SAIDAS(U,'6'))-
SUM((V), X(V) *ENTRADAS(V, '6'))+co("bcc")=L=0;
CAL7('7').. SUM((U),Y(u)*SAIDAS(U,'7'))-
SUM((V), X(V) *ENTRADAS(V, '7'))+co("bcc")=L=0;
CAL8('8').. SUM((U),Y(u)*SAIDAS(U,'8'))+co("bcc")-
SUM((V),X(V) *ENTRADAS(V, '8'))=L=0;
CAL9('9').. SUM((U),Y(u)*SAIDAS(U,'9'))-
SUM((V),X(V)*ENTRADAS(V,'9'))+co("bcc")=L=0;
CAL10('10').. SUM((U),Y(u)*SAIDAS(U,'10'))-
SUM((V), X(V) *ENTRADAS(V, '10'))+co("bcc")=L=0;
CAL11('11').. SUM((U),Y(u)*SAIDAS(U,'11'))-
SUM ((V), X(V) *ENTRADAS(V, '11')) +co("bcc") =L=0;
CAL12('12').. SUM((U),Y(u)*SAIDAS(U,'12'))+co("bcc")-
SUM ((V), X(V) *ENTRADAS(V, '12'))=L=0;
CAL13('13').. SUM((U),Y(u)*SAIDAS(U,'13'))-
SUM((V), X(V) *ENTRADAS(V, '13'))+co("bcc")=L=0;
CAL14('14').. SUM((U),Y(u)*SAIDAS(U,'14'))-
SUM((V),X(V)*ENTRADAS(V,'14'))+co("bcc")=L=0;
CAL15('15').. SUM((U),Y(u)*SAIDAS(U,'15'))-
SUM((V), X(V) *ENTRADAS(V, '15'))+co("bcc")=L=0;
CAL16('16').. SUM((U),Y(u)*SAIDAS(U,'16'))-
SUM((V), X(V) *ENTRADAS(V, '16'))+co("bcc")=L=0;
CAL17('17').. SUM((U),Y(u)*SAIDAS(U,'17'))-
SUM((V), X(V) *ENTRADAS(V, '17'))+co("bcc")=L=0;
CAL18('18').. SUM((U),Y(u)*SAIDAS(U,'18'))-
SUM((V), X(V) *ENTRADAS(V, '18'))+co("bcc")=L=0;
CAL19('19').. SUM((U),Y(u)*SAIDAS(U,'19'))-
SUM ((V), X(V) *ENTRADAS(V, '19')) +co("bcc") =L=0;
CAL20('20').. SUM((U),Y(u)*SAIDAS(U,'20'))-
SUM((V), X(V) *ENTRADAS(V, '20'))+co("bcc")=L=0;
CAL21('21').. SUM((U),Y(u)*SAIDAS(U,'21'))-
SUM((V), X(V) *ENTRADAS(V, '21'))+co("bcc")=L=0;
CAL22('22').. SUM((U),Y(u)*SAIDAS(U,'22'))-
SUM((V), X(V) *ENTRADAS(V, '22'))+co("bcc")=L=0;
CAL23('23').. SUM((U),Y(u)*SAIDAS(U,'23'))-
SUM((V), X(V) *ENTRADAS(V, '23'))+co("bcc")=L=0;
CAL24('24').. SUM((U),Y(u)*SAIDAS(U,'24'))-
SUM((V), X(V) *ENTRADAS(V, '24'))+co("bcc")=L=0;
CAL25('25').. SUM((U),Y(u)*SAIDAS(U,'25'))-
SUM((V), X(V) *ENTRADAS(V, '25'))+co("bcc")=L=0;
```

```
* BLOCO DE EQUAÇÕES PERTINENTES A SAÍDAS - ENTRADAS= 0
* BLOCO DE EQUAÇÕES PERTINENTES AS ENTRADAS DE CADA DMU =1
___
calculo1.. sum((v), X(v)*DMU("1")*entradas(v, "1"))=e=1;
calculo2.. sum((v), X(v)*DMU("2")*entradas(v, "2"))=e=1;
calculo3.. sum((v), X(v)*DMU("3")*entradas(v, "3"))=e=1;
calculo4.. sum((v), X(v)*DMU("4")*entradas(v, "4"))=e=1;
calculo5.. sum((v),X(v)*DMU("5")*entradas(v,"5"))=e=1;
calculo6.. sum ((v), X(v) * DMU("6") * entradas(v, "6")) = e= 1;
calculo7.. sum((v), X(v)*DMU("7")*entradas(v, "7"))=e= 1;
calculo8.. sum((v),X(v)*DMU("8")*entradas(v,"8"))=e= 1;
calculo9.. sum((v), X(v)*DMU("9")*entradas(v, "9"))=e= 1;
calculo10.. sum((v), X(v)*DMU("10")*entradas(v, "10"))=e= 1;
calculo11.. sum((v), X(v)*DMU("11")*entradas(v,"11"))=e=1;
calculo12.. sum((v), X(v)*DMU("12")*entradas(v,"12"))=e=1;
calculo13.. sum((v), X(v)*DMU("13")*entradas(v, "13"))=e=1;
calculo14.. sum ((v), X(v)) *DMU("14") *entradas(v, "14")) = e= 1;
calculo15.. sum((v), X(v)*DMU("15")*entradas(v, "15"))=e= 1;
calculo16.. sum ((v), X(v)) *DMU("16") *entradas (v, "16")) = e= 1;
calculo17.. sum((v), X(v)*DMU("17")*entradas(v, "17"))=e=1;
calculo18.. sum ((v), X(v)*DMU("18")*entradas(v, "18"))=e=1;
calculo19.. sum((v), X(v)*DMU("19")*entradas(v, "19"))=e= 1;
calculo20.. sum((v), X(v)*DMU("20")*entradas(v, "20"))=e= 1;
calculo21.. sum((v), X(v)*DMU("21")*entradas(v, "21"))=e=1;
calculo22.. sum((v), X(v)*DMU("22")*entradas(v, "22"))=e=1;
calculo23.. sum ((v), X(v)*DMU("23")*entradas(v, "23"))=e=1;
calculo24.. sum((v), X(v)*DMU("24")*entradas(v, "24"))=e=1;
calculo25.. sum((v), X(v)*DMU("25")*entradas(v, "25"))=e= 1;
·
MODEL DEA BCC 1
/CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, CALCULO1, FUNCAO, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 2
/CAL1, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, CALCULO2, FUNCAO2, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 3
/CAL1, CAL2, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, CALCULO3, FUNCAO3, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 4
/CAL1, CAL2, CAL3, CAL5, CAL6, CAL7,
CALCULO4, FUNCAO4, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 5
/CAL1, CAL2, CAL3, CAL4, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
```

```
CAL12, CAL13, CAL14, CALCULO5, FUNCAO5, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 6
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, CALCULO6, fuNCAO6, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25/;
MODEL DEA BCC 7
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao7, calculo7, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 8
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao8, calculo8, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 9
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao9, calculo9, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CAL2
1, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 10
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL11,
CAL12, CAL13, CAL14, funcao10, calculo10, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CA
L21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 11
/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10,
CAL12, CAL13, CAL14, funcao11, calculo11, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20, CA
L21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 12 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL13, CAL14, funcao12, calculo12, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 13 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL14, funcao13, calculo13, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 14 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, funcao14, calculo14, CAL15, CAL16, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 15 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, CAL16, funcao15, calculo15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 16 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao16, calculo16, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 17 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao17, calculo17, CAL15, CAL16, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 18/CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao18, calculo18, CAL15, CAL17, CAL16, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 19 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao19, calculo19, CAL15, CAL17, CAL18, CAL16, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 20 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao20, calculo20, CAL15, CAL17, CAL18, CAL19, CAL16,
CAL21, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 21 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao21, calculo21, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL16, CAL22, CAL23, CAL24, CAL25 /;
MODEL DEA BCC 22 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL11,
CAL12, CAL13, CAL14, funcao22, calculo22, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL16, CAL23, CAL24, CAL25 /;
```

MODEL DEA BCC 23 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,

```
CAL12, CAL13, CAL14, funcao23, calculo23, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL16, CAL24, CAL25 /;
MODEL DEA BCC 24 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao24, calculo24, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL16, CAL25 /;
MODEL DEA BCC 25 /CAL1, CAL2, CAL3, CAL4, CAL5, CAL6, CAL7, CAL8, CAL9, CAL10, CAL11,
CAL12, CAL13, CAL14, funcao25, calculo25, CAL15, CAL17, CAL18, CAL19, CAL20,
CAL21, CAL22, CAL23, CAL24, CAL16 /;
SOLVE DEA BCC 1 USING LP MAXIMIZING Z;
SOLVE DEA BCC 2 USING LP MAXIMIZING Z2;
SOLVE DEA BCC 3 USING LP MAXIMIZING Z3;
SOLVE DEA BCC 4 USING LP MAXIMIZING Z4;
SOLVE DEA BCC 5 USING LP MAXIMIZING Z5;
SOLVE DEA BCC 6 USING LP MAXIMIZING Z6;
SOLVE DEA BCC 7 USING LP MAXIMIZING Z7;
SOLVE DEA BCC 8 USING LP MAXIMIZING Z8;
SOLVE DEA BCC 9 USING LP MAXIMIZING Z9;
SOLVE DEA BCC 10 USING LP MAXIMIZING Z10;
SOLVE DEA_BCC_11 USING LP MAXIMIZING Z11;
SOLVE DEA BCC 12 USING LP MAXIMIZING Z12;
SOLVE DEA BCC 13 USING LP MAXIMIZING Z13;
SOLVE DEA BCC 14 USING LP MAXIMIZING Z14;
SOLVE DEA BCC 15 USING LP MAXIMIZING Z15;
SOLVE DEA BCC 16 USING LP MAXIMIZING Z16;
SOLVE DEA BCC 17 USING LP MAXIMIZING Z17;
SOLVE DEA BCC 18 USING LP MAXIMIZING Z18;
SOLVE DEA BCC 19 USING LP MAXIMIZING Z19;
SOLVE DEA BCC 20 USING LP MAXIMIZING Z20;
SOLVE DEA BCC 21 USING LP MAXIMIZING Z21;
SOLVE DEA BCC 22 USING LP MAXIMIZING Z22;
SOLVE DEA BCC 23 USING LP MAXIMIZING Z23;
SOLVE DEA BCC 24 USING LP MAXIMIZING Z24;
SOLVE DEA BCC 25 USING LP MAXIMIZING Z25;
DISPLAY
z.1, Z2.L, Z3.L, Z4.L, Z5.L, Z6.L, Z7.L, Z8.1, Z9.1, Z10.1, Z11.1, Z12.1, Z13.1, Z14.1, Z
15.L, Z16.L, Z17.L, Z18.L, Z19.L, Z20.L, Z21.L, Z22.L, Z23.L, Z24.L, Z25.L;
execute_unload "DEABCC.gdx" z.1 z2.1 z3.1 z4.1 z5.1 z6.1 z7.1 z8.1 z9.1
z10.l z11.l z12.l z13.l z14.l Z15.L Z16.L Z17.L Z18.L Z19.L Z20.L Z21.L
Z22.L Z23.L Z24.L Z25.LO
execute 'gdxxrw.exe DEABCC.gdx var=z.l rng=dea!b2'
execute 'gdxxrw.exe DEABCC.gdx var=z2.1 rng=dea!b3'
execute 'gdxxrw.exe DEABCC.gdx var=z3.1 rng=dea!b4'
execute 'gdxxrw.exe DEABCC.gdx var=z4.l rng=dea!b5'
execute 'gdxxrw.exe DEABCC.gdx var=z5.1 rng=dea!b6'
execute 'gdxxrw.exe DEABCC.gdx var=z6.1 rng=dea!b7'
execute 'gdxxrw.exe DEABCC.gdx var=z7.1 rng=dea!b8'
execute 'gdxxrw.exe DEABCC.gdx var=z8.1 rng=dea!b9'
execute 'gdxxrw.exe DEABCC.gdx var=z9.1 rng=dea!b10'
execute 'gdxxrw.exe DEABCC.gdx var=z10.1 rng=dea!b11'
execute 'gdxxrw.exe DEABCC.gdx var=z11.1 rng=dea!b12'
execute 'gdxxrw.exe DEABCC.gdx var=z12.1 rng=dea!b13'
execute 'gdxxrw.exe DEABCC.gdx var=z13.1 rng=dea!b14'
execute 'gdxxrw.exe DEABCC.gdx var=z14.1 rng=dea!b15'
```

```
execute 'gdxxrw.exe DEABCC.gdx var=z15.1 rng=dea!b16'
execute 'gdxxrw.exe DEABCC.gdx var=z16.1 rng=dea!b17'
execute 'gdxxrw.exe DEABCC.gdx var=z17.1 rng=dea!b18'
execute 'gdxxrw.exe DEABCC.gdx var=z18.1 rng=dea!b19'
execute 'gdxxrw.exe DEABCC.gdx var=z19.1 rng=dea!b20'
execute 'gdxxrw.exe DEABCC.gdx var=z20.1 rng=dea!b21'
execute 'gdxxrw.exe DEABCC.gdx var=z21.1 rng=dea!b22'
execute 'gdxxrw.exe DEABCC.gdx var=z22.1 rng=dea!b23'
execute 'gdxxrw.exe DEABCC.gdx var=z23.1 rng=dea!b24'
execute 'gdxxrw.exe DEABCC.gdx var=z24.1 rng=dea!b25'
```

APÊNDICE - Artigos publicados em congressos e periódicos

Artigos aprovados em periódicos

- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F.; MARINS, F. A. S. A new approach to reducing search space and increasing efficiency in simulation optimization problems via the Fuzzy-DEA-BCC. **Mathematical Problems in Engineering**, v.2014, p.1-15, 2014.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; PENTEADO, K. M.; AGUIAR, M. S.;
 PINHO, A. F. Análise de uma Unidade de Processamento de Roupas de um Hospital
 Através da Simulação a Eventos Discretos. Produto & Produção, v.13, p. 7-24, 2012.
- MIRANDA, R. C.; VALADÃO, A. F. C.; TURRIONI, J. B. Análise da expansão dos modelos de excelência regionais em gestão da qualidade no Brasil. Sistemas & Gestão, v.7, p. 514-525, 2012.
- MONTEVECHI, J. A. B.; COSTA, R. F. S.; MIRANDA, R. C.; PINHO, A. F. Aplicação do planejamento de experimentos simulados para auxílio à tomada de decisões em uma célula de manufatura de alta tecnologia. Pesquisa Operacional para o Desenvolvimento, v.60, p.110-136, 2014.
- PEREIRA, T. F.; MIRANDA, R. C. Processo de desenvolvimento de *software* aplicado no gerenciamento de patrimônio. **Produto & Produção**, v.14, p.49-62, 2013.
- PEREIRA, T. F.; MONTEVECHI, J. A. B.; MIRANDA, R. C.; FRIEND, J. D. Integrating soft systems methodology to aid simulation conceptual modeling.
 International Transactions in Operational Research, v. 21, p. 1-21, 2014.
- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; COSTA, R. F. S.;
 MIRANDA, R. C.; FRIEND, J. D. Evaluation of a proposed optimization method for discrete-event simulation models. Pesquisa Operacional, v.32, p. 543-560, 2012.
- RANGEL, J. J. A.; PEIXOTO, T. A.; MATIAS, I. O.; MONTEVECHI, J. A. B.; MIRANDA, R. C. Ururau Um Ambiente para Desenvolvimento de Modelos de Simulação a Eventos Discretos. Pesquisa Operacional para o Desenvolvimento, v.5, p. 373-405, 2013.

Capítulos de livros publicados

- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; MIRANDA, R. C. Algoritmos Genéticos. In: LOPES, H. S.; RODRIGUES, L. C. A.; STEINER, M. T. A. Fundamentos e Aplicações. Meta-Heurísticas em Pesquisa Operacional. 1^a. ed. Cutitiba: Omnipax, p. 21-32, 2013.
- MONTEVECHI, J. A. B.; MIRANDA, R. C.; FRIEND, J. D. Sensitivity Analysis in Discrete Event Simulation Using Design of Experiments. In: LIM, E. W. C. (Org.).
 Discrete Event Simulations Development and Applications. 1st. Ed. Croatia: InTech, p. 63-102, 2012.

Artigos aprovados em congresso

- MACIEL, A. C.; MONTEVECHI, J. A. B.; MIRANDA, R. C.; FAGUNDES, L. D. Análise do impacto dos tempos de setup na disponibilidade operacional de uma máquina de corte através da simulação a eventos discretos. In: Simpósio de Engenharia de Produção, Anais... Bauru, 2012.
- MENDONÇA, M. M.; MONTEVECHI, J. A. B.; MIRANDA, R. C. Aplicação da modelagem conceitual IDEF-SIM ao software de modelagem computacional SIMUL8: um caso prático. In: Encontro Nacional de Engenharia de Produção, Anais... Salvador, 2013.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F. Redução do Espaço de Busca em Problemas de Otimização Multiobjetivo via Simulação. In: XLVI Simpósio Brasileiro de Pesquisa Operacional, Anais... Salvador, 2014.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; PEREIRA, T. F. Otimização via simulação: um estudo comparativo envolvendo otimizadores comerciais. In: XXXIV Encontro Nacional de Engenharia de Produção, Anais... Curitiba, 2014.
- MIRANDA, R. C.; MONTEVECHI, J. A. B. Planejamentos fatoriais na análise de sensibilidade para otimização de modelos de simulação a eventos discreto. In: Encontro Nacional de Engenharia de Produção, Anais... Bento Gonçalves, 2012.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; SILVA, A. F. Redução do espaço de busca em problemas de otimização via simulação. In: Simpósio Brasileiro de Pesquisa Operacional, Anais... Natal, 2013.

- MONTEVECHI, J. A. B.; LEAL, L.; MIRANDA, R. C.; PEREIRA, T. F. Interactive Learning of Modeling and Discrete-Events Simulation through Lego Parts. In: Winter Simulation Conference, **Proceedings...** Washington, D.C., EUA, 2013.
- PALMA, M. J. C.; MIRANDA, R. C; SILVA, A. F. . Implementação do fluxo contínuo em uma linha de produção por meio da simulação a eventos discretos. In: XXI Simpósio de Engenharia de Produção, Anais... Bauru, 2014.
- PEREIRA, L. F.; MONTEVECHI, J. A. B.; RODRIGUES, U.; MIRANDA, R. C. Metodologia para emprego da bifurcação sequencial para seleção de variáveis em modelos de simulação a eventos discretos. In: Congresso Latino-Iberoamericano de Investigación Operativa e Simpósio Brasileiro de Pesquisa Operacional, Anais... Rio de Janeiro, 2012.
- PEREIRA, T. F.; MIRANDA, R. C.; MONTEVECHI, J. A. B.; ROCHA, F. Gestão do conhecimento em projetos de simulação a eventos discretos apoiada pela tecnologia da informação. In: XLVI Simpósio Brasileiro de Pesquisa Operacional, Anais... Salvador, 2014.
- PEREIRA, T. F.; FRIEND, J. D.; MONTEVECHI, J. A. B.; MIRANDA, R. C. Soft System Methodology como auxílio à Gestão do Conhecimento em projetos de simulação a eventos discretos. In: Encontro Nacional de Engenharia de Produção, Anais... Bento Gonçalves, 2012.
- PEREIRA, T. F.; MIRANDA, R. C.; MONTEVECHI, J. A. B.; PINHO, A. F. gestão do conhecimento em projetos de simulação: um estudo de caso. In: Simpósio Brasileiro de Pesquisa Operacional, Anais... Natal, 2013.
- PEREIRA, T. F.; MONTEVECHI, J. A. B.; MIRANDA, R. C. Gestão do conhecimento em projetos de simulação: uma abordagem da espiral do conhecimento.
 In: Encontro Nacional de Engenharia de Produção, Anais... Salvador, 2013.
- QUEIROZ, J. A.; MIRANDA, R. C. Integração da Simulação a Eventos Discretos ao Value Stream Mapping: uma proposta metodológica. In: Encontro Nacional de Engenharia de Produção, Anais... Salvador, 2013.
- QUEIROZ, J. A.; MIRANDA, R. C.; TORRES, A. F.; PINHO, A. F. Proposta de uma metodologia para utilização da simulação no planejamento e implantação dos sistemas de produção enxuta. In: Congresso Latino-Iberoamericano de Investigación Operativa e Simpósio Brasileiro de Pesquisa Operacional, Anais... Rio de Janeiro, 2012.

- ROCHA, G. V.; VILELA, H. P.; FERREIRA JUNIOR, J. S.; MIRANDA, R. C.; MONTEVECHI, J. A. B. Otimização da programação da produção em manufatura calçadista. In: Encontro Nacional de Engenharia de Produção, Anais... Bento Gonçalves, 2012.
- RODRIGUES, U.; MONTEVECHI, J. A. B.; MIRANDA, R. C.; PEREIRA, L. F. Aplicação de simulação a eventos discretos e arranjo ortogonal de Taguchi na otimização de uma célula de manufatura. In: Congresso Latino-Iberoamericano de Investigación Operativa e Simpósio Brasileiro de Pesquisa Operacional, Anais... Rio de Janeiro, 2012.
- SILVA, A. F.; MIRANDA, R. C; MARINS, F. A. S.; ROTELA JUNIOR, P. .
 Programação por metas e análise por envoltória de dados para avaliação da eficiência
 de serviços hospitalares. In: XXI Simpósio de Engenharia de Produção, Anais...
 Bauru, 2014.
- SILVA, A. F.; MARINS, F. A. S.; MIRANDA, R. C.; SILVA, E. R.; ROTELA JUNIOR, P. Avaliação da eficiência sob incerteza por meio da combinação da lógica Fuzzy com a programação por metas e análise envoltória de dados. In: XXI Simpósio de Engenharia de Produção, Anais... Bauru, 2014.
- SILVA, A. F.; MARINS, F. A. S.; OLIVEIRA, F. A.; LUCHE, J. R. D.; MIRANDA,
 R. C.; ROTELA JUNIOR, P. Programação por Metas Binária-Mista Aplicada no
 Processo de Orçamento de Capital. In: XLVI Simpósio Brasileiro de Pesquisa
 Operacional, Anais... Salvador, 2014.
- SILVA, A. F.; MARINS, F. A. S.; SANTOS, M. V. B.; GOMES, R. F.; MIRANDA, R. C. Avaliação da eficiência sob incerteza por meio da programação por metas, análise por envoltória de dados e teoria fuzzy: aplicação em mini fábricas do segmento de autopeças. In: Simpósio Brasileiro de Pesquisa Operacional, Anais... Natal, 2013.