

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

Renato Pontes Rodrigues

**UTILIZAÇÃO DA METODOLOGIA DE SUPERFÍCIE
DE RESPOSTA PARA OTIMIZAÇÃO DE MODELOS
DE SIMULAÇÃO A EVENTOS DISCRETOS**

Junho de 2015

Itajubá – MG

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

Renato Pontes Rodrigues

**UTILIZAÇÃO DA METODOLOGIA DE SUPERFÍCIE
DE RESPOSTA PARA OTIMIZAÇÃO DE MODELOS
DE SIMULAÇÃO A EVENTOS DISCRETOS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como requisito parcial à obtenção do título de Mestre em Engenharia de Produção.

Orientador: Prof. Dr. José Arnaldo Barra Montevechi.

Junho de 2015

Itajubá – MG

DEDICATÓRIA

*Aos meus pais José Altamiro Rodrigues
e Isabel Carvalho Pontes Rodrigues.*

AGRADECIMENTOS

A Deus, por me dar forças para fazer o meu trabalho da melhor forma, a cada dia, com dedicação e responsabilidade.

Ao meu orientador Professor José Arnaldo Barra Montevechi, um muito obrigado pela paciência, compreensão, motivação e amizade fundamentais para conclusão desta pesquisa.

Por todo o apoio, eu agradeço aos meus pais José Altamiro Rodrigues e Isabel Carvalho Pontes Rodrigues, em especial a minha mãe pelo apoio e amor em todos os momentos difíceis da minha vida.

A minha namorada Luana Gonçalves Ribeiro por me ouvir, me apoiar e me incentivar em meu trabalho.

Ao Professor José Henrique de Freitas Gomes pelo apoio nas dúvidas técnicas em relação a este trabalho.

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

Aos amigos do NEAAD do Instituto de Engenharia de Produção e Gestão agradeço pela companhia agradável e pelas dicas úteis para o desenvolvimento desta pesquisa.

Aos coordenadores do programa de mestrado em engenharia de produção em meu período, professor Carlos Sanches e Carlos Mello, por todo auxílio prestado ao longo desses dois anos de mestrado.

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

A todos vocês, muito obrigado!

RESUMO

Modelos de simulação são frequentemente aplicados à otimização de problemas complexos, que não podem ser resolvidos por métodos analíticos ou matemáticos. O presente trabalho busca analisar a aplicação da Metodologia de Superfície de Resposta (MSR) como uma forma organizada e eficiente de buscar a otimização na Simulação a Eventos Discretos (SED). Ele é categorizado como uma pesquisa quantitativa usando ferramentas estatísticas e o método de pesquisa de experimentação, seguindo um modelo empírico normativo. Os resultados encontrados são representados por meio dos valores de cada variável de entrada do Delineamento de Experimentos (DOE) obtido no ponto ótimo. Depois disso, é feita uma comparação com os resultados da otimização utilizada aqui com os de um *software* de mercado, em que foi constatado a eficácia do modelo de otimização adotado em quatro objetos de estudo. Sendo ainda que, o ponto ótimo foi atingido com uma redução de cerca de 80 % no número de experimentos, além das análises de sensibilidades geradas pela MSR.

PALAVRAS-CHAVE: Simulação; Otimização; Delineamento de Experimentos (DOE); Metodologia de Superfície de Resposta (MSR).

ABSTRACT

Simulation models are frequently applied to optimize complex problems, which can't be solved with mathematics methods. This work will analyze the applicability of the Response Surface Methodology (RSM) as an organized and efficient way to optimize discrete event simulations. It will be a quantitative research using statistical tools and it will use the experimentation research method, using a normative empiric model. The results to be found will be the values of each input variable in the Design of Experiments in the optimal point. After that, a comparison between the optimization by the RSM and market software will be made, where conclusions despite the efficacy of the process adopted will be made in four study objects. In this work, the optimal point was achieved with a reduction of 80 % in number of experiments using the RSM compared to the market software. And it was even possible to make a sensitive analysis using the RSM.

KEYWORDS: Simulation; Optimization; Design of Experiments; Response Surface Methodology (RSM).

LISTA DE FIGURAS

Figura 2.1: Sete passos para conduzir um estudo de sucesso na simulação	26
Figura 2.2: Sequência de passos para um projeto de simulação.....	27
Figura 2.3: Princípio de funcionamento de um modulo de otimização integrado a um <i>software</i> de simulação	30
Figura 2.4: Representação de modelagem, simulação e otimização	32
Figura 2.5: Modelo geral de um processo	39
Figura 2.6: Superfície de Resposta	42
Figura 2.7: Superfície de Resposta de modelos lineares.	43
Figura 2.8: Superfície de Resposta de modelos de segunda ordem.....	44
Figura 2.9: Arranjo Composto Central para dois fatores.....	48
Figura 2.10: Arranjo CCD com três variáveis	49
Figura 2.11: Gráfico de contorno	50
Figura 3.1: Classificação da pesquisa científica.	55
Figura 4.1: Fluxograma da utilização da MSR na otimização via simulação	59
Figura 5.1: Modelo implementado no <i>ProModel</i> para o primeiro objeto de estudo	61
Figura 5.2: Gráfico de sensibilidade das variáveis de entrada e suas interações.....	64
Figura 5.3: Teste de normalidade dos resíduos.	68
Figura 5.4: Teste de correlação dos resíduos.....	68
Figura 5.5: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.....	69
Figura 5.6: Superfície de Resposta entre os fatores B e C	69
Figura 5.7: Modelo implementado no <i>ProModel</i> para o segundo objeto de estudo.....	70
Figura 5.8: Gráfico de sensibilidade das variáveis de entrada e suas interações.....	75
Figura 5.9: Teste de normalidade dos resíduos.	79
Figura 5.10: Teste de correlação dos resíduos.....	79
Figura 5.11: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.....	80
Figura 5.12: Superfície de Resposta dos fatores A e B.	80
Figura 5.13: Modelo implementado no <i>ProModel</i> para o terceiro objeto de estudo.....	82
Figura 5.14: Gráfico de sensibilidade das variáveis de entrada e suas interações	84
Figura 5.15: Teste de normalidade dos resíduos.	89
Figura 5.16: Teste de correlação dos resíduos.....	89
Figura 5.17: Vista superior da SR entre A e D – Gráfico de Contorno.....	90

Figura 5.18: Superfície de Resposta entre A e D	90
Figura 5.19: Modelo implementado no <i>ProModel</i> para o quarto objeto de estudo.....	91
Figura 5.20: Teste de normalidade dos resíduos.	97
Figura 5.21: Teste de correlação dos resíduos.....	97
Figura 5.22: Vista superior da SR entre os fatores C e D – Gráfico de Contorno.....	98
Figura 5.23: Superfícies de Resposta entre C e D.	98
Figura 5.24: Modelo implementado no <i>AnyLogic</i> para o quinto objeto de estudo.....	99
Figura 5.25: Gráfico de sensibilidade das variáveis de entrada e suas interações	101
Figura 5.26: Teste de normalidade dos resíduos.	103
Figura 5.27: Teste de correlação dos resíduos.....	104
Figura 5.28: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.....	104
Figura 5.29: Superfícies de Resposta entre A e B.	105
Figura 6.1: Gráficos de pontos para comparação estatística no objeto de estudo 1.	110
Figura 6.2: Gráficos de pontos para comparação estatística no objeto de estudo 3	111
Figura 6.3: Gráficos de pontos para comparação estatística no objeto de estudo 4	111
Figura 6.4: Gráficos de pontos para comparação estatística no objeto de estudo 5	112
Figura B.1 - Modelo conceitual do objeto de estudo 1.....	120
Figura B.2 - Modelo conceitual do objeto de estudo 2.....	120
Figura B.3 - Modelo conceitual do objeto de estudo 3.....	121
Figura B.4 - Modelo conceitual do objeto de estudo 4.....	121
Figura C.1: Vista superior da SR entre os fatores A e C – Gráfico de Contorno.....	122
Figura C.2: Superfície de Resposta dos fatores A e C.	122
Figura C.3: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.....	123
Figura C.4: Superfície de Resposta dos fatores B e C.....	123
Figura C.5: Vista superior da SR entre A e B – Gráfico de Contorno.	124
Figura C.6: Superfície de Resposta entre A e B	124
Figura C.7: Vista superior da SR entre A e E – Gráfico de Contorno.....	125
Figura C.8: Superfície de Resposta entre A e E	125
Figura C.9: Vista superior da SR entre B e D – Gráfico de Contorno.	126
Figura C.10: Superfície de Resposta entre B e D.	126
Figura C.11: Vista superior da SR entre B e E – Gráfico de Contorno.....	127
Figura C.12: Superfície de Resposta entre B e E.	127
Figura C.13: Vista superior da SR entre D e E – Gráfico de Contorno.....	128
Figura C.14: Superfície de Resposta entre D e E.	128

Figura C.15: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.....	129
Figura C.16: Superfícies de Resposta entre A e B	129
Figura C.17: Vista superior da SR entre os fatores A e C – Gráfico de Contorno.....	130
Figura C.18: Superfícies de Resposta entre A e C.	130
Figura C.19: Vista superior da SR entre os fatores A e D – Gráfico de Contorno.....	131
Figura C.20: Superfícies de Resposta entre A e D.	131
Figura C.21: Vista superior da SR entre os fatores A e E – Gráfico de Contorno.....	132
Figura C.22: Superfícies de Resposta entre A e E.....	132
Figura C.23: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.....	133
Figura C.24: Superfícies de Resposta entre B e C.....	133
Figura C.25: Vista superior da SR entre os fatores B e D – Gráfico de Contorno.....	134
Figura C.26: Superfícies de Resposta entre B e D.	134
Figura C.27: Vista superior da SR entre os fatores B e E – Gráfico de Contorno.	135
Figura C.28: Superfícies de Resposta entre B e E.....	135
Figura C.29: Vista superior da SR entre os fatores C e E – Gráfico de Contorno.	136
Figura C.30: Superfícies de Resposta entre C e E.....	136
Figura C.31: Vista superior da SR entre os fatores D e E – Gráfico de Contorno.....	137
Figura C.32: Superfícies de Resposta entre D e E.....	137

LISTA DE TABELAS

Tabela 2.1: Programas de otimização.....	29
Tabela 2.2: Características fundamentais das principais técnicas de DOE	40
Tabela 5.1: Decodificação dos níveis em número de operadores.....	62
Tabela 5.2: Experimentos fatoriais e centrais.....	63
Tabela 5.3: Resultado do experimento fatorial completo.....	64
Tabela 5.4: Resultado do experimento fatorial completo eliminando termos menos significantes	65
Tabela 5.5: Experimentos axiais.....	65
Tabela 5.6: Resultado do experimento de Superfície de Resposta.....	65
Tabela 5.7: Falta de ajuste	66
Tabela 5.8: Coeficientes dos termos usados na otimização.....	66
Tabela 5.9: Cálculo do ponto ótimo	67
Tabela 5.10: Decodificação dos níveis em número de operadores e bastidores.....	71
Tabela 5.11 : : Experimentos fatoriais e centrais.....	72
Tabela 5.12 : Resultado do experimento fatorial fracionado.....	74
Tabela 5.13: Resultado do experimento fatorial fracionado eliminando termos insignificantes	75
Tabela 5.14: Experimentos axiais.....	76
Tabela 5.15: Resultado do experimento de superfície de resposta.....	76
Tabela 5.16: Falta de ajuste	77
Tabela 5.17: Coeficientes dos termos usados na otimização.....	77
Tabela 5.18: Cálculo do ponto ótimo	78
Tabela 5.19: Decodificação dos níveis das variáveis de entrada.....	82
Tabela 5.20: Experimentos fatoriais e centrais.....	83
Tabela 5.21: Resultado do experimento fatorial fracionado.....	84
Tabela 5.22: Resultado do experimento fatorial fracionado eliminando termos não significantes	85
Tabela 5.23: Experimentos axiais.....	86
Tabela 5.24: Resultado do experimento de superfície de resposta.....	86
Tabela 5.25: Falta de ajuste	86
Tabela 5.26: Coeficientes dos termos usados na otimização.....	87

Tabela 5.27: Cálculo do ponto ótimo	88
Tabela 5.29: Experimentos realizados	92
Tabela 5.30: Experimentos axiais.....	93
Tabela 5.31: Resultado do experimento de superfície de resposta.....	94
Tabela 5.32: Falta de ajuste	94
Tabela 5.33: Coeficientes dos termos usados na otimização.....	95
Tabela 5.34: Cálculo do ponto ótimo	96
Tabela 5.35: Decodificação dos níveis em número de operadores.....	99
Tabela 5.36: Experimentos realizados	100
Tabela 5.37: Resultado do experimento fatorial completo.....	100
Tabela 5.38: Experimentos axiais.....	101
Tabela 5.39: Resultado do experimento de superfície de resposta.....	102
Tabela 5.40: Coeficientes dos termos usados na otimização.....	102
Tabela 5.41: Cálculo do ponto ótimo	102
Tabela 6.1: Características de cada experimento.....	107
Tabela 6.2: Resultados do experimento 1	108
Tabela 6.3: Resultados do experimento 2.....	108
Tabela 6.4: Resultados do experimento 3.....	109
Tabela 6.5: Resultados do experimento 4.....	109
Tabela 6.6: Resultados do experimento 5.....	109
Tabela A - Simbologia utilizada na técnica IDEF-SIM	119

LISTA DE ABREVIATURAS

DOE	Delineamento de Experimentos
SR	Superfície de Resposta
MSR	Metodologia de Superfície de Resposta
SED	Simulação a Eventos Discretos

SUMÁRIO

1. Introdução.....	17
1.1. Contextualização	17
1.2. O problema de pesquisa.....	17
1.3. Objetivo	18
1.4. Condições de contorno da pesquisa.....	18
1.5. Estrutura da dissertação	18
2. Fundamentação teórica.....	20
2.1. Considerações iniciais	20
2.2. Simulação a eventos discretos	20
2.2.1. Síntese da história da simulação	20
2.2.2. Introdução à simulação	21
2.2.3. Vantagens e desvantagens da simulação	22
2.2.4. Onde aplicar e onde não aplicar a simulação.....	24
2.2.5. Metodologias para estudos de simulação.....	25
2.3. Otimização via simulação.....	28
2.3.1. Introdução	28
2.3.2. Princípios de funcionamento	30
2.3.3. Dificuldades da otimização via simulação.....	32
2.3.4. Metodologia para otimização via simulação	33
2.3.5. Casos na literatura de otimização via simulação	34
2.4. Planejamento e análise de experimentos	35
2.4.1. Introdução	35
2.4.2. Conceitos importantes.....	35
2.4.2.1. Fatores	35

2.4.2.2.	Níveis	35
2.4.2.3.	Respostas.....	36
2.4.2.4.	Efeitos.....	36
2.4.2.5.	Interação	36
2.4.2.6.	Replicação	36
2.4.2.7.	Análise de sensibilidade	37
2.4.2.8.	Metamodelo.....	37
2.4.3.	Características gerais do DOE	37
2.4.4.	Planejamentos Fatoriais	41
2.4.5.	Metodologia de superfície de resposta.....	42
2.4.5.1.	Falta de ajuste.....	46
2.4.5.2.	Teste de significância dos modelos.....	47
2.4.5.3.	Análise de resíduos.....	47
2.4.5.4.	Arranjo composto central	48
2.4.5.5.	Gráficos de contorno	49
2.4.6.	O DOE na Simulação.....	51
2.5.	Considerações finais deste capítulo	52
3.	Método de pesquisa.....	53
3.1.	Considerações iniciais	53
3.2.	Método de pesquisa: experimentação.....	53
3.3.	Classificação da pesquisa quantitativa	53
3.4.	Etapas de uma pesquisa em experimentação.....	56
3.5.	Considerações finais deste capítulo.....	57
4.	Metodologia de otimização utilizada	58
4.1.	Considerações iniciais	58
4.2.	Condições básicas para aplicação da metodologia.....	58
4.3.	Fluxograma da metodologia aplicada.....	59

4.4.	Considerações finais do capítulo	60
5.	Aplicação da metodologia de superfície de resposta	61
5.1.	Considerações iniciais	61
5.2.	Objeto de estudo 1	61
5.2.1.	Delineamento de experimentos	62
5.2.2.	Fatorial completo	63
5.2.3.	Superfície de resposta	65
5.2.4.	Ponto ótimo	66
5.3.	Objeto de estudo 2	70
5.3.1.	Delineamento de experimentos	71
5.3.2.	Fatorial fracionado	73
5.3.3.	Superfície de resposta	76
5.3.4.	Ponto ótimo	77
5.4.	Objeto de estudo 3	81
5.4.1.	Delineamento de experimentos	82
5.4.2.	Fatorial fracionado	83
5.4.3.	Superfície de resposta	85
5.4.4.	Ponto ótimo	87
5.5.	Objeto de estudo 4	91
5.5.1.	Delineamento de experimentos	91
5.5.2.	Fatorial fracionado	93
5.5.3.	Superfície de resposta	93
5.5.4.	Ponto ótimo	95
5.6.	Objeto de estudo 5	99
5.6.1.	Delineamento de experimentos	99
5.6.2.	Fatorial fracionado	100
5.6.3.	Superfície de resposta	101

5.6.4. Ponto ótimo.....	102
5.7. Considerações finais deste capítulo.....	105
6. Análise dos Resultados.....	107
6.1. Considerações iniciais.....	107
6.2. Resumo dos resultados.....	107
6.3. Comparações estatísticas.....	110
6.4. Considerações finais do capítulo.....	112
7. Conclusões.....	113
7.1. Sugestões para trabalhos futuros.....	114
Referências bibliográficas.....	115
ANEXO A – Simbologia usada no IDEF-SIM.....	119
ANEXO B – Modelos conceituais em IDEF-SIM.....	120
ANEXO C - Gráficos de contorno e respectivas superfícies de respostas.....	122
APÊNDICE - Artigos submetidos em congressos.....	138

1. Introdução

1.1. Contextualização

Este trabalho busca ligar a área da simulação à otimização, visto que são áreas que se complementam, existindo ainda muitos aspectos a serem pesquisados dentro dessa interação. Uma crítica feita por Chwif e Medina (2010), é que a simulação, por si só, não é capaz de identificar uma solução ótima, para isso é necessário o uso de técnicas complementares à simulação para se atingir um ponto ótimo.

O presente trabalho busca estudar uma dessas técnicas de otimização: a Metodologia de Superfície de Resposta (MSR). Esta metodologia propõe representar uma variável de saída do modelo a uma equação onde seja possível calcular um ponto ótimo. Em outras palavras, busca-se é obter o nível ótimo para cada variável de entrada e o valor da variável de saída para este ponto.

Para estudar a fase de otimização das variáveis, serão utilizadas técnicas estatísticas, nesse caso o Delineamento de Experimentos (DOE). Dentro dessa, o Fatorial Completo, Fracionado e a Superfície de Resposta (SR), além da otimização para se obter os resultados.

Para realização dos experimentos serão utilizados quatro modelos de simulação já testados e validados anteriormente. Portanto, as fases anteriores à otimização das variáveis não estão em foco neste trabalho. Os modelos utilizados foram feitos nos trabalhos de: (COSTA, 2010); (MIRANDA *et al.*, 2012) e (OLIVEIRA, 2010).

Serão utilizados quatro objetos de estudo diferentes, que correspondem a simulações de processos de fabricação usando-se o *software ProModel*. Modelos prontos foram usados porque o foco do trabalho é estudar a forma de otimização de modelos de Simulação a Eventos Discretos (SED) aplicando a MSR, e não a criação desses modelos.

1.2. O problema de pesquisa

O problema abordado por esta dissertação consiste em responder à seguinte pergunta: Quais as vantagens de se utilizar a MSR ao invés de *softwares* de otimização via simulação em SED?

1.3. Objetivo

O objetivo principal do trabalho é aplicar a MSR na SED, analisando suas vantagens e desvantagens em relação à *softwares* otimização via simulação. Nesse caso, o *software* utilizado para comparação é o *SimRunner*, em todos os cinco objetos de estudo. Para o terceiro e quarto objetos de estudo é feita uma comparação com o ótimo global, para isso foram feitas simulações de todos os possíveis cenários dentro da região de solução.

Segmentando este objetivo, tem-se como objetivos específicos:

- Avaliar os principais fatores que afetam no resultado da simulação e detectar interações significativas entre esses fatores.
- Avaliar se existe curvatura dentro da região de solução proposta.
- Fazer a análise gráfica da superfície de resposta.
- Analisar as vantagens e desvantagens em relação aos *softwares* de otimização via simulação.

1.4. Condições de contorno da pesquisa

Para a aplicação da MSR em modelos de SED, neste trabalho, é necessário que as variáveis de decisão, que são as variáveis de entrada do modelo simulação, sejam do tipo: discretas e determinísticas. De acordo com Pinho (2008), essas condições de contorno estão presentes na maioria dos trabalhos de otimização via simulação.

Como os valores utilizados aqui serão inteiros, ainda há a necessidade de que essas variáveis tenham uma amplitude que permita variar entre os níveis -2 e +2, pois esses valores serão necessários no arranjo usado na MSR deste trabalho, que usa os níveis -2, -1, 0 +1 e +2. Portanto, a diferença entre o nível superior e inferior deverá ser de no mínimo quatro.

Existe a possibilidade de se utilizar outros arranjos experimentais que tem uma amplitude menor entre os níveis máximo e mínimo, porém esses arranjos não foram utilizados neste trabalho.

1.5. Estrutura da dissertação

Esta dissertação está estruturada em seis capítulos. Sendo que o capítulo 1 apresentou a contextualização desta pesquisa e apontou os objetivos a serem alcançados nesta dissertação.

O Capítulo 2 apresenta a fundamentação teórica que apoia este trabalho. Neste capítulo, procura-se descrever o que há de mais recente na literatura sobre SED, otimização via simulação e MSR. 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 Experimentação, método este que guiou a condução deste trabalho. Ao longo do capítulo, são apresentados os principais conceitos relacionados a este método de pesquisa, as etapas que envolvem a elaboração de um projeto de experimentação e a classificação deste trabalho segundo Bertrand e Fransoo (2002).

O Capítulo 4 descreve a metodologia de otimização proposta utilizando a SR, apresentando um fluxograma explicando o passo a passo para otimização de modelos de SED. Neste capítulo são apresentados também os detalhes técnicos em sua teoria e depois é utilizada essa metodologia na prática, apresentados no capítulo posterior.

O Capítulo 5 aplica a MSR na otimização de cinco objetos de estudo, e compara os resultados alcançados com o resultado de um *software* de otimização comercial, o *SimRunner*.

O Capítulo 6 analisa os resultados deste trabalho, discute os resultados atingidos e faz as comparações estatísticas dos pontos ótimos.

Por fim, o Capítulo 7 encerra o trabalho apresentando as principais conclusões obtidas e propõe sugestões para trabalhos futuros.

2. Fundamentação teórica

2.1. Considerações iniciais

Este capítulo tem o objetivo de apresentar os conceitos que dão o suporte teórico a esta dissertação, com base em livros acadêmicos, artigos de congressos da área e artigos de periódicos.

O primeiro tema a ser discutido neste capítulo é a SED. Assim, apresenta uma revisão do processo de criação de um modelo conceitual, a preparação da coleta de dados de entrada, construção do modelo computacional, e os processos contínuos de validação, verificação e o estabelecimento de credibilidade. Ou seja, apresentam-se os passos para se conduzir um modelo computacional e sua relação com a otimização, apresentando um fluxograma mais moderno utilizado na condução de todo o projeto de simulação.

Depois disso, estuda-se a otimização via simulação apresentando artigos que integram as duas áreas mostrando as vantagens dessa união. Mostra-se a importância dos trabalhos desse tipo e apresentam-se exemplos na literatura da utilização da otimização via simulação.

O último assunto utilizado aqui nesse trabalho é a MSR, onde estuda-se a viabilidade de sua utilização na simulação, seu funcionamento, detalhes e os passos da otimização através desse método.

2.2. Simulação a eventos discretos

2.2.1. Síntese da história da simulação

Segundo Goldsman, Nance e Wilson (2009), a aplicação da simulação se restringia ao método de Monte Carlo até o ano de 1950, e era operada de forma manual. Somente após esse período é que nasceu a SED.

O desenvolvimento contínuo da tecnologia dos computadores e dos *softwares* têm levado à evolução de programas de simulação ainda mais potentes e complexos, de acordo com Banks *et al.* (2009). Isso viabiliza ainda mais o uso da simulação nos dias atuais, sendo que ficou muito fácil e barato a aquisição de computadores capazes de desempenhar essas tarefas, o que tem contribuído muito para o uso da simulação.

Robinson (2005) afirma que, desde o princípio, a SED foi desenvolvida de forma significativa, pois seus conceitos foram bem estruturados, porém esta teve que acompanhar a

evolução de desenvolvimentos em computação. Logo, no início o principal problema não estava no conhecimento em SED, mas sim na evolução tecnológica da época.

Segundo Nance e Sargent (2002), a SED jamais seria uma poderosa ferramenta de auxílio à tomada de decisões sem o rápido desenvolvimento do computador digital.

Um fato constatado por Kelton, Sadowski e Sturrock (2007), foi que a simulação utilizada atualmente, iniciou-se na década de 1970, quando os computadores tornaram-se mais rápidos e mais baratos. Sendo assim, o valor da simulação começava a ser descoberto pela indústria de um modo geral, ainda que no começo fosse utilizada apenas pelas empresas de grande porte, aquelas que estão sempre abertas à inovação. Depois dessa época, a simulação passou a fazer parte dos currículos de Engenharia de Produção e Pesquisa Operacional.

2.2.2. Introdução à simulação

Para Saraiva Júnior, Tabosa e Costa (2011), a simulação é uma representação de um processo ou sistema real, num dado período de tempo, que envolve a observação desta para fazer inferências relativas às características do processo. Esta se inicia com o desenvolvimento de um modelo que represente o sistema a ser investigado, com o máximo de fidelidade possível.

De acordo com Banks (1998), a simulação funciona como a criação de um sistema artificial a partir de um sistema real ao longo do tempo, procurando imitar esse processo ou sistema real. Ela envolve a observação deste sistema artificial para fazer inferências a respeito das características da operação do sistema real representado.

A simulação, de acordo com Harrel *et al.* (2004), é como um meio de reproduzir o comportamento de sistemas dinâmicos usando um modelo computacional. Funciona como a imitação de um sistema dinâmico com o objetivo de avaliar o desempenho do sistema.

Ela traz vantagens como a de se poder visualizar o sistema, promover mudanças nos dados de entrada e responder a questões do tipo "o que aconteceria se", também conhecida como "*what-if*", reduzindo gastos desnecessários e tempo, caso não existisse a simulação e as situações tivessem que ser testadas na prática.

Segundo Chwif e Medina (2010) é muito importante destacar de que maneira a simulação não pode ser vista ou definida. Os tópicos abaixo mostram algumas dessas situações:

- Uma bola de cristal, antecipando eventos futuros, ela não tem esse poder. Contudo, a simulação pode prever o comportamento de um sistema, baseado em dados de entrada específicos, com certa confiança.
- Uma ferramenta de otimização, visto que a simulação é uma ferramenta de análise de cenários. A simulação por si só não é capaz de identificar uma solução ótima. Para isso, é necessário o uso de técnicas complementares à simulação, o que é apresentado nessa dissertação.
- Uma substituta do pensamento humano no processo de tomada de decisão, porém ela pode fornecer dados para auxiliar os gestores na tomada de decisão.
- Uma técnica de último recurso. Para usuários mais fluentes na ferramenta, pode ser usada até mesmo para problemas mais simples, contrariando as opiniões de muitos profissionais, que acham que a simulação deveria ser utilizada apenas quando todas as técnicas possíveis falhassem.
- Uma ferramenta que solucionará todos os problemas existentes. A simulação possui uma classe de problemas bem específicos nos quais se adapta bem, como a manufatura com processos discretos, por exemplo.

2.2.3. Vantagens e desvantagens da simulação

Uma das maiores vantagens, de acordo com Law e Kelton (2007), é o uso simulação para mostrar aos tomadores de decisão uma visão ampla de todo o sistema, sendo que estes tomadores de decisão, que são em sua maioria gerentes e diretores, não tem tanto contato com o chão de fábrica como os engenheiros em início de carreira.

Segundo Chwif e Medina (2010), a simulação é uma poderosa ferramenta, porém a mesma não serve para resolver todos os problemas, ela possui uma classe de problemas específicos nos quais se adapta bem, apresentados mais adiante. Esses mesmos autores explicam que um modelo de simulação pode capturar características de natureza dinâmica e aleatória com mais precisão, tentando reproduzir, em um computador, o mesmo comportamento que o sistema apresentaria quando submetido às mesmas condições no mundo real.

Os modelos de simulação são tão completos que, segundo Baines *et al.* (2004), eles podem até mesmo considerar aspectos característicos do trabalho humano em sua programação, em contraposição a modelos que assumem o comportamento humano como o de uma máquina. O autor sugere que o efeito da idade do trabalhador e a variação no

desempenho provocada de acordo com o horário do dia, podem ser inseridos em modelos de simulação através de algumas funções e parâmetros da programação.

Então pode-se perguntar o porquê de se usar a simulação, concluindo que para responder a estas perguntas deve-se conhecer as vantagens da simulação. Harrell *et al.* (2004) indicam que a simulação é uma grande alternativa ao invés de usar a abordagem de tentativa e erro, que é cara, consome muito tempo e esforço e perturba o sistema sob avaliação, uma vez que faz modificações no sistema real. Já a simulação traz uma maneira de se tomar as melhores decisões com uma certa confiança satisfatória (se o modelo for bem validado).

Algumas das vantagens possibilitadas pela simulação, segundo Banks *et al.* (2009), são:

- Novos *layouts* de manufatura e sistemas de transporte podem ser testados antes de investir em novos equipamentos, o que possibilita, também, uma análise econômica dos projetos mais detalhada e menos estimada.
- Uma das principais vantagens da simulação é que esta pode promover mudanças no sistema sem interrompê-lo ou modificá-lo, explorando novas políticas, procedimentos, regras de decisão e fluxos de informação.
- Tempo pode ser acelerado ou desacelerado de acordo com a necessidade. Quando se foca apenas no resultado é comum se acelerar o processo, porém para análises detalhadas nas partes do processo em andamento pode-se desacelerar a simulação.
- Hipóteses de como e porque certos fenômenos ocorrem podem ser testados.
- Conhecimento pode ser obtido sobre a interação das variáveis e sua importância ao funcionamento do sistema, ou seja, pode-se obter uma análise de sensibilidade se forem combinadas outras técnicas à simulação, como o DOE, por exemplo.
- Pode ser empregada a análise de gargalo, que tem por objetivo descobrir onde está a obstrução do fluxo de informação, recursos ou materiais.
- O estudo da simulação ajuda na demonstração de como o sistema realmente funciona, é útil para transmitir informações durante o transporte de linhas para outras unidades de uma empresa, por exemplo.
- As tradicionais perguntas de “O que ocorre se...” podem ser respondidas sem que mude o sistema real.

A crescente complexidade dos sistemas de manufatura é evidente nos sistemas atuais, uma vez que estes não estão mais dispostos apenas em linhas simples e fáceis de manipular.

De acordo com O'Kane *et al.* (2000), os sistemas de manufatura modernos consistem de muitas operações que ocorrem de modo aleatório e não-linear, a modelagem através da SED, nesses casos, torna-se um dos mais eficientes meios de estudo desses sistemas.

Dentro desta mesma linha de raciocínio, Law e Kelton (2007) afirmam o mesmo que foi constatado por O'Kane (2000), que a maioria dos sistemas de manufatura atuais são complexos demais para permitir que modelos realistas sejam resolvidos analiticamente, porém estes modelos podem ser estudados por meio de simulação, tornando o problema muito mais simples. Na simulação, um software é usado para inter-relacionar as mais diversas variáveis de um modelo, e os dados são coletados para estimar as verdadeiras características desejadas do modelo.

Esse mesmos autores apresentam algumas desvantagens da simulação:

- A construção do modelo de simulação requer treinamento especial em um *software* ou linguagem de programação.
- Os resultados provenientes do modelo de simulação podem ser difíceis de serem interpretados pelos tomadores de decisões.
- A modelagem através da simulação e a análise podem ser demoradas e caras, isso porque estes *softwares* são muito caros e os profissionais que sabem operá-los com competência também são raros no mercado.
- O emprego incorreto da simulação para resolver problemas onde a solução analítica é possível ou mesmo preferível.
- A cada execução de um modelo de simulação estocástico produz somente estimativas da verdadeira característica do modelo para um particular conjunto de parâmetros de entrada.

2.2.4. Onde aplicar e onde não aplicar a simulação

Neste item são apresentadas algumas situações onde Banks e Gibson (1997) indicam em seu artigo, as regras em que a simulação computacional não se aplica como a melhor ferramenta para a resolução de problemas:

- O problema pode ser resolvido pelo senso comum.
- O problema pode ser resolvido usando métodos analíticos.
- A experimentação no sistema real for mais econômica e fácil de realizar do que a modelagem e simulação.

- O custo da modelagem for superior aos ganhos que poderão ser atingidos.
- Os recursos são escassos ou não houver tempo hábil ao projeto de simulação.
- Os dados não estiverem disponíveis e não puderem ser estimados.
- A verificação e validação do modelo forem impossíveis por não existir tempo suficiente ou pessoal disponível para isso.
- Os gerentes tiverem expectativas irreais.
- O comportamento do sistema for excessivamente complexo ou não pode ser definido.

Porém, segundo Banks *et al.* (2009), existem algumas aplicações em áreas muito interessantes para pesquisas de simulação:

- Sistemas de manufatura em geral.
- Sistemas públicos, como: hospitais, áreas militares e recursos naturais.
- Sistemas de transporte e logística.
- Sistemas de construção civil.
- Sistemas de restaurantes e entretenimento.
- Gerenciamento e redesenho de processos de negócios.
- Processamento de alimentos.
- Desempenho de sistemas de computadores.

2.2.5. Metodologias para estudos de simulação

Sturrock (2009) apresenta passos que são importantes para se conduzir metodicamente um projeto de simulação, que consiste em fases como:

- Definir objetivo do trabalho, identificando os interessados no projeto e como eles irão avaliar o desempenho deste.
- Entendimento do sistema, especificação funcional de onde se quer chegar avaliando o nível de detalhe a ser observado e construído.
- Administração do projeto, evitando pular fases, mas fazendo-o no tempo requerido, pois um projeto prático feito após a decisão tomada não terá muito valor.
- Coletar dados de entrada, que é uma fase essencial, pois dados de entrada errados ou inexistentes na simulação fará com que esta se torne obsoleta.
- Construir e verificar o modelo, que serão fases interativas, pois a cada verificação, cada erro detectado, deve-se atualizar o modelo para que retrate a realidade.

- Validação do modelo, que deve ser feita observando-se a proximidade à realidade, e a validade do modelo para resolução do problema. O autor lembra que a validação perfeita não existe, pois o modelo perfeito é apenas o modelo real.
- A última fase é a experimentação, análise e apresentação dos resultados obtidos. Nela se apresentam os diferentes cenários testados e análise de cada um, fazendo proposições sobre as variáveis e o modelo que será bem conhecido pelo simulador.

Dentre todos os passos que são importantes para se conduzir metodicamente um projeto de simulação, se apresenta o último que é a experimentação, análise e apresentação dos resultados obtidos. Nela se testam os diferentes cenários e se analisam cada um deles, fazendo proposições sobre os melhores valores para as variáveis de entrada a fim de atingir o melhor resultado. É nesta última fase que se baseia esse trabalho, buscando uma alternativa para a otimização da simulação que seja diferente, tanto da tentativa e erro, bem como da otimização através de *softwares* de otimização via simulação.

Paralelamente ao que foi mostrado, um guia prático para condução de SED de sucesso foi apresentado por Law (2006), dividido em sete passos, mostrados na Figura 2.1:

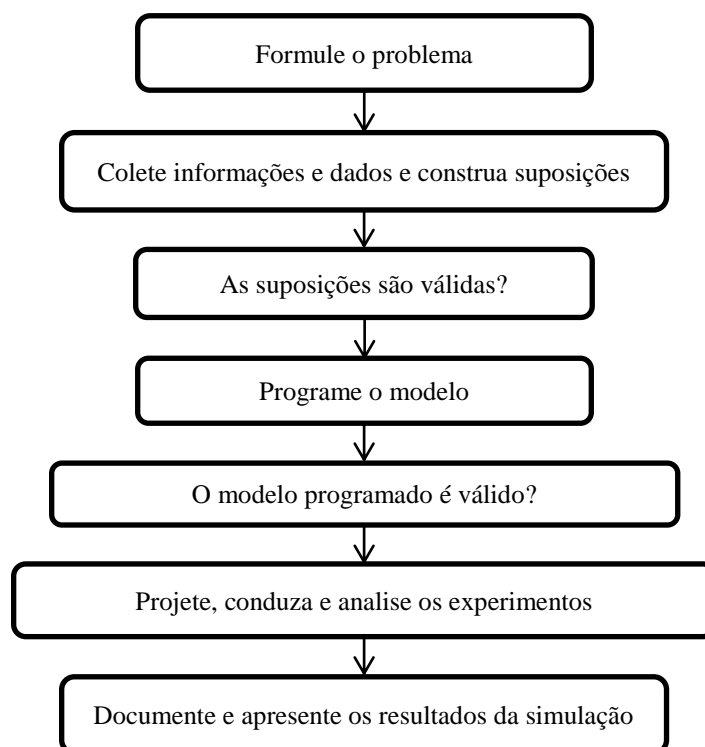


Figura 2.1: Sete passos para conduzir um estudo de sucesso na simulação.

Fonte: Law (2006).

Mostra-se aqui, uma outra metodologia para se conduzir um projeto de simulação, para mostrar que nos dois modelos apresentados tem-se a fase de experimentação e análise

dos experimentos a fim de se obter o melhor cenário, ou seja, realizar a otimização. Essa fase será o foco desta dissertação, que apresentará uma maneira mais organizada de realizar esses experimentos.

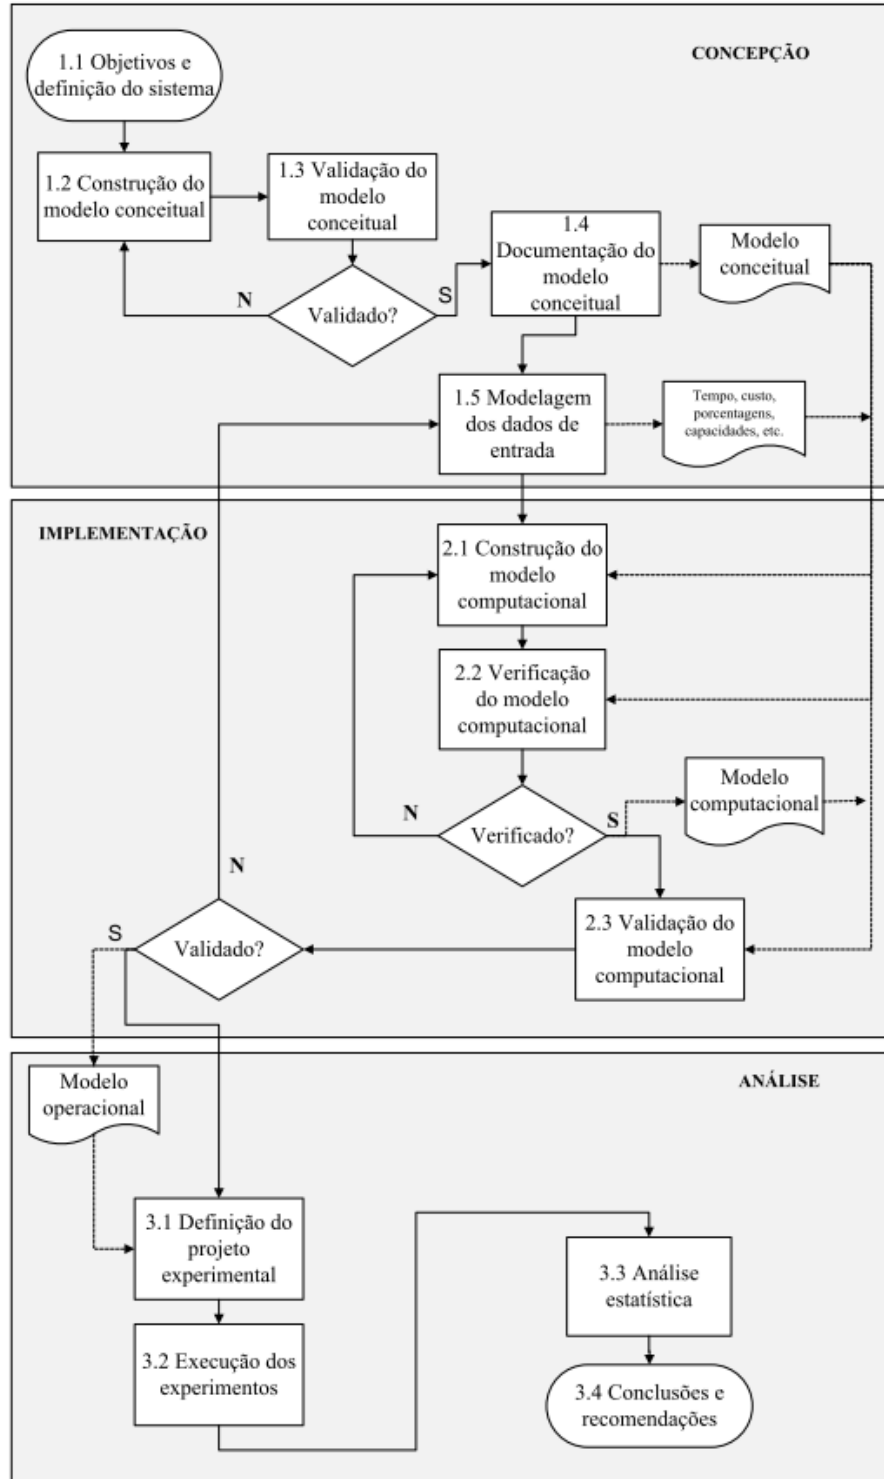


Figura 2.2: Sequência de passos para um projeto de simulação.

Fonte: Montevechi *et al.* (2010).

Montevecchi *et al.* (2010) mostram, em seu trabalho, o fluxograma da Figura 2.2, que serve como guia para conduzir um projeto de simulação. Esse fluxograma apresenta os passos gerais para condução de um projeto de simulação com a integração do DOE como forma de otimização. Esse fluxograma é mais detalhado e define melhor a fase de análise, foco desse trabalho. Sendo, portanto, mais importante para o mesmo.

Para a fase de análise será adotada uma estratégia parecida com a de Leal *et al.* (2007) mostrada mais adiante, onde se faz o experimento fatorial para a análise de sensibilidade e eliminação de variáveis sem efeito significativo no resultado. Porém, aqui o uso do DOE seguirá mais adiante, fazendo-se o experimento de SR.

2.3. Otimização via simulação

2.3.1. Introdução

Segundo Banks *et al.* (2009), a expressão otimização via simulação é muito usada quando o objetivo é minimizar ou maximizar algumas medidas de desempenho do processo, o qual só pode ser avaliado por meio da simulação. Ou seja, em casos onde os experimentos necessários para se otimizar certo processo não podem ser feitos no sistema real e sim em um ambiente computacional.

Problemas de otimização via simulação podem ser resolvidos por meio de técnicas heurísticas de otimização. Segundo Silva (2005), essas técnicas até proporcionam boas soluções, porém não asseguram que as soluções encontradas sejam ótimas. Essas técnicas necessitam de um número elevado de avaliações da função objetivo para busca do ponto ótimo. Portanto, devido ao avanço dos recursos computacionais, estes métodos baseados na busca aleatória controlada por critérios probabilísticos, tiveram um importante crescimento nos últimos anos.

Segundo Harrel *et al.* (2004), a otimização serve, principalmente, para responder à seguinte pergunta: Quais os valores ótimos das variáveis de entrada que maximizam (ou minimizam) a variável saída no modelo de simulação?

De acordo com Chwif e Medina (2010), o uso de ferramentas de otimização em conjunto com a simulação tem se tornado mais frequente, uma vez que esta última se torna uma geradora de soluções e não só uma forma de avaliação destas. Ou seja, a simulação permite que se gere uma solução ótima quando combinada à otimização.

A distinção entre o objetivo da otimização e os objetivos da escolha do melhor sistema é ressaltada por Law e Kelton (2007). Quando escolhe-se o melhor sistema, existem alternativas de configurações dos sistemas (cenários) que são dadas, e o dever é apenas escolher a melhor entre elas. Já na otimização, a situação é diferente, deve-se decidir quais parâmetros de entrada serão modificados e sua amplitude, de modo a simular e atingir o ponto ótimo, comparando seus resultados.

Seguindo a definição de Harrel *et al.* (2004), a otimização é definida como o processo de tentar diferentes combinações de valores para variáveis de entrada, a fim de procurar a combinação de valores que fornece o resultado mais desejável para o modelo de simulação.

De acordo com Fu (2002), o uso da simulação integrada à otimização é um movimento recente, pois até a década de 90 não havia esta integração. Hoje, porém, grande parte das pesquisas consideram importante combinar otimização e simulação. Entretanto, com a incorporação de programas de otimização nos pacotes de simulação, a situação começou a mudar, uma vez que estes *softwares* são bem práticos e simples de se utilizar.

O mesmo autor evidencia essa integração entre as duas áreas mostrando o fato dos pacotes comerciais de simulação atuais conterem módulos que realizam algum tipo de otimização, contrastando com a situação de 1990 quando nenhum dos pacotes incluía essa opção.

A seguir são mostrados a Tabela 2.1 que lista dos pacotes de otimização incorporados aos pacotes de simulação.

Tabela 2.1: Programas de otimização. Fonte: Law e Kelton (2007).

Programa de Otimização	Pacote de Simulação	Procedimento de busca
<i>AutoStart</i>	<i>AutoMod, AutoSched</i>	Estratégias Evolucionárias
<i>OptQuest</i>	<i>Arena, Micro Saint, QUEST, Taylor Enterprise Dynamics, SIMUL8</i>	Busca “scatter”, Busca Tabu, Redes Neurais
<i>SimRunner</i>	<i>MedModel, ProModel, ServiceModel</i>	Estratégias Evolucionárias, Algoritmo Genético
<i>WITNESS Optimizer</i>	<i>WITNESS</i>	Recozimento Simulado, Busca Tabu

Nessa dissertação, como já foi dito anteriormente, é utilizado o *SimRunner*, por ele ser o pacote de otimização que é integrado ao *ProModel*, *software* do qual foram feitos os modelos a serem utilizados para os experimentos.

2.3.2. Princípios de funcionamento

Segundo Law e Kelton (2007), o objetivo dos pacotes de otimização é simular uma sequência de configurações do sistema de modo que uma boa configuração obtida forneça uma solução quase-ótima. O funcionamento desses *softwares* começa com o modelo sendo conduzido pelo pacote de otimização a simular varias configurações do sistema. Os resultados dessas simulações são realimentados no pacote de otimização que utiliza seu algoritmo interno de busca para decidir as configurações adicionais a serem simuladas. Este processo continua até que o critério de parada seja atendido. A Figura 2.3 apresenta a interação entre o pacote de otimização e o modelo de simulação.

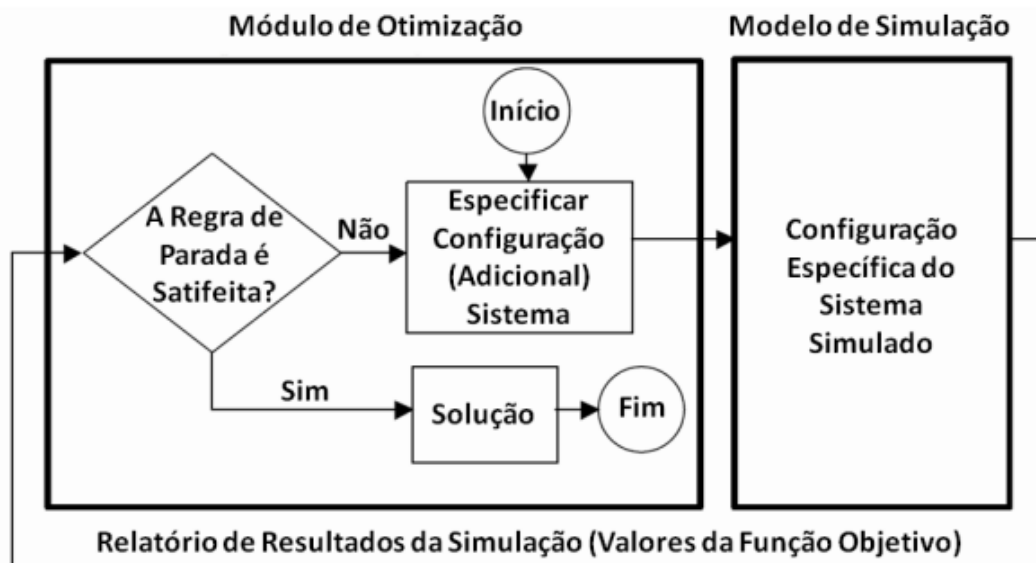


Figura 2.3: Princípio de funcionamento de um módulo de otimização integrado a um *software* de simulação

Fonte: Adaptado de Law (2007)

Entretanto, o funcionamento interno desses *softwares* não permite dizer que os resultados encontrados sejam os ideais. Esses resultados dependem do método de otimização utilizado e de como os parâmetros (como nível de confiança e convergência) foram especificados. Segundo Wang e Schonfeld (2006), um bom pacote de otimização deve gerar, de forma eficiente, uma configuração próxima à ideal. Sendo assim, a diferença entre o ótimo global e a solução apresentada pelo *software* é insignificante ou até estatisticamente igual se considerarmos as incertezas nas entradas e nas relações funcionais.

Para Fernandes *et al.* (2013), a otimização através da simulação tem se tornado cada vez mais frequente e a complexidade dos sistemas atuais impede que soluções analíticas levem a soluções completamente satisfatórias. E afirma que, para usar a simulação na avaliação e na melhoria do desempenho de um processo, é necessário construir cenários, executá-los e analisar os resultados. Porém, isso pode não garantir que as melhores configurações sejam experimentadas. Daí a necessidade de se estudar a metodologia de otimização da simulação, justificativa deste artigo que estudará a aplicabilidade da técnica de SR, que é umas das subdivisões do DOE, na otimização de simulações.

Muitos tomadores de decisões em empresas não se satisfazem com um resultado ótimo sem conhecimento de seu sistema de produção e de como se atingiu esse ótimo. Esses decisores muitas vezes necessitam comprar equipamentos caros para atingir a um ponto ótimo, ficando na dúvida constantemente. Segundo Huyet (2006), faz-se necessário não apenas otimizar, mas prover esses administradores de produção conhecimentos sobre o processo, como interações entre os parâmetros do sistema, bem como os efeitos desses e de suas interações. Em outras palavras, é necessário uma aprendizagem sobre o sistema, e não apenas uma resposta ótima que venha de um modo visto como uma “caixa preta” entre os gestores.

Em busca do melhor entendimento das definições de modelagem, simulação e otimização, a Figura 2.4 sintetiza as principais diferenças entre esses métodos muito utilizados. Segundo Protil (2001), um sistema pode ser representado por uma relação de entrada e saída, onde X são as variáveis de entrada, Y as variáveis de saída e M é uma representação que processa ou relaciona as informações de entrada e saída.

A modelagem busca as inter-relações existentes entre os dados de entrada e os dados de saída de um determinado sistema, ou seja, procura-se um modelo do comportamento do sistema. A simulação manipula as entradas de um modelo e verifica suas diferentes saídas, ou seja, serve para análises do tipo “e se”, pois verifica as diferentes respostas com as variações nas entradas. Já a otimização busca obter uma solução ótima, alterando a composição das entradas, ou seja, ela vai em busca de um resultado e para isso manipula suas entradas.

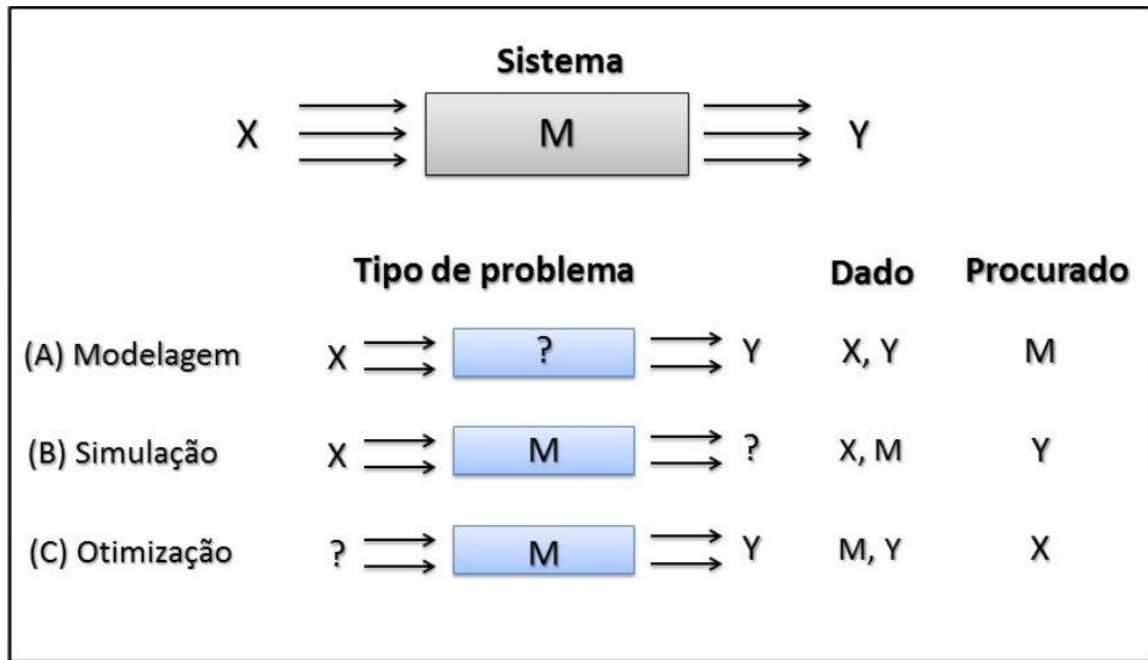


Figura 2.4: Representação de modelagem, simulação e otimização.

Fonte: Protil (2001)

2.3.3. Dificuldades da otimização via simulação

É possível concluir através do capítulo do livro de Montevechi, Miranda e Friend (2012), que uma das maiores desvantagens da simulação é que ela não serve como uma técnica de otimização por si só. No passado, costumava-se otimizar testando cenários e tomando como valores ótimos os valores das variáveis do cenário que gerou o melhor resultado. E, apesar de existirem pacotes com rotinas lógicas de otimização, o usuário nunca sabe se esses valores foram realmente alcançados.

De acordo com Banks *et al.* (2009), na otimização via simulação não é possível concluir seguramente que uma configuração seja melhor que outra, isso porque o desempenho de uma configuração específica é estimado, pois ele não pode ser determinado exatamente. Esta incerteza é um ponto negativo do algoritmo de otimização. Um modo de resolver o problema é fazer várias replicações do mesmo cenário de modo que o resultado seja a média. Assim, pode-se dizer com mais segurança que um cenário é melhor que outro, visto que essa técnica da replicação reduz a variância do processo simulado.

Diante dessas dificuldades apresentadas, pode-se dizer que MSR é uma metodologia em que o caminho para se atingir a otimização seja mais visível e mais lógico, sendo que ela trás uma visualização das variáveis de entrada em relação a variável de saída, gerando um

resultado mais simples e lógico de se acreditar do que os *softwares* de otimização via simulação convencionais.

2.3.4. Metodologia para otimização via simulação

Como é utilizado, nessa dissertação, o *software* de otimização *SimRunner*, será descrita a metodologia proposta por Harrel *et al.* (2004). Partindo-se de um modelo computacional já construído e validado, são mostradas as etapas necessárias para que a otimização seja bem sucedida. Os cinco passos estão descritos a seguir:

- 1°. Passo: definir as variáveis de entrada que irão afetar as variáveis de saída do modelo de simulação. Estas variáveis terão seus valores alterados a cada rodada de simulação.
- 2°. Passo: definir se as variáveis de entrada serão do tipo real ou inteira e definir os limites inferiores e superiores. O algoritmo de otimização buscará soluções que estão dentro dos limites impostos para cada variável. A definição de limites é importante porque quanto maior for a amplitude (diferença entre limite inferior e superior) maior será o tempo consumido para identificar a solução ótima.
- 3°. Passo: definir a função objetivo para avaliar as soluções testadas pelo algoritmo. A função objetivo definida será minimizada ou maximizada, dependendo do que se deseja. Por exemplo: é muito comum se minimizar os custos e se maximizar o número de unidades produzidas.
- 4°. Passo: definir o modo de busca (agressivo, moderado ou cauteloso). Isso afetará a confiabilidade e o tempo requerido na busca da solução ótima. Nesta fase, também são definidos outros parâmetros, tais como: a precisão requerida, o nível de significância e o número de replicações.
- 5°. Passo: uma vez concluída a busca, o analista deve estudar as soluções encontradas, pois deve-se considerar várias outras soluções competitivas com a considerada ótima. Por exemplo: em uma otimização de unidades produzidas pode-se ter uma solução competitiva que use bem menos operadores, sendo assim, deve prevalecer o bom senso do tomador de decisão.

Essa metodologia pode ser estendida, devido a sua generalidade, a outros *softwares* que utilizam como técnica de otimização os Algoritmos Genéticos.

2.3.5. Casos na literatura de otimização via simulação

No trabalho de Zhang, Chiang e Wu (2014), foi usada a simulação como uma ferramenta para se otimizar um determinado processo. Isso porque era inviável modificar as variáveis de entrada de determinado processo na prática. Logo, a simulação buscou relacionar essas variáveis de entrada (velocidade de produção, taxa de defeitos e manutenção de cada máquina) com a variável de saída (custo de manufatura) que seria minimizada. Baseado nos princípios da otimização via simulação foram buscados os valores ótimos para as variáveis de entrada. A partir daí, os resultados estimados para minimizar o custo de manufatura puderam ser relacionados com o investimento a ser realizado para a realização do cenário que geraria o ponto ótimo, ou seja, o custo mínimo de manufatura. Lembrando que, tudo isso foi feito sem se variar absolutamente nada dentro do mundo real.

Assim como proposto nesse trabalho, o artigo de Yalcinkaya e Bayhan (2009) usa a MSR para otimizar uma simulação de uma linha de metrô. O objetivo dos autores era variar o tempo entre partida de dois trens (que seria a variável de entrada) a fim de otimizar duas variáveis: o tempo de viagem de um passageiro desde que ele entra na estação de metrô, ou seja, somando-se o tempo de espera; e o nível de lotação do trem, o que caracteriza como uma otimização multiobjetivo. Claro que, quanto menor fosse o tempo de partida entre dois trens menor seria o tempo de espera do passageiro, porém seria pior para a companhia de metrô, uma vez que estes ficariam vazios. Portanto, o objetivo foi alcançado porque a otimização buscou atingir um ponto ótimo entre as duas variáveis de saída. Além da vantagem já observada da otimização via simulação, foram feitos vários testes “e se” dentro da simulação, e ainda foi feita uma análise de sensibilidade da mesma. Com a simulação também foi possível mudar facilmente algumas características como: velocidade máxima permitida e taxa mínima desejada de lotação dos trens, as quais eram requerimentos do departamento de trânsito e da companhia, respectivamente. O número de testes necessário usando a otimização por meio da MSR também foram bem reduzidos, isso porque a MSR busca realizar o menor número de experimentos possíveis para chegar as suas conclusões.

Rosen *et al.* (2007) usam a MSR em otimização via simulação multiobjetivo, ou seja, onde existem mais de uma resposta para o mesmo processo que precisa ser otimizado. Nesse trabalho, eles comparam essa técnica de otimização com outras, como estratégia de tomada de decisão multicritério, por exemplo. Os autores conseguem provar através de experimentos feitos que a metodologia de otimização por meio da SR gera respostas de melhor qualidade que os demais em otimizações multiobjetivo.

2.4. Planejamento e análise de experimentos

2.4.1. Introdução

Para melhor entendimento deste item, serão apresentados alguns conceitos gerais importantes quando se trata de planejamento de experimentos. Serão analisadas as características gerais de um planejamento de experimentos, definindo suas etapas, seus objetivos e alguns elementos básicos. Depois será apresentado um resumo dos tipos de experimento, como Taguchi, fatorial completo e fracionado, além da MSR.

2.4.2. Conceitos importantes

2.4.2.1. Fatores

De acordo com Kleijnen (1998), o fator é um parâmetro ou variável de entrada que sofrerá transformações durante os experimentos, de acordo com um arranjo pré-definido pelo planejamento dos experimentos. Como consequência dessa variação, um fator pode ter vários níveis, no caso dessa dissertação se usará cinco níveis.

O fator pode ser controlável ou incontrolável. Nos experimentos, foram utilizados os fatores controláveis. Já os fatores incontroláveis, segundo Montgomery (2005), podem ser analisados por meio da análise de covariância, usado frequentemente para compensar seus efeitos. Esses fatores incontroláveis também são conhecidos como ruídos, pois tem interferência nos processos, mas não fazem parte do arranjo experimental. Normalmente, de acordo com Law e Kelton (2007), procura-se trabalhar com os fatores controláveis nos experimentos de simulação, pois eles são mais relevantes para decisões que devem ser feitas sobre implementação de sistemas.

Os fatores também podem ser classificados como quantitativos e qualitativos. Segundo Law e Kelton (2007), os fatores quantitativos são os que têm valores numéricos. Já os qualitativos representam considerações estruturais que não são normalmente quantificadas.

2.4.2.2. Níveis

Segundo Chung (2004), níveis são as variações de um mesmo fator, ou seja, quais valores podem assumir um mesmo fator no arranjo experimental.

De acordo com Kleijnen *et al.* (2005), a combinação dos níveis de todos os fatores define um cenário. Se a quantidade de fatores é elevada, usa-se, normalmente, apenas dois níveis, sendo um positivo e outro negativo, a fim de se diminuir o número de experimentos.

2.4.2.3. Respostas

Segundo Leal (2008), a variável de resposta é a medição desempenho de um sistema para uma determinada configuração de fatores. Essas variáveis descrevem o comportamento de um sistema para estas configurações.

2.4.2.4. Efeitos

Segundo Montgomery e Runger (2003), o efeito é a mudança na resposta produzida pela mudança no nível do fator. Sendo que, existem os efeitos principais que são referidos aos efeitos dos fatores individualmente e os efeitos combinados que são os efeitos das interações entre os fatores. Dentro da simulação, os efeitos devem ser medidos por métodos estatísticos, a fim de definir os efeitos matemáticos de cada fator (LEAL, 2008).

2.4.2.5. Interação

De acordo com Montgomery (2005), a interação acontece quando um fator falha em produzir o mesmo efeito na resposta quando se varia o outro fator em diferentes níveis.

Para Chung (2004), a interação ocorre quando há sinergia entre os fatores, levando ao fenômeno de que o efeito da soma dos fatores que tem interação pode ser maior que a soma do efeito de cada fator isoladamente.

A interação acontece quando os efeitos de dois fatores não são apenas a soma dos efeitos de cada fator. Nos casos onde há uma forte interação, os efeitos principais ou isolados apresentam pouco significado, uma vez que estes estão mascarados. Contudo o que terá um maior efeito é, justamente, a interação entre esses dois fatores (MONTGOMERY e RUNGER, 2003).

2.4.2.6. Replicação

Segundo Montgomery (2005), replicação significa uma nova realização dos mesmos experimentos. As réplicas são importantes para estimar o erro experimental dos efeitos com maior precisão, e é muito utilizada em modelos com dados de entrada estocásticos. Em

simulação, normalmente são realizadas inúmeras réplicas, uma vez que a realização dos experimentos não representa um custo no mundo real.

2.4.2.7. Análise de sensibilidade

Segundo Kleijnen (1998), a análise de sensibilidade corresponde à análise dos efeitos dos fatores na resposta da simulação, efeitos esses provocados pelas variações extremas nas variáveis de entrada. Essa análise é muito utilizada para identificar as variáveis mais importantes do sistema, selecionando-as e eliminando as menos importantes para uma análise mais correta do delineamento de experimentos. Em outras palavras, o objetivo da análise de sensibilidade é justamente identificar para quais variáveis o sistema modelado é mais sensível.

2.4.2.8. Metamodelo

Metamodelo é definido como o modelo de um modelo. Em outras palavras, ele é uma aproximação matemática que define a transformação das entradas nas saídas. O metamodelo é o resultado da aplicação da MSR, uma equação que resume todo o modelo de simulação onde as entradas e saídas do modelo são observadas e os efeitos dos fatores no metamodelo são estimados (KLEIJNEN, 2008).

Os metamodelos gerados pela MSR podem ser:

- Polinômios de primeira ordem, que contém apenas os efeitos principais;
- Polinômios de primeira ordem com as interações entre os fatores;
- Polinômios de segunda ordem que contém todos os anteriores somados aos termos quadráticos.

A grande vantagem do uso do DOE para a criação de metamodelos, segundo o mesmo autor, é fornecer melhores estimativas dos efeitos dos fatores que as abordagens intuitivas, como a de “um fator por vez”, muito utilizada na prática, além de poder ser utilizada tanto para modelos determinísticos quanto estocásticos.

2.4.3. Características gerais do DOE

Todo experimento, segundo Montgomery (2009), pode ser visto como testes onde as mudanças nas variáveis de entrada são feitas propositalmente dentro do processo, tendo o objetivo de observar a forma como as respostas são afetadas pelas mudanças provocadas nas variáveis de entrada. Por essa razão, a experimentação se tornou uma parte fundamental do

método científico, contribuindo para a análise e melhoria das diversas aplicações de engenharia.

Dessa maneira, o mesmo autor cita o Planejamento de Experimentos, que vem do inglês *Design of Experiments* (DOE), como um processo onde se planejam os experimentos para que dados apropriados sejam coletados e depois analisados por métodos estatísticos, resultando em conclusões válidas e objetivas. Sendo assim, qualquer problema experimental necessita ser sustentado por dois elementos: o projeto dos experimentos e a análise estatística dos dados.

É fundamental que o experimentador tenha um bom grau de conhecimento a respeito do fenômeno ou modelo que se pretende estudar, como os dados serão coletados, sendo também necessário um conhecimento básico sobre as ferramentas de análise estatísticas utilizadas. Para uma melhor condução do DOE, o mesmo autor sugere que o planejamento de experimentos seja dividido nas seguintes etapas:

- Definição do problema;
- Escolha dos fatores e definição dos níveis de trabalho;
- Seleção das variáveis de resposta;
- Escolha do projeto experimental;
- Execução dos experimentos;
- Análise estatística dos dados;
- Conclusões e recomendações.

Em outro livro publicado no mesmo ano, o controle estatístico utilizado por Montgomery (2009), que utiliza o DOE dentro desse campo, define dois tipos de variáveis em um processo (Figura 2.5): as variáveis controláveis, que são as variáveis que serão manipuladas no experimento (x_1, x_2, \dots, x_p); e as variáveis não controláveis (z_1, z_2, \dots, z_q), também conhecidas como ruídos, as quais não se tem controle sobre seu comportamento.

Os experimentos podem ter vários objetivos, mas os mais importantes para este trabalho são:

- Determinar quais variáveis tem mais influência na resposta (y).
- Determinar os valores de x (significativos) de modo que a resposta esteja perto da exigência nominal, que neste trabalho será a maximização do lucro ou das unidades produzidas.

Segundo o autor, os elementos básicos que compõem o planejamento de experimentos são:

- Fatores controlados: variáveis que podem ser modificadas durante os experimentos para determinar a influência nas saídas.
- Fatores não controlados: variáveis que deveriam permanecer constantes durante os experimentos, mas de alguma forma variam alterando as saídas.
- Respostas: saídas que deverão ser otimizadas.
- Modelo: consiste na equação que relaciona as respostas com as variáveis do processo.

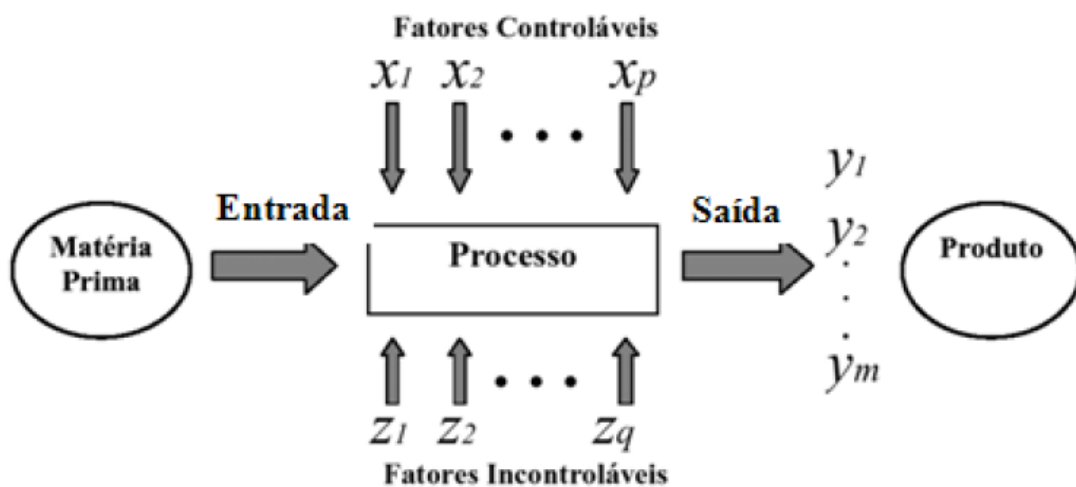


Figura 2.5: Modelo geral de um processo.

Fonte: Montgomery (2009)

Em relação aos projetos experimentais, as técnicas mais utilizadas, segundo Nilo Júnior (2003), são: planejamento fatorial completo, o planejamento fatorial fracionado, os arranjos de Taguchi e a MSR, os quais são mostrados na Tabela 2.2 a seguir:

Tabela 2.2: Características fundamentais das principais técnicas de DOE

Fonte: (Adaptado de Nilo Júnior, 2003)

Projeto experimental	Vantagens	Desvantagens	Aplicações
Fatorial Completo 2^k	Permite a varredura completa da região de estudo, pois utiliza todos os fatores e respectivos níveis	Não identifica variação intermediária, pois só trabalha em dois níveis Necessita de um alto número de corridas para problemas com grande número de variáveis	Processos onde já se tem um prévio domínio e onde a realização das corridas não demanda maior tempo ou custo
Fatorial Fracionado 2^{k-1}	Permite uma pré-análise do processo com um número reduzido de corridas	Não promove a varredura completa da região experimental	Processos onde se deseja um pré-conhecimento e onde a literatura é limitada Corridas que demandam maior tempo ou custo
Taguchi	Permite a análise de um processo com muitas variáveis de entrada com um número extremamente reduzido de experimentos	Fornecer uma ideia do processo, porém pode apresentar modelos matemáticos não confiáveis	Processos onde há pouco ou quase nenhum conhecimento prévio de comportamento Processos com alta dispersão ou que as corridas demandem alto custo ou tempo
Metodologia de Superfície de Resposta	Permite a verificação de variações intermediárias do processo	Pode apresentar erros na extrapolação dos pontos estrela, já que são realizadas poucas corridas nestes níveis	Otimização de processos, principalmente bem conhecidos e com baixa dispersão

De todos esses arranjos experimentais apresentados por Nilo Junior (2003), o único que não será utilizado é o arranjo de Taguchi, pois, como foi visto na tabela 3.2, este arranjo pode apresentar modelos matemáticos não confiáveis, além de ser utilizado em processos que demandam alto custo ou tempo. Logo, como os processos usados neste trabalho se resumem à simulação computacional, não terá um tempo e, tampouco, um custo elevado.

Foram utilizados os arranjos fatoriais completos ou fracionados no início do processo, a fim de se ter uma ideia das variáveis significativas, e para que se possa eliminar da posterior fase do projeto de experimentos, que seria a MSR, as variáveis de entrada não significativas no resultado. Assim, escolhe-se entre completo e fracionado de acordo com o número de

variáveis de entrada que se tem, se o número for elevado escolhe-se o fracionado por realizar um número menor de experimentos.

Por fim, utiliza-se os coeficientes gerados na MSR para realizar a otimização do processo, que é uma grande vantagem dessa metodologia.

2.4.4. Planejamentos Fatoriais

De acordo com Montgomery (2005), um experimento que envolve a análise dos efeitos de duas ou mais variáveis de entrada deve usar o planejamento fatorial, seja ele completo ou fracionado. Ao contrário de experimentos com apenas um fator onde um teste “ANOVA” (Análise de Variância) ou um “*Two Sample T*” seriam suficientes para o estudo dos efeitos. Esta estratégia permite que os efeitos de determinado fator sejam analisados em relação à variação dos níveis dos outros fatores. Fazendo com que se chegue a conclusões válidas e realistas no que diz respeito ao efeito real de um fator de entrada.

Segundo Montgomery e Runger (2003), no planejamento fatorial existe um arranjo que permite que os fatores variem juntos e não um por vez, ou seja, em cada linha do planejamento experimental, todas as combinações possíveis dos níveis das variáveis de entrada são investigadas. Essa é a única maneira de se descobrir interações entre os fatores, bem como efeitos de fatores combinados, evitando conclusões incorretas em casos em que há interações entre fatores.

Um fato constatado por Sanchez, Moeeni e Sanchez (2006), é que muitos trabalhos dentro da literatura em Pesquisa Operacional utilizam os Planejamentos Fatoriais devido a sua simplicidade, sendo que este arranjo permite ao analista identificar interações entre os fatores bem como os efeitos principais e efeitos combinados.

O principal problema em um planejamento fatorial, segundo Kleijnen (1998), é o crescimento exponencial das combinações de níveis com o aumento do número de fatores. Esse problema pode ser controlado com o planejamento fatorial fracionado, onde o número de experimentos é drasticamente reduzido, sem que haja, na maioria dos casos, perda da capacidade de análise do experimento.

2.4.5. Metodologia de superfície de resposta

A MSR se constitui de uma série de ferramentas matemáticas e estatísticas que são usadas para modelar e analisar problemas para os quais se deseja respostas influenciadas por algumas variáveis e onde o objetivo é a otimização desta resposta por meio da variação das variáveis de entrada (MYERS e MONTGOMERY, 2002).

Segundo Montgomery (2005), a MSR é uma estratégia adequada quando se tem um bom conhecimento do processo que se deseja otimizar, o que é o caso da simulação onde o profissional que a está utilizando normalmente tem uma boa ideia do processo simulado. A análise de uma SR é feita em termos de uma superfície ajustada. Quando se tem um ajuste adequado, significa que a análise será aproximadamente equivalente à análise da superfície real. Quando se utiliza um projeto de experimentos adequado na coleta dos dados da variável de saída, os parâmetros de entrada do modelo serão calculados com eficácia.

A Figura 2.6 representa a SR de um determinado processo modelado de acordo com a Equação 1.

$$\hat{y} = f(x_1, x_2) + \varepsilon \quad (1)$$

Onde:

x_1 e x_2 – representam as variáveis de controle

ε – representa o erro observado na resposta

\hat{y} – representa a resposta do modelo




Figura 2.6: Superfície de Resposta.

Fonte: Montgomery (2005)

Montgomery (2005) evidencia que, na maioria dos problemas, as relações entre a variável de saída e as variáveis independentes são desconhecidas. Portanto, busca-se encontrar uma aproximação adequada para representar as respostas de interesse como função destas variáveis. Dessa maneira, se uma resposta for bem modelada por uma função linear, a relação aproximada pode ser representada pelo seguinte modelo de primeira ordem representado pela Equação 2:

$$\hat{y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (2)$$

Onde:

y – Resposta de interesse

x_i – Variáveis independentes

β_i – Coeficientes a serem estimados

k – Número de variáveis independentes

ε – Erro experimental

De acordo com Montgomery e Runger (2003), existem modelos que possuem efeitos de interação e, portanto, podem ser analisados pelos métodos de regressão linear múltipla. Uma interação entre duas variáveis pode ser representada por um termo cruzado no modelo, mostrado na Equação 3:

$$\hat{y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_i X_i + \beta_{12} X_1 X_2 + \dots + \beta_{ij} X_i X_j + \varepsilon \quad (3)$$

A Figura 2.7 a seguir mostra o tipo de SR gerada nos modelos lineares, onde a região em vermelho indica os maiores pontos no gráfico:




Figura 2.7: Superfície de Resposta de modelos lineares.

Fonte: Gomes (2013).

Contudo, caso exista curvatura no sistema, então a função de aproximação do modelo mais utilizada é um polinômio de ordem superior, como o modelo de segunda ordem representado pela Equação 4:

$$\hat{y} = \beta_0 + \sum_{i=0}^k \beta_i X_i + \sum_{i=0}^k \beta_{ii} X_i^2 + \sum_{i < j} \sum \beta_{ij} X_i X_j + \varepsilon \quad (4)$$

A Figura 2.8 a seguir mostra o tipo de SR gerada nos modelos de segunda ordem (quadráticos):




Figura 2.8: Superfície de Resposta de modelos de segunda ordem.

Fonte: Gomes (2013).

Segundo Box e Draper (1987), os modelos de primeira ordem (sistemas sem curvatura) e os modelos de segunda ordem (sistemas com curvatura) são capazes de representar quase todos os problemas referentes à superfícies de resposta. Como um dos objetivos do uso da MSR é a otimização das mesmas, recomenda-se o uso de modelos de segunda ordem, considerando que a curvatura apresentada por estes modelos define a localização de um ponto estacionário.

Porém, de acordo com Montgomery (2005), é bem improvável que qualquer modelo polinomial seja considerado uma boa aproximação do modelo real em todo o espaço experimental. Esta aproximação só pode ser considerada adequada para uma região específica.

Ainda segundo o mesmo autor, o método dos mínimos quadrados ordinários (*Ordinary Least Squares – OLS*) é o algoritmo usado para estimar os coeficientes de modelos como: fatoriais completos, fracionados ou superfície de resposta. Sendo assim, o OLS é

usado para estimar os regressores do modelo polinomial, que podem ser representados matricialmente na Equação 5:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (5)$$

Sendo \mathbf{X} a matriz de fatores codificados e \mathbf{Y} a resposta.

De modo geral, a curvatura tende a se apresentar pequena quando se está num ponto do espaço experimental distante do ótimo. Isso evidencia que um modelo de primeira ordem é apropriado para representar o sistema. Nesses casos, deve-se caminhar em direção à região que contém ponto de ótimo (ou ponto estacionário), a fim de se poder usar o modelo polinomial de segunda ordem (modelo quadrático), que é um modelo mais elaborado. Mas nem sempre isso pode ser feito, como será visto mais adiante, o segundo modelo otimizado nessa dissertação está numa região linear e, portanto, distante do ponto estacionário. Porém, não foi possível ir ao encontro da região de curvatura, onde se encontra o ponto de ótimo, devido às restrições do segundo modelo de simulação. Sendo assim, foi usado o modelo linear.

Segundo Paiva (2006), a estimação de coeficientes definidos pelos modelos das equações lineares e quadráticas é feita usando-se o OLS, que constrói a função aproximada que relaciona a resposta de interesse com as variáveis do processo. Depois que o modelo experimental for construído, este deve ser verificado segundo sua significância estatística através de um procedimento de ANOVA. Este teste de significância é importante para avaliar se o modelo é estatisticamente significativo, além de verificar quais entre os termos do modelo são significativos e quais podem ser eliminados da análise. O ajuste representa o percentual dos dados observados na resposta que o modelo matemático consegue explicar, e é representado pelo coeficiente de determinação R^2 . Associado a este coeficiente, encontra-se o R^2 ajustado ($R^2_{adj.}$), que é uma medida alternativa ao coeficiente de determinação. O R^2 ajustado penaliza a inclusão de regressores pouco explicativos, combatendo a tendência de superestimação da variação atual nos dados, feita pelo R^2 , quando um maior número de variáveis é inserido. Uma explicação mais detalhada sobre o ajuste dos modelos, o teste de falta de ajuste (*Lack-of-fit*) e a análise de resíduos será explicada mais adiante.

Ainda segundo Paiva (2006), a finalidade da MSR é determinar um ponto ótimo para o sistema ou então uma região que atende às especificações operacionais deste, ou seja, onde as respostas estão acima de um valor mínimo requerido por algum processo. Os procedimentos

de alcance do ponto ótimo da metodologia garantem convergência para somente um ótimo local. Os pontos centrais são os responsáveis para avaliar a presença de curvatura no modelo.

2.4.5.1. Falta de ajuste

De acordo com Montgomery (2005), os pontos centrais também proporcionam a obtenção de uma estimativa do erro experimental, fazendo com que a soma de quadrados residual (SS_e) seja discriminada em dois componentes, mostrados na Equação (6):

$$SS_e = SS_{pe} + SS_{lof} \quad (6)$$

Onde:

SS_{pe} - a soma de quadrados devida ao erro puro;

SS_{lof} - a soma de quadrados devido à falta de ajuste do modelo escolhido.

SS_{lof} é uma soma quadrática ponderada dos desvios encontrados entre a resposta média em um dado nível da variável independente e o valor correspondente ajustado. O valor ajustado é a estimativa fornecida pelo modelo de regressão escolhido para os valores das variáveis independentes em uma dada observação. Se o valor ajustado possuir um valor numérico muito próximo ao valor das médias das respostas, então, há um forte indício que o modelo de regressão escolhido é o mais correto.

A estatística de teste para a falta de ajuste pode, então, ser escrita na forma mostrada na Equação (7):

$$F_0 = \frac{SS_{lof}/(m-p)}{SS_{pe}/(n-m)} \quad (7)$$

Onde:

m - número de níveis das variáveis de entrada;

n - número de observações de uma dada resposta;

p - número de parâmetros que devem ser estimados pelo modelo.

Há $m-p$ graus de liberdade associados à SS_{lof} porque existem m níveis de x e p graus de liberdade perdidos em função dos p parâmetros que devem ser estimados pelo modelo.

Uma vez que existem n_i-1 graus de liberdade associados ao erro puro em cada nível, o número de graus de liberdade para o termo de erro puro é igual a $n-m$.

Quando a estatística de F_0 assumir valores menores que o nível de significância escolhido, então, haverá evidência suficiente para se aceitar a hipótese nula de que a diferença

tre o valor ajustado e a média observada é nula. Logo, não haverá falta de ajuste na estimativa proporcionada pelo modelo escolhido.

2.4.5.2. Teste de significância dos modelos

O teste de significância é medido através do R quadrático e é realizado como um procedimento de ANOVA. A significância do modelo é avaliada encontrando-se a estatística F, que é a razão entre a média quadrática dos termos de regressão e a média quadrática do erro. A mesma é comparada com o valor crítico de F ($F_{\text{crítico}}$) para um dado nível de significância do modelo, se F for maior que $F_{\text{crítico}}$ então o modelo é adequado (MONTGOMERY, 2005).

O R quadrático do modelo pode ser aumentado ou diminuído de acordo com o teste individual de significância de cada coeficiente, o que pode conduzir à otimização do modelo através da eliminação ou da adição de termos. Se um fator é significativo, então ele é adequado ao modelo e deve ser mantido. Caso contrário, deve ser eliminado, o que pode fazer aumentar R quadrático, além de fazer diminuir o erro residual e a falta de ajuste do modelo. Além disso, a retirada de qualquer termo deve obedecer ao princípio da Hierarquia. Este princípio postula que quando um termo de ordem alta é mantido no modelo, o de ordem baixa que o compõe também deve ser conservado.

2.4.5.3. Análise de resíduos

Outra característica a ser observada para a adequação dos modelos é a análise de resíduos, que verifica se há distorções nos dados. Somente depois da dessa análise pode-se dizer que os dados são confiáveis e, portanto, o modelo. Segundo Montgomery (2005), o resíduo é a diferença entre o valor observado e o valor ajustado correspondente, conforme a Equação (8). Os resíduos devem ser normais, aleatórios e não correlacionados.

$$e_i = y_i - \hat{y}_i \quad (8)$$

Onde:

e_i - erro ou resíduo;

y_i - valor observado experimentalmente;

\hat{y}_i - Valor previsto pelo modelo.

De acordo com Montgomery e Runger (2003), testes de hipóteses e estimação do intervalo requerem que os erros sejam normalmente distribuídos. Essa normalidade é verificada através do gráfico de probabilidade normal dos resíduos, um histograma de

resíduos que deve representar uma distribuição normal, apesar de pequenas distorções na normalidade serem esperadas quando o tamanho da amostra é pequeno. A plotagem dos resíduos lembrará uma linha reta e se algum ponto mostrar um afastamento anormal em relação aos demais será chamado de *outlier*.

2.4.5.4. Arranjo composto central

Entre os arranjos que Montgomery (2005) cita utilizados para a aplicação da SR, o arranjo composto central (*Central Composite Design - CCD*) é o mais utilizado na prática para ajustar um modelo de SR de segunda ordem devido à sua eficiência em relação ao relativo baixo número de corridas requeridas. O valor alfa está relacionado à distância do ponto central aos pontos axiais, este ponto pode ser customizado e, no caso dessa dissertação, como está se utilizando de variáveis inteiras, utilizou-se um alfa (α) igual a dois.

Esse arranjo é formado por três conjuntos de elementos experimentais representados pela Figura 2.9, sendo:

- Um arranjo fatorial completo ou fracionado, representado pelos pontos azuis;
- Um conjunto de réplicas do ponto central, representado pelo ponto verde;
- Um conjunto de pontos axiais, representados pelos pontos vermelhos.




Figura 2.9: Arranjo Composto Central para dois fatores.

Fonte: Paiva (2006)

De acordo com Montgomery (2005), um arranjo do tipo CCD com k fatores, requer 2^k corridas fatoriais, $2k$ corridas axiais e um ponto central pelo menos. Porém, na prática utiliza-se de três a cinco pontos centrais, pois um CCD rotacional é aproximadamente ortogonal se forem adotados em torno de cinco pontos centrais. E o requisito de ortogonalidade do arranjo é necessário para a avaliação de quais efeitos são significativos (linear, quadrático ou de interação). Sendo assim, pode-se esperar uma boa estimativa do erro experimental. A

rotacionalidade é a propriedade da variância da resposta prevista se manter constante para qualquer ponto experimental ao longo da circunferência de raio “ α ”.

Para melhor entendimento do que foi dito no anteriormente, um exemplo de um arranjo com três variáveis é mostrado na Figura 2.10, onde pode-se perceber que existem oito pontos fatoriais ($2^3 = 8$) e seis pontos axiais ($2 \times 3 = 6$) e 1 ponto central.




Figura 2.10: Arranjo CCD com três variáveis.
Fonte: Montgomery (2005)

2.4.5.5. Gráficos de contorno

Para finalizar a parte conceitual sobre MSR, a Figura 2.11 mostrada a seguir proporciona uma melhor visão para o entendimento dos gráficos de contorno que serão mostrados nessa dissertação. Eles são as projeções da SR no plano, apenas uma forma diferente de representação da mesma, que tem suas vantagens, como uma melhor visualização dos valores das variáveis de entrada que atingirão o ponto ótimo.

O gráfico de contorno da Figura 2.11 funciona como uma representação no plano da SR, uma vista superior, onde as linhas representam pontos onde a resposta é a mesma. Cada linha tem uma resposta diferente e percebe-se, pelo gráfico que a resposta vai aumentando quando se desloca na direção delimitada pela linha com valor igual a 96.





Figura 2.11: Gráfico de contorno.

Fonte: Montgomery (2005)

2.4.6. O DOE na Simulação

O DOE apresenta uma forma ou arranjo organizado de testes, onde são propostas mudanças nas variáveis de entrada de um processo e, depois, observadas as mudanças ocorridas nas variáveis de saída. Essa técnica permite fazer uma análise de sensibilidade das variáveis de entrada a fim de diminuir o número de variáveis que serão inseridas do *software* de otimização, diminuindo o tempo usado no programa. Além de verificar se há ou não interações entre elas. Leal *et al.* (2007) usam o DOE como uma forma de melhorar a performance da simulação, evitando a tentativa e erro como técnica usada para buscar uma otimização do modelo simulado.

Segundo Montgomery e Runger (2003), o DOE é uma maneira organizada de realizar experimentos, onde eles são planejados de maneira apropriada para que se possa analisar os experimentos, através de técnicas estatísticas, tirando conclusões válidas e realistas a respeito do mesmo. Isso acontece porque no DOE os experimentos foram planejados de maneira lógica, gerando o melhor arranjo possível para se tirar conclusões válidas com o mínimo de experimentos possível.

De acordo com Montevechi *et al.* (2008), além dos efeitos das variáveis de entrada nos resultados, calculados pelas variações nos níveis de cada variável de entrada, uma grande vantagem do DOE é que ele mostra efeitos de interações, onde o efeito de cada fator depende do nível dos outros fatores.

Caso haja um grande número de variáveis de entrada, para diminuir o número de simulações e o tempo, pode-se usar o fatorial fracionado, onde apenas uma parte de todos os experimentos possíveis são realizados e avaliados. Mesmo assim, esse arranjo consegue ser bem eficiente quando tem resoluções altas.

De maneira parecida com o trabalho de Dengiz e Belgin (2014), para buscar a otimização será utilizada a SR, a qual produz uma função aproximada que relaciona as variáveis de entrada com as variáveis de saída. A aplicação da SR em um modelo de simulação gera uma equação que descreve matematicamente o comportamento do modelo. Essa equação é chamada de metamodelo.

Pode-se observar no livro de Montgomery e Runger (2003) que a SR é uma coleção de técnicas matemáticas e estatísticas que modelam e analisam problemas onde o interesse é otimizar uma variável de saída que depende de várias variáveis de entrada. A superfície representada pela relação funcional entre essas variáveis $y = f(x_1, x_2)$ é chamada de SR. Para a

construção de uma superfície curva, onde se pode localizar um ponto estacionário, é necessário uma função quadrática. A partir daí surge a necessidade dos pontos axiais.

Segundo Hu, Yao e Hua (2008), a SR gerada de funções de segunda ordem é eficiente na resolução da maioria dos problemas e usa pouco esforço computacional, sendo rápida e barata. E ainda é importante na comparação das influências de cada termo (variáveis ou combinações de variáveis), eliminando os não importantes.

2.5. Considerações finais deste capítulo

O presente capítulo abordou os conceitos principais em cada área de interesse desta dissertação: SED, otimização via simulação e projeto e análise de experimentos, mais especificamente a MSR, que é a metodologia usada nessa dissertação. Tudo isso foi feito para apresentar o estado da arte sobre o tema de pesquisa, gerando uma base teórica dos conceitos aplicados aqui.

3. Método de pesquisa

3.1. Considerações iniciais

Este capítulo contextualiza o método de pesquisa quantitativo, utilizado nessa dissertação: a experimentação, que será aplicada em modelos de SED. Logo após, a pesquisa quantitativa é classificada segundo sua natureza, definindo o modelo apresentado nessa dissertação.

3.2. Método de pesquisa: experimentação

O presente trabalho segue a linha de pesquisa quantitativa, pois usa métodos estatísticos para a resolução do problema. Ou seja, faz a análise de dados de maneira quantitativa utilizando as respostas dos diferentes cenários gerando, na fase final, um ponto ótimo das variáveis de entrada para maximizar a variável de saída, que nesse trabalho, será o lucro ou a produção.

O método de pesquisa utilizado é a experimentação, onde foram feitos vários experimentos, obedecendo ao arranjo fatorial completo ou fracionado do DOE, e posteriormente, foram realizados os experimentos axiais para obtenção da SR.

3.3. Classificação da pesquisa quantitativa

A pesquisa segue o modelo empírico normativo. Empírico porque, segundo Bertrand e Fransoo (2002), a simulação a ser usada traz uma realidade complexa ao computador para que possam ser feitas simulações, modificando-se as diversas variáveis do problema, realidade a qual não poderia ser resolvida por modelos matemáticos. E é normativo porque o objetivo do trabalho é estudar a maneira de otimizar um modelo de simulação, propondo um novo modo em relação ao usado atualmente.

Ainda de acordo com Bertrand e Fransoo (2002), a classificação quantitativa é dada às pesquisas onde modelos de relações causais entre variáveis de controle e variáveis de saída são desenvolvidas, analisadas e alteradas sobre um domínio específico. Por isso, este trabalho é classificado como uma pesquisa baseada em modelagem quantitativa, uma vez que se utiliza de métodos estatísticos para realizar as otimizações.

Segundo esses autores, a metodologia de pesquisa pode ser classificada como axiomática ou empírica, dentro da pesquisa quantitativa. As pesquisas axiomáticas produzem

conhecimento sobre o comportamento das variáveis dentro de um sistema e como manipulá-las no modelo. Já na pesquisa empírica, procura-se imitar um sistema real transmitindo-o ao computador. Neste tipo de pesquisa, os resultados teóricos são aplicados em processos reais.

Ainda existe a classificação das pesquisas por serem descritivas ou normativas. As descritivas, como o próprio nome traduz, procura compreender e descrever um modelo, explicando e analisando as características do mesmo. Já a normativa procura desenvolver novas maneiras, estratégias e ações para resolver algum problema, e assim o faz, comparando os resultados obtidos em seu trabalho com algum resultado gerado por um método convencional e usual.

Com essas explicações, pode-se resumir em quatro tipos de modelos adotados na pesquisa quantitativa:

- Axiomáticos normativos: nesse modelo a principal preocupação é desenvolver políticas, estratégias e ações para melhorar os resultados disponíveis na literatura existente.
- Axiomáticos descritivos: os trabalhos que seguem este tipo de pesquisa estão interessados em analisar o modelo, que conduz ao entendimento e explicação das características do mesmo.
- Empíricos descritivos: os pesquisadores estão interessados em criar um modelo que adequadamente descreve relações causais que podem existir na realidade, conduzindo ao entendimento dos processos atuais.
- Empíricos normativos: existe o interesse em desenvolver políticas, estratégias ou ações para melhorar um sistema real corrente.

Nessa dissertação foi utilizado este último caso, o modelo de pesquisa empírico normativo. Empírico porque o trabalho usa simulações de sistemas reais de manufatura que foram transmitidos ao computador por meio da simulação, e através dos sucessivos experimentos chega-se às conclusões do trabalho. E normativo porque o objetivo desse trabalho é utilizar MSR comparando-a a métodos convencionais de otimização.

Para uma visualização geral tem-se a Figura 3.1 que, de acordo com as definições de Turrioni e Mello (2012), apresenta as classificações da pesquisa científica segundo alguns critérios, como: natureza, objetivos, forma de abordar o problema e métodos utilizados.

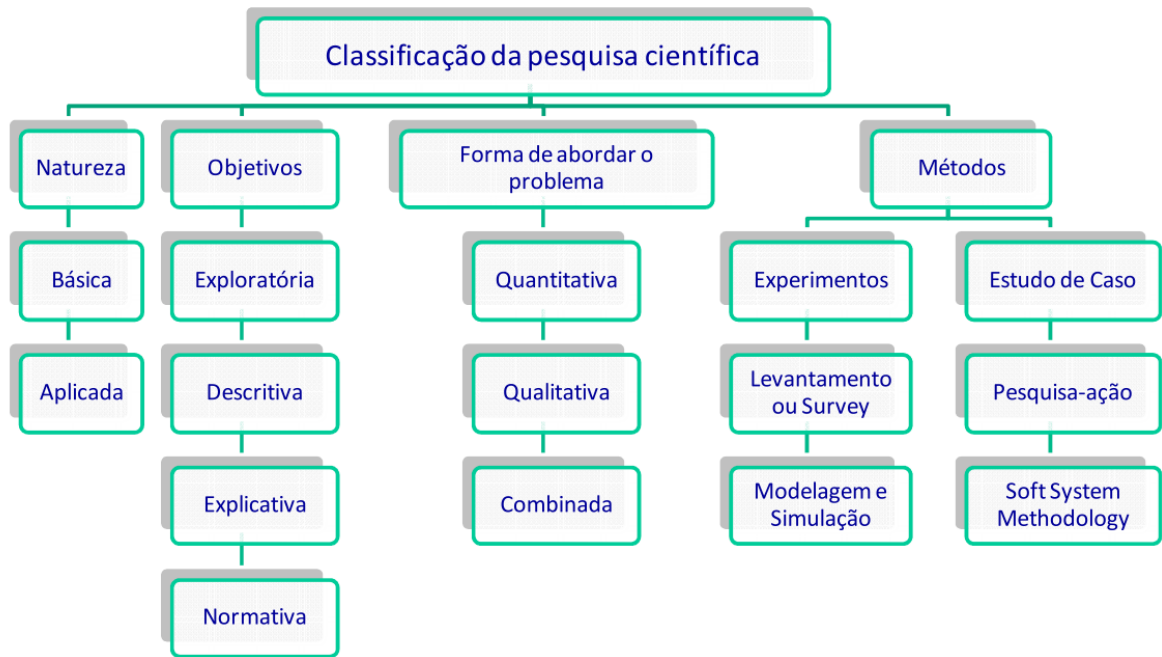


Figura 3.1: Classificação da pesquisa científica.

Fonte: Turrioni e Mello (2012)

Para resumir o que foi dito anteriormente, segundo Turrioni e Mello (2012), essa dissertação será classificada da seguinte maneira:

- Quanto à natureza: aplicada, visto que o presente trabalho caracteriza-se por seu interesse prático, os resultados serão aplicados ou utilizados imediatamente na solução dos problemas que ocorrem na realidade.
- Quanto ao objetivo: normativa, pois procura desenvolver novas maneiras, estratégias e ações para resolver algum problema, comparando os resultados alcançados com os resultados usuais para resolver determinado problema.
- Quanto à forma de abordar o problema: quantitativa, uma vez que considera que tudo pode ser quantificável, traduzindo em números, as opiniões e informações obtidas para classificá-las e analisá-las numericamente. Ou seja, é uma análise mais objetiva do que a abordagem qualitativa. Também requer o uso de recursos e de técnicas estatísticas.
- Quanto aos métodos: experimental, pois ele é empregado quando se determina um objeto de estudo (que nesse caso são os modelos de simulação). Neste método, selecionam-se as variáveis que seriam capazes de influenciá-los, definem-se as formas de controle e a observação dos efeitos que a variável produz no objeto de estudo.

Ainda de acordo com Turrioni e Mello (2012), é de vital importância reafirmar que a principal característica da pesquisa experimental é que o pesquisador/experimentador tem total controle sobre os valores que as variáveis independentes irão assumir. Em outras palavras, é o pesquisador quem controla os valores que serão experimentados. Por usar de técnicas de análise estatísticas, trata-se de um método de pesquisa quantitativo, onde o objetivo do pesquisador ao fazer uso do mesmo é demonstrar as relações entre as variáveis de entrada entre si, e com a variável de saída, ou seja, mostrar as interações e efeitos de cada variável de entrada na variável de saída.

3.4. Etapas de uma pesquisa em experimentação

Neste trabalho não foram feitos os modelos de simulação, foram adotados modelos prontos para realizar os experimentos. Logo, seguiu-se o método de experimentação, que de acordo com Nakano (2008) é o estudo da relação de causa e efeito entre as variáveis de entrada e saída de um sistema sob condições controladas pelo pesquisador. Nesse trabalho foram feitos experimentos completamente controlados pelo pesquisador dentro da simulação, onde foram feitas modificações nas variáveis de entrada e medidos os resultados nas variáveis de saída, tudo isso seguindo o arranjo experimental de SR. Como no caso desse trabalho foram usados sistemas simulados para realizar os experimentos, gerou-se um meta-modelo para cada simulação.

Segundo Bryman (1989), a pesquisa experimental é um método quantitativo e deve ser utilizado quando o pesquisador, que possui total controle sobre o experimento, quer demonstrar as relações de causa e efeito entre as variáveis independentes e dependentes utilizando técnicas de análise estatística.

No caso de uma pesquisa experimental com delineamento fatorial, busca-se identificar os efeitos principais das variáveis de entrada e os efeitos das interações entre essas, bem como, identificar uma função de transferência do tipo $Y = f(x)$.

Desta forma, o método de pesquisa científico adotado neste trabalho foi composto pelas seguintes etapas:

- Definição de hipótese;
- Planejamento do experimento;
- Execução do experimento;
- Análise dos resultados;

- Experimento de confirmação.

A etapa de definição de hipótese é extremamente importante, uma vez que afeta todo o trabalho futuro. No caso deste trabalho, a hipótese principal a ser discutida é a já descrita no problema de pesquisa: a solução otimizada encontrada através da MSR é estatisticamente igual a encontrada através de *softwares* de otimização via simulação?

3.5. Considerações finais deste capítulo

Neste capítulo, foi apresentada a metodologia de pesquisa que será seguida para esta dissertação, a experimentação, devido às características apresentadas neste método, percebe-se que é o mais indicado para este trabalho.

Finalmente, a pesquisa é classificada, segundo Bertrand e Fransoo (2002), como empírica normativa.

Sendo assim, o próximo capítulo traz uma fundamentação teórica sobre o tema da pesquisa.

4. Metodologia de otimização utilizada

4.1. Considerações iniciais

Neste capítulo, será apresentado a metodologia de otimização proposta utilizando MSR na otimização de SED.

A princípio, são apresentadas as condições básicas para aplicação da metodologia e depois um fluxograma mostrado na Figura 4.1, a fim de se obter um melhor entendimento e uma visão geral do funcionamento desse tipo de otimização.

A finalidade da otimização é maximizar ou minimizar uma variável qualquer (variável de saída), podendo ser, por exemplo, o lucro ou o número de unidades produzidas de uma célula de produção.

4.2. Condições básicas para aplicação da metodologia

O arranjo de SR aqui utilizado requer que a amplitude entre os níveis de cada variável seja igual ou maior que quatro. Em outras palavras, a diferença entre o nível máximo e mínimo deve ser maior ou igual a quatro. Isso porque o arranjo utilizado exige os níveis: -2, -1, 0, 1 e 2. Isso acontece porque as variáveis de entrada que se usa nas simulações utilizadas aqui são números inteiros, como por exemplo, número de operadores e de máquinas. Porém, existem outros arranjos que podem trabalhar com amplitudes menores, os quais não são tratados neste trabalho.

Outra condição é que o alfa utilizado no arranjo seja igual a dois, exatamente pelo mesmo motivo anterior, as variáveis são inteiras. Por isso é preciso customizá-lo. Se isso não for feito o arranjo gerado irá pedir números reais, o que é impossível considerando que as variáveis serão inteiras. Caso haja alguma simulação onde as variáveis são reais, essa condição pode ser desconsiderada.

4.3. Fluxograma da metodologia aplicada

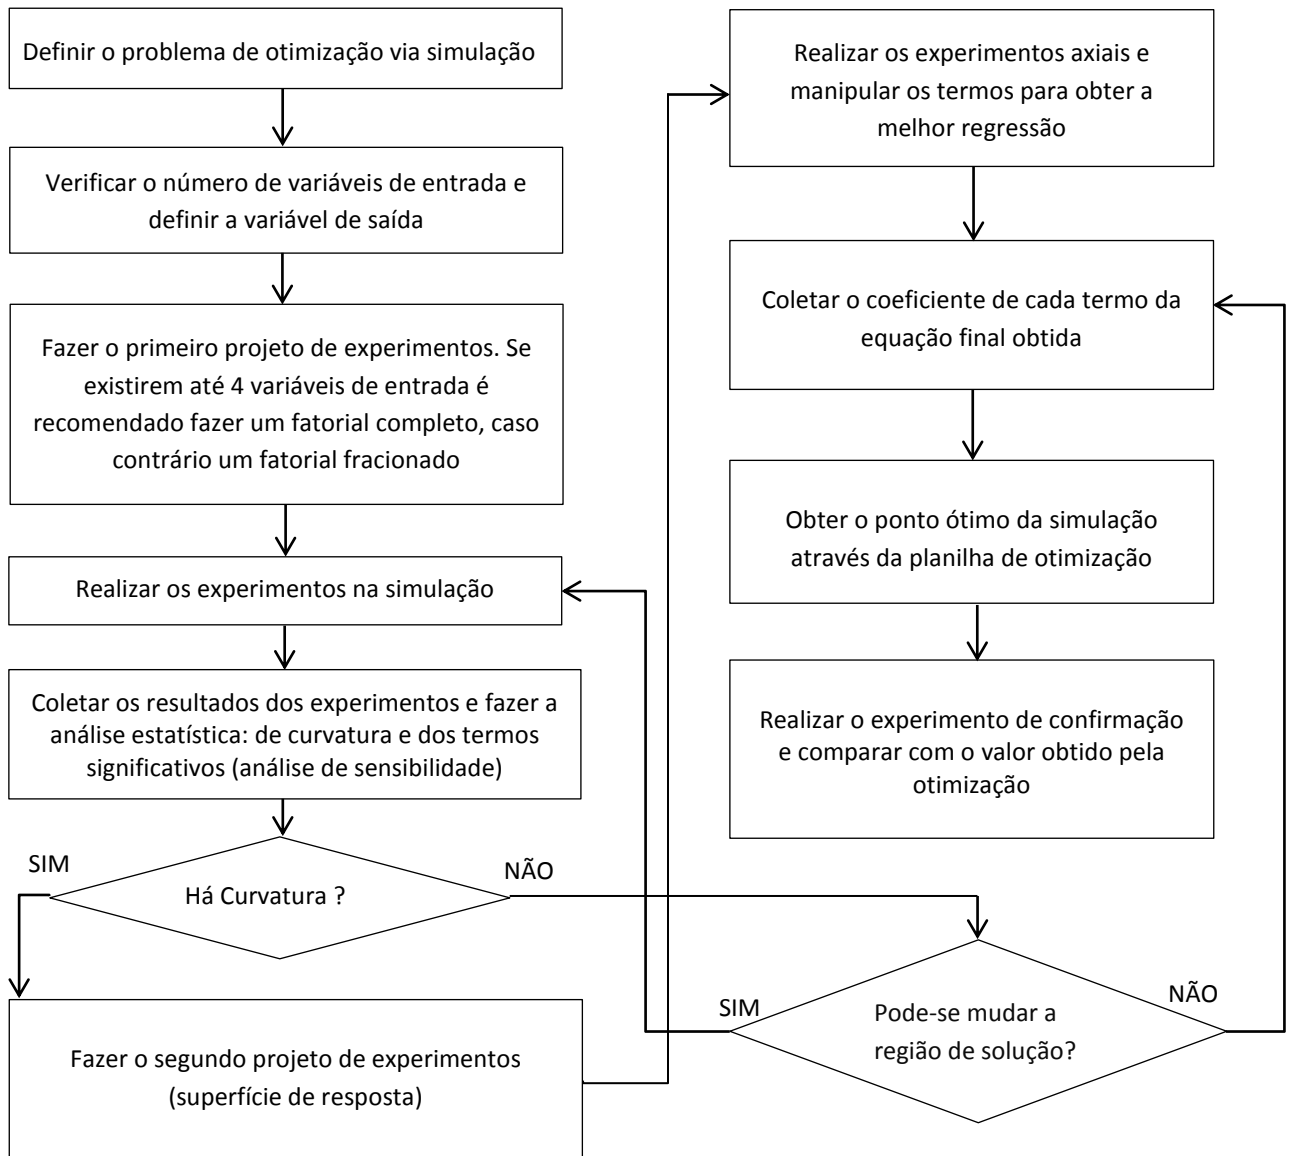


Figura 4.1: Fluxograma da utilização da MSR na otimização via simulação

Para facilitar o entendimento, são mostrados abaixo os passos da MSR utilizados neste trabalho:

- Seleção das variáveis de entrada e saída.
- Realização do experimento fatorial juntamente com o ponto central em suas cinco réplicas. O ponto central é importante para:
 - Ajudar na obtenção das variáveis relevantes, pois a relevância dessas depende do erro experimental calculado nos pontos centrais.

- Diminuição do número de experimentos, pois se elimina a necessidade de realização de duas réplicas dos experimentos fatoriais.
- Além de apresentar a curvatura que mostrará se existe ou não um ponto estacionário na região de solução proposta.
- Caso haja curvatura, realizam-se os experimentos axiais que, somados aos experimentos já realizados, geram a SR.
- Otimização da variável de saída, obtendo-se o ponto estacionário da regressão obtida com os coeficientes de cada variável de entrada isolada ou combinada à outra. Para essa fase, utiliza-se a função solver do *software Excel*, restringindo-se os valores das variáveis aos valores inteiros e à região de solução.

4.4. Considerações finais do capítulo

Neste capítulo, foi apresentado o fluxograma da metodologia para otimização de modelos de SED lineares e não lineares.

Também foram apresentadas as condições básicas para aplicação da metodologia proposta.

Com isso, procurou-se simplificar o entendimento da metodologia com o objetivo de melhorar o entendimento da parte prática do trabalho.

5. Aplicação da metodologia de superfície de resposta

5.1. Considerações iniciais

A seguir serão apresentados quatro modelos que foram otimizados através da SR. As respostas dessas otimizações, ou seja, seus pontos de ótimo serão comparadas com o ponto ótimo obtido por um *software* de otimização utilizado no mercado em todos os objetos de estudo, além de comparar com o ótimo global, nos dois últimos.

5.2. Objeto de estudo 1

O primeiro experimento foi feito em um modelo de simulação, já testado e validado anteriormente, de uma célula de produção de equipamentos bélicos. Nesta célula existem 4 grupos de operadores que executam atividades diferentes. A Figura 5.1 representa o modelo implementado no software *ProModel*. As variáveis de decisão desse problema de otimização foram definidas como sendo o número de operadores por grupo de trabalho na célula (MIRANDA, 2012).




Figura 5.1: Modelo implementado no *ProModel* para o primeiro objeto de estudo

5.2.1. Delineamento de experimentos

Para começar a explicar a parte prática do trabalho, é apresentada a Tabela 5.1, a qual contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que conterà uma SR linear ou quadrática, considerando a ausência ou presença de curvatura nessa região. Caso haja, existirá ponto estacionário dentro dessa região (que seria o ponto ótimo do modelo), fato confirmado por Montgomery e Runger (2003), que servirá para todos os modelos dessa dissertação.

A simulação contém quatro variáveis a serem otimizadas, que correspondem ao número de operadores em cada um dos quatro setores da célula de produção analisada. A variável de saída é o lucro, que dependerá da quantidade produzida descontado o valor gasto com mão-de-obra.

Tabela 5.1: Decodificação dos níveis em número de operadores

Variáveis	Níveis				
	-2	-1	0	1	2
Número de operadores tipo 1	1	2	3	4	5
Número de operadores tipo 2	1	2	3	4	5
Número de operadores tipo 3	1	2	3	4	5
Número de operadores tipo 4	1	2	3	4	5

Devido ao número de variáveis (quatro) foi possível fazer um experimento fatorial completo que contém dezesseis pontos cúbicos e cinco centrais, totalizando vinte e um experimentos. É apresentada a Tabela 5.2, que contém os experimentos:

Tabela 5.2: Experimentos fatoriais e centrais

Ordem	Tipo	A	B	C	D	Lucro
1	1	-1	-1	-1	-1	31666
2	1	1	-1	-1	-1	29866
3	1	-1	1	-1	-1	98296
4	1	1	1	-1	-1	96496
5	1	-1	-1	1	-1	29334
6	1	1	-1	1	-1	27534
7	1	-1	1	1	-1	171394
8	1	1	1	1	-1	169594
9	1	-1	-1	-1	1	29946
10	1	1	-1	-1	1	28146
11	1	-1	1	-1	1	96576
12	1	1	1	-1	1	94776
13	1	-1	-1	1	1	27614
14	1	1	-1	1	1	25814
15	1	-1	1	1	1	169674
16	1	1	1	1	1	167874
17	0	0	0	0	0	115492
18	0	0	0	0	0	115150
19	0	0	0	0	0	115106
20	0	0	0	0	0	114900
21	0	0	0	0	0	115178

Vale lembrar que, todos os experimentos (fatorial completo e superfície de resposta) foram feitos com a média do lucro, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise.

A Tabela 5.2 mostra os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial completo e a segunda parte (tipo 0) mostra o ponto central em suas cinco réplicas.

5.2.2. Fatorial completo

Na Tabela 5.3 se encontram os resultados estatísticos da análise do experimento fatorial completo. Nesta fase, é feita a análise de sensibilidade de cada variável de entrada no resultado, no caso o lucro, e a presença ou não de curvatura na região de solução.

Tabela 5.3: Resultado do experimento fatorial completo

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		80912,5	53,18	1521,36	0,000
A	-1800,0	-900,0	53,18	-16,92	0,000
B	104345,0	52172,5	53,18	980,97	0,000
C	35383,0	17691,5	53,18	332,64	0,000
D	-1720,0	-860,0	53,18	-16,17	0,000
A*B	0,0	0,0	53,18	0,00	1,000
A*C	-0,0	-0,0	53,18	-0,00	1,000
A*D	-0,0	-0,0	53,18	-0,00	1,000
B*C	37715,0	18857,5	53,18	354,57	0,000
B*D	0,0	0,0	53,18	0,00	1,000
C*D	0,0	0,0	53,18	0,00	1,000
A*B*C	0,0	0,0	53,18	0,00	1,000
A*B*D	0,0	0,0	53,18	0,00	1,000
A*C*D	-0,0	-0,0	53,18	-0,00	1,000
B*C*D	0,0	0,0	53,18	0,00	1,000
A*B*C*D	-0,0	-0,0	53,18	-0,00	1,000
<i>Ct Pt</i>		34252,7	109,00	314,26	0,000

R-quadrático (ajustado) = 100,00 %




Figura 5.2: Gráfico de sensibilidade das variáveis de entrada e suas interações

Percebe-se pela Figura 5.2 que as variáveis A e D não têm grande influência no resultado, sendo, portanto, eliminadas do experimento. É possível notar pela Tabela 6 que há curvatura na região, pois $ct\ pt < 0,05$, existindo, portanto, um ponto ótimo. Nota-se um R-quadrático (ajustado) = 100%, o que mostra que o modelo com suas variáveis é satisfatório na previsão do resultado.

A Tabela 5.4 mostra a análise fatorial feita apenas com as variáveis B e C. Essa tabela foi obtida através da manipulação das variáveis observando os valores dos *P-values*.

Tabela 5.4: Resultado do experimento fatorial completo eliminando termos menos significantes

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		80913	312,3	259,05	0,000
B	104345	52172	312,3	167,04	0,000
C	35383	17692	312,3	56,64	0,000
B*C	37715	18857	312,3	60,37	0,000
Ct Pt		34253	640,1	53,51	0,000

R-quadrático (ajustado) = 99,95%

Confirma-se aqui que há curvatura e que essas variáveis são importantes no resultado. Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com 99,95% de confiança.

5.2.3. Superfície de resposta

A Tabela 5.5 mostra os pontos axiais que são utilizados para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas oito experimentos, que são os pontos axiais.

Tabela 5.5: Experimentos axiais

Ordem	Tipo	A	B	C	D	Lucro
1	-1	-2	0	0	0	84009
2	-1	2	0	0	0	113692
3	-1	0	-2	0	0	-47466
4	-1	0	2	0	0	147048
5	-1	0	0	-2	0	-18960
6	-1	0	0	2	0	121208
7	-1	0	0	0	-2	17598
8	-1	0	0	0	2	113772

Esses pontos são importantes para se obter uma regressão quadrática, onde se tem um ponto estacionário, que é o objetivo principal da SR. Nota-se que aqui utiliza-se somente as variáveis importantes na análise de sensibilidade para obtenção da regressão. A Tabela 5.6 mostra os resultados da SR.

Tabela 5.6: Resultado do experimento de Superfície de Resposta

Termo	Coefficientes	SE Coeficientes	T	P
Constant	102512	6430	15,943	0,000
B	50991	4353	11,714	0,000
C	23475	4353	5,393	0,000
B*B	-12073	4059	-2,975	0,007
C*C	-11740	4059	-2,893	0,008
B*C	18858	5331	3,537	0,002

R -quadrático (ajustado) = 87,09%

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com um bom grau de confiança, pois o R -quadrático (ajustado) é igual a 87,09%.

Tabela 5.7: Falta de ajuste

	DF	SS	MS	F	P-value
Erro residual	23	10459392339	454756189		
Falta de ajuste	3	1864225234	621408411	1,45	0,259
Erro puro	20	8595167105	429758355		

É possível notar pela Tabela 5.7 que o modelo não possui falta de ajuste, uma vez que a falta de ajuste é igual a 0,259, maior que 0,05. O valor 0,05 é usado devido a confiança de 95% utilizada na MSR.

O modelo é capaz de prever o resultado com confiança, afirmação comprovada também pela regressão que tem P -value = 0.

Os coeficientes da equação quadrática originada pelos experimentos de SR são mostrados na Tabela 5.8, e serão usados para obtenção do ponto ótimo de lucro, que será feita usando-se a função *solver* do *software Excel*.

Tabela 5.8: Coeficientes dos termos usados na otimização

Termos	Coeficientes
Constante	102512
B	50991
C	23475
B*B	-12073
C*C	-11740
B*C	18858

5.2.4. Ponto ótimo

Finalmente, a formulação a ser otimizada é representada pela Equação (9), que multiplica os coeficientes aos seus respectivos fatores:

$$Lucro = 102512 + 50991 * B + 23475 * C - 12073 * B^2 - 11740 * C^2 + 18858 * BC \quad (9)$$

Através dos coeficientes chega-se ao ponto ótimo, mostrado na Tabela 5.9. Os valores de B e C são 1 e 1, respectivamente, que correspondem a 4 operadores em cada um desses setores da célula de produção. As variáveis não analisadas no experimento, no caso A e D, são pouco significativas no experimento e, portanto, serão deixadas no estado atual, que é o nível -1, pois não há a necessidade de se contratar mais operadores visto que isso não é importante. Esse nível corresponde a 2 operadores.

Logo, o ponto ótimo corresponde a: 2, 4, 4 e 2 operadores para os setores A, B, C e D, respectivamente. É importante ressaltar que se utilizou a restrição de valores inteiros, pois não teria sentido obter valores decimais, uma vez que o número de operadores é uma variável inteira.

Tabela 5.9: Cálculo do ponto ótimo

Fatores	Coefficientes	$z(x)$
Constante	102512	1
B	50991	1
C	23475	1
BB	-12073	1
CC	-11740	1
BC	18858	1
Y (Lucro)	172023,00	
	Restrição esférica $g(x)$	2

Percebe-se que, na otimização obtida pela SR, o valor do lucro é de R\$ 172.023,00. Esse valor é válido porque se encontra dentro da restrição esférica $g(x)$, que é o valor de alfa ao quadrado ($\alpha = 2$).

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na Tabela 5.8 (2, 4, 4, 2) 30 vezes e calculando a média, tem-se um lucro de R\$ 171.394,00. Percebe-se que, esse valor não está muito distante do valor ótimo obtido na regressão, pois o desvio padrão desse ponto é R\$ 1.047,20.

Quando se utiliza o *software SimRunner*, no modo moderado, tem-se um lucro de R\$ 172.823,00 com 115 experimentos, que é um número muito maior de experimentos para um lucro bem próximo ao obtido pela SR, que só faz 29 experimentos. Sendo que o desvio padrão desse ponto é R\$ 1.587,35.

Além disso, o valor das variáveis de entrada é 2, 5, 4, 2 para A, B, C e D, respectivamente. Esses valores também estão bem próximos dos obtidos na SR, os quais só terão variação em B, saindo de 4 para 5 operadores. Porém, apesar dos resultados serem muito próximos o *SimRunner* apresentou um resultado ligeiramente maior do que a MSR.

Na Figura 5.3, pode-se observar que os resíduos são normais pois o *P-value* é maior que 0,05, o que viabiliza o uso dos dados obtidos.




Figura 5.3: Teste de normalidade dos resíduos.

A figura 5.4 mostra que os resíduos são não correlacionados, o que também pode ser constatado pelo coeficiente de Pearson que é zero e pelo *P-Value* que é 1,000.




Figura 5.4: Teste de correlação dos resíduos.

A Figura 5.5 apresenta o gráfico de contorno, que funciona como uma vista superior da curva de SR, onde as linhas representam diferentes pontos onde a resposta é a mesma. Percebe-se que na região situada acima da linha de 150000 é onde se encontra o ponto ótimo.




Figura 5.5: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.

A Figura 5.6 mostra a SR do modelo, ou seja, os diferentes valores de lucro (mostrados no eixo vertical) para as variáveis de entrada B e C.




Figura 5.6: Superfície de Resposta entre os fatores B e C

Fazendo-se uma análise visual da SR (Figura 5.6) e do gráfico de contorno (Figura 5.5), que funciona como uma vista superior, pode-se concluir que o ponto de máximo lucro se situa no ponto $B = 2$ e $C = 2$, porém este ponto se situa fora da restrição esférica mostrada na Equação (12):

$$g(x) \leq \text{alfa}^2 \quad (10)$$

$$\text{alfa} = 2 \quad (11)$$

$$g(x) \leq 4. \quad (12)$$

Estando fora dessa região, o modelo não serve como referência para previsão do lucro. Por essa razão, o ponto ótimo codificado calculado foi $B = 1$ e $C = 1$, que corresponde a 4 operadores em cada célula. Para fazer isso foi usada a restrição de valores inteiros no solver para as variáveis de entrada B e C, como foi dito anteriormente.

O objeto de estudo 1 foi usado para publicação no SBPO 2014, dentro do artigo de Rodrigues *et al.* (2014): “Uso da técnica de superfície de resposta na otimização da simulação computacional do processo”.

5.3. Objeto de estudo 2

O segundo objeto de estudo foi feito em um modelo de simulação previamente testado e validado no trabalho de Costa (2010), de uma célula de produção de *transponders*. A simulação contém seis variáveis a serem otimizadas, as três primeiras correspondem ao número de operadores em cada um dos três setores da célula de produção analisada, as outras são correspondentes ao número de bastidores (que são espécies de suportes para os *transponders*) utilizados em cada um desses setores. A variável de saída é o lucro, que dependerá da quantidade produzida descontado o valor gasto com mão de obra. A Figura 5.7 representa o modelo implementado no software *ProModel*.




Figura 5.7: Modelo implementado no *ProModel* para o segundo objeto de estudo

5.3.1. Delineamento de experimentos

A Tabela 5.10 contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que conterà uma SR linear ou quadrática, considerando a ausência ou presença de curvatura nessa região. A simulação contém seis variáveis a serem otimizadas.

Tabela 5.10: Decodificação dos níveis em número de operadores e bastidores

Variáveis	Níveis				
	-2	-1	0	1	2
Número de operadores tipo 1	1	2	3	4	5
Número de operadores tipo 2	1	2	3	4	5
Número de operadores tipo 3	1	2	3	4	5
Número de bastidores tipo 1	1	2	3	4	5
Número de bastidores tipo 2	1	2	3	4	5
Número de bastidores tipo 3	1	2	3	4	5

Seguindo os mesmos passos do exemplo anterior, apresenta-se a Tabela 5.11 que contém os experimentos fatoriais e centrais. Nesse objeto de estudo utilizou-se o fatorial fracionado por se tratar de seis variáveis de entrada. Se fosse um fatorial completo seria necessário sessenta e quatro pontos cúbicos, mas como foi utilizado o fatorial fracionado necessitou-se de apenas trinta e dois pontos cúbicos nessa fase.

Vale lembrar ainda que, todo o experimento (fatorial fracionado e SR) foi feito com a média do lucro, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise.

A Tabela 5.11 mostra todos os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial fracionado, a segunda parte (tipo 0) mostra o ponto central em suas cinco réplicas.

5.3.2. Fatorial fracionado

Na Tabela 5.12 se encontram os resultados estatísticos da análise do experimento fatorial fracionado. Nesta fase, é feita a análise de sensibilidade de cada variável de entrada no resultado, no caso o lucro, e a presença ou não de curvatura na região de solução.

Tabela 5.12 : Resultado do experimento fatorial fracionado

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		2275711	602	3780,06	0
A	-18423	-9211	602	-15,3	0,000
B	-15042	-7521	602	-12,49	0,000
C	-13695	-6848	602	-11,37	0,000
D	-420	-210	602	-0,35	0,745
E	388	194	602	0,32	0,763
F	-342	-171	602	-0,28	0,790
A*B	320	160	602	0,27	0,803
A*C	-68	-34	602	-0,06	0,958
A*D	-449	-224	602	-0,37	0,728
A*E	414	207	602	0,34	0,748
A*F	-61	-31	602	-0,05	0,962
B*C	-135	-68	602	-0,11	0,916
B*D	-426	-213	602	-0,35	0,741
B*E	521	261	602	0,43	0,687
B*F	-202	-101	602	-0,17	0,875
C*D	277	139	602	0,23	0,829
C*E	18	9	602	0,01	0,989
C*F	-24	-12	602	-0,02	0,985
D*E	-571	-286	602	-0,47	0,660
D*F	-651	-326	602	-0,54	0,617
E*F	283	141	602	0,23	0,826
A*B*C	555	278	602	0,46	0,669
A*B*D	78	39	602	0,06	0,952
A*B*E	-2256	-1128	602	-1,87	0,134
A*B*F	-595	-297	602	-0,49	0,647
A*C*D	-2237	-1119	602	-1,86	0,137
A*C*E	549	274	602	0,46	0,672
A*C*F	315	158	602	0,26	0,806
A*D*E	-1027	-514	602	-0,85	0,442
A*D*F	211	106	602	0,18	0,869
A*E*F	-406	-203	602	-0,34	0,753
Ct		-692	1637,7	-0,42	0,694

R-quadrático (ajustado) = 93,26 %




Figura 5.8: Gráfico de sensibilidade das variáveis de entrada e suas interações

Percebe-se pela Figura 5.8 que as variáveis D, E e F (ou seja, o número de bastidores) não têm grande influência no resultado, sendo, portanto, eliminadas do experimento. É possível notar pela Tabela 5.12 que não há curvatura na região, pois $ct\ pt > 0,05$, isso implica que a região será plana. Será visto mais adiante que não se pode mudar essa região, pois fora dela o modelo não rodaria, visto que não se teria mais operadores.

Nota-se um R-quadrático (ajustado) = 93,26 %, o que mostra que o modelo com suas variáveis é satisfatório na previsão do resultado.

A Tabela 5.13 mostra a análise fatorial feita apenas com as variáveis A, B e C. Essa tabela foi obtida através da manipulação das variáveis observando os valores dos *P-values*.

Tabela 5.13: Resultado do experimento fatorial fracionado eliminando termos insignificantes

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante		2275711	400,9	5676,07	0
A	-18423	-9211	400,9	-22,98	0,000
B	-15042	-7521	400,9	-18,76	0,000
C	-13695	-6848	400,9	-17,08	0,000
Ct		-692	1090,6	-0,63	0,530

R-quadrático (ajustado) = 97,01 %

Confirma-se aqui que essas variáveis são importantes no resultado. Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com 97,01 % de confiança.

A partir daqui, em termos práticos, já se poderia partir para a otimização através da função solver do *Excel*, pois os termos significativos são lineares. Porém, para a obtenção das curvas que a SR proporciona é necessário fazer os experimentos axiais. Por isso seguiu-se adiante, a fim de fazer uma análise visual do comportamento do lucro na simulação, e entender porque a região não apresenta curvatura e mesmo assim não se pode mudá-la.

5.3.3. Superfície de resposta

A Tabela 5.14 são utilizados os pontos axiais para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas doze experimentos, que são os pontos axiais.

Tabela 5.14: Experimentos axiais

Ordem	Tipo	A	B	C	D	E	F	Lucro
1	-1	-2	0	0	0	0	0	2291713,33
2	-1	2	0	0	0	0	0	2257366,67
3	-1	0	-2	0	0	0	0	2292446,67
4	-1	0	2	0	0	0	0	2259006,67
5	-1	0	0	-2	0	0	0	2286220,00
6	-1	0	0	2	0	0	0	2263580,00
7	-1	0	0	0	-2	0	0	2272133,33
8	-1	0	0	0	2	0	0	2275193,33
9	-1	0	0	0	0	-2	0	2275046,67
10	-1	0	0	0	0	2	0	2273806,67
11	-1	0	0	0	0	0	-2	2276446,67
12	-1	0	0	0	0	0	2	2273806,67

Esses pontos são importantes para uma regressão quadrática, onde se pode obter um ponto ótimo, que é o objetivo principal da SR. Nota-se que, aqui, utiliza-se somente as variáveis importantes na análise de sensibilidade para obtenção da regressão. A Tabela 5.15 mostra os resultados da SR.

Tabela 5.15: Resultado do experimento de superfície de resposta

Termo	Coefficientes	SE Coeficientes	T	P
Constante	2275400	303,9	7487,15	0,00
A	-9087	336,4	-27,014	0,00
B	-7689	336,4	-22,859	0,00
C	-6610	336,4	-19,652	0,00

R-quadrático (ajustado) = 97,15 %

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado um bom grau de confiança, pois o R-quadrático (ajustado) é igual a 97,15 %.

Tabela 5.16: Falta de ajuste

	DF	SS	MS	F	P-value
Erro residual	45	203653099	4525624		
Falta de ajuste	11	30419619	2765420	1	0,86
Erro puro	34	173233480	5095102		

É possível notar pela Tabela 5.16 que o modelo não possui falta de ajuste, uma vez que a falta de ajuste é igual a 0,86, maior que 0,05.

O modelo é capaz de prever o resultado com confiança, afirmação comprovada também pela regressão que tem $P\text{-value} = 0$.

Os coeficientes da equação originada pelos experimentos de SR são mostrados na Tabela 5.17, e serão usados para obtenção do ponto ótimo de lucro, que será feita usando-se a função solver do *software Excel*.

Tabela 5.17: Coeficientes dos termos usados na otimização

Termo	Coefficientes
Constante	2275400
A	-9087
B	-7689
C	-6610

Comparando a Tabela 5.15 com a Tabela 5.17 vê-se que os coeficientes são bem próximos, provando que o modelo linear poderia ter sido usado para a otimização. Fez-se o modelo de SR para provar isso gerando seus gráficos.

5.3.4. Ponto ótimo

Finalmente, a formulação a ser otimizada é representada pela Equação (10), que multiplica os coeficientes aos seus respectivos fatores:

$$Lucro = 2275400 - 9087 * A - 7689 * B - 6610 * C \quad (10)$$

Através dos coeficientes chegou-se ao ponto ótimo, mostrado na Tabela 5.18. Os valores de A, B e C são -2, -2 e -2, respectivamente, que correspondem a 1 operador em cada um desses setores da célula de produção.

Apesar de esse valor ficar fora da restrição esférica $g(x)$, como o modelo é linear o ponto ótimo fica localizado sempre no limite da região de solução.

As variáveis não analisadas no experimento, no caso D, E e F não são significativas no experimento e, portanto, serão deixadas no nível -2, pois não há a necessidade de se comprar

mais bastidores visto que isso não é importante. Esse nível corresponde a 1 bastidor para cada setor.

Logo, o ponto ótimo corresponde a: 1, 1, 1, 1, 1 e 1 operadores para os setores A, B, C, D, E e F, respectivamente. É importante ressaltar que foi utilizada a restrição de valores inteiros, pois não teria sentido obter valores decimais, uma vez que o número de operadores e bastidores é uma variável inteira.

Tabela 5.18: Cálculo do ponto ótimo

Fatores	Coefficientes	$z(x)$
Constante	2275400	1
A	-9087	-2
B	-7689	-2
C	-6610	-2
Y(Lucro)	2322172	

Observa-se que, na otimização obtida pela SR, o valor do lucro é de R\$ 2.322.172,00.

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na Tabela 5.16 (1, 1, 1, 1, 1, 1) 30 vezes e calculando a média, tem-se um lucro de R\$ 2.321.113,33. Percebe-se que, esse valor não está muito distante do valor ótimo obtido da regressão.

Quando utiliza-se o *software SimRunner*, no modo moderado, tem-se um lucro de R\$ 2.321.113,33 com 188 experimentos, que é um número muito maior de experimentos para um lucro igual ao obtido pela SR, que só faz 49 experimentos. Além disso, o valor das variáveis de entrada decodificadas são todos iguais a 1 para A, B, C, D, E e F quando utiliza-se o *SimRunner*. Esses valores também são iguais aos obtidos na SR.

Como o ponto ótimo foi o mesmo, o desvio padrão também foi o mesmo, igual a R\$ 13.857,27.

Na Figura 5.9, pode-se observar que os resíduos são normais devido ao valor do *P-value* e a proximidade dos pontos à reta, o que viabiliza o uso dos dados obtidos.




Figura 5.9: Teste de normalidade dos resíduos.

A figura 5.10 mostra que os resíduos são não correlacionados, o que também pode ser constatado pelo coeficiente de Pearson que é zero e pelo *P-Value* que é 1,000.




Figura 5.10: Teste de correlação dos resíduos.

Abaixo apresenta-se o gráfico de contorno na Figura 5.11, que funciona como uma vista superior da curva de SR, onde as linhas representam diferentes pontos onde a resposta é a mesma. Percebe-se que o ponto ótimo situa-se na região acima da linha de 2250000.

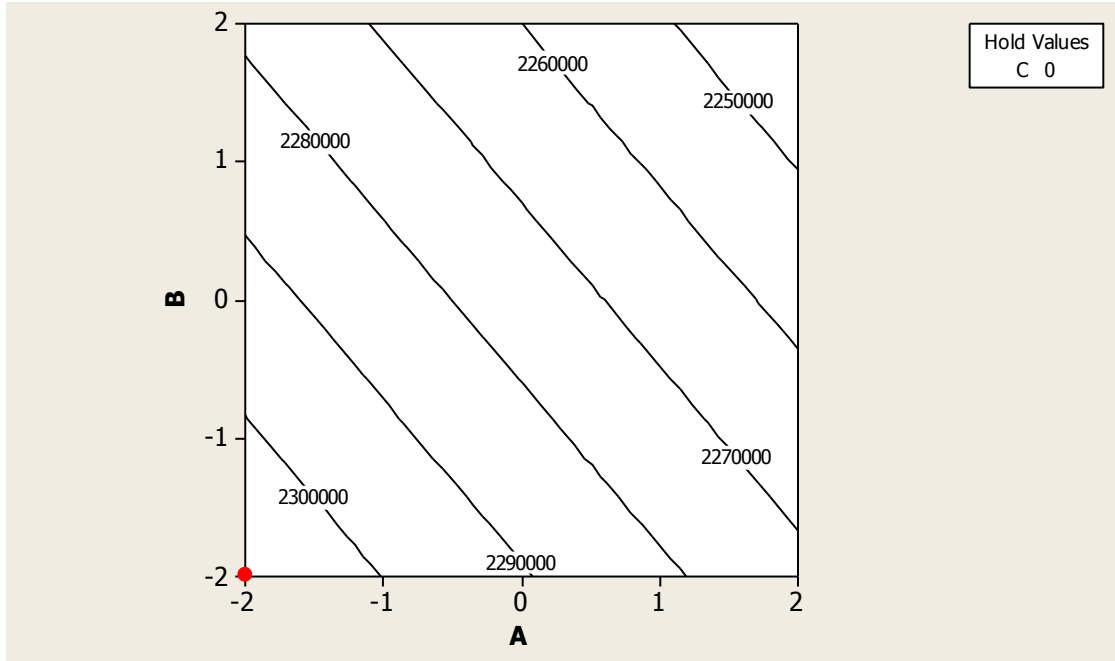


Figura 5.11: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.

Em seguida, é apresentada a respectiva SR na Figura 5.12, para o gráfico de contorno da Figura 5.10, onde se pode ter uma visualização em três dimensões do resultado. Nele é possível notar, visualmente, que o modelo é linear e que o valor máximo da variável de resposta é um dos vértices da região de solução.




Figura 5.12: Superfície de Resposta dos fatores A e B.

É importante salientar que as outras superfícies de resposta e os outros gráficos de contorno de todos os objetos de estudo são mostrados nos anexos deste trabalho, a fim de não deixar o mesmo muito repetitivo, pois suas análises são as mesmas das Figuras 5.5 e 5.6.

Fazendo-se uma análise visual das superfícies de respostas e dos gráficos de contorno, que funciona como uma vista superior, pode-se concluir que o ponto ótimo se situa no ponto $A = -2$, $B = -2$ e $C = -2$, que corresponde a 1 operador em cada um dos três setores da célula de produção. Através das curvas de SR, vê-se que o lucro tende a subir com um número menor de operadores, mas como esse número é igual a 1 para cada setor, constata-se que não se pode mudar a região de solução, pois sem operadores o modelo não rodaria.

Porém, como $g(x) = 12$, este ponto se situa fora da restrição esférica mostrada na Equação (13):

$$g(x) \leq \text{alfa}^2 \quad (11)$$

$$\text{alfa} = 2 \quad (12)$$

$$g(x) \leq 4. \quad (13)$$

Nesse caso, mesmo estando fora dessa região, utilizou-se esse ponto, pois essa região não tem curvatura. Logo, fica nítido que o lucro aumenta no limite da região de solução, diferente do que aconteceu no objeto de estudo 1, que apresentava curvatura e não se podia utilizar um ponto fora da restrição esférica.

Portanto, o ponto ótimo codificado calculado foi $A = -2$, $B = -2$ e $C = -2$, que corresponde a 1 operador em cada célula. Para fazer isso foi usada a restrição de valores inteiros no solver para as variáveis de entrada A, B e C, como foi dito anteriormente.

5.4. Objeto de estudo 3

O terceiro experimento foi feito em um modelo de simulação do trabalho de Miranda *et al.* (2012), já testado e validado anteriormente, uma lavanderia. Nesta célula existem cinco variáveis a serem otimizadas, que correspondem ao número de: lavadoras, centrífugas, secadoras e número de operadores tipo 1 e tipo 2, definidos de acordo com as atividades que realizam. A variável de saída é o peso (em kg) de roupas lavadas. A Figura 5.13 representa o modelo implementado no software *ProModel*.

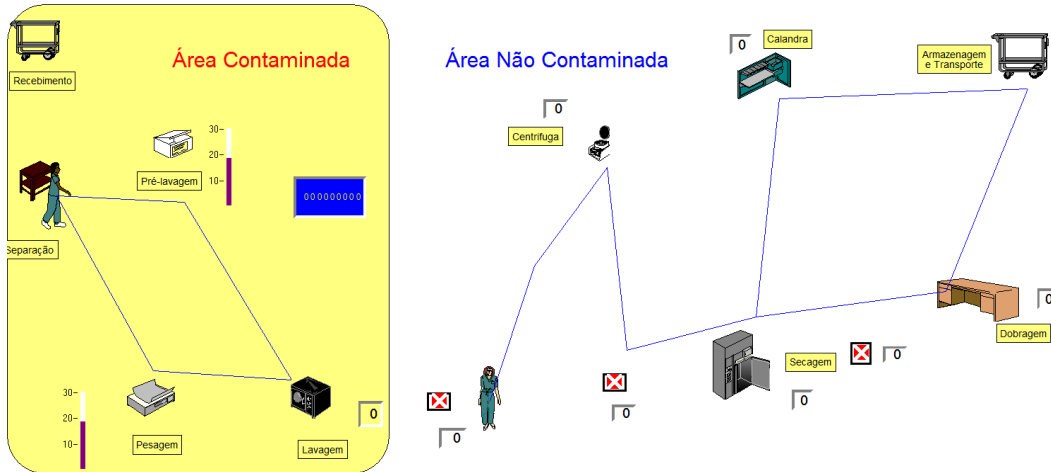


Figura 5.13: Modelo implementado no *ProModel* para o terceiro objeto de estudo

5.4.1. Delineamento de experimentos

A Tabela 5.19 contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que conterà uma SR linear ou quadrática, considerando a ausência ou presença de curvatura nessa região. A simulação contém cinco variáveis a serem otimizadas.

Tabela 5.19: Decodificação dos níveis das variáveis de entrada

Variáveis	Níveis				
	-2	-1	0	1	2
lavadoras	1	3	5	7	9
centrifugas	1	3	5	7	9
secadoras	1	3	5	7	9
operador tipo 1	1	3	5	7	9
operador tipo 2	1	3	5	7	9

Para começar a explicar a parte prática do trabalho, é apresentada a Tabela 5.20 que contém os experimentos fatoriais e centrais. Devido ao número de variáveis (cinco) foi feito um experimento fatorial fracionado que contém dezesseis pontos cúbicos e cinco pontos centrais. Se fosse feito o fatorial completo, ter-se-ia trinta e dois pontos cúbicos.

Tabela 5.20: Experimentos fatoriais e centrais

Ordem	Tipo	A	B	C	D	E	Roupas lavadas
1	1	-1	-1	-1	-1	1	5323
2	1	1	-1	-1	-1	-1	5286
3	1	-1	1	-1	-1	-1	5312
4	1	1	1	-1	-1	1	5324
5	1	-1	-1	1	-1	-1	5305
6	1	1	-1	1	-1	1	5277
7	1	-1	1	1	-1	1	5330
8	1	1	1	1	-1	-1	5295
9	1	-1	-1	-1	1	-1	5305
10	1	1	-1	-1	1	1	5277
11	1	-1	1	-1	1	1	5330
12	1	1	1	-1	1	-1	5295
13	1	-1	-1	1	1	1	5323
14	1	1	-1	1	1	-1	5286
15	1	-1	1	1	1	-1	5312
16	1	1	1	1	1	1	5324
17	0	0	0	0	0	0	5331
18	0	0	0	0	0	0	5320
19	0	0	0	0	0	0	5350
20	0	0	0	0	0	0	5332
21	0	0	0	0	0	0	5328

Vale lembrar que, todo o experimento (fatorial fracionado e MSR) foi feito com a média do peso de roupas lavadas, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise. A Tabela 5.20 mostra todos os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial fracionado, a segunda parte (tipo 0) mostra o ponto central em suas cinco réplicas.

5.4.2. Fatorial fracionado

Na Tabela 5.21 se encontram os resultados estatísticos da análise do experimento fatorial fracionado. Nesta fase é feita a análise de sensibilidade de cada variável de entrada no resultado, no caso o peso de roupas lavadas, e a presença ou não de curvatura na região de solução.

Tabela 5.21: Resultado do experimento fatorial fracionado

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante	5306,50	2,752	1928,04	0,000	
A	-22,00	-11,00	2,752	-4,00	0,016
B	17,50	8,75	2,752	3,18	0,034
C	-0,00	-0,00	2,752	-0,00	1,000
D	0,00	0,00	2,752	0,00	1,000
E	14,00	7,00	2,752	2,54	0,064
A*B	10,50	5,25	2,752	1,91	0,129
A*C	-0,00	-0,00	2,752	-0,00	1,000
A*D	-0,00	-0,00	2,752	-0,00	1,000
A*E	-4,00	-2,00	2,752	-0,73	0,508
B*C	0,00	0,00	2,752	0,00	1,000
B*D	-0,00	-0,00	2,752	-0,00	1,000
B*E	9,50	4,75	2,752	1,73	0,159
C*D	9,50	4,75	2,752	1,73	0,159
C*E	0,00	0,00	2,752	0,00	1,000
D*E	-0,00	-0,00	2,752	-0,00	1,000
Ct	Pt	25,70	5,640	4,56	0,010

R-quadrático (ajustado) = 70,34 %




Figura 5.14: Gráfico de sensibilidade das variáveis de entrada e suas interações

Percebe-se pela Figura 5.14 que o número de lavadoras e de centrífugas são as que têm maior influência no resultado. Porém, as outras variáveis e interações que aparecem no gráfico têm um peso relevante (apesar de ser menor), pois geraram uma regressão com maior *R*-quadrático quando consideradas na fase posterior de SR.

É possível notar pela Tabela 5.21 que há curvatura na região, pois $ct\ pt < 0.05$, existindo, portanto, um ponto estacionário (ótimo). Nota-se um R-quadrático (ajustado) = 70,34 %, o que mostra que o modelo com suas variáveis é satisfatório na previsão do resultado.

A Tabela 5.22 mostra a análise fatorial feita apenas com os fatores mais importantes. Essa tabela foi obtida através da manipulação das variáveis observando os valores dos *P-values* e do gráfico de Pareto.

Tabela 5.22: Resultado do experimento fatorial fracionado eliminando termos não significantes

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constante	5306,50	1,741	3048,50	0,000	
A	-22,00	-11	1,741	-6,32	0,000
B	17,50	8,75	1,741	5,03	0,001
C	-0,00	-0,00	1,741	-0,00	1,000
D	0,00	0,00	1,741	0,00	1,000
E	14,00	7,00	1,741	4,02	0,002
A*B	10,50	5,25	1,741	3,02	0,013
A*E	-4,00	-2,00	1,741	-1,15	0,277
B*E	9,50	4,75	1,741	2,73	0,021
C*D	9,50	4,75	1,741	2,73	0,021
Ct	Pt	25,70	3,567	7,20	0,000

R-quadrático (ajustado) = 88,14 %

Confirma-se aqui que há curvatura e que essas variáveis são importantes no resultado. Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com 88,14% de confiança.

5.4.3. Superfície de resposta

A seguir são utilizados os pontos axiais para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas dez experimentos, que são os pontos axiais, mostrados na Tabela 5.23.

Tabela 5.23: Experimentos axiais

Ordem	Tipo	A	B	C	D	E	Roupas lavadas
1	-1	-2	0	0	0	0	3013
2	-1	2	0	0	0	0	5286
3	-1	0	-2	0	0	0	5237
4	-1	0	2	0	0	0	5312
5	-1	0	0	-2	0	0	5305
6	-1	0	0	2	0	0	5305
7	-1	0	0	0	-2	0	5301
8	-1	0	0	0	2	0	5305
9	-1	0	0	0	0	-2	4534
10	-1	0	0	0	0	2	5357

Esses pontos são importantes para uma regressão quadrática, onde se pode obter um ponto ótimo, que é o objetivo principal dessa MSR. Nota-se que aqui utiliza-se somente as variáveis importantes na análise de sensibilidade para obtenção da regressão. A Tabela 5.24 mostra os resultados da SR.

Tabela 5.24: Resultado do experimento de superfície de resposta

Termo	Coefficiente	SE Coeficiente	T	P
Constante	5324,43	4,531	1175,182	0,000
A	-10,93	2,912	-3,753	0,002
B	12,08	2,447	4,938	0,000
D	0,33	2,447	0,136	0,893
E	7,07	2,912	2,427	0,027
A*A	-4,28	3,064	-1,397	0,180
B*B	-12,55	2,297	-5,465	0,000
D*D	-5,43	2,297	-2,363	0,030
E*E	4,47	3,064	1,458	0,163
A*B	5,25	2,997	1,752	0,098
A*E	-2,00	2,997	-0,667	0,513
B*E	4,75	2,997	1,585	0,131

R-quadrático (ajustado) = 75,74 %

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado com um bom grau de confiança, pois o R-quadrático (ajustado) é igual a 75,74 %.

Tabela 5.25: Falta de ajuste

	DF	SS	MS	F	P-value
Erro residual	17,0	2442,8	143,69		
Falta de ajuste	11	901,1	81,91	0,32	0,952
Erro puro	6,0	1541,7	256,95		

É possível notar pela Tabela 5.25, que o modelo não possui falta de ajuste, uma vez que a falta de ajuste é igual a 0,952, maior que 0,05.

O modelo é capaz de prever o resultado com confiança, afirmação comprovada também pela regressão que tem $P\text{-value} = 0$.

Os coeficientes da equação quadrática originada pelos experimentos de SR são mostrados na Tabela 5.26, e serão usados para obtenção do ponto ótimo de peso de roupas lavadas, que será feita usando-se a função solver do *software Excel*.

Tabela 5.26: Coeficientes dos termos usados na otimização

Termo	Coefficiente
Constante	5324,43
A	-10,93
B	12,08
D	0,33
E	7,07
A*A	-4,28
B*B	-12,55
D*D	-5,43
E*E	4,47
A*B	5,25
A*E	-2,00
B*E	4,75

5.4.4. Ponto ótimo

Finalmente, a formulação a ser otimizada é representada pela Equação (14), que multiplica os coeficientes aos seus respectivos fatores:

$$\begin{aligned} \text{Lucro} = & 5324,43 - 10,93 * A + 12,08 * B + 0,33 * D + 7,07 * E - 4,29 * A^2 \\ & - 12,55 * B^2 - 5,43 * D^2 + 4,47 * E^2 + 5,25 * AB - 2 * AE + 4,75 * BE \end{aligned} \quad (14)$$

Através dos coeficientes chega-se ao ponto ótimo, mostrado na Tabela 5.27. Os valores de A, B, C e D são -1, 0, 0 e 0, respectivamente, que correspondem a 3, 5, 5 e 5 operadores em cada um desses setores da célula de produção. A variável não analisada na otimização, no caso a variável C, não é significativa no experimento e, portanto, será deixada no nível -2, pois não há a necessidade de se contratar mais operadores visto que essa variável não é importante. Esse nível corresponde a 1 operador.

Logo, o ponto ótimo decodificado corresponde a: 3, 5, 1, 5 e 5 operadores para os setores A, B, C, D, e E, respectivamente. É importante ressaltar que utilizou-se a restrição de

valores inteiros, pois não teria sentido obter valores decimais, uma vez que o número de operadores é uma variável inteira.

Tabela 5.27: Cálculo do ponto ótimo

Fatores	Coefficientes	$z(x)$
Constante	5324,43	1
A	-10,93	-1
B	12,08	0
D	0,33	0
E	7,07	0
AA	-4,28	1
BB	-12,55	0
DD	-5,43	0
EE	4,47	0
AB	5,25	0
AE	-2	0
BE	4,75	0
Y (peso de roupas lavadas)	5331,08	
	Restrição $g(x)$	1

Percebe-se que, na otimização obtida pela SR, o peso de roupas lavadas é de 5331. Esse valor é válido porque se encontra dentro da restrição esférica $g(x)$, que é o valor de alfa ao quadrado ($\alpha = 2$).

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na Tabela 5.27 (3, 5, 1, 5, 5) por 30 vezes e calculando a média, tem-se 5329 kg de roupas lavadas. Percebe-se que, esse valor não está muito distante do valor ótimo obtido da regressão, visto que o desvio padrão é igual a 120,4 kg de roupas lavadas.

Nessa simulação foi feita uma comparação diferente dos dois casos anteriores, além de se comparar com o *software SimRunner*, também se comparou com o ponto ótimo global da região de solução, uma vez que a simulação foi feita com todos os 3125 cenários possíveis. Esse ponto ótimo real gera 5363 kg de roupas lavadas e equivale aos valores 3, 4, 1, 1 e 5 para as variáveis de entrada, respectivamente. Com um desvio padrão de 116,2 kg de roupas lavadas.

Quando se utiliza a SR, que nesse caso só fez 31 experimentos, tem-se uma pequena diferença entre o ponto ótimo real e o ótimo obtido na SR, se for considerado o desvio padrão.

Na Figura 5.15, pode-se observar que os resíduos são normais pois o *P-value* é maior que 0,05; o que viabiliza o uso dos dados obtidos.




Figura 5.15: Teste de normalidade dos resíduos.

A figura 5.16 mostra que os resíduos são não correlacionados, o que também pode ser constatado pelo coeficiente de Pearson que é zero e pelo *P-Value* que é 1,000.

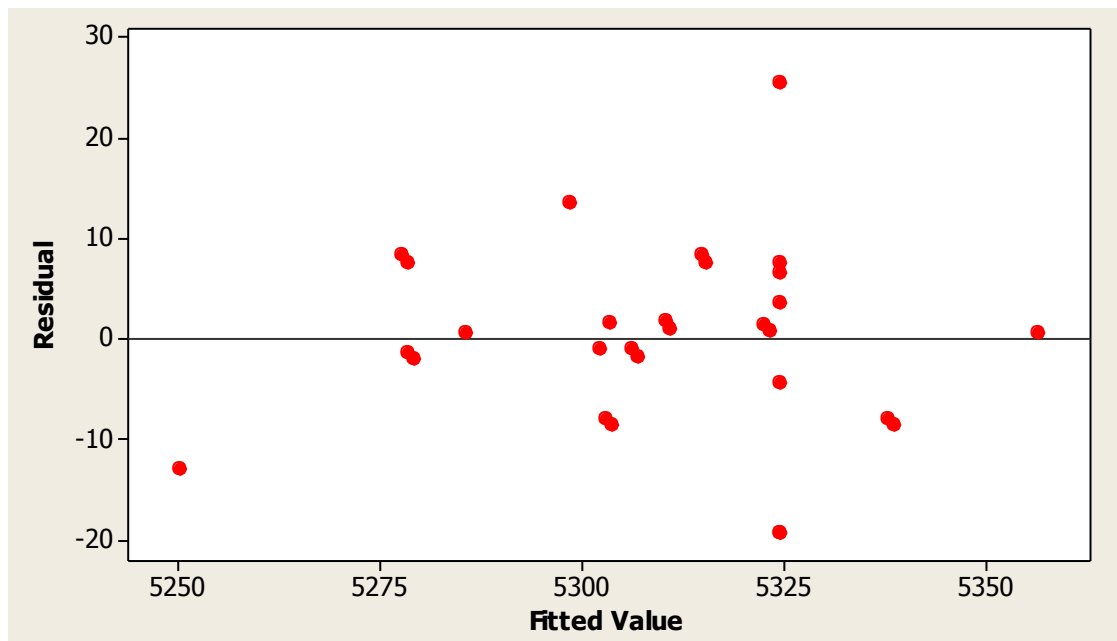


Figura 5.16: Teste de correlação dos resíduos.

Na Figura 5.17 apresenta-se o gráfico de contorno entre A, D e a variável de saída. O gráfico funciona como uma vista superior da curva de SR, onde as linhas representam diferentes pontos onde a resposta é a mesma. Percebe-se que o ponto ótimo situa-se no círculo delimitado pelo valor 5330.




Figura 5.17: Vista superior da SR entre A e D – Gráfico de Contorno.

Em seguida, é apresentada a respectiva SR na Figura 5.18, onde se pode ter uma visualização em três dimensões do resultado. O eixo vertical corresponde a resposta que é o peso de roupas lavadas. Com a análise visual fica nítido que o modelo é quadrático.




Figura 5.18: Superfície de Resposta entre A e D

Fazendo-se uma análise visual da superfície de resposta (Figura 5.18) e do gráfico de contorno (Figura 5.17), pode-se concluir que o ponto ótimo se situa próximo aos topos desses gráficos, o que realmente acontece, pois os valores ótimos codificados de A e D são -1 e 0, respectivamente. Além de estar dentro da restrição esférica mostrada na Equação (17):

$$g(x) \leq \text{alfa}^2 \tag{15}$$

$$\text{alfa} = 2 \tag{16}$$

$$g(x) \leq 4. \tag{17}$$

Como o $g(x) = 1$ nesse caso, o resultado previsto é válido.

O objeto de estudo 3 foi submetido para publicação no SBPO 2015 dentro do artigo de Rodrigues *et al* (2015): Aplicação da metodologia de superfície de resposta na otimização via simulação.

5.5. Objeto de estudo 4

O quarto experimento foi feito em um modelo de simulação tirado do trabalho de Oliveira (2010), já testado e validado anteriormente, de uma célula de produção de *transponders*. Porém, esta célula é diferente da usada no objeto de estudo 2, apesar de situar-se na mesma empresa. A simulação contém cinco variáveis a serem otimizadas, que correspondem ao: número de estagiários, fator aumento de funcionários, equipamentos para uma determinada atividade, além do número de técnicos para dois diferentes setores. A variável de saída é o número de *transponders* produzidos. A Figura 5.19 representa o modelo implementado no software *ProModel*.




Figura 5.19: Modelo implementado no *ProModel* para o quarto objeto de estudo

5.5.1. Delineamento de experimentos

A Tabela 5.28 contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que conterà uma SR linear ou quadrática,

considerando a ausência ou presença de curvatura nessa região. A simulação contém cinco variáveis a serem otimizadas.

Tabela 5.28: Decodificação dos níveis em número de operadores

Variáveis	Níveis				
	-2	-1	0	1	2
número de estagiários	1	3	5	7	9
fator aumento de funcionários	1	3	5	7	9
equipamentos para atividade AC	1	3	5	7	9
número de técnicos 1	1	3	5	7	9
número de técnicos 2	1	3	5	7	9

Para começar a explicar a parte prática do trabalho, é apresentada a Tabela 5.29 que contém os experimentos fatoriais e centrais.

Tabela 5.29: Experimentos realizados

Ordem	Tipo	A	B	C	D	E	Producao
1	1	-1	-1	-1	-1	1	1390,50
2	1	1	-1	-1	-1	-1	1395,57
3	1	-1	1	-1	-1	-1	1392,27
4	1	1	1	-1	-1	1	1392,47
5	1	-1	-1	1	-1	-1	1398,23
6	1	1	-1	1	-1	1	1391,57
7	1	-1	1	1	-1	1	1393,63
8	1	1	1	1	-1	-1	1391,93
9	1	-1	-1	-1	1	-1	1390,87
10	1	1	-1	-1	1	1	1394,57
11	1	-1	1	-1	1	1	1394,53
12	1	1	1	-1	1	-1	1390,70
13	1	-1	-1	1	1	1	1392,10
14	1	1	-1	1	1	-1	1394,10
15	1	-1	1	1	1	-1	1394,83
16	1	1	1	1	1	1	1390,70
17	0	0	0	0	0	0	1392,07
18	0	0	0	0	0	0	1392,20
19	0	0	0	0	0	0	1394,87
20	0	0	0	0	0	0	1390,03
21	0	0	0	0	0	0	1393,33

Devido ao número de variáveis (cinco) foi feito um experimento fatorial fracionado que contém dezesseis pontos cúbicos e cinco pontos centrais. É importante considerar que o fatorial completo usaria trinta e dois pontos cúbicos.

Vale lembrar que, todo o experimento (fatorial fracionado e SR) foi feito com a média das unidades produzidas, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise.

A Tabela 5.29 mostra todos os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial fracionado, a segunda parte (tipo 0) mostra o ponto central em suas cinco réplicas.

5.5.2. Fatorial fracionado

O modelo fatorial fracionado não foi colocado aqui como nos exemplos anteriores porque obteve um R-quadrático muito baixo. Portanto, se partirá diretamente para o modelo de SR.

5.5.3. Superfície de resposta

A seguir são utilizados os pontos axiais para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas dez experimentos, que são os pontos axiais, mostrados na Tabela 5.30.

Tabela 5.30: Experimentos axiais

Ordem	Tipo	A	B	C	D	E	Producao
1	-1	-2	0	0	0	0	1391,40
2	-1	2	0	0	0	0	1394,20
3	-1	0	-2	0	0	0	1334,73
4	-1	0	2	0	0	0	1390,77
5	-1	0	0	-2	0	0	1131,97
6	-1	0	0	2	0	0	1398,23
7	-1	0	0	0	-2	0	844,67
8	-1	0	0	0	2	0	1390,77
9	-1	0	0	0	0	-2	1391,87
10	-1	0	0	0	0	2	1391,67

Esses pontos são importantes para obter uma regressão quadrática, onde se pode obter um ponto estacionário (ótimo), que é o objetivo principal dessa SR. Nota-se que, neste modelo, utiliza-se somente as variáveis importantes para obtenção da regressão. A Tabela 5.31 mostra os resultados da SR.

Tabela 5.31: Resultado do experimento de superfície de resposta

Termo	Coefficiente	SE Coeficiente	T	P
Constante	1392,45	0,4606	3023,079	0,000
A	0,01	0,2668	0,036	0,971
B	-0,49	0,2958	-1,658	0,120
C	0,38	0,3167	1,195	0,252
D	-0,21	0,3167	-0,660	0,520
E	-0,37	0,2668	-1,380	0,189
C*C	1,20	0,3385	3,553	0,003
D*D	-0,37	0,3385	-1,094	0,292
E*E	-0,20	0,2520	-0,787	0,444
A*B	-0,85	0,3267	-2,595	0,021
A*C	-0,98	0,3267	-2,991	0,010
B*E	0,73	0,3267	2,225	0,043
C*E	-0,86	0,3267	-2,634	0,020
D*E	0,70	0,3267	2,149	0,050

R-quadrático (ajustado) = 63,89 %

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado um grau médio de confiança, pois o R-quadrático (ajustado) é igual a 63,89 %.

Tabela 5.32: Falta de ajuste

	DF	SS	MS	F	P-value
Erro residual	14	23,91	1,7079		
Falta de ajuste	10	11,253	1,1253	0,36	0,916
Erro puro	4	12,658	3,1644		

É possível notar, pela Tabela 5.32, que o modelo não possui falta de ajuste, uma vez que a falta de ajuste é igual a 0,916, maior que 0,05.

Para comprovar que modelo é capaz de prever o resultado com confiança, apresenta-se o *P-value* da regressão, que é igual a 0,004.

Os coeficientes da equação quadrática originada pelos experimentos de SR são mostrados na Tabela 5.33, e serão usados para obtenção do ponto ótimo, que será feita usando-se a função solver do *software Excel*.

Tabela 5.33: Coeficientes dos termos usados na otimização

Termo	Coefficiente
Constant	1392,45
A	0,01
B	-0,49
C	0,38
D	-0,21
E	-0,37
C*C	1,20
D*D	-0,37
E*E	-0,20
A*B	-0,85
A*C	-0,98
B*E	0,73
C*E	-0,86
D*E	0,70

5.5.4. Ponto ótimo

Finalmente, a formulação a ser otimizada é representada pela Equação (18), que multiplica os coeficientes aos seus respectivos fatores:

$$\begin{aligned}
 Lucro = & 1392,45 + 0,01 * A - 0,49 * B + 0,38 * C - 0,21 * D - 0,37 * E + 1,20 * C^2 \\
 & - 0,37 * D^2 - 0,20 * E^2 - 0,85 * AB - 0,98 * AC + 0,73 * BE - 0,86 * CE + 0,7 * DE \quad (18)
 \end{aligned}$$

Através dos coeficientes chega-se ao ponto ótimo, mostrado na Tabela 5.34. Os valores de A, B, C, D e E são 0, -2, 0, 0 e -2, respectivamente, que correspondem a 5, 1, 5, 5 e 1 operadores em cada um desses setores da célula de produção.

Logo, o ponto ótimo decodificado corresponde a: 5, 1, 5, 5 e 1 operadores para os setores A, B, C, D, e E, respectivamente. É importante ressaltar que se utilizou a restrição de valores inteiros, pois não teria sentido obter valores decimais, uma vez que as variáveis são inteiras.

Tabela 5.34: Cálculo do ponto ótimo

Coefficientes	Lucro	z (x)
Constante	1392,45	1
A	0,01	0
B	-0,49	-2
C	0,38	0
D	-0,21	0
E	-0,37	-2
C*C	1,20	0
D*D	-0,37	0
E*E	-0,20	4
A*B	-0,85	0
A*C	-0,98	0
B*E	0,73	4
C*E	-0,86	0
D*E	0,70	0
Y	1396,29	
	g(x)	4

Vê-se que, na otimização obtida pela SR, o número de *transponders* produzido é de 1396,29. Esse valor é válido porque se encontra dentro da restrição esférica $g(x)$, que é o valor de alfa ao quadrado ($\alpha = 2$).

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na Tabela 5.30 (5, 1, 5, 5 e 1) 30 vezes e calculando a média, tem-se 1395,33 unidades produzidas. Percebe-se que, esse valor não está muito distante do valor ótimo obtido da regressão, uma vez que o desvio padrão foi de 8,71 unidades produzidas.

Nessa simulação também foi feita uma comparação diferente dos dois primeiros casos, aqui não se comparou com o *software* de otimização, mas sim o ponto ótimo real da região de solução, uma vez que a simulação foi feita com todos os 3125 cenários possíveis. Esse ponto ótimo real produz 1398,97 *transponders* e equivale aos valores 1, 3, 5, 2 e 5 para as variáveis de entrada, respectivamente. Sendo que o desvio padrão foi de 8,12 unidades produzidas.

Quando se utiliza a MSR, que nesse caso só fez 31 experimentos, se for analisado o desvio padrão, vê-se que existe uma pequena diferença entre o ponto ótimo real e o ótimo obtido na SR.

Na Figura 5.20, pode-se observar que os resíduos são normais, uma vez que o *P-value* é maior que 0,05, o que viabiliza o uso dos dados obtidos.




Figura 5.20: Teste de normalidade dos resíduos.

A figura 5.21 mostra que os resíduos são não correlacionados, o que também pode ser constatado pelo coeficiente de Pearson que é zero e pelo *P-Value* que é 1,000.




Figura 5.21: Teste de correlação dos resíduos.

Na Figura 5.22, apresenta-se o gráfico de contorno, que funciona como uma vista superior da curva de SR, onde as linhas representam diferentes pontos onde a resposta é a mesma. A partir desse gráfico tem-se uma visão do valor ótimo para cada variável, que situará dentro do círculo delimitado pela linha de 1300 unidades produzidas.




Figura 5.22: Vista superior da SR entre os fatores C e D – Gráfico de Contorno.

Na Figura 5.23, é apresentada a respectiva SR para o gráfico de contorno da Figura 5.21, onde se pode ter uma visualização em três dimensões do resultado. O eixo vertical corresponde a resposta que é o número de unidades produzidas.




Figura 5.23: Superfícies de Resposta entre C e D.

Fazendo-se uma análise visual da superfície de resposta (Figura 5.23) e do gráfico de contorno (Figura 5.22), que funciona como uma vista superior, pode-se concluir que o ponto ótimo se situa próximos aos topos desses gráficos. Além de estar dentro da restrição esférica mostrada na Equação (21):

$$g(x) \leq \text{alfa}^2 \tag{19}$$

$$\text{alfa} = 2 \tag{20}$$

$$g(x) \leq 4. \tag{21}$$

Como o $g(x) = 4$ nesse caso o resultado previsto é válido.

5.6. Objeto de estudo 5

O quinto experimento foi feito em um modelo de simulação já testado e validado anteriormente, de uma célula de produção de palmito. A simulação contém duas variáveis a serem otimizadas, que correspondem ao: número de produtos em estoque e número de operadores. A variável de saída é a margem de contribuição total (Y). A Figura 5.24 representa o modelo implementado no software *AnyLogic*.

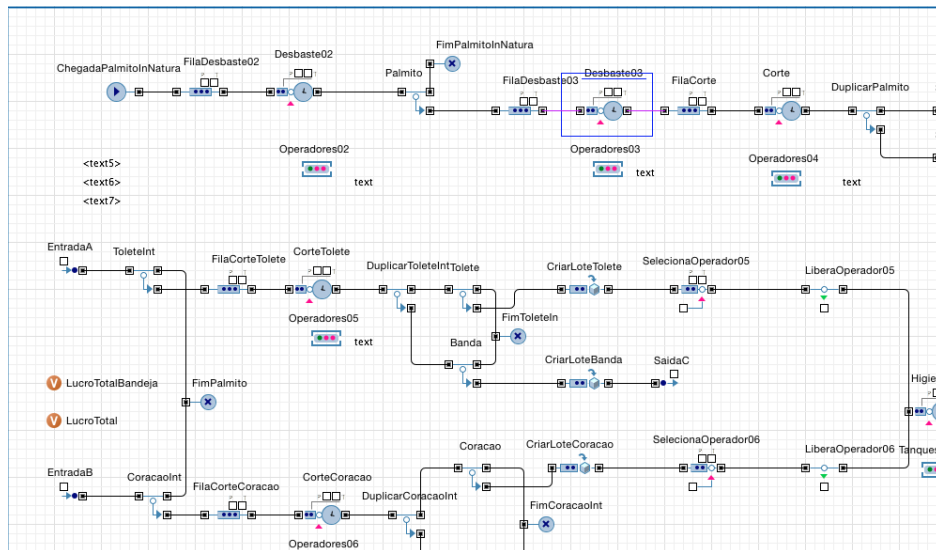


Figura 5.24: Modelo implementado no *AnyLogic* para o quinto objeto de estudo

5.6.1. Delineamento de experimentos

A Tabela 5.35 contém a decodificação dos níveis das variáveis de entrada. Dentro desses limites está a região de solução, que conterà uma SR linear ou quadrática, considerando a ausência ou presença de curvatura nessa região. A simulação contém duas variáveis a serem otimizadas.

Tabela 5.35: Decodificação dos níveis em número de operadores

Variáveis	Níveis				
	-2	-1	0	1	2
A - número de produtos em estoque	50	150	250	350	450
B - número de operadores	1	2	3	4	5

Para começar a explicar a parte prática do trabalho, é apresentada a Tabela 5.36 que contém os experimentos fatoriais e centrais.

Tabela 5.36: Experimentos realizados

Ordem	Tipo	A	B	Y
1	1	-1	-1	142994,59
2	1	1	-1	126335,61
3	1	-1	1	225310,15
4	1	1	1	222010,06
5	0	0	0	160456,09
6	0	0	0	168967,32
7	0	0	0	161879,75
8	0	0	0	164174,28
9	0	0	0	163027,02

Devido ao baixo número de variáveis (duas) foi feito um experimento fatorial completo que contém quatro pontos cúbicos e cinco pontos centrais.

Vale lembrar que, todo o experimento (fatorial completo e SR) foi feito com a média das unidade produzidas, rodando-se cada cenário com 30 réplicas. Isso é importante considerando que o modelo usado é estocástico e apenas uma réplica prejudicaria a análise.

A Tabela 5.36 mostra os experimentos realizados. A primeira parte (tipo 1) mostra o experimento fatorial fracionado, a segunda parte (tipo 0) mostra o ponto central em suas cinco réplicas.

5.6.2. Fatorial fracionado

Na Tabela 5.37 se encontram os resultados estatísticos da análise do experimento fatorial completo. Nesta fase é feita a análise de sensibilidade de cada variável de entrada no resultado, no caso a margem de contribuição total, e a presença ou não de curvatura na região de solução.

Tabela 5.37: Resultado do experimento fatorial completo

Termo	Efeito	Coefficiente	SE Coeficiente	T	P
Constant		179163	1625	110,24	0,000
A	-9980	-4990	1625	-3,07	0,037
B	88995	44498	1625	27,38	0,000
A*B	6679	3340	1625	2,06	0,109
Ct Pt		-15462	2180	-7,09	0,002

R-quadrático (ajustado) = 99,02%




Figura 5.25: Gráfico de sensibilidade das variáveis de entrada e suas interações

Percebe-se pela Figura 5.25 que o número de produtos em estoque é o que tem maior influência no resultado, seguido pelo número de operadores. A interação que aparece no gráfico tem um peso menor, mas gera uma regressão com maior R -quadrático quando considerada.

É possível notar pela Tabela 5.37 que há curvatura na região, pois $ct\ pt < 0.05$, existindo, portanto, um ponto estacionário (ótimo). Nota-se um R -quadrático (ajustado) = 99,02 %, o que mostra que o modelo com suas variáveis é satisfatório na previsão do resultado.

5.6.3. Superfície de resposta

A seguir são utilizados os pontos axiais para a execução do experimento de SR. Todos os experimentos feitos anteriormente na fase fatorial foram utilizados, somando-se apenas quatro experimentos, que são os pontos axiais, mostrados na Tabela 5.38.

Tabela 5.38: Experimentos axiais

Ordem	Tipo	A	B	Y
1	-1	-2	0	166885,44
2	-1	2	0	158647,80
3	-1	0	-2	115057,11
4	-1	0	2	248863,57

Esses pontos são importantes para obter uma regressão quadrática, onde se pode obter um ponto estacionário (ótimo), que é o objetivo principal dessa SR. Nota-se que, neste modelo, utiliza-se somente as variáveis importantes para obtenção da regressão. A Tabela 5.39 mostra os resultados da SR.

Tabela 5.39: Resultado do experimento de superfície de resposta

Term	Coef	SE Coef	T	P
Constant	166722	3097	53,832	0,000
A	-3036	2682	-1,132	0,287
B	37134	2682	13,845	0,000
B*B	4769	1861	2,562	0,031

R-quadrático (ajustado) = 94,25 %.

Percebe-se que o modelo com suas variáveis são capazes de prever o resultado um grau médio de confiança, pois o R-quadrático (ajustado) é igual a 94,25 %.

Para comprovar que modelo é capaz de prever o resultado com confiança, apresenta-se o P-value da regressão, que é igual a 0,000.

Os coeficientes da equação quadrática originada pelos experimentos de SR são mostrados na Tabela 5.40, e serão usados para obtenção do ponto ótimo, que será feita usando-se a função solver do *software Excel*.

Tabela 5.40: Coeficientes dos termos usados na otimização

Termo	Coefficiente
Constante	166722
A	-3036
B	37134
B*B	4769

5.6.4. Ponto ótimo

Finalmente, a formulação a ser otimizada é representada pela Equação (22), que multiplica os coeficientes aos seus respectivos fatores:

$$\text{Margem de Contribuição} = 166722 - 3036 * A + 37134 * B + 4769 * B^2 \quad (22)$$

Através dos coeficientes chega-se ao ponto ótimo, mostrado na Tabela 5.41. Os valores de A e B são 0 e 2, respectivamente, que correspondem a que correspondem a 250 unidades em estoque e 5 operadores.

Tabela 5.41: Cálculo do ponto ótimo

Coeficientes	Lucro	z (x)
Constante	166722	1
A	-3036	0
B	37134	2
B*B	4769	4
Y	260066,00	
	g(x)	4

Vê-se que, na otimização obtida pela SR, a margem de contribuição total é de 260066,00. Esse valor é válido porque se encontra dentro da restrição esférica $g(x)$, que é o valor de alfa ao quadrado ($\alpha = 2$).

Fazendo-se o experimento de confirmação, ou seja, rodando o modelo para o ponto obtido na Tabela 5.41 (0 e 2) 30 vezes e calculando a média, tem-se R\$ 261348,65 de margem de contribuição total. Percebe-se que, esse valor está muito próximo do valor ótimo obtido da regressão, visto que o desvio padrão é igual a R\$ 21550,64.

Para fins comparativos, a simulação foi otimizada em um software chamado *Optquest* que é utilizado no *AnyLogic*. A margem de contribuição total foi de R\$ 250236,88, com um desvio padrão de R\$ 20252,25.

As variáveis de entrada desse ponto são 220 unidades de estoque e 5 operadores, também muito próximas às encontradas com a MSR. Sendo importante salientar que o otimizador utilizou 3540 experimentos para convergir, e a MSR 13 experimentos com 30 réplicas, totalizando 390. Percebe-se uma redução de 89 % no número de experimentos.

Na Figura 5.26, pode-se observar que os resíduos são normais, uma vez que o *P-value* é maior que 0,05, o que viabiliza o uso dos dados obtidos.




Figura 5.26: Teste de normalidade dos resíduos.

A figura 5.27 mostra que os resíduos são não correlacionados, o que também pode ser constatado pelo coeficiente de Pearson que é zero e pelo *P-Value* que é 1,000.




Figura 5.27: Teste de correlação dos resíduos.

Na Figura 5.28, apresenta-se o gráfico de contorno, que funciona como uma vista superior da curva de SR, onde as linhas representam diferentes pontos onde a resposta é a mesma. A partir desse gráfico tem-se uma visão do valor ótimo para cada variável, que situará acima da linha de R\$ 240000,00.

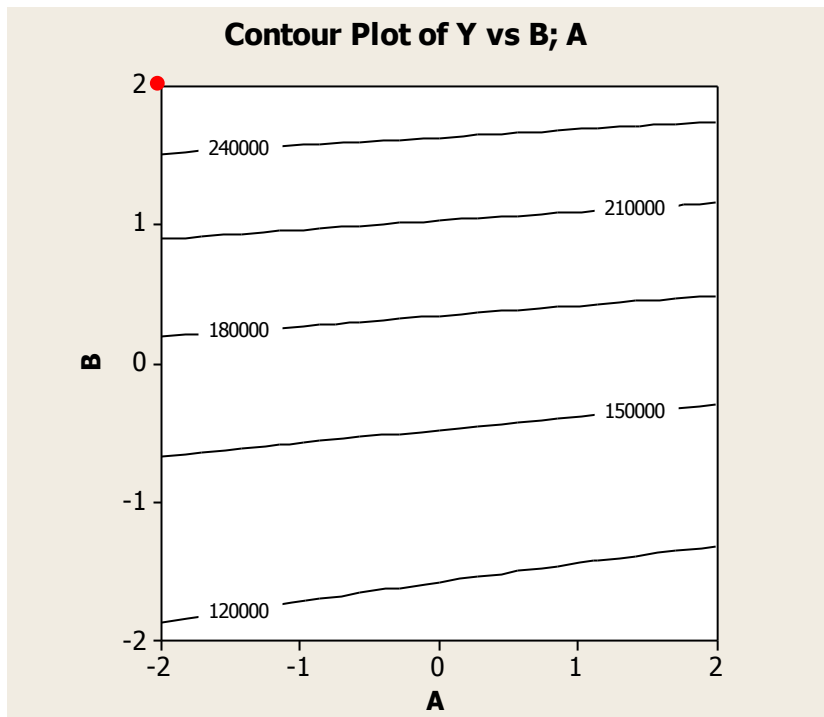


Figura 5.28: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.

Na Figura 5.29, é apresentada a respectiva SR para o gráfico de contorno da Figura 5.28, onde se pode ter uma visualização em três dimensões do resultado. O eixo vertical corresponde a resposta que é a margem de contribuição total.




Figura 5.29: Superfícies de Resposta entre A e B.

Fazendo-se uma análise visual da superfície de resposta (Figura 5.29) e do gráfico de contorno (Figura 5.28), que funciona como uma vista superior, pode-se concluir que o ponto ótimo se situa próximos aos topos desses gráficos. Além de estar dentro da restrição esférica mostrada na Equação (24):

$$g(x) \leq \text{alfa}^2 \quad (22)$$

$$\text{alfa} = 2 \quad (23)$$

$$g(x) \leq 4. \quad (24)$$

Como o $g(x) = 4$ nesse caso o resultado previsto é valido.

5.7. Considerações finais deste capítulo

Este capítulo apresentou os resultados do estudo comparativo da otimização através da MSR, tanto com a otimização utilizando o *SimRunner* (que foi utilizada nos dois primeiros modelos), como com o ponto ótimo real que foi alcançado fazendo-se a simulação de todos os cenários possíveis (que foi utilizada no terceiro e quarto modelos). Além de comparar com o *OptQuest* no quinto modelo.

A metodologia de otimização aqui utilizada gerou resultados tão eficientes quanto o otimizador comercial, alcançando respostas de estatisticamente iguais às alcançadas pelo *software* em três dos cinco casos, mas mesmo no que não foi igual os resultados foram muito próximos. No último, o resultado alcançado pela MSR foi estatisticamente superior ao encontrado pelo software.

Contudo, o número de cenários simulados para se atingir uma resposta é menor quando comparado ao tempo gasto pelo otimizador comercial para encontrar sua melhor solução.

No próximo capítulo também são mostradas as otimizações feitas pelo *SimRunner* para os objetos de estudo 3 e 4, apenas para análise da redução do número de experimentos necessários.

6. Análise dos Resultados

6.1. Considerações iniciais

Neste capítulo serão mostrados todos os resultados apresentados no capítulo 5, porém de modo resumido e comparativo. Serão feitas análises estatísticas de todos esses resultados gerados pelo MSR em contraposição ao resultado do *software* comercial e do ótimo global.

Para melhorar o entendimento dos resultados, serão mostradas algumas tabelas comparativas das diferentes metodologias utilizadas para buscar a otimização.

6.2. Resumo dos resultados

Na Tabela 6.1 são mostradas as características ou parâmetros das quatro otimizações por meio da MSR, a fim de comprovar que a metodologia aplicada com sucesso. Além de mostrar o número de experimentos de cada tipo.

Conforme foi dito anteriormente, devido ao número de variáveis desses experimentos foi usado, no objeto de estudo 1, o arranjo fatorial completo, e o fracionado nos demais, para depois se fazer a SR.

Tabela 6.1: Características de cada experimento

Características	Objeto de estudo 1	Objeto de estudo 2	Objeto de estudo 3	Objeto de estudo 4	Objeto de estudo 5
R-quadrático (ajustado)	87,09%	97,15%	75,74%	63,89%	94,25%
Falta de ajuste	0,259	0,86	0,952	0,916	0,273
P-value da curvatura	0,0	0,53 (modelo linear)	0,0	0,0	0,0
Número de fatores	4	6	5	5	5
Pontos cúbicos	16	32	16	16	4
Pontos axiais	8	12	10	10	4
Pontos centrais	5	5	5	5	5
Experimentos	29	49	31	31	13

Vê-se que os modelos 1, 2 e 5 possuem excelentes R-quadráticos, e os demais, um aceitável. Nenhum dos modelos possui falta de ajuste, visto que seus P-values são maiores que 0,05. Além disso, através do P-value da curvatura, percebe-se que o modelo 2 é linear e os demais quadráticos.

Também é apresentado o número de experimentos de cada tipo para mostrar que o número de fatores é que determina o número de experimentos. Confirmando o que foi dito na fundamentação teórica que o número de pontos axiais é igual ao dobro do número de fatores. Já os pontos cúbicos são relacionados ao experimento fatorial, que pode ser completo ou fracionado. Percebe-se que quando se usa um fatorial completo com quatro fatores é o mesmo que usar um fracionado com cinco fatores.

A seguir serão apresentados os resultados de cada modelo, mostrando a tabela de resultados de cada um dos experimentos resumida. Essas tabelas comparam os resultados da MSR com os resultados de uma otimização por meio de *software* nos cinco modelos, e com os ótimos globais para os modelos 3 e 4.

Nas Tabelas 6.2 a 6.6, constata-se que a MSR foi eficaz na previsão da variável de saída, uma vez que foram feitos experimentos de confirmação com as mesmas configurações das variáveis de entrada encontradas na MSR, e os valores foram muito próximos, confirmando a eficácia das superfícies de resposta.

Além disso, os resultados da MSR foram muito próximos aos encontrados com o *software* comercial, isso com um número muito menor de experimentos (cerca de 80 %). As letras representam as variáveis, os valores decodificados correspondentes ficam na coluna abaixo das letras.

Tabela 6.2: Resultados do experimento 1

Modelo	Lucro (R\$)	Desvio (R\$)	A	B	C	D	Experimentos
Superfície de Resposta	172.023,00		2	4	4	2	29
<i>SimRunner</i>	172.823,00	1.587,35	2	5	4	2	115
Exp. de Confirmação	171.394,00	1.047,20	2	4	4	2	

Analisando a Tabela 6.2, é possível notar uma economia de 74,8 % no número de experimentos para a otimização do objeto de estudo 1, visto que o número de experimentos reduziu de 115 para 29. Sendo fácil de perceber que se teve variação somente na variável B, que corresponde ao número de operadores no setor 2.

Tabela 6.3: Resultados do experimento 2

Modelo	Lucro (R\$)	Desvio padrão	A	B	C	D	E	F	Experimentos
Superfície de Resposta	2.322.172,00		1	1	1	1	1	1	37
<i>SimRunner</i>	2.321.113,33	13.857,27	1	1	1	1	1	1	188
Exp. de Confirmação	2.321.113,33	13.857,27	1	1	1	1	1	1	

Já no objeto de estudo 2, foi possível notar uma economia de 80,3 % no número de experimentos para a otimização, analisando a Tabela 6.3, visto que o número de experimentos

reduziu de 188 para 37. Além disso, é possível notar que o ponto atingido pela MSR é exatamente o mesmo do *software*.

Nas Tabelas 6.4 e 6.5 têm-se uma linha indicando o ponto ótimo global, que foi feito com todas as 3125 combinações possíveis de cada caso. Esses valores também foram muito próximos aos encontrados com a MSR, se for considerado o desvio padrão. As letras representam as 5 variáveis e o valores decodificados correspondentes na coluna abaixo das letras.

Tabela 6.4: Resultados do experimento 3

Modelo	Roupas lavadas	Desvio padrão	A	B	C	D	E	Experimentos
Superfície de Resposta	5331		3	5	1	5	5	31
Ótimo global	5363	116,2	3	4	1	1	5	3125
Exp. de confirmação	5329	120,4	3	5	1	5	5	
<i>SimRunner</i>	5350	114,0	5	3	1	5	5	163

É possível notar na Tabela 6.4, uma economia de 81,0 % no número de experimentos para a otimização do objeto de estudo 3, visto que o número de experimentos reduziu de 163 para 31. Também se percebe que os valores das variáveis de entrada para o ótimo são bem próximos utilizando a MSR e o *software* comercial, tendo variação somente em A e B, onde ocorre uma inversão no número de lavadoras e centrífugas.

Tabela 6.5: Resultados do experimento 4

Modelo	Unidade produzidas	Desvio padrão	A	B	C	D	E	Experimentos
Superfície de Resposta	1396,29		5	1	5	5	1	31
Ótimo global	1398,97	8,12	1	3	5	2	5	3125
Exp. de Confirmação	1395,33	8,71	5	1	5	5	1	
<i>Simrunner</i>	1398,00	9,69	1	5	4	4	5	243

Através da Tabela 6.5, pode-se notar uma economia de 87,2 % no número de experimentos para a otimização do objeto de estudo 4, visto que o número de experimentos reduziu de 243 para 31. Comparando as variáveis de entrada da MSR com o *software* pode-se notar que foram completamente diferentes desta vez.

Tabela 6.6: Resultados do experimento 5

Modelo	Lucro (R\$)	Desvio (R\$)	A	B	Experimentos
Superfície de Resposta	260066,00		250	5	13*30 = 390
<i>OptQuest</i>	250236,88	20252,25	220	5	3540
Exp. de Confirmação	261348,65	21550,64	250	4	

Através da Tabela 6.6, pode-se notar uma economia de 89 % no número de experimentos para a otimização do objeto de estudo 5, visto que o número de experimentos

reduziu de 3540 para 390. Comparando as variáveis de entrada da MSR com o *software* pode-se notar que os valores foram muito próximos.

6.3. Comparações estatísticas

Neste item são mostradas as comparações estatísticas do resultado gerado pela MSR com o gerado pelo *software* no objeto de estudo 1 e 5. No objeto de estudo 2 essa comparação é desnecessária, visto que o ponto encontrado pelas duas metodologias foi idêntico. Nos objetos 3 e 4 será feita a mesma comparação estatística, porém com o ótimo global do modelo, pois estes são sempre maiores ou iguais aos ótimos de qualquer metodologia utilizada.

O teste estatístico usado neste trabalho foi o “*Two Sample T*”, usado para comparar duas amostras diferentes. As comparações podem ser do tipo: maior que, menor que, e igual. Neste caso irá se comparar se as amostras são iguais ou não.

O número de valores da amostra é igual a 30, já que foram feitas 30 réplicas de cada cenário para se atingir o ponto ótimo.

A Figura 6.1 apresenta o gráfico de valores dos pontos do objeto de estudo 1, onde o *P-value* do teste foi igual a 0, mostrando que os valores são diferentes estatisticamente. Este foi o único objeto de estudo em que o resultado estatístico não foi igual, porém pode-se notar pelo gráfico de valores dos pontos que os resultados foram próximos, tendo até uma região de interseção entre eles.




Figura 6.1: Gráficos de pontos para comparação estatística no objeto de estudo 1.

Como foi dito anteriormente, não será mostrado o gráfico do objeto de estudo 2, pois o ponto ótimo é exatamente o mesmo, usando-se a MSR ou o *software* de mercado.

A Figura 6.2 apresenta o gráfico de valores dos pontos do objeto de estudo 3, onde o *P-value* do teste foi igual a 0,270, mostrando que os valores são iguais estatisticamente.




Figura 6.2: Gráficos de pontos para comparação estatística no objeto de estudo 3

A Figura 6.3 apresenta o gráfico de valores dos pontos do objeto de estudo 4, onde o *P-value* do teste foi igual a 0,100, mostrando que os valores também são iguais estatisticamente.




Figura 6.3: Gráficos de pontos para comparação estatística no objeto de estudo 4

A Figura 6.4 apresenta o gráfico de valores dos pontos do objeto de estudo 5, onde o *P-value* do teste foi igual a 0,005 escolhendo a opção “*greater than*”, mostrando que o resultado gerado pela MSR é estatisticamente maior que o gerado pelo *OptQuest*.




Figura 6.4: Gráficos de pontos para comparação estatística no objeto de estudo 5

Percebe-se que, os pontos ótimos foram estatisticamente iguais em 3 dos 5 objetos de estudo. Em um deles, o quinto, o resultado atingido pela MSR foi maior. E mesmo no primeiro objeto de estudo em que o resultado do *software* de otimização via simulação foi maior, pode-se notar pelo gráfico da Figura 6.1 que os valores foram muito próximos.

6.4. Considerações finais do capítulo

Neste capítulo foram mostrados os resultados de todo o trabalho de modo mais claro e comparativo, analisando os resultados com maior clareza e precisão. Foi comprovado estatisticamente que a MSR foi eficaz no cálculo do ponto ótimo. Isso foi importante para se chegar às conclusões que serão apresentadas no próximo capítulo.

7. Conclusões

Neste trabalho foi apresentada uma forma alternativa de otimização em simulações, ficando provado que essa metodologia apresenta grandes vantagens em relação à otimização realizada por *softwares* de otimização via simulação. A principal seria a redução de cerca de 80 % no número de experimentos necessários para se realizar a otimização.

A presente pesquisa propôs-se a estudar o emprego da MSR na otimização de modelos de SED, objetivando uma otimização mais clara e visível, eliminando o efeito “caixa preta” que acontece quando utilizamos *softwares* de otimização via simulação onde temos que simplesmente acreditar no resultado gerado pelo *software*.

Foi visto, nos experimentos de confirmação, que a regressão foi satisfatória na previsão dos resultados, pois seus resultados foram bem próximos aos experimentos de confirmação. Ou seja, quando se coloca a mesma configuração de variáveis de entrada no modelo de simulação e na equação do metamodelo, têm-se resultados muito próximos.

Além disso, os valores encontrados pelo *software* comercial usado, também foram bem próximos ao da MSR. Em três dos quatro casos apresentados eles foram estatisticamente iguais, mostrando a eficácia da metodologia adotada para se chegar ao ponto ótimo. E mesmo no caso em que não foi igual, foi constatado que os valores foram muito próximos.

Para desenvolver esse estudo, quatro aplicações foram desenvolvidas para verificar a viabilidade da MSR na otimização de modelos de simulação, identificando as suas vantagens e desvantagens.

Vantagens:

- Análise de sensibilidade das variáveis de entrada e das interações entre essas.
- Análise de curvatura da região de solução proposta e visualização da curva de superfície de resposta.
- Para calcular o ponto ótimo é necessário um menor número de experimentos que a otimização através do *SimRunner*. Essa redução foi em média de 80,8 %, o que é uma redução bem considerável, ainda mais se tratando de simulações que gastam grande quantidade de tempo.

Desvantagens:

- Possibilidade de erro e gasto de tempo na preparação e análise dos experimentos.

- Erro causado pela criação do metamodelo, ou seja, a simulação já possui um erro porque nunca corresponde exatamente à realidade, com a MSR adiciona-se um erro.

7.1. Sugestões para trabalhos futuros

Existe a possibilidade de se usar a MSR para otimizações multiobjetivo, abrangendo respostas de maneira combinada, tais como: custos, lucro, número de unidades produzidas, ociosidades de funcionários, entre outras.

Além disso, pode-se estudar arranjos diferentes do usado nessa dissertação para atingir o mesmo objetivo e avaliar se existem vantagens em relação ao arranjo CCD. Isso porque o arranjo CCD pede uma amplitude maior ou igual a quatro para variáveis inteiras, como foi visto neste trabalho. Já outro arranjo pode requerer uma amplitude menor, como a arranjo de face centrada, também usado na MSR.

Outra sugestão percebida com este trabalho seria a utilização do DOE para avaliar a credibilidade de modelos de simulação. O motivo disso é que determinados modelos, apesar de serem considerados como validados, não geram variação suficiente em suas variáveis de saída quando se analisam os diferentes cenários produzidos pelo arranjo do DOE. Ou seja, os modelos são validados no cenário real corrente, mas se o mesmo não produzir variações em sua saída nos diferentes cenários como ocorrem na realidade, o modelo deixa de ter utilidade para determinados fins.

Referências bibliográficas

- BAINES, T.; MASON, S.; SIEBERS, P.; LADBROOK, J. **Humans: the missing link in manufacturing simulation?** *Simulation Modelling Practice and Theory*, n.12, p.515–526, 2004.
- BANKS, J. **Handbook of simulation: principles, methodology, advances, applications and practice.** John Wiley & Sons, 1998.
- BANKS, J.; CARSON, J. S.; NELSON, B. L.; NICOL, D. M. **Discrete Event System Simulation.** 5.ed. Upper Saddle River, NJ: Prentice Hall, 2009.
- BANKS, J.; GIBSON, R. R. **Don't simulate when: 10 rules for determining when simulation is not appropriate.** IIE Solutions. 1997.
- BERTRAND, J. W. M., FRANSOO, J. C. **Operations management research methodologies using quantitative modeling,** *International Journal of Operations & Production Management*, v. 22, n. 2, 241-264, 2002.
- BOX, G. E. P., DRAPER, N. R. **“Empirical Model-Building and Response Surfaces”.** John Wiley and Sons, 1 ed., pp. 650, 1987.
- BRYMAN, A. **Research methods and organization studies (contemporary social research),** Routledge, 1 st edition, London, 1989.
- CHUNG, C. A. **Simulation Modeling Handbook. A Practical Approach.** London, New York: CRC Press, 2004.
- CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações.** 3ª. Ed. São Paulo: Editora dos Autores, 2010.
- COSTA, R. F. S. **Abordagem sistemática para avaliação econômica de cenários para modelos de simulação discreta em manufatura.** 2010. 136 p. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2010.
- DENGIZ, B. e BELGIN, O. **Simulation optimization of a multi-stage multi-product paint shop line with response surface methodology,** *Simulation*, 1-10, 2014.
- FERNANDES, L. J. RODRIGUEZ L. A. O., CORREA A. R. e MARINS F. A. S. **Planejamento e controle da produção de cilindros para laminação: um estudo de caso quantitativo,** *Produção*, v. 23, n. 1, 120-135, 2013.
- GOLDSMAN, D.; NANCE, R. E.; WILSON, J. R. **A brief history of simulation.** In: Winter Simulation Conference, Proceedings... Austin, TX, USA, 2009.
- GOMES, J. H. F. **Método dos Polinômios Canônicos de Misturas para Otimização Multiobjetivo.** 2013. 141 p. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2013.
- 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, 2003.
- HARREL, C.; GHOSH, B. K.; BOWDEN, R. O. **Simulation Using Promodel.** 2.ed. New York: McGraw-Hill, 2004.
- HU, W. YAO, L. G. e HUA, Z. Z. **Optimization of sheet metal forming processes by adaptive response surface based on intelligent sampling method,** *Journal of Materials Processing Technology*, 197, 77–88, 2008.

- HUYET, A. L. **Optimization and analysis aid via data-mining for simulated production systems**. European Journal of Operational Research. v. 173, p. 827–838, 2006.
- KELTON, D. W.; SADOWSKI, R. P.; STURROCK, D. T. **Simulation with Arena**. 4.ed. New York: McGraw-Hill, 2007.
- KLEIJNEN, J. P. C.; SANCHEZ, S. M.; LUCAS, T. W.; CIOPPA, T. M. **State-of-the-Art Review: A User's Guide to the Brave New World of Designing Simulation Experiments**. Journal on Computing, v.17, n.3, p. 263–289, 2005.
- KLEIJNEN, J. P. C. **Experimental design for sensitivity analysis, optimization, and validation of simulation models**. In: BANKS, J. (Ed.) (1998). Handbook of Simulation. New York: John Wiley & Sons. cap. 6, p. 173-223. ISBN 0-471-13403-1, 1998.
- LAW, A. M.; KELTON, W. D. **Simulation modeling and analysis**, 4 th ed. New York: McGraw-Hill, 2007.
- LAW, A. M. **How to build valid and credible simulation models**. p. 58-66, 2006
- LEAL, F. **Análise do efeito interativo de falhas em processos de manufatura através de experimentos simulados**. 2008. 237 p. Tese (Doutorado) - Engenharia Mecânica na área de Transmissão e Conversão de Energia. Universidade Estadual Paulista, Guaratinguetá, 2008.
- LEAL, F. MONTEVECHI, J. A. B., PINHO, A. F. e MARINS F. A. S. **Application of design of experiments on the simulation of a process in an automotive industry**, Winter Simulation Conference, 2007.
- MIRANDA, R. C. **Algoritmo genético adaptativo para otimização de modelos de simulação a eventos discretos**. 2012. 147 p. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2012.
- 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 (Impresso), v. 13, p. 7-24, 2012.
- MONTEVECHI, J. A. B. LEAL, F. PINHO, A. F. COSTA, R. F. S. OLIVEIRA, M. L. M. e SILVA, A. L. F. **Conceptual modeling in simulation projects by mean adapted IDEF: an application in a Brazilian tech company**, Winter Simulation Conference, 2010.
- MONTEVECHI, J. A. B.; MIRANDA, R. D. C.; FRIEND, J. D. **Sensitivity analysis in discrete-event simulation using design of experiments**. Capítulo submetido ao livro Discrete Event Simulations, 2012.
- MONTEVECHI, J. A. B.; PINHO, A. F.; LEAL, F.; SILVA, F. A.; COSTA, R. F. S. **Improving a process in a brazilian automotive plant applying process mapping, design of experiments and discrete events simulation**. 20th European Modeling and Simulation Symposium, 472-480, 2008.
- MONTGOMERY, D. C. **Design and Analysis of Experiments**. 6th. Ed. New York: Wiley, 2005.
- MONTGOMERY, D. C. **Introdução ao controle estatístico da qualidade**. 4ª. ed., Rio de Janeiro: LTC, 2009.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 2ª. Ed. Rio de Janeiro: Editora LTC, 2003.

MYERS, R. H., MONTGOMERY, D. C. **Response Surface Methodology: process and product optimization using design of experiments**. 2 ed, Wiley – Interscience, New York, USA, 700p., 2002.

NAKANO, D. **Métodos de pesquisa adotados na engenharia de produção e gestão de operações**. Capítulo submetido ao livro Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações, Elsevier Editora Ltda, 2012.

NANCE, R. E.; SARGENT, R. **Perspectives on the evolution of simulation**. Operations Research, v.50, n.1, p.161-172, 2002.

NILO JÚNIOR, L. P. **Otimização de um processo de solda MIG/MAG para aplicação na indústria automobilística através da utilização da técnica do projeto e análise de experimentos**. 2003. 111 p. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2003.

O’KANE, J. F.; SPENCELEY, J. R.; TAYLOR, R. **Simulation as an essential tool for advanced manufacturing technology problems**. Journal of Materials Processing Technology, v.107, p.412-424, 2000.

OLIVEIRA, M. L. M. **Análise da aplicabilidade da técnica de modelagem IDEF-SIM nas etapas de um projeto de simulação a eventos discretos**. 2010. 168 p. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2010.

PAIVA, A. P. **Metodologia de Superfície de Resposta e Análise de Componentes Principais em otimização de processo de manufatura com múltiplas respostas correlacionadas**. 2006. 229 p. Tese (Doutorado em Engenharia Mecânica) – Instituto de Engenharia Mecânica, Universidade Federal de Itajubá, Itajubá. 2006.

PINHO, A. F. **Proposta de um método de otimização de modelos de simulação a eventos discretos**. 2008. 189 f. Tese (Doutorado em Engenharia Mecânica). Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista (UNESP), Guaratinguetá, SP, 2008.

PROTIL, R. M. **Otimização do processo decisório utilizando simulação computacional**. In: XXXIII Simpósio Brasileiro de Pesquisa Operacional, Anais... Campos de Jordão, SP, Brasil, p. 1535-1546, 2001.

ROBINSON, S. **Discrete-Event Simulation: From the Pioneers to the Present, What Next?** Journal of the Operational Research Society, v.56, n.6, p.619-629, 2005.

ROSEN, S. L.; HARMONOSKY, C. M.; TRABAND, M. T. **A simulation optimization method that considers uncertainty and multiple performance measures**. European Journal of Operational Research. v. 181, p. 315–330, 2007.

SANCHEZ, S.M.; MOEENI, F.; SANCHEZ, P.J. **So many factors, so little time... Simulation experiments in the frequency domain**. International Journal of Production Economics, v.103, p. 149–165, 2006.

SARAIVA JÚNIOR, A. F.; TABOSA, C. D. M.; COSTA, R. P. **Simulação de Monte Carlo aplicada à análise econômica de pedido**, Produção, v. 21, n. 1, p. 149-164, 2011.

SILVA, W. A. **Otimização de parâmetros da gestão baseada em atividades aplicada em uma célula de manufatura**. 120 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá, Itajubá, 2005.

STURROCK, D. T. **Tips for successful practice of simulation**, Winter Simulation Conference, 2009.

TURRIONI, J. B.; MELLO, C. H. P. **Metodologia de pesquisa em engenharia de produção**. Universidade Federal de Itajubá. 2012.




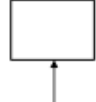
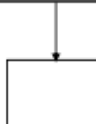




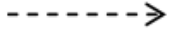



WANG, S.; SCHONFELD, P. **Genetic Algorithm for Selecting and Scheduling Waterway Projects**. NETS Report, 2006.

YALCINKAYA, O.; BAYHAN, G. M. **Modelling and optimization of average travel time for a metro line by simulation and response surface methodology**. European Journal of Operational Research. v. 196, p. 225–233, 2009.

ZHANG, R.; CHIANG, W. C.; WU, C. **Investigating the impact of operational variables on manufacturing cost by simulation optimization**. International Journal of Production Economics. v. 147, p. 634-646, 2014.

ANEXO A – Simbologia usada no IDEF-SIM

Tabela A - 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
	 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 B – Modelos conceituais em IDEF-SIM

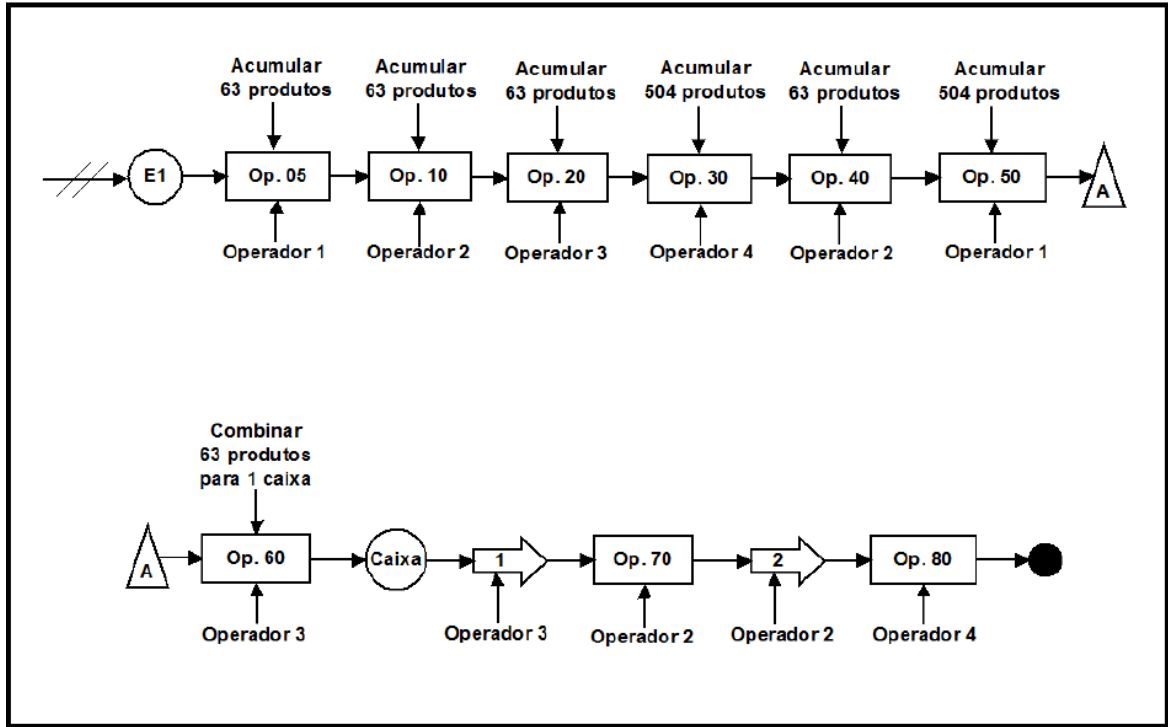


Figura B.1 - Modelo conceitual do objeto de estudo 1

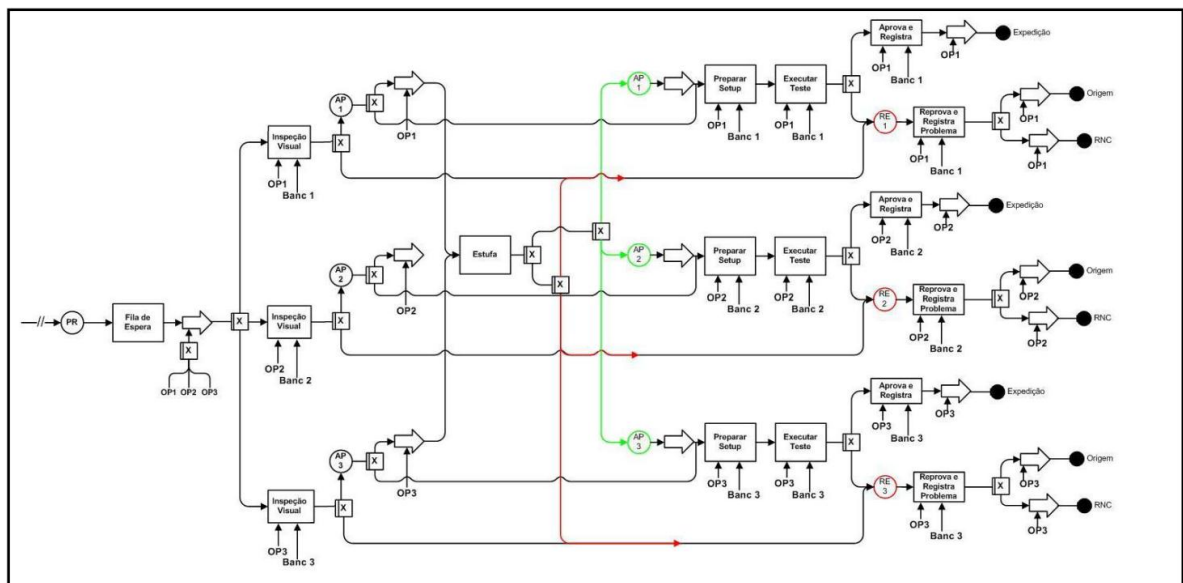


Figura B.2 - Modelo conceitual do objeto de estudo 2

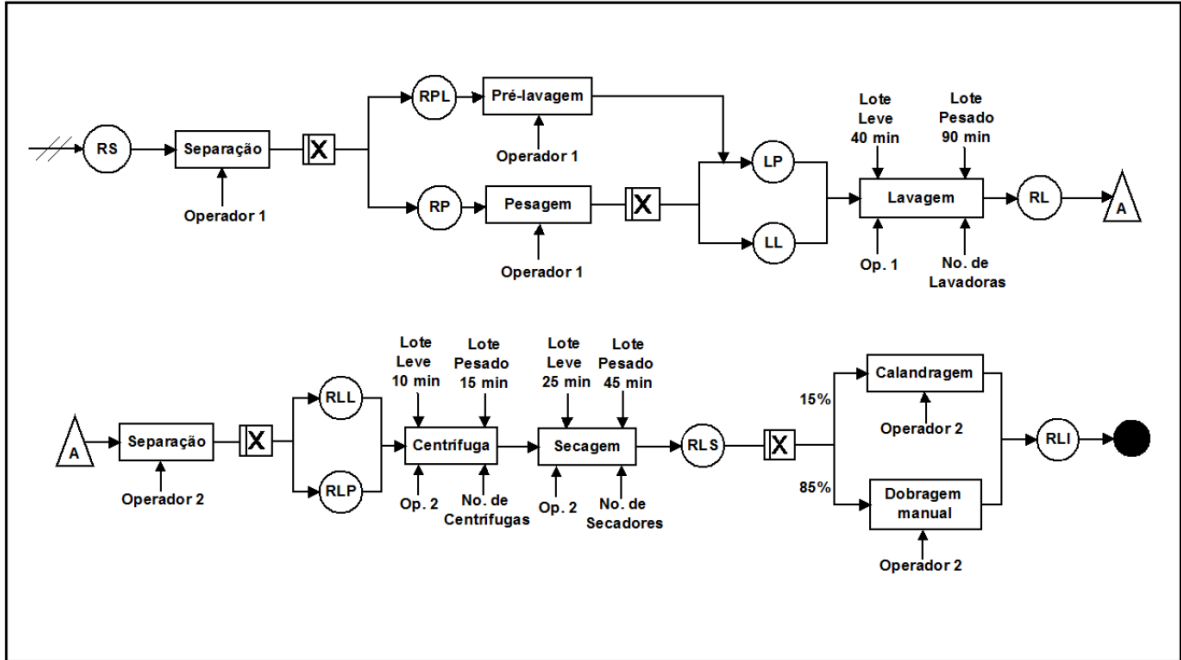


Figura B.3 - Modelo conceitual do objeto de estudo 3

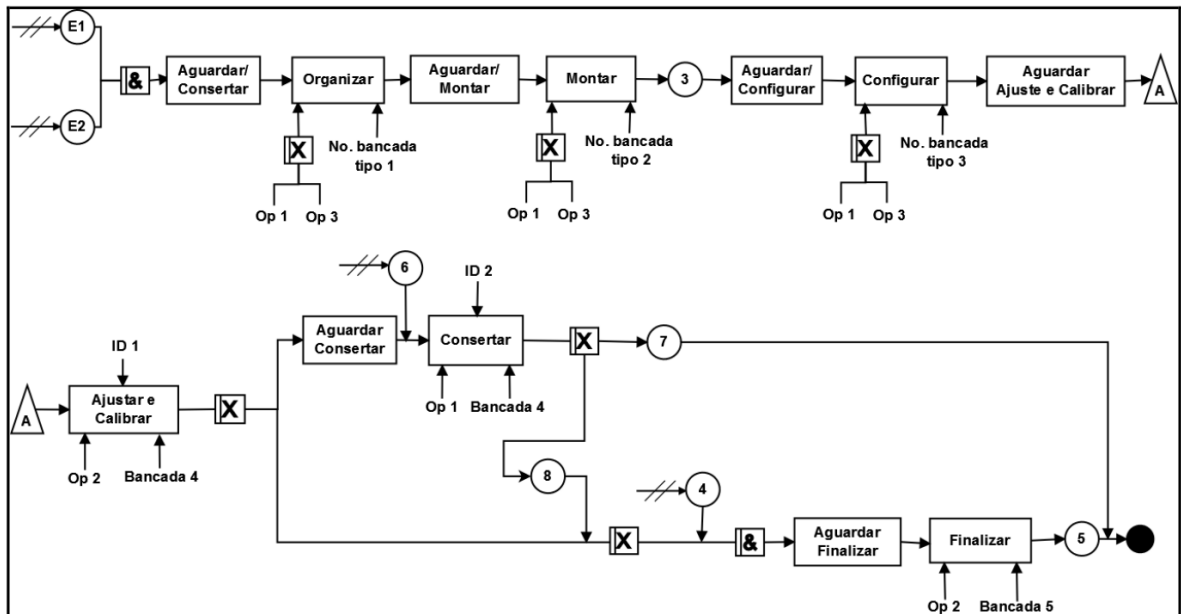


Figura B.4 - Modelo conceitual do objeto de estudo 4

ANEXO C - Gráficos de contorno e respectivas superfícies de respostas.

Nos anexos são mostrados os gráficos de contorno e as superfícies de resposta não mostradas no texto dessa dissertação. Sendo que, neste anexo não é mostrado nenhum gráfico do objeto de estudo 1, pois o mesmo apresenta somente os que foram mostrados durante o texto.

Objeto de estudo 2:




Figura C.1: Vista superior da SR entre os fatores A e C – Gráfico de Contorno.




Figura C.2: Superfície de Resposta dos fatores A e C.




Figura C.3: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.




Figura C.4: Superfície de Resposta dos fatores B e C.

Objeto de estudo 3




Figura C.5: Vista superior da SR entre A e B – Gráfico de Contorno.




Figura C.6: Superfície de Resposta entre A e B




Figura C.7: Vista superior da SR entre A e E – Gráfico de Contorno.




Figura C.8: Superfície de Resposta entre A e E




Figura C.9: Vista superior da SR entre B e D – Gráfico de Contorno.




Figura C.10: Superfície de Resposta entre B e D.




Figura C.11: Vista superior da SR entre B e E – Gráfico de Contorno.




Figura C.12: Superfície de Resposta entre B e E.




Figura C.13: Vista superior da SR entre D e E – Gráfico de Contorno.




Figura C.14: Superfície de Resposta entre D e E.

Objeto de estudo 4:




Figura C.15: Vista superior da SR entre os fatores A e B – Gráfico de Contorno.





Figura C.16: Superfícies de Resposta entre A e B



FiguraC.17: Vista superior da SR entre os fatores A e C – Gráfico de Contorno.




Figura C.18: Superfícies de Resposta entre A e C.




Figura C.19: Vista superior da SR entre os fatores A e D – Gráfico de Contorno.




Figura C.20: Superfícies de Resposta entre A e D.




Figura C.21: Vista superior da SR entre os fatores A e E – Gráfico de Contorno.




Figura C.22: Superfícies de Resposta entre A e E.




Figura C.23: Vista superior da SR entre os fatores B e C – Gráfico de Contorno.




Figura C.24: Superfícies de Resposta entre B e C.




Figura C.25: Vista superior da SR entre os fatores B e D – Gráfico de Contorno.




Figura C.26: Superfícies de Resposta entre B e D.




Figura C.27: Vista superior da SR entre os fatores B e E – Gráfico de Contorno.




Figura C.28: Superfícies de Resposta entre B e E.




Figura C.29: Vista superior da SR entre os fatores C e E – Gráfico de Contorno.




Figura C.30: Superfícies de Resposta entre C e E.




Figura C.31: Vista superior da SR entre os fatores D e E – Gráfico de Contorno.




Figura C.32: Superfícies de Resposta entre D e E.

APÊNDICE - Artigos submetidos em congressos

RODRIGUES, R. P.; PINHO, A. F.; GOMES, J. H. F.; QUEIRÓZ, J. A. Uso da técnica de superfície de resposta na otimização da simulação computacional do processo. Simpósio Brasileiro de Pesquisa Operacional, Anais... Salvador, BA, Brasil, 2014.

RODRIGUES, R. P.; MONTEVECHI, J. A. B.; GOMES, J. H. F.; QUEIRÓZ, J. A.; LEAL, F. Otimização de simulação a eventos discretos utilizando a metodologia de superfície de resposta. Simpósio Brasileiro de Pesquisa Operacional, Anais... Porto de Galinhas, PE, Brasil, 2015.