

UNIVERSIDADE FEDERAL DE ITAJUBÁ

Renaldo Gonzaga de Almeida Filho

**PLANEJAMENTOS FATORIAIS FRACIONADOS
PARA ANÁLISE DE SENSIBILIDADE DE
MODELOS DE SIMULAÇÃO DE 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. José Arnaldo Barra Montevechi, Dr.

Itajubá - MG

2006

DEDICATÓRIA

*À minha família:
minha amada esposa Márcia Andréa,
meus queridos filhos Júlio César e Isabela Catarina
e meus pais Renaldo e Maria do Carmo.*

AGRADECIMENTOS

Agradeço à Indústria de Material Bélico do Brasil – Fábrica de Itajubá na pessoa do seu superintendente sr. Alte Saturno Evangelista Zylberbergue por disponibilizar o tempo necessário para freqüentar o curso na Universidade Federal de Itajubá - UNIFEI e permitir a realização desta pesquisa nas suas instalações. Agradeço aos chefes que tive no período de realização do curso, Eng. Ronaldo Roberto Rodrigues e Eng. Afonso Henrique Castilho, pela compreensão e colaboração que eu recebi.

Aos amigos do Núcleo de Estudos Avançados para Auxílio à Decisão – NEAAD do Instituto de Engenharia de Produção e Gestão agradeço pela companhia agradável e pelas dicas úteis para o desenvolvimento desta pesquisa. Em especial, para o meu orientador Professor José Arnaldo Barra Montevechi, um muito obrigado pela paciência, compreensão, motivação e amizade fundamentais para conclusão desta pesquisa.

A minha querida esposa Márcia Andréa Souza de Oliveira Almeida agradeço pela paciência e compreensão e aos meus amados pais Renaldo Gonzaga de Almeida e Maria do Carmo Bezerra da Silva agradeço pela oportunidade, investimento e incentivo para seguir o caminho o qual me conduziu até este momento.

Por fim, a todos aqueles que de uma forma ou de outra colaboraram ou acompanharam-me nessa jornada, meu muito obrigado!

RESUMO

A modelagem de sistemas de manufatura através da simulação é utilizada desde primórdios da década de 1960 e tornou-se uma das mais populares e poderosas ferramentas empregadas para analisar complexos sistemas de manufatura. Através da modelagem dos sistemas é possível realizar sua otimização. Entretanto, a integração entre otimização e simulação não ocorreu rapidamente, na prática, até o fim do último milênio otimização e simulação estiveram bem separadas, mas esse quadro tem mudado e, atualmente, programas de otimização são parte integrantes na maioria dos pacotes de simulação.

A otimização via simulação exige um considerável esforço computacional, pois para se localizar a solução ótima é necessário verificar diversas configurações de valores dos parâmetros. Uma forma de acelerar a otimização é reduzir o seu espaço de busca limitando o número de variáveis que o compõem, uma vez que nem todas as variáveis são igualmente importantes com respeito ao seu efeito sobre a resposta do modelo.

A presente pesquisa estudou o emprego das técnicas estatísticas de planejamento fatorial fracionado na identificação das variáveis mais importantes de dois modelos de simulação de eventos discretos objetivando a redução do espaço de busca da otimização de modo a acelerar esta fase. Esta pesquisa classifica-se como experimental quantitativa de natureza aplicada com objetivo explicativo. A ferramenta utilizada para a realização dos experimentos é a simulação de eventos discretos.

O procedimento experimental seguido foi otimizar cada modelo de duas formas distintas. Na primeira forma, inicialmente, realizou-se a análise de sensibilidade das variáveis do modelo utilizando planejamentos fatoriais fracionados. Após a identificação das variáveis mais significativas, realizou-se a otimização do modelo utilizando esse espaço de busca reduzido. A segunda forma consistia na otimização pura e simples do modelo. Nenhum estudo foi feito nesta abordagem para determinar se todas as variáveis do modelo têm o mesmo efeito no resultado final. Por fim, comparou-se o número de execuções de cada uma das formas.

O resultado da primeira aplicação indicou uma redução de 59% no número de execuções entre a otimização planejada e a otimização não planejada. Para a segunda aplicação, não houve vantagem no planejamento preliminar da otimização. A principal razão para o resultado desfavorável desta última aplicação deveu-se a sua forma de modelagem mostrando a importância da construção do modelo.

Palavras chave: Simulação, Planejamento de Experimentos, Otimização, Fatorial Fracionado.

ABSTRACT

The manufacturing system modeling through simulation is used since the early 60's and became one of the most popular and powerful tools for analyzing complex manufacturing systems. Through system modeling is possible perform its optimization. However, the integration between optimization and simulation did not happen fast. In fact, until the end of last millennium, optimization and simulation were kept well separated but this situation has changed and, nowadays, optimization software is a component of almost every simulation package.

Optimization via simulation demands a considerable computational effort since to locate the optimum solution it is necessary to verify several parameter value settings. One way to accelerate the optimization is reducing the search space by selecting the variables which comprises it, once not all variables have the same importance with respect of their effect over the model output.

This research has studied the use of fractional factorial design statistic techniques to identify the more important variables from two discrete-event simulation models aiming to reduce the optimization's space search in order to accelerate that phase. This is an applied quantitative experimental research, with explanatory objective. The tool to perform the experiments is the discrete-event simulation.

The research methodology was to optimize each model by two distinct procedures. The first procedure performs a variable sensitivity analysis of the model using fractional factorial designs. After identifying the more important variables, the model's optimization is performed using this reduced search space. The second procedure performs a straightforward model's optimization. No study was done in this approach to determine if all model's variables impact the same effect to the output. Finally, for each model, the amount of runs of each procedure was compared.

The result of the first application appointed a 59% reduction for the amount of runs between the planned optimization and the straightforward one. The second application did not present such reduction. The main reason for this bad result in the last application is the way the system was modeled, showing the importance of planning the system's model correctly.

Keywords: Simulation, Design of Experiments, Optimization, Fractional Factorial Design.

LISTA DE FIGURAS

<i>Figura 1.1 – Classificação da pesquisa científica. Fonte: Baseado em Silva e Menezes (2005).</i>	5
<i>Figura 2.1 – Formas de estudar um sistema. Fonte: Adaptado de Law e Kelton (2000).</i>	9
<i>Figura 2.2 – Estado do sistema. Fonte: Adaptado de Banks et al. (2005).</i>	10
<i>Figura 2.3 – Eliminação da fase transiente para simulação não-terminante. Fonte: Adaptado de Banks (1998).</i>	11
<i>Figura 2.4 – Etapas de um estudo por simulação. Fonte: Banks et al. (2005).</i>	17
<i>Figura 2.5 – Natureza iterativa de um projeto de simulação. Fonte: Adaptado de Harrel et al. (2000).</i>	18
<i>Figura 2.6 – Tela de abertura do ProModel.</i>	22
<i>Figura 3.1 – Emprego da otimização na simulação. Fonte: adaptado de Fu (2002).</i>	26
<i>Figura 3.2 – Interação entre o pacote de otimização e o modelo de simulação. Fonte: Adaptado de Law e Kelton (2000).</i>	28
<i>Figura 3.3 – Representação binária de um cromossomo com quatro genes e seis bits cada gene. Fonte: Silva (2005).</i>	32
<i>Figura 3.4 – Cruzamento de ponto único. Fonte: Izidoro (2001).</i>	35
<i>Figura 3.5 – Cruzamento de dois pontos. Fonte: Izidoro (2001).</i>	35
<i>Figura 3.6 – Cruzamento uniforme. Fonte: Izidoro (2001).</i>	36
<i>Figura 3.7 – Operador mutação. Fonte: Izidoro (2001).</i>	36
<i>Figura 3.8 – Seleção do modelo ou projeto.</i>	38
<i>Figura 3.9 – Definição da função objetivo.</i>	39
<i>Figura 3.10 – Definição das entradas.</i>	39
<i>Figura 3.11 – Módulo de análise do modelo.</i>	40
<i>Figura 3.12 – Execução da análise.</i>	40
<i>Figura 3.13 – Opções da otimização.</i>	41
<i>Figura 3.14 – Execução da otimização.</i>	42
<i>Figura 3.15 – Gráfico das medidas de desempenho.</i>	42
<i>Figura 3.16 – Superfície de resposta.</i>	43
<i>Figura 5.1 – Fluxograma do processo no grupo 1 para a aplicação 1.</i>	56
<i>Figura 5.2 – Modelo do Grupo 1 da aplicação 1.</i>	60
<i>Figura 6.1 – Fluxograma do processo no grupo 1 para a aplicação 2.</i>	71
<i>Figura 6.2 – Modelo do Grupo 1 da aplicação 2.</i>	80

LISTA DE GRÁFICOS

Gráfico 5.1 – Efeitos principais para Resultado.	64
Gráfico 5.2 – Interação de 2ª ordem entre os fatores.	64
Gráfico 5.3 – Desempenho da otimização da aplicação 1 com fatores selecionados.	66
Gráfico 5.4 - Desempenho da otimização da aplicação 1 com todos os fatores.	67
Gráfico 6.1 – Boxplot dos tempos da operação 52.	74
Gráfico 6.2 – Boxplot dos tempos da operação 52 sem outliers.	74
Gráfico 6.3 – Gráfico de probabilidade para tempo de fixação da operação 52.	75
Gráfico 6.4 – Gráfico de probabilidade para tempo de usinagem da operação 52.	75
Gráfico 6.5 – Gráfico de probabilidade para tempo de remoção da operação 52.	76
Gráfico 6.6 – Gráfico de probabilidade para tempo de troca da operação 52.	76
Gráfico 6.7 – Resíduos para a variável “Produção”.	84
Gráfico 6.8 – Efeitos principais	85
Gráfico 6.9 – Pareto dos efeitos padronizados.	86
Gráfico 6.10 – Probabilidade normal dos efeitos.	86
Gráfico 6.11 – Interação de 2ª ordem entre os fatores.	87
Gráfico 6.12 – Desempenho da otimização da aplicação 2 com fatores selecionados.	89
Gráfico 6.13 – Desempenho da otimização da aplicação 2 com todos os fatores.	90
Gráfico A.1 – Boxplot dos tempos da operação 50.	102
Gráfico A.2 – Gráfico de probabilidade para tempo de fixação da operação 50.	103
Gráfico A.3 – Gráfico de probabilidade para tempo de usinagem da operação 50.	103
Gráfico A.4 – Gráfico de probabilidade para tempo de remoção da operação 50.	104
Gráfico A.5 – Boxplot dos tempos da operação 51.	105
Gráfico A.6 – Gráfico de probabilidade para tempo de fixação da operação 51.	105
Gráfico A.7 – Gráfico de probabilidade para tempo de usinagem da operação 51.	106
Gráfico A.8 – Gráfico de probabilidade para tempo de remoção da operação 51.	106
Gráfico A.9 – Gráfico de probabilidade para tempo de troca da operação 51.	107
Gráfico A.10 – Boxplot dos tempos da operação 52.	108
Gráfico A.11 – Boxplot dos tempos da operação 52 sem outliers.	108
Gráfico A.12 – Gráfico de probabilidade para tempo de fixação da operação 52.	109
Gráfico A.13 – Gráfico de probabilidade para tempo de usinagem da operação 52.	109
Gráfico A.14 – Gráfico de probabilidade para tempo de remoção da operação 52.	110
Gráfico A.15 – Gráfico de probabilidade para tempo de troca da operação 52.	110
Gráfico A.16 – Boxplot dos tempos da operação 70.	111
Gráfico A.17 – Boxplot dos tempos da operação 70 sem outliers.	112
Gráfico A.18 – Gráfico de probabilidade para tempo de fixação da operação 70.	112
Gráfico A.19 – Gráfico de probabilidade para tempo de usinagem da operação 70.	113
Gráfico A.20 – Gráfico de probabilidade para tempo de remoção da operação 70.	113
Gráfico A.21 – Boxplot dos tempos da operação 80.	114
Gráfico A.22 – Gráfico de probabilidade para tempo de fixação da operação 80.	115
Gráfico A.23 – Gráfico de probabilidade para tempo de usinagem da operação 80.	115
Gráfico A.24 – Gráfico de probabilidade para tempo de remoção da operação 80.	116
Gráfico A.25 – Boxplot dos tempos da operação 82.	117
Gráfico A.26 – Boxplot dos tempos da operação 82 sem outliers.	117
Gráfico A.27 – Gráfico de probabilidade para tempo de fixação da operação 82.	118
Gráfico A.28 – Gráfico de probabilidade para tempo de usinagem da operação 82.	118
Gráfico A.29 – Gráfico de probabilidade para tempo de remoção da operação 82.	119
Gráfico A.30 – Boxplot dos tempos da operação 100.	120

<i>Gráfico A.31 – Boxplot dos tempos da operação 100 sem outliers.</i>	<i>120</i>
<i>Gráfico A.32 – Gráfico de probabilidade para tempo de fixação da operação 100.</i>	<i>121</i>
<i>Gráfico A.33 – Gráfico de probabilidade para tempo de usinagem da operação 100.</i>	<i>121</i>
<i>Gráfico A.34 – Gráfico de probabilidade para tempo de remoção da operação 100.</i>	<i>122</i>
<i>Gráfico A.35 – Boxplot dos tempos da operação 110.</i>	<i>123</i>
<i>Gráfico A.36 – Boxplot dos tempos da operação 110 sem outliers.</i>	<i>123</i>
<i>Gráfico A.37 – Gráfico de probabilidade para tempo de fixação da operação 110.</i>	<i>124</i>
<i>Gráfico A.38 – Gráfico de probabilidade para tempo de usinagem da operação 110.</i>	<i>124</i>
<i>Gráfico A.39 – Gráfico de probabilidade para tempo de troca da operação 110.</i>	<i>125</i>
<i>Gráfico A.40 – Gráfico de probabilidade para tempo de remoção da operação 110.</i>	<i>125</i>
<i>Gráfico A.41 – Boxplot dos tempos da operação 120.</i>	<i>126</i>
<i>Gráfico A.42 – Boxplot dos tempos da operação 120 sem outliers.</i>	<i>127</i>
<i>Gráfico A.43 – Gráfico de probabilidade para tempo de fixação da operação 120.</i>	<i>127</i>
<i>Gráfico A.44 – Gráfico de probabilidade para tempo de usinagem da operação 120.</i>	<i>128</i>
<i>Gráfico A.45 – Gráfico de probabilidade para tempo de remoção da operação 120.</i>	<i>128</i>
<i>Gráfico A.46 – Boxplot dos tempos da operação 170.</i>	<i>129</i>
<i>Gráfico A.47 – Gráfico de probabilidade para tempo de fixação da operação 170.</i>	<i>130</i>
<i>Gráfico A.48 – Gráfico de probabilidade para tempo de usinagem da operação 170.</i>	<i>130</i>
<i>Gráfico A.49 – Gráfico de probabilidade para tempo de remoção da operação 170.</i>	<i>131</i>

LISTA DE TABELAS

<i>Tabela 5.1 – Detalhamento do processo da aplicação 1.</i>	57
<i>Tabela 5.2 – Detalhamento do processo da aplicação 1 (cont.).</i>	58
<i>Tabela 5.3 – Simbologia utilizada e seu significado.</i>	58
<i>Tabela 5.4 – Resultados dos experimentos do planejamento $2_{IV}^{(9-4)}$.</i>	63
<i>Tabela 5.5 – Resultados obtidos na aplicação 1.</i>	68
<i>Tabela 6.1 – Tempos coletados da operação 52.</i>	73
<i>Tabela 6.2 – Detalhamento do processo da aplicação 2.</i>	77
<i>Tabela 6.3 – Detalhamento do processo da aplicação 2 (cont.).</i>	78
<i>Tabela 6.4 – Resultados dos experimentos da aplicação 2.</i>	83
<i>Tabela 6.5 – Classificação das operações mais longas.</i>	85
<i>Tabela 6.6 – Melhores resultados da otimização da aplicação 2 com fatores selecionados.</i>	88
<i>Tabela 6.7 – Melhores resultados da otimização da aplicação 2 com todos os fatores.</i>	89
<i>Tabela 6.8 – Comparativo do número de execuções da aplicação 2.</i>	90
<i>Tabela A.1 – Tempos coletados da operação 50.</i>	102
<i>Tabela A.2 – Tempos coletados da operação 51.</i>	104
<i>Tabela A.3 – Tempos coletados da operação 52.</i>	107
<i>Tabela A.4 – Tempos coletados da operação 70.</i>	111
<i>Tabela A.5 – Tempos coletados da operação 80.</i>	114
<i>Tabela A.6 – Tempos coletados da operação 82.</i>	116
<i>Tabela A.7 – Tempos coletados da operação 100.</i>	119
<i>Tabela A.8 – Tempos coletados da operação 110.</i>	122
<i>Tabela A.9 – Tempos coletados da operação 120.</i>	126
<i>Tabela A.10 – Tempos coletados da operação 170.</i>	129

LISTA DE QUADROS

<i>Quadro 2.1 – Classificação de sistemas, modelos e simulação. Fonte: Adaptado de Harrel et al. (2000), Law e Kelton (2000), Pereira (2000).</i>	11
<i>Quadro 3.1 – Programas de otimização. Fonte: Law e Kelton (2000).</i>	26
<i>Quadro 3.2 – Principais técnicas de otimização. Fonte: Adaptado de Fu (2002).</i>	30
<i>Quadro 3.3 – Algoritmo Genético. Fonte: Goldberg et al. (2005).</i>	33
<i>Quadro 5.1 – Resumo dos elementos do sistema.</i>	55
<i>Quadro 5.2 – Resumo do processo da aplicação 1.</i>	59
<i>Quadro 5.3 – Fatores experimentais para a aplicação 1.</i>	59
<i>Quadro 5.4 – Planejamentos fatoriais fracionados para nove fatores.</i>	61
<i>Quadro 5.5 – Distribuição das variáveis entre os fatores.</i>	61
<i>Quadro 5.6 – Matriz do planejamento fatorial fracionado $2_{IV}^{(9-4)}$.</i>	62
<i>Quadro 5.7 – Parâmetros da simulação.</i>	63
<i>Quadro 5.8 – Fatores mais significativos da aplicação 1.</i>	65
<i>Quadro 5.9 – Melhor solução da aplicação 1 com fatores selecionados.</i>	66
<i>Quadro 5.10 – Fatores de entrada da otimização com todos os fatores da aplicação 1.</i>	66
<i>Quadro 5.11 – Melhor solução da aplicação 1 com todos os fatores.</i>	67
<i>Quadro 6.1 – Resumo dos elementos do sistema.</i>	71
<i>Quadro 6.2 – Seqüência de execução das atividades das operações.</i>	72
<i>Quadro 6.3 – Resumo do processo da aplicação 2.</i>	78
<i>Quadro 6.4 – Fatores experimentais.</i>	79
<i>Quadro 6.5 – Planejamentos fatoriais fracionados para doze fatores.</i>	81
<i>Quadro 6.6 – Distribuição das variáveis entre os fatores.</i>	81
<i>Quadro 6.7 – Matriz do planejamento fracionado $2_{IV}^{(12-7)}$.</i>	82
<i>Quadro 6.8 – Parâmetros da simulação.</i>	82
<i>Quadro 6.9 – Fatores utilizados na otimização da aplicação 2.</i>	88

SUMÁRIO

<i>Dedicatória</i>	<i>i</i>
<i>Agradecimentos</i>	<i>ii</i>
<i>Resumo</i>	<i>iii</i>
<i>Abstract</i>	<i>iv</i>
<i>Lista de figuras</i>	<i>v</i>
<i>Lista de gráficos</i>	<i>vi</i>
<i>Lista de tabelas</i>	<i>viii</i>
<i>Lista de quadros</i>	<i>ix</i>
<i>Sumário</i>	<i>x</i>
<i>Capítulo 1 - Introdução</i>	<i>1</i>
1.1 - Considerações iniciais	1
1.2 - Apresentação da pesquisa	2
1.3 - Estrutura da dissertação	7
<i>Capítulo 2 - Simulação</i>	<i>8</i>
2.1 - Considerações iniciais	8
2.2 - Sistemas, modelos e a simulação	8
2.3 - Simulação: vantagens, desvantagens e emprego	14
2.4 - Desenvolvimento de um projeto de simulação	16
2.5 - O simulador ProModel	22
2.6 - Considerações finais	23
<i>Capítulo 3 - Otimização via simulação</i>	<i>24</i>
3.1 - Considerações iniciais	24
3.2 - Otimização via simulação	24
3.3 - Integração entre simulação e otimização	25
3.4 - Principais técnicas	29
3.5 - Algoritmos Genéticos	29
3.6 - Simrunner	37
3.7 - Considerações finais	43
<i>Capítulo 4 - Planejamento de Experimentos</i>	<i>44</i>
4.1 - Considerações iniciais	44
4.2 - Estratégias de experimentação	44
4.3 - Planejamento estatístico de experimentos	46
4.4 - Vantagens da experimentação por simulação	47
4.5 - Principais conceitos	48

4.6 - Planejamento fatorial 2^k	50
4.7 - Planejamento fatorial fracionário 2^{k-p}	51
4.8 - Verificação da validade do modelo experimental	52
4.9 - Considerações finais	53
Capítulo 5 - Primeira Aplicação	54
5.1 - Considerações iniciais	54
5.2 - Objeto de estudo	54
5.3 - Desenvolvimento da Aplicação 1	54
5.4 - Otimização da aplicação 1	65
5.5 - Considerações finais	68
Capítulo 6 - Segunda Aplicação	70
6.1 - Considerações iniciais	70
6.2 - Desenvolvimento da Aplicação 2	70
6.3 - Otimização da aplicação 2	87
6.4 - Considerações finais	91
Capítulo 7 - Conclusões	92
7.1 - Considerações iniciais	92
7.2 - Conclusões e contribuições da pesquisa	92
7.3 - Sugestões para trabalhos futuros	94
Referências Bibliográficas	95
Anexo A - Coleta dos dados	102
Anexo B - Planejamento fracionado da aplicação 2	132
Anexo C - Artigos originados desta pesquisa	135

CAPÍTULO 1 - INTRODUÇÃO

1.1 - Considerações iniciais

A modelagem de sistemas de manufatura através da simulação é utilizada desde primórdios da década de 1960 (LAW E MCCOMAS, 1998) e tornou-se uma das mais populares e poderosas ferramentas empregadas para analisar complexos sistemas de manufatura (SHANNON, 1998; O'KANE *et al.*, 2000; BANKS *et al.*, 2005).

Segundo O'Kane *et al.* (2000), uma forma de prever o comportamento destes sistemas é utilizando a simulação de eventos discretos que consiste em modelar um sistema onde as mudanças ocorrem em intervalos discretos de tempo. Esta técnica é apropriada para sistemas de manufatura onde o comportamento muda dessa forma.

Considerando que uma importante função da administração de uma empresa é a coordenação e o controle das complexas atividades incluindo a alocação ótima dos recursos no desempenho dessas atividades (JOHNSON E MONTGOMERY, 1974) é natural o desenvolvimento de técnicas de otimização utilizando modelos de simulação.

A otimização é apresentada por Harrel *et al.* (2000) como *o processo de tentar diferentes combinações de valores que podem ser controlados com o objetivo de procurar a combinação de valores que fornece a saída mais desejável do modelo de simulação.*

Entretanto, a integração entre otimização e simulação não ocorreu rapidamente. Segundo Fu (2002), *até o fim do último milênio, otimização e simulação estiveram bem separadas na prática ... entretanto, rotinas de otimização ... têm notavelmente conquistado seu espaço nos pacotes de simulação.*

Andradóttir (1998) faz uma observação bastante pertinente sobre a otimização via simulação. Segundo este autor, a verificação do desempenho de um sistema para uma determinada configuração de valores dos parâmetros com razoável precisão através da simulação exige um considerável esforço computacional. Para se localizar a solução ótima é necessária verificar diversas configurações de valores dos parâmetros, logo, a otimização via simulação é extremamente exaustiva do ponto de vista do esforço computacional.

Considerando que nem todas as variáveis são igualmente importantes com respeito ao seu efeito sobre a resposta do modelo (BILES, 1979, 1984), deve-se selecionar as variáveis que compõem o espaço de busca da otimização, uma vez que quanto menos variáveis compõem o espaço de busca mais rápida torna-se a otimização.

Assim, para proceder à seleção das variáveis, podem-se realizar experimentos de caracterização ou *screening* (da expressão em inglês *factor screening experiments*), onde se tenta separar as variáveis mais importantes daquelas que são negligenciáveis (BILES, 1979, 1984). Esse mesmo autor apresenta alguns exemplos de planejamentos de experimentos utilizados em experimentos de caracterização:

- Planejamentos fatoriais 2^n ;
- Planejamentos fatoriais fracionados 2^{n-p} ;
- Planejamentos supersaturados;
- Planejamentos de caracterização por grupo.

A presente pesquisa trata do emprego de planejamentos fatoriais fracionados em modelos de simulação. Para informações sobre outros planejamentos experimentais consultar Montgomery (2001), Kleijnen (1998), Law e Kelton (2000), Banks *et al.* (2005).

O planejamento fatorial fracionado é umas das técnicas de Planejamento de Experimentos no qual apenas uma fração dos experimentos é executada reduzindo, dessa forma, a quantidade de experimentos quanto comparado ao planejamento fatorial completo. Deseja-se através da presente pesquisa verificar o emprego em simulação deste tipo de planejamento para identificar as variáveis mais importantes do modelo de modo a reduzir o espaço de busca da etapa de otimização.

Para alcançar tal objetivo, dois estudos são apresentados comparando uma otimização realizada sem estudo prévio da significância das variáveis de entrada (fatores) e uma otimização realizada com um espaço de busca reduzido através do planejamento fatorial fracionado.

A seguir neste capítulo são apresentados o problema, os objetivos da pesquisa, as questões envolvidas, a justificativa do tema, a metodologia empregada e as suas limitações. Encerrando o capítulo apresenta-se a estrutura desta dissertação.

1.2 - Apresentação da pesquisa

1.2.1 - Problema a ser pesquisado

Estudar o emprego das técnicas estatísticas de planejamento fatorial fracionado na identificação das variáveis mais importantes de modelos de simulação de eventos discretos objetivando a redução do espaço de busca da fase de otimização de modo a acelerar esta fase.

1.2.2 - Objetivo da pesquisa

Verificar como as técnicas de planejamento fatorial fracionado podem ser empregadas na análise de sensibilidade de modelos de simulação, identificando as suas vantagens e desvantagens e efeitos na otimização desses modelos.

1.2.3 - Questões

A presente pesquisa propõe-se a responder as seguintes questões:

1. O emprego das técnicas de planejamento fatorial fracionado em modelo de simulação é possível e eficaz?
2. As técnicas de planejamento fatorial fracionado permitem a análise de sensibilidade das variáveis de um modelo de simulação?
3. A identificação das variáveis mais significativas de um modelo de simulação acelera a otimização deste modelo?

1.2.4 - Justificativa da pesquisa

No Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Itajubá, dentro da subárea de concentração Simulação, foram desenvolvidas várias pesquisas onde os focos foram os empregos da Simulação no estudo de células de manufatura (PEREIRA, 2000; DUARTE, 2003) e na avaliação de custo de produção (OLIVEIRA, 2003; SILVA, 2005). Para Taveira (1997), a simulação é uma ferramenta muito útil, uma vez que prevê o comportamento de sistemas complexos, calculando os movimentos e interações dos componentes do sistema.

Juntamente com a simulação, a otimização vem sendo cada vez mais utilizada nas organizações, pois esta ferramenta obtém as melhores respostas do modelo (PRICE E HARREL, 1999), economizando tempo e dinheiro em manipulações do modelo. A pesquisa desenvolvida por Silva (2005) enquadra-se perfeitamente nesse contexto, pois buscou, através de rotinas de otimização, a redução dos custos de fabricação em uma célula cujo sistema de custeio era baseado em atividades.

Por outro lado, segundo Shannon (1998), a simulação *é o processo de projetar um modelo de um sistema real e realizar experimentos neste modelo com o propósito de compreender o comportamento do sistema e/ou avaliar várias estratégias para a operação do sistema*. Dessa forma, é relevante o emprego das técnicas de Planejamento ou Delineamento de Experimentos (*DOE* do inglês *Design of Experiments*) para que os experimentos produzam

resultados válidos e úteis tanto sob o ponto de vista científico quanto sob o ponto de vista prático de simulação e otimização.

Utilizando-se as técnicas de *DOE*, é possível reduzir o número de experimentos a serem executados ou determinar quais são as variáveis independentes que afetam a variável dependente e a amplitude desse efeito. Para a otimização, a identificação das variáveis mais significativas é importante haja vista que quanto maior o número de variáveis do espaço de busca mais demorada torna-se a fase de otimização.

1.2.5 - Metodologia da pesquisa

Para responder as questões propostas adotaram-se duas abordagens distintas. Na primeira abordagem realizou-se a análise de sensibilidade das variáveis do modelo utilizando planejamentos fatoriais fracionados. Após a identificação das variáveis mais significativas, a otimização do modelo é realizada utilizando esse espaço de busca reduzido.

A segunda abordagem consiste na otimização pura e simples do modelo. Nesta abordagem não é feito nenhum estudo para determinar se todas as variáveis do modelo têm o mesmo efeito no resultado final.

Essas abordagens foram empregadas tanto em um modelo de simulação determinístico quanto em um modelo estocástico. Através dessas duas aplicações deseja-se verificar o emprego das técnicas de planejamento fatorial fracionado apontando as suas vantagens e desvantagens e efeitos na otimização das aplicações.

1.2.6 - Classificação da pesquisa

Pesquisa é *um conjunto de ações, propostas para encontrar a solução para um problema, que têm por base procedimentos racionais e sistemáticos* (SILVA E MENEZES, 2005), para estes autores, quando se tem um problema e não se tem informações para solucioná-lo realiza-se uma pesquisa.

Assim, segundo Silva e Menezes (2005), a pesquisa é *a construção de conhecimento original de acordo com certas exigências científicas*. Para estes autores a pesquisa científica deve ser coerente, consistente, original e objetiva.

Gil (1999) afirma que a pesquisa tem um caráter pragmático sendo um *processo formal e sistemático de desenvolvimento do método científico*. O objetivo fundamental da pesquisa é *descobrir respostas para problemas mediante o emprego de procedimentos científicos*.

A **Figura 1.1** apresenta uma classificação clássica da pesquisa científica. Nesta figura observa-se que a pesquisa científica pode ser classificada considerando-se quatro aspectos distintos, a saber: natureza, objetivos, forma de abordagem e procedimentos técnicos.

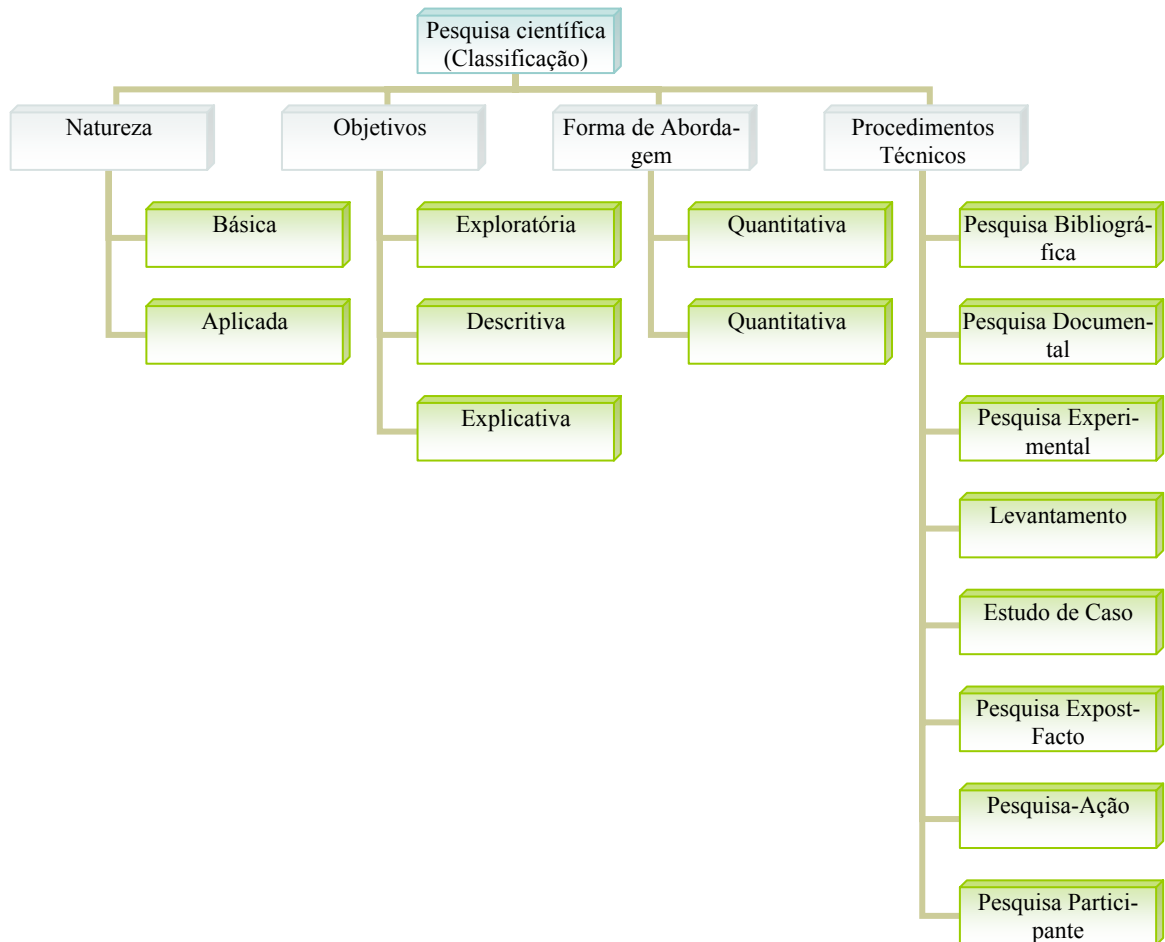


Figura 1.1 – Classificação da pesquisa científica. Fonte: Baseado em Silva e Menezes (2005).

Considerando a natureza da pesquisa, Silva e Menezes (2005) afirmam que a Pesquisa Básica *objetiva gerar conhecimentos novos úteis para o avanço da ciência sem aplicação prática prevista. Envolve verdades e interesses universais* enquanto que a Pesquisa Aplicada *objetiva gerar conhecimentos para aplicação prática e dirigidos à solução de problemas específicos. Envolve verdades e interesses locais.*

Sob o enfoque da forma de abordagem, para Silva e Menezes (2005), a Pesquisa Quantitativa *considera que tudo pode ser quantificável, o que significa traduzir em números opiniões e informações para classificá-las e analisá-las. Requer o uso de recursos e de técnicas estatísticas (percentagem, média, moda, mediana, desvio-padrão, coeficiente de correlação, análise de regressão, etc.).* A Pesquisa Qualitativa, por sua vez, *considera que há uma relação dinâmica entre o mundo real e o sujeito, isto é, um vínculo indissociável entre o*

mundo objetivo e a subjetividade do sujeito que não pode ser traduzido em números. Para estes autores, a interpretação dos fenômenos e a atribuição de significados são básicas no processo de pesquisa qualitativa. Não requer o uso de métodos e técnicas estatísticas.

Quanto aos objetivos da pesquisa, Gil (1991) as classifica como pesquisa exploratória, descritiva e explicativa. A Pesquisa Exploratória *visa proporcionar maior familiaridade com o problema com vistas a torná-lo explícito ou a construir hipóteses... Assume, em geral, as formas de Pesquisas Bibliográficas e Estudos de Caso.* A Pesquisa Descritiva *visa descrever as características de determinada população ou fenômeno ou o estabelecimento de relações entre variáveis... Assume, em geral, a forma de Levantamento.* E a Pesquisa Explicativa *visa identificar os fatores que determinam ou contribuem para a ocorrência dos fenômenos. Aprofunda o conhecimento da realidade porque explica a razão, o “porquê” das coisas... Assume, em geral, as formas de Pesquisa Experimental e Pesquisa Expost-facto.*

Considerando os procedimentos técnicos utilizados na pesquisa, Gil (1991) apresenta a Pesquisa Bibliográfica como sendo aquela elaborada a partir de material já publicado, a Pesquisa Documental, por sua vez, é aquela que é elaborada a partir de materiais que não receberam tratamento analítico. A Pesquisa Experimental ocorre *quando se determina um objeto de estudo, selecionam-se as variáveis que seriam capazes de influenciá-lo, definem-se as formas de controle e de observação dos efeitos que a variável produz no objeto.* Quando o “experimento” é realizado depois dos fatos, então, a pesquisa é Expost-Facto.

Quando a pesquisa envolve a interrogação direta das pessoas cujo comportamento se deseja conhecer ocorre o Levantamento (GIL, 1991). O Estudo de Caso *envolve o estudo profundo e exaustivo de um ou poucos objetos de maneira que se permita o seu amplo e detalhado conhecimento.* Por outro lado, se a pesquisa é concebida e realizada em estreita associação com uma ação ou com a resolução de um problema coletivo ela é dita ser Pesquisa-Ação. Nesta pesquisa, os pesquisadores e participantes representativos da situação ou do problema estão envolvidos de modo cooperativo ou participativo. A pesquisa é classificada como participante quando se desenvolve a partir da interação entre pesquisadores e membros das situações investigadas.

Baseado o exposto acima, classifica-se a presente pesquisa como de natureza aplicada com objetivo exploratório. A forma de abordagem é quantitativa empregando a simulação de eventos discretos como ferramenta para a realização dos experimentos (BERTRAND E FRANSOO, 2002). Esta pesquisa devido ao procedimento técnico ser experimental caracteriza-se como uma pesquisa experimental (BRYMAN, 1989).

1.2.7 - Limitações da metodologia

De acordo com Bryman (1989), a “força” da pesquisa experimental é permitir ao pesquisador tirar conclusões com segurança sobre relações causais. Para tanto, os experimentos devem ser realizados de forma a terem validade interna e externa.

Por validade interna denota-se a capacidade de concluir que a variável independente realmente afeta a variável dependente, ou seja, a capacidade de eliminar explicações concorrentes de uma aparente relação causal através dos resultados obtidos. Por validade externa denota-se a extensão para a qual as conclusões obtidas pela pesquisa podem ser generalizadas além das fronteiras das configurações para as quais a pesquisa foi realizada (BRYMAN, 1989).

Considerando as questões acima, a presente pesquisa apresenta validade interna, pois os experimentos são realizados de forma a concluir quais das variáveis independentes afetam a variável dependente, contudo, a mesma não possui validade externa uma vez que não é possível estender os resultados obtidos para outras situações, o que também não é a intenção dessa pesquisa.

1.3 - Estrutura da dissertação

Esta dissertação está estruturada em sete capítulos. O presente capítulo é introdutório. Nos capítulos 2, 3 e 4 são apresentados os embasamentos teóricos para Simulação, Otimização e Planejamento de Experimentos respectivamente.

Nos capítulos 5 e 6 são desenvolvidas as aplicações para avaliação do uso dos planejamentos fatoriais. No capítulo 5, o projeto de simulação utiliza um modelo determinístico enquanto, no capítulo 6, o modelo é estocástico. Em cada capítulo, são realizadas as otimizações das aplicações e a apresentação dos resultados. Por fim, no capítulo 7 são apresentadas as conclusões e sugestões de continuidade para novos trabalhos.

CAPÍTULO 2 - SIMULAÇÃO

2.1 - Considerações iniciais

No Dicionário Houaiss da Língua Portuguesa (2006) encontra-se diversas definições de simulação tais como *imitação do funcionamento de um processo por meio do funcionamento de outro e teste, experiência ou ensaio em que se empregam modelos para simular o ser humano, em especial em casos de grande perigo de vida*.

Nesse dicionário é possível encontrar ainda as seguintes locuções: simulação analógica definida como *teste ou experiência em que os modelos empregados têm comportamento análogo ao da realidade* e simulação digital definida como *experiência ou ensaio constituído por uma série de cálculos numéricos e decisões de escolha limitada, executados de acordo com um conjunto de normas preestabelecidas e apropriadas à utilização de computadores*.

É justamente esta última definição, simulação digital, o assunto deste capítulo. Neste capítulo são apresentadas definições de simulação, as classificações comumente adotadas, as razões de se utilizar a simulação. São apresentados procedimentos propostos por diversos autores para o desenvolvimento de estudos de simulação.

2.2 - Sistemas, modelos e a simulação

Blanchard (1991) e Banks *et al.* (2005) definem sistema como um conjunto de objetos que estão agrupados em alguma interação regular ou interdependência com o objetivo de satisfazer algum propósito. Desta definição observam-se os seguintes pontos chaves: *um sistema consiste de múltiplos elementos, estes elementos estão inter-relacionados e trabalham em cooperação e um sistema existe para o propósito de alcançar objetivos específicos* (HARREL *et al.*, 2000).

Segundo Law e Kelton (2000), na prática, o que é definido como sistema depende do objetivo do estudo. O que para um estudo particular foi definido como sistema em outro estudo pode ser apenas um subconjunto de elementos de um sistema mais amplo.

A representação de um sistema é chamada de modelo (BANKS, 1998; LAW E KELTON, 2000). Segundo Bertrand e Fransoo (2002), um modelo *é sempre uma abstração da realidade no sentido de que a realidade completa não está incluída*. Para estes autores, tem-se um modelo idealizado quando, além da abstração da realidade a qual é estendida de forma que as relações essenciais tornam-se evidentes, as funções tornam-se unidimensionais ou bidimensionais, diferenciáveis, etc., com o objetivo de fazer o modelo tratável para análise

matemática. Um modelo de simulação é um modelo matemático para ser estudado por meio de simulação (BANKS *et al.*, 2005; LAW E KELTON, 2000), **Figura 2.1**.

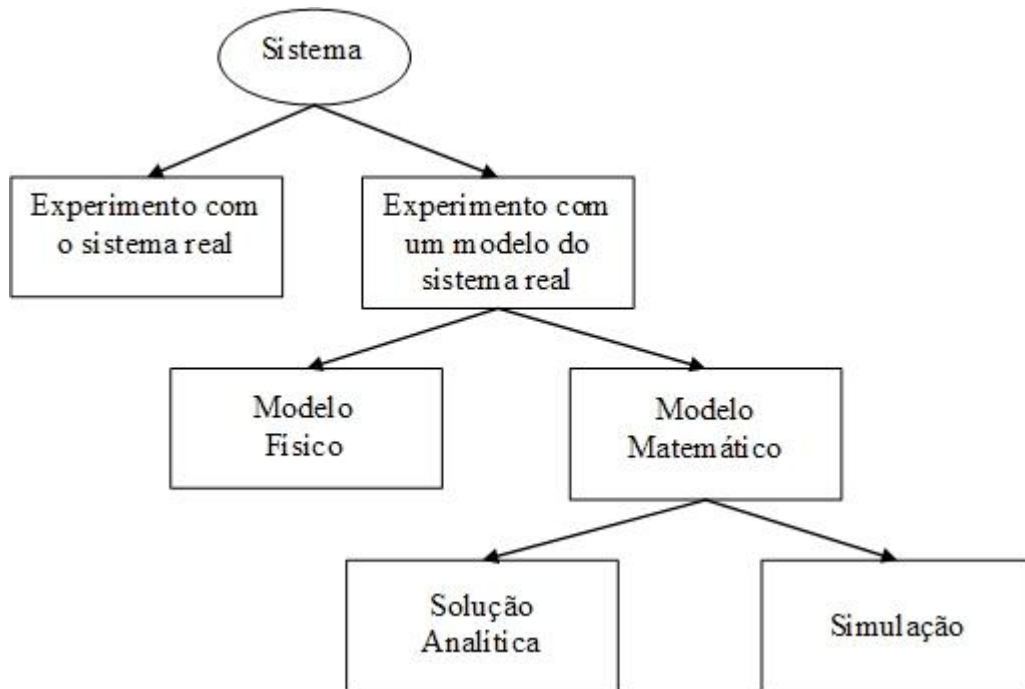


Figura 2.1 – Formas de estudar um sistema. Fonte: Adaptado de Law e Kelton (2000).

Harrel *et al.* (2000) definem a simulação como um meio de reproduzir o comportamento de sistemas dinâmicos. O modelo usado é um modelo computacional. Simulação, nesse contexto, pode ser definida como a imitação de um sistema dinâmico usando um modelo computacional com o objetivo de avaliar o desempenho do sistema.

Para Pereira (2000), a simulação é a representação de um sistema real através de um modelo utilizando o computador, trazendo vantagens como a de se poder visualizar o sistema, implementar mudanças e responder a questões do tipo: "o que aconteceria se" (*what-if*), reduzindo gastos desnecessários e tempo.

Para Shannon (1998), a simulação *é o processo de projetar um modelo de um sistema real e realizar experimentos neste modelo com o propósito de compreender o comportamento do sistema e/ou avaliar várias estratégias para a operação do sistema.*

Nesse sentido tem-se também Carrie (1988) que considera a simulação como a técnica de construir uma abstração, um modelo lógico de um sistema, a qual descreve o comportamento interno de seus componentes e suas interações, incluindo a aleatoriedade do sistema. Isto permite que o comportamento do sistema como um todo seja predito de forma a ganhar informação sobre ele ou treinar o pessoal na sua operação sem interromper o sistema

real, seja porque experimentação com o sistema real ou é impossível ou não é economicamente viável.

Diversos autores (CARRIE, 1988; HARREL *et al.*, 2000; LAW E KELTON, 2000) classificam os modelos de simulação sob três diferentes dimensões: tempo, mudança de estado do sistema e aleatoriedade, detalhadas a seguir:

a) Tempo

Quando o tempo não é relevante ou é invariável, o modelo é dito estático. Caso a passagem do tempo exerça papel fundamental o modelo é dito dinâmico (BANKS, 1998);

b) Mudança de estado do sistema

O estado do sistema é definido como a coleção de variáveis necessárias para descrever o sistema a qualquer tempo (BANKS *et al.*, 2005). Se o estado do sistema muda continuamente com o tempo, o sistema é dito ser contínuo. Caso o estado do sistema mude instantaneamente em pontos específicos do tempo, o sistema é dito ser discreto (LAW E KELTON, 2000; BANKS *et al.*, 2005), **Figura 2.2**.




Figura 2.2 – Estado do sistema. Fonte: Adaptado de Banks *et al.* (2005).

De forma análoga, classificam-se os modelos em contínuos ou discretos, ou seja, se as mudanças ocorrem disparadas por eventos em pontos discretos no tempo, o modelo é classificado como discreto. Caso as mudanças ocorram de modo contínuo em relação ao tempo, o modelo é dito ser contínuo.

Segundo Law e Kelton (2000), um modelo discreto não é sempre usado para modelar um sistema discreto, nem um modelo contínuo é sempre usado para sistemas contínuos. Para estes autores, a decisão de quando usar um modelo discreto ou contínuo para um sistema particular depende dos objetivos específicos do estudo.

c) Aleatoriedade

Os modelos que não possuem entradas aleatórias são determinísticos. Se o modelo possuir pelo menos uma entrada aleatória então ele é estocástico.

Um outro aspecto importante ao utilizar-se simulação refere-se à extensão do período simulado. Quando a simulação é executada com o objetivo de estudar uma situação definida, ou seja, inicia em um estado ou tempo definido e termina quando alcança algum outro estado ou tempo definido a simulação é dita ser terminante (BANKS, 1998). Por outro lado, quando o objetivo é estudo o comportamento do sistema operando em regime estacionário por um período indefinido de tempo, simulação de longo termo, a mesma é dita ser não-terminante. Essa distinção é importante, pois afeta a análise dos resultados e técnicas estatísticas adequadas devem ser escolhidas para cada situação (BANKS, 1998; LAW E KELTON, 2000). Por exemplo, os efeitos das condições iniciais, ou fase transiente, devem ser removidos dos resultados da simulação não-terminante (BANKS, 1998), *Figura 2.3*. O *Quadro 2.1* apresenta um resumo das classificações apresentadas anteriormente.




Figura 2.3 – Eliminação da fase transiente para simulação não-terminante. Fonte: Adaptado de Banks (1998).

SISTEMA	MODELO		SIMULAÇÃO
DISCRETO As variáveis de estado mudam instantaneamente em pontos específicos no tempo	DETERMINÍSTICO O modelo não contém qualquer componente probabilístico	ESTÁTICO O tempo não é fator relevante	TERMINANTE Inicia em um estado ou tempo definido e termina quando alcança algum outro estado ou tempo definido
CONTÍNUO As variáveis de estado mudam continuamente com respeito ao tempo	ESTOCÁSTICO O modelo tem no mínimo uma entrada aleatória (ou probabilístico)	DINÂMICO Representa um sistema que avança no tempo	NÃO TERMINANTE Objetiva estudar o comportamento do sistema operando “normalmente”

Quadro 2.1 – Classificação de sistemas, modelos e simulação. Fonte: Adaptado de Harrel *et al.* (2000), Law e Kelton (2000), Pereira (2000).

2.2.1 - Simulação de eventos discretos

Neste estudo, é utilizada a simulação de eventos discretos a qual *consiste na modelagem de um sistema que evolui ao longo do tempo por uma representação onde as variáveis de estado mudam instantaneamente em pontos específicos no tempo* (LAW E KELTON, 2000).

Carrie (1988) afirma que a simulação de eventos discretos é adequada quando mudanças discretas predominam no sistema modelado. Para este autor, mudanças discretas são observadas em muitos sistemas de manufatura, ou seja, as mudanças ocorrem em pontos distintos do tempo e entre estes instantes não ocorrem alterações no sistema.

A simulação de eventos discretos utiliza, por sua própria natureza, modelos dinâmicos, ou seja, a passagem do tempo exerce papel fundamental (BANKS, 1998).

2.2.2 - Elementos de um sistema

Sob o enfoque da simulação, um sistema consiste de entidades, atividades, recursos e controles (HARREL *et al.*, 2000). Esses elementos definem quem, o quê, quando, onde e o como ocorre o processamento da entidade na simulação. A seguir, eles são melhores definidos:

a) Entidades

São os itens processados através do sistema tais como produtos, clientes e documentos (HARREL *et al.*, 2000). Carrie (1998) apresenta um conceito diferenciado onde as entidades são os componentes do sistema tais como máquinas, itens, equipamento de manuseio, etc. Este autor classifica as entidades como permanentes e temporárias, onde as primeiras estão no modelo durante toda a simulação e as últimas entram no modelo em algum instante, passam por ele e deixam o modelo em algum instante posterior.

b) Atividades

São as tarefas realizadas no sistema que estão direta ou indiretamente envolvidas no processamento das entidades (HARREL *et al.*, 2000; CARRIE, 1998).

c) Recursos

São os meios pelos quais as atividades são realizadas. Eles fornecem as instalações de apoio, equipamentos e pessoal para condução das atividades (HARREL *et al.*, 2000);

d) Controles

Ditam como, quando e onde as atividades são realizadas. Eles definem as regras do sistema. No mais alto nível, os controles consistem de programação, planos e políticas. No mais baixo nível, os controles fornecem as informações e a lógica de decisão de como o sistema deve operar. Exemplos: seqüência de roteamento, planos de produção, programação da produção, priorização de tarefas, programas de controle e folhas de instruções (HARREL *et al.*, 2000).

2.2.3 - Variáveis de um sistema

Segundo Harrel *et al.* (2000), *projetar um novo sistema ou fazer melhorias em um sistema existente requer mais que simplesmente identificar os elementos e os objetivos de desempenho do sistema. Isto requer uma compreensão de como os elementos do sistema afetam um ao outro e o desempenho global dos objetivos.*

Para ajudar na compreensão desses relacionamentos, Harrel *et al.* (2000) classificam as variáveis do sistema em três tipos: variáveis de decisão, variáveis de resposta e variáveis de estado:

a) Variáveis de decisão

As variáveis de decisão, também chamadas de variáveis independentes quando se realiza experimentos, afetam o comportamento do sistema. Estas variáveis podem ser controláveis ou incontroláveis dependendo do usuário poder ou não manipulá-las.

b) Variáveis de resposta

As variáveis de resposta, também chamadas variáveis de desempenho ou de saída, são dependentes e medem o desempenho do sistema em resposta a um particular conjunto de variáveis de decisão.

c) Variáveis de estado

As variáveis de estado indicam o estado do sistema em qualquer ponto específico do tempo. Para Law e Kelton (2000), um sistema pode ser classificado segundo a forma como as variáveis de estado mudam. Quando as variáveis de estado mudam instantaneamente em pontos específicos do tempo diz-se que o sistema é discreto. Por outro lado, um sistema é dito contínuo quando as variáveis de estado mudam continuamente no tempo.

2.3 - Simulação: vantagens, desvantagens e emprego

O desenvolvimento de sistemas dinâmicos complexos tem levado a necessidade de se avaliar antecipadamente o seu comportamento em face de mudanças e, no caso de sistemas em desenvolvimento, seu funcionamento. Contudo, esses sistemas são complexos demais para serem modelados de forma analítica e a obtenção de soluções tornam-se inviáveis seja por causa do custo seja por causa da complexidade matemática.

Considerando-se que os sistemas de manufatura modernos consistem de muitas operações discretas que ocorrem de modo aleatório e não-linear (O'KANE *et al.*, 2000), a modelagem desses sistemas através da simulação de eventos discretos torna-se um dos mais eficientes meios de estudo desses sistemas. Nesse sentido, têm-se Law e Kelton (2000) que afirmam que a maioria dos sistemas reais é tão complexa para permitir que modelos realistas sejam resolvidos analiticamente, mas que estes modelos podem ser estudados por meio de simulação. Na simulação, um computador é usado para calcular um modelo numérico sobre um período de tempo de interesse, e os dados são coletados para estimar as características verdadeiras desejadas do modelo.

Através da simulação pode-se prever o comportamento de sistemas ou o efeito da mudança de um parâmetro em seu regime de funcionamento. A simulação permite modelar também a interdependência e a aleatoriedade dos sistemas. Segundo Harrel *et al.* (2000), a simulação fornece um meio para validar se as melhores decisões estão sendo tomadas e evita as técnicas de tentativa e erro que são demoradas e caras.

Harrel *et al.* (2000) afirmam também que o poder da simulação reside no fato que ela fornece um método de análise que não é somente formal e preditivo, mas capaz de avaliar com precisão o desempenho até dos sistemas mais complexos. Carrie (1988), por outro lado, afirma que o fato dos resultados obtidos serem probabilísticos e da existência de alguma incerteza na sua precisão tornam a simulação mais apropriada para comparar alternativas que para fornecer previsões de desempenho precisas. Contudo, a importância da simulação pode ser verificada pelas suas vantagens:

- Permite avaliar o funcionamento dos sistemas antecipadamente reduzindo custos;
- Permite verificar efeitos de mudanças e avaliar cenários distintos auxiliando na tomada de decisão;
- Custos para estudo de um sistema em desenvolvimento são inferiores aos custos de alterar um sistema implantado;

- Interface gráfica que permite a visualização do modelo facilitando a compreensão e identificação de falhas.

Para Shannon (1998), a simulação apresenta as seguintes vantagens:

- Permite estudar sistemas que já existem bem como aqueles que podem vir a existir;
- Permite identificar gargalos no fluxo de informações, materiais ou produtos e testar opções para aumentar a taxa de fluxo;
- Permite adquirir conhecimento como um sistema modelado realmente trabalha e compreender quais variáveis são importantes para o desempenho;
- Possibilidade de realizar experimentos com situações novas e não familiares e responder questões do tipo “e se”.

A simulação apresenta também desvantagens que devem ser consideradas ao se decidir por este tipo de abordagem (LAW E KELTON, 2000; BANKS *et al.*, 2005):

- A construção do modelo de simulação requer treinamento especial;
- Os resultados da simulação podem ser difíceis de serem interpretados;
- A modelagem por simulação e a análise podem ser demoradas e caras;
- 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-se somente estimativas da verdadeira característica do modelo para um particular conjunto de parâmetros de entrada.

Algumas características encontradas em problemas a serem analisados que justificam o emprego da simulação são (STRACK, 1984; LAW E KELTON, 2000; O’KANE *et al.*, 2000):

- Ausência de formulação matemática completa;
- Sistemas reais com elementos aleatórios não podem ser descritos precisamente por um modelo matemático que possa ser resolvido analiticamente;
- Inexistência de métodos analíticos para resolução do modelo matemático;
- Maior facilidade de obter resultados do modelo de simulação que usando métodos analíticos;
- Experimentação é impossível ou muito difícil no sistema real;

- Necessidade de estudar longos períodos de tempo ou alternativas que os modelos físicos não fornecem.

A simulação de eventos discretos pode ser empregada para estudar diversos casos e procedimentos como, por exemplo, (HARREL *et al.*, 2000):

- Planejamento do fluxo de trabalho, da capacidade, de mão de obra e recursos;
- Redução do tempo de ciclo, de custos, de inventário;
- Priorização de trabalhos, otimização do tamanho de lote e balanceamento de linha;
- Análise de gargalos, de produção, de leiaute;
- Melhoria da qualidade, de produtividade;
- Agendamento da produção, de recursos, da manutenção;
- Projeto de sistemas de controle.

No âmbito da Engenharia de Produção, o foco da simulação são os problemas operacionais, de manuseio de materiais, de serviços e de tomada de decisão.

2.4 - Desenvolvimento de um projeto de simulação

Para O'Kane *et al.* (2000), *a decisão de usar simulação para estudos de sistemas de manufatura requer que uma abordagem estruturada do estudo da simulação seja continuamente seguida, tal que os projetistas possam identificar no modelo elementos de projeto que são críticos para o sucesso. Segundo este autor, antes que se inicie a aplicação das técnicas de simulação para sistemas de manufatura é importante estar consciente das dificuldades que necessitam ser superadas na tentativa de fornecer soluções para situações do mundo real.* Estas dificuldades abrangem tarefas tais como a definição do problema e dos objetivos até a construção do modelo, validação e análise dos dados.

Da mesma forma, Harrel *et al.* (2000) afirmam que *simulação não é uma ferramenta para ser aplicada indiscriminadamente com pouco ou nenhum planejamento.* Para este autor algumas questões devem ser consideradas tais como: a aplicação é apropriada para simulação? Há outras abordagens que sejam igualmente efetivas e mais baratas? Caso seja verificada que a simulação é a ferramenta apropriada para a situação em questão, devem-se executar três atividades preliminares ao início do projeto de simulação: seleção da aplicação, identificação da equipe e escolha do programa de simulação.

A **Figura 2.4** apresenta um conjunto de doze etapas proposto por Banks *et al.* (2005) para o desenvolvimento de um projeto de simulação. Outras propostas podem ser encontradas em diversas obras como Carrie (1988), Andrade (1989) e Law e Kelton (2000).

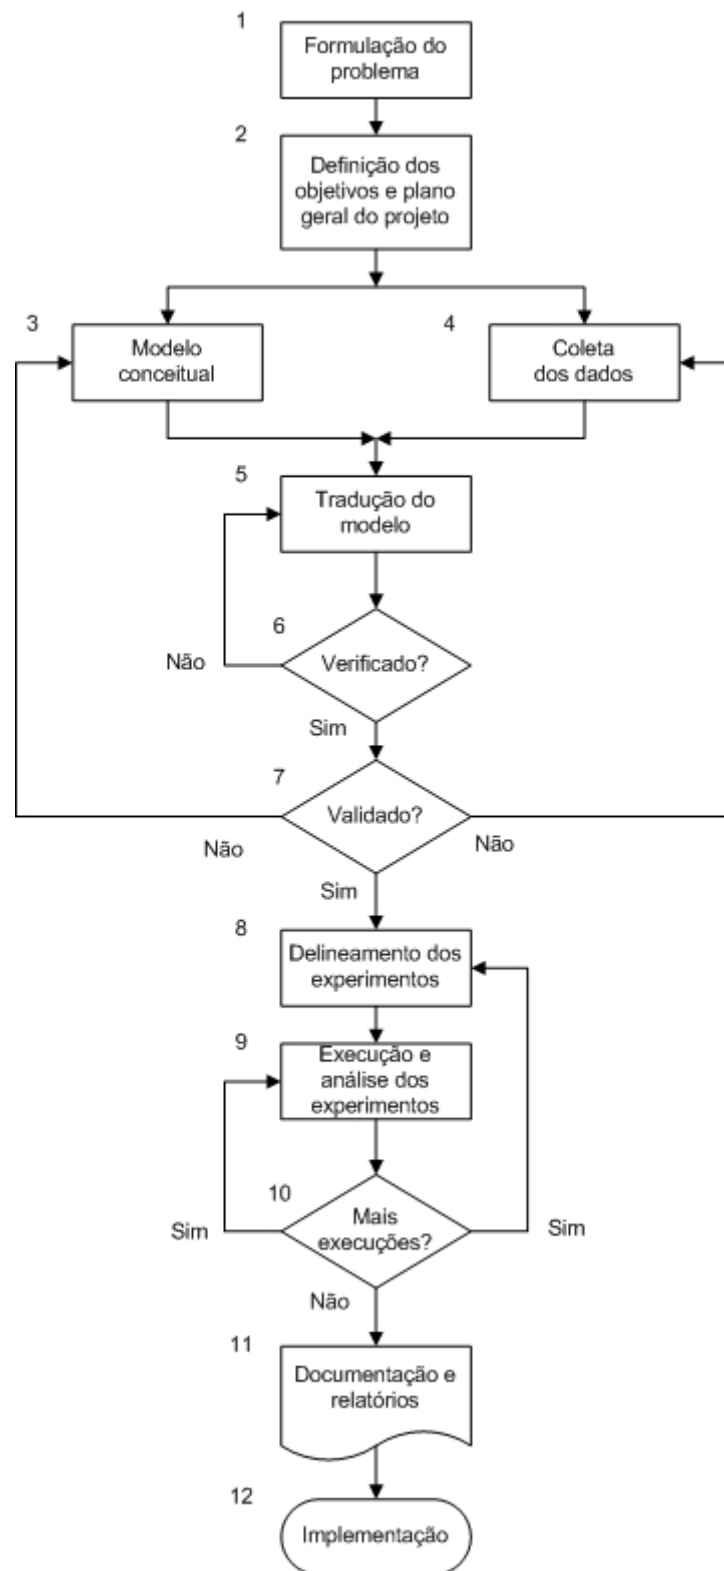


Figura 2.4 – Etapas de um estudo por simulação. Fonte: Banks *et al.* (2005).

Harrel *et al.* (2000) apresentam uma síntese das etapas onde a iteratividade entre cada etapa está realçada, **Figura 2.5**. Para estes autores, as etapas não são estáticas podendo ser refinadas e algumas vezes redefinidas conforme o projeto avança. Esta idéia é amparada por Pidd (1996) que ao propor cinco princípios básicos no desenvolvimento do projeto de simulação aconselha a iniciar a modelagem do sistema com modelos simples e ir aumentando sua complexidade à medida do necessário.

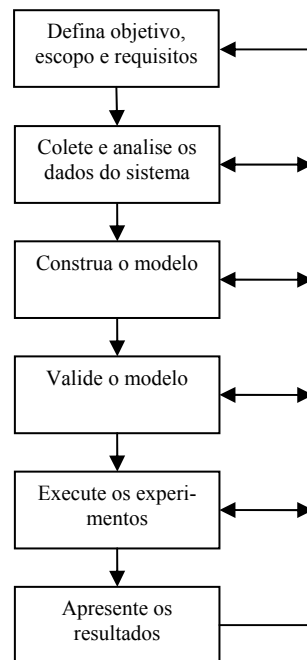


Figura 2.5 – Natureza iterativa de um projeto de simulação. Fonte: Adaptado de Harrel *et al.* (2000).

A seguir são apresentadas algumas características das etapas de um projeto de simulação, **Figura 2.4**.

2.4.1 - Formulação do problema

A formulação do problema envolve a expressão clara do problema a ser estudado. O problema pode ser expresso pela administração ou pela própria área afetada. Esta etapa é de fundamental importância para o sucesso do projeto, pois garante que o problema correto seja estudado e as soluções propostas sejam adequadas.

2.4.2 - Definição dos objetivos e plano geral de trabalho

Segundo Banks *et al.* (2005), *os objetivos indicam as questões a serem respondidas pela simulação*. Para estes autores, é nesta etapa que se deve avaliar se a simulação é a metodologia adequada para o problema proposto e os objetivos desejados.

Esta posição é compartilhada por Harrel *et al.* (2000), para os quais o objetivo da simulação define o propósito ou razão para conduzir o estudo de simulação. Estes autores agrupam os objetivos nas seguintes categorias:

- Análise de desempenho;
- Análise de capacidade/restrição;
- Comparação de configuração;
- Otimização;
- Análise de sensibilidade;
- Visualização.

Segundo Harrel *et al.* (2000), para um objetivo ser eficaz ele deve atender as seguintes condições: alto potencial de impacto, ser alcançável, ser específico, ser quantificável, ser mensurável e identificar qualquer restrição relevante.

Para alcançar os objetivos propostos, um plano de trabalho deve ser definido. Segundo Banks *et al.* (2005), este plano deve conter os sistemas alternativos a serem considerados e um método para avaliar a efetividade destas alternativas (indicadores de desempenho), o número de pessoas envolvidas, o custo do estudo, o número de dias necessários para completar cada fase do trabalho junto com os resultados esperados ao fim de cada estágio.

Law e Kelton (2000) incluem a definição do escopo do modelo nessa etapa. De acordo com Harrel *et al.* (2000), *o escopo do trabalho é importante para guiar o estudo bem como fornecer uma especificação do trabalho a ser feito*. Segundo estes últimos autores, o escopo do modelo, o nível de detalhamento, a responsabilidade pela coleta de dados, os experimentos e a forma dos resultados devem ser incluídas no plano de estudo para garantir que o orçamento e o cronograma sejam realísticos.

2.4.3 - Coleta de dados

A coleta de dados é uma das etapas mais demoradas no projeto de modelagem (HARREL *et al.*, 2000; BANKS *et al.*, 2005). Banks *et al.* (2005) afirmam que há uma interação constante entre a criação do modelo conceitual e a conjunto de dados de entrada necessários, quando a complexidade do modelo muda, os elementos de dados requeridos podem mudar também.

2.4.4 - Modelo conceitual

O modelo conceitual é a abstração do sistema real incorporando simplificações e suposições que permitam a sua modelagem (BANKS *et al.*, 2005). Diversos autores

(SHANNON, 1998; HARREL *et al.*, 2000; BANKS *et al.*, 2005), consideram a construção do modelo conceitual do sistema mais arte que ciência. De acordo com Banks *et al.* (2005), *a arte de modelagem é aprimorada pela habilidade de abstrair as características essenciais do problema, selecionar e modificar hipóteses básicas que caracterizam o sistema e, então, enriquecer e elaborar o modelo até uma aproximação útil dos resultados.*

Segundo Harrel *et al.* (2000), o modelo conceitual é o resultado dos dados coletados e é uma formulação de como opera um sistema em particular. Este modelo pode tomar a forma de um documento descritivo, um diagrama de fluxo ou mesmo um esboço do sistema real.

2.4.5 - Tradução do modelo

Esta etapa consiste na tradução do modelo conceitual para a linguagem do simulador utilizado, ou seja, o desenvolvimento do modelo de simulação do sistema propriamente dito. Nesta etapa, o ideal é iniciar com um modelo simples e aumentar gradualmente a sua complexidade sem, contudo, exceder os requisitos necessários para alcançar os propósitos do modelo (HARREL *et al.*, 2000; BANKS *et al.*, 2005).

Segundo Harrel *et al.* (2000), a tradução do modelo conceitual em um modelo de simulação requer duas importantes transições. A primeira, o modelador deve ser capaz de pensar o sistema em termos do paradigma de modelagem adotado pelo programa de simulação utilizado. Segundo, as diversas maneiras de modelar o sistema devem ser avaliadas para determinar a mais eficiente e efetiva forma de representar o sistema.

2.4.6 - Verificação e Validação

As etapas de verificação e validação são etapas complementares para garantir a confiabilidade nos resultados do modelo de simulação. Enquanto a etapa de verificação refere-se à correta implementação do programa ou modelo de simulação, a etapa de validação refere-se a correta representação do sistema pelo modelo de simulação.

Assim, o foco da primeira é verificar se não há erros no programa que estejam impedindo a sua execução ou causando a execução de modo não previsto. E, o foco da segunda é confrontar os resultados e o comportamento do modelo de simulação com os do sistema real de forma que a verificar se as idealizações e hipóteses adotadas não distanciam o modelo de simulação da realidade do sistema.

2.4.7 - Delineamento dos experimentos

Nesta etapa são definidas as alternativas que serão simuladas, a extensão do período de inicialização, a extensão do período simulado e o número de replicações para cada

experimento (BANKS *et al.*, 2005). No caso de modelos estocásticos, para cada cenário devem ser executadas tantas simulações (replicações) quanto necessárias para obter resultados com o grau de confiança especificado. Para modelos determinísticos, apenas uma execução é realizada uma vez que os resultados não são aleatórios.

2.4.8 - Execução e análise dos experimentos

Após o delineamento dos experimentos, pode-se proceder a execução deles obedecendo aos parâmetros preestabelecidos (extensão do período de inicialização, extensão do período simulado, etc.).

Os resultados obtidos são usados para estimar as medidas de desempenho para o sistema que está sendo analisado (BANKS *et al.*, 2005). A análise dos resultados é afetada se a simulação é terminante ou não-terminante (HARREL *et al.*, 2000).

2.4.9 - Mais execuções

Após a análise dos resultados das simulações já executadas, pode-se decidir por executar mais replicações ou, então, novos experimentos (BANKS *et al.*, 2005).

2.4.10 - Documentação e relatórios

Os modelos de simulação são construídos para serem usados e através do uso eles evoluem. Assim, uma completa documentação do modelo e do projeto fornece as informações necessárias para apoiar o uso continuado do modelo e sua ampliação (MUSSELMAN, 1998).

Segundo Banks *et al.* (2005) há dois tipos de documentação: programa e progresso. A documentação do programa auxilia a compreensão de como o programa funciona, gera confiança nele e facilita alterações futuras além de identificar os parâmetros de entrada do modelo e os indicadores de desempenho permitindo que os usuários modifiquem esses parâmetros num esforço de compreender seus relacionamentos. Os relatórios de projeto mostram a cronologia do trabalho realizado e as decisões tomadas podendo ser de grande valor na manutenção do curso do projeto.

2.4.11 - Implementação

Para Musselman (1998), o projeto de simulação precisa conduzir para alguma ação concreta a ser realizada pelo cliente. Ou seja, o cliente avaliará o projeto de simulação pelo resultado obtido pela ação indicada, se o resultado da ação for positivo o projeto é considerado um sucesso. Para Banks *et al.* (2005), o sucesso nessa etapa depende de quão boa foi a execução das etapas anteriores.

2.5 - O simulador ProModel

Para o presente estudo foi utilizado programa de simulação ProModel da ProModel Corporation. O ProModel é um programa de simulação de eventos discretos para aplicação em processos de manufatura e manuseio de materiais. Este programa é fornecido em conjunto com outros dois programas o SimRunner, para otimização de modelos de otimização, e o Stat::Fit, para estudo de distribuições de probabilidade. A **Figura 2.6** mostra a tela de abertura do ProModel.



Figura 2.6 – Tela de abertura do ProModel.

Para a construção de um modelo, o ProModel utiliza os seguintes elementos: *locations* (locais), *entities* (entidades), *resources* (recursos), *processing* (processamento) e *arrivals* (chegadas), encontrados no menu *Build* do programa. As definições e o funcionamento dos principais elementos são mostrados abaixo:

a) Locations (Locais)

Representam os lugares fixos do sistema onde se realizam os processos, são usados para representar elementos como: postos de trabalhos, “pulmões”, transportadores e filas. Para cada local pode-se definir: capacidade, quantidade (uma ou várias), setups, manutenção, nível de detalhamento estatístico, além de regras de seleção das entidades na entrada e regra de filas para as saídas.

b) Entities (Entidades)

São os itens a serem processados pelo sistema representando matéria-prima, produtos, pallets, pessoas ou documentos. Para cada entidade pode-se definir velocidade, nível de detalhamento estatístico e imagem. Elas podem ser agrupadas ou divididas ao longo do processo produtivo e são movimentadas por meios próprios ou por meio de recursos.

c) Arrivals (Chegadas)

Definem a entrada ou criação das entidades dentro do modelo. Para cada chegada são definidos a entidade, a quantidade, a frequência e o período, bem como se pode especificar uma lógica de chegada. As chegadas podem ser definidas, também, através de um arquivo de chegada externo.

d) Resources (Recursos)

São os elementos usados para movimentar as entidades, executar operações, realizar manutenção dos locais ou outras atividades. Os recursos podem representar pessoas ou equipamentos. Em um sistema pode haver recursos estáticos ou dinâmicos.

Os recursos estáticos não são dotados de movimento. Os recursos dinâmicos, por sua vez, podem se mover sobre um caminho definido através de uma rede de caminhos (*path network*).

e) Processing (Processamento)

Consiste em uma tabela onde são definidas as operações sofridas pelas entidades para cada local específico e uma tabela de rotas para movimentação destas entidades.

É neste elemento que se especificam os recursos necessários para realização de determinada tarefa, as esperas ocorridas ou outras lógicas como junção, carregamento, acumulação, etc., que representam os processos sofridos pelas entidades, bem como o modo como se dá a movimentação do local corrente para o local de destino, o tempo gasto e os recursos necessários nesta movimentação.

O ProModel dispõe, ainda, de elementos auxiliares como: *cost* (custo) que define as taxas de custo de recursos, locais e entidades, e *shifts* (turnos) para definição de turnos de trabalho.

2.6 - Considerações finais

Neste capítulo objetivou-se introduzir o conceito de simulação de eventos discretos. As principais definições, as vantagens e desvantagens e algumas classificações foram apresentadas, bem como as etapas de um projeto de simulação. Por fim, as principais características do simulador de eventos discretos ProModel foram apresentadas.

CAPÍTULO 3 - OTIMIZAÇÃO VIA SIMULAÇÃO

3.1 - Considerações iniciais

Técnicas clássicas de otimização são conhecidas há mais de um século e possuem aplicações nos mais diferentes campos da ciência. Porém, estas técnicas podem apresentar algumas dificuldades numéricas e problemas de robustez relacionados com: a falta de continuidade das funções a serem otimizadas ou de suas restrições, funções não convexas, multimodalidade (vários pontos ótimos), existência de ruídos nas funções, necessidade de se trabalhar com valores discretos para as variáveis, existência de mínimos ou máximos locais, etc. (SARAMAGO, 2003).

Objetivando evitar as dificuldades encontradas nas técnicas analíticas de otimização, foram desenvolvidas técnicas heurísticas. Atualmente diversos pacotes de simulação já incorporam rotinas de otimização. Segundo Banks *et al.* (2005), a otimização via simulação é um tópico relativamente novo, mas já vasto, e programas comerciais tornaram-se largamente disponíveis.

Neste capítulo são apresentadas definições de otimização e principais tipos, integração entre a otimização e a simulação. É dada uma ênfase nos algoritmos genéticos, apresentando sua origem, o princípio de funcionamento, os operadores genéticos e seus parâmetros. Por fim, é apresentado o Simrunner, o otimizador que acompanha o ProModel.

3.2 - Otimização via simulação

Segundo Banks *et al.* (2005), a otimização *é uma ferramenta chave usada por pesquisadores de operações e cientistas de administração, e há algoritmos bem desenvolvidos para muitas classes de problemas, sendo os mais famosos por programação linear.*

Banks *et al.* (2005) utilizam a expressão “otimização via simulação” para designar a situação *onde o objetivo é minimizar ou maximizar algumas medidas de desempenho do sistema e o desempenho do sistema só pode ser avaliado executando uma simulação computacional.*

Fu (2002) apresenta como objetivo da otimização *procurar configurações aperfeiçoadas de parâmetros do sistema selecionados pelo usuário com respeito à(s) medida(s) de desempenho de interesse.*

Law e Kelton (2000) ressaltam a distinção entre o objetivo da otimização e os objetivos da escolha do melhor sistema. Na escolha do melhor sistema, as alternativas de

configurações dos sistemas são simplesmente dadas. Enquanto na otimização, a situação é bem menos estruturada onde se devem decidir quais alternativas de configurações de sistemas simular bem como avaliar e comparar seus resultados.

No contexto desse trabalho, define-se otimização como *o processo de tentar diferentes combinações de valores para variáveis que podem ser controladas a fim de procurar a combinação de valores que fornece o resultado mais desejável do modelo de simulação* (HARREL *et al.*, 2000).

Diferentemente dos pacotes de programação matemática, não é possível afirmar que a resposta obtida por esses programas de otimização é ótima (FU, 2002).

Segundo Silva (2005), soluções para este tipo de problema podem ser encontradas através de técnicas heurísticas de otimização. Tais técnicas proporcionam boas soluções, contudo não se assegura que as soluções encontradas sejam ótimas. Por isso, estes métodos baseados na busca aleatória controlada por critérios probabilísticos, tiveram um importante crescimento nos últimos anos, principalmente devido ao avanço dos recursos computacionais, uma vez que esses métodos necessitam de um número elevado de avaliações da função objetivo.

3.3 - Integração entre simulação e otimização

A integração entre simulação e otimização é um movimento recente. Segundo Fu (2002), apesar da grande quantidade de pesquisas considerarem importante combinar otimização e simulação, na prática, até a década de 90 não havia esta integração. Contudo, esse cenário mudou naquela década com a incorporação de programas de otimização nos pacotes de simulação conforme se verifica no **Quadro 3.1** o qual lista os pacotes de otimização incorporados aos pacotes de simulação.

Fu (2002) apresenta como evidência da integração entre otimização e simulação o fato dos atuais pacotes comerciais de simulação conterem módulos que realizam algum tipo de otimização contrastando com a situação de 1990 quando nenhum dos pacotes incluíam essa opção. E reforçando esta evidência se tem as recentes edições de Law e Kelton (2000) e Banks *et al.* (2005), duas obras de simulação de evento discreto largamente utilizadas, que incluíram capítulos específicos sobre otimização e a própria disseminação do termo “simulation optimization” o qual já consta na *Encyclopedia of Operations Research and Management Science* (GASS E HARRIS, 2000).

O emprego da otimização pela simulação é ilustrado na **Figura 3.1**, onde, segundo Fu (2002), a relação da otimização com a simulação é de subserviência, ou seja, a primeira é um acessório fornecido pelo pacote de simulação.

Programa de Otimização	Distribuidor	Pacote de Simulação	Procedimento de busca
AutoStart	AutoSimulations, Inc.	AutoMod, AutoSched	Estratégias Evolucionárias
optQuest	Optimization Technologies, Inc.	Arena, Micro Saint, QUEST, Taylor Enterprise Dynamics	Busca “scatter”, Busca Tabu, Redes Neurais
OPTMIZ	Visual Thinking International Ltd.	SIMUL8	Redes Neurais
SimRunner	PROMODEL Corp.	MedModel, ProModel, ServiceModel	Estratégias Evolucionárias, Algoritmo Genético
WITNESS Optimizer	Lanner Group, Inc.	WITNESS	Recozimento Simulado, Busca Tabu

Quadro 3.1 – Programas de otimização. Fonte: Law e Kelton (2000).

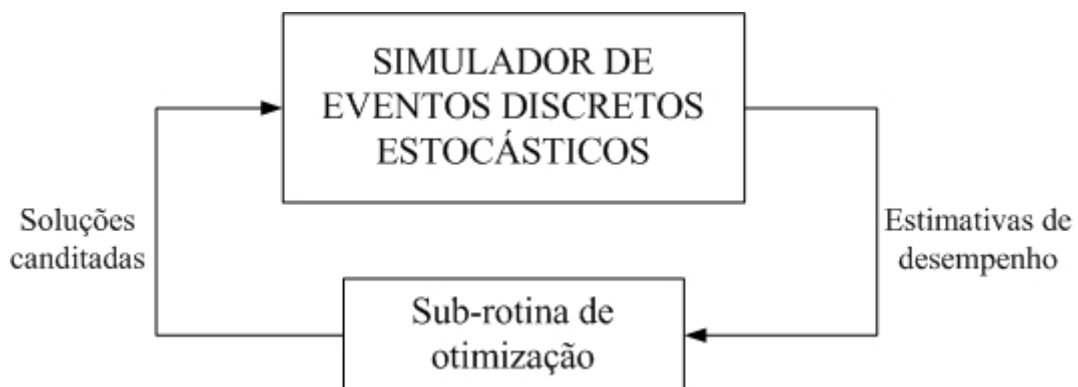


Figura 3.1 – Emprego da otimização na simulação. Fonte: adaptado de Fu (2002).

Segundo Banks *et al.* (2005), o resultado de uma simulação de eventos discretos estocástica é uma variável aleatória. Considerando x_1, x_2, \dots, x_m as m variáveis controláveis do modelo e $Y(x_1, x_2, \dots, x_m)$ a variável de desempenho observada durante a simulação, qual é o significado de “otimizar” $Y(x_1, x_2, \dots, x_m)$ com respeito à x_1, x_2, \dots, x_m ?

A definição mais comum de otimização é dada pela **Equação 3.1** (BANKS *et al.*, 2005),

$$\text{Maximizar ou minimizar } E(Y(x_1, x_2, \dots, x_m)) \tag{3.1}$$

ou seja, uma vez que não se pode otimizar o valor real de Y , por ela ser uma variável aleatória, maximiza-se ou minimiza-se a sua esperança. Segundo Banks *et al.* (2005), *esta é a definição padrão de otimização usada em todos os pacotes comerciais de simulação.*

A definição anterior considera que se deseja otimizar uma única medida de desempenho. Contudo, há situações em que se deseja considerar medidas de desempenho adicionais. Segundo Banks *et al.* (2005), a otimização multiobjetivos via simulação não está bem desenvolvida. Esse autor apresenta três estratégias usualmente adotadas para esta situação:

1. Combinar todas as medidas de desempenho em uma única medida;
2. Otimizar considerando uma medida de desempenho chave e então avaliar as melhores soluções obtidas considerando as medidas de desempenho secundárias. Esta técnica requer que sejam mantidas informações de outras soluções além da solução ótima;
3. Otimizar considerando uma medida de desempenho chave, mas considerar somente aquelas alternativas que atendam as restrições das outras medidas de desempenho.

O objetivo dos pacotes de otimização, segundo Law e Kelton (2000), é conduzir a simulação de uma seqüência de configurações do sistema tal que uma configuração eventualmente obtida forneça uma solução quase-ótima. A **Figura 3.2** apresenta a interação entre o pacote de otimização e o modelo de simulação. Inicialmente, o pacote de otimização instrui o modelo de simulação para simular uma ou mais 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.

3.3.1 - Dificuldades da otimização via simulação

A característica estocástica da simulação embute um fator de dificuldade considerável para a otimização conforme apresentado anteriormente, contudo, mesmo em situações sem incertezas, a grande quantidade de variáveis de projeto, a diversidade dos tipos de variáveis e a falta de informação sobre o comportamento da função objetivo tornam a otimização uma tarefa bastante complexa (LAW E KELTON, 2000; BANKS *et al.*, 2005).

Segundo Banks *et al.* (2005), na otimização via simulação não é possível concluir com segurança que uma configuração é melhor que outra, pois o desempenho de uma configuração

específica não pode ser determinado exatamente, mas sim estimado. Esta incerteza “frustra” o algoritmo de otimização. Uma alternativa para superar esse problema é fazer muitas replicações de forma que a estimativa da medida de desempenho seja essencialmente “sem variância”.

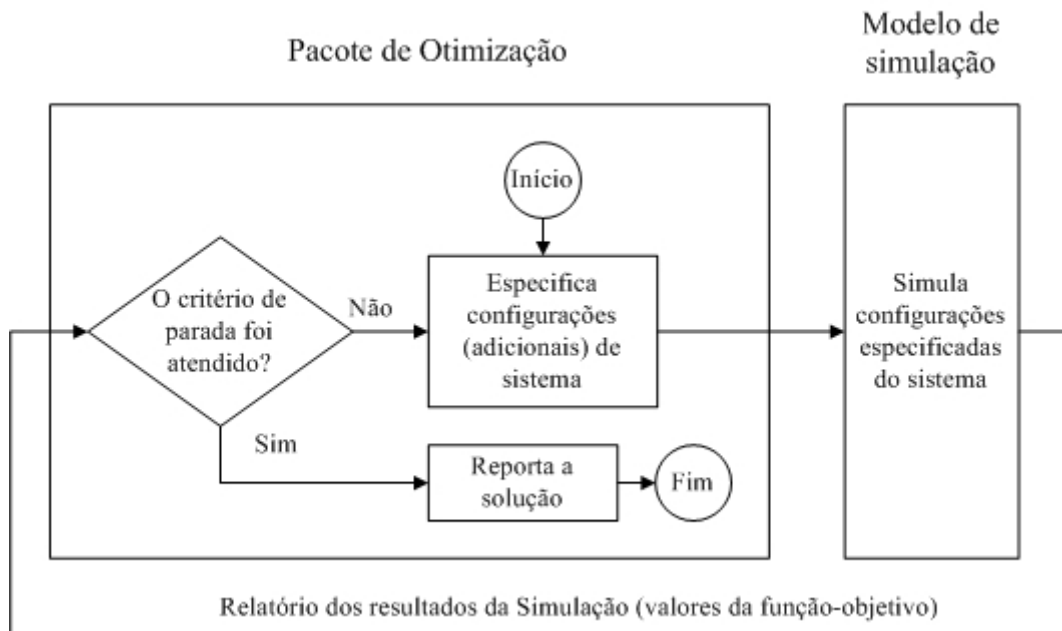


Figura 3.2 – Interação entre o pacote de otimização e o modelo de simulação. Fonte: Adaptado de Law e Kelton (2000).

Segundo Banks *et al.* (2005), a existência da variabilidade da amostragem força a otimização via simulação a firmar compromissos, esses compromissos objetivam garantir a confiabilidade dos resultados alcançados. Os mais comuns, garantir uma probabilidade pré-especificada de seleção correta, garantir convergência assintótica, obter o ótimo para contraparte determinística e heurísticas robustas, são explicados a seguir:

a) Garantir uma probabilidade pré-especificada de seleção correta

O procedimento deve permitir a especificação do nível de confiança desejado. Estes algoritmos tipicamente requerem que cada configuração possível seja simulada ou que um relacionamento funcional “forte” entre as configurações (por exemplo, metamodelos) seja estabelecido.

b) Garantir convergência assintótica

Há muitos algoritmos que garantem a convergência para a solução ótima global quando o esforço de simulação (número de replicações, duração da replicação) torna-se infinito. Estas garantias são úteis porque elas indicam que o algoritmo tende a ir

para onde o analista deseja que ele vá. Entretanto, a convergência pode ser lenta e normalmente não há garantia da qualidade da solução reportada quando o algoritmo é terminado em um tempo finito.

c) Obter o ótimo para contraparte determinística

A idéia é usar um algoritmo que encontraria a solução ótima se o desempenho de cada configuração pudesse ser avaliado com certeza. Como exemplo poder-se-ia aplicar um algoritmo padrão de programação não-linear para o problema de otimização da simulação. Cabe ao analista assegurar que suficiente esforço de simulação é gasto para garantir que tal algoritmo não seja desorientado pela variabilidade da amostragem.

d) Heurísticas robustas

Muitas heurísticas têm sido desenvolvidas para problemas de otimização determinísticos. Apesar de não garantir que a solução encontrada é ótima, estas técnicas heurísticas mostram-se muito eficientes na otimização de muitos problemas práticos cuja otimização é difícil devida a sua não linearidade, por exemplo. Algumas dessas heurísticas usam aleatoriedade como parte das suas estratégias de busca, assim argumenta-se que essas heurísticas são menos sensíveis a variabilidade da amostragem que outros tipos de algoritmos. Todavia, ainda é importante que suficiente esforço de simulação seja gasto para garantir que tal algoritmo não seja desorientado pela variabilidade da amostragem.

3.4 - Principais técnicas

Segundo Fu (2002), as rotinas de otimização implantadas nos programas de simulação são todas baseadas em metaheurísticas com predominância dos algoritmos evolutivos os quais possuem a vantagem de interagir numa família de soluções em vez de um único ponto e muitos deles incorporam algum tipo de memória dos resultados. O **Quadro 3.2** apresenta as características chave das principais técnicas de otimização.

Entre as técnicas apresentadas, os Algoritmos Genéticos (AG) são as de maior interesse para o desenvolvimento deste trabalho e, por isso, são detalhados a seguir.

3.5 - Algoritmos Genéticos

3.5.1 - A Teoria da Evolução

A Teoria da Evolução foi apresentada por Charles Darwin em seus livros, *Sobre a Origem das Espécies por Meio da Seleção Natural*, publicado em 1859, e *A Descendência do*

Homem e Seleção em Relação ao Sexo, publicado em 1871, onde Darwin defendia que o homem, assim como os outros seres vivos, evoluiu de um ancestral comum, através de um mecanismo de transformação, a seleção natural, que atua sobre a variação individual.

Técnica	Características chave
Busca gradiente	Move localmente na direção mais promissora de acordo com o gradiente.
Busca aleatória	Move aleatoriamente para um novo ponto, não são usadas informações de resultados anteriores na busca.
Recozimento simulado	Ocasionalmente move na direção de resultados piores localmente para evitar aprisionamento em extremos locais.
Algoritmos genéticos e busca “scatter”	Baseado em população, gera novos membros através de operações em atributos dos membros atuais.
Busca tabu	Usa memória (examina um histórico) para evitar movimentos para pontos já analisados.
Redes neurais	Aproximação por função não linear.
Programação matemática	Poderoso arsenal de programas rigorosamente testados.

Quadro 3.2 – Principais técnicas de otimização. Fonte: Adaptado de Fu (2002).

A teoria é apoiada nos estudos que Darwin realizou a bordo do navio *Beagle* em sua volta ao redor do mundo nos meados do século XIX. Em seus estudos, Darwin concluiu que nem todos os organismos que nascem sobrevivem e reproduzem-se. Os indivíduos com maior oportunidade de sobrevivência seriam aqueles com características mais apropriadas para enfrentar as condições ambientais, tendo também, maior chance de se reproduzirem e deixar descendentes. Nessas condições a frequência de um gene vantajoso aumenta gradativamente na população. Contudo, Darwin não conseguiu explicar adequadamente o mecanismo de origem e transmissão dessas características, somente com as posteriores descobertas sobre os princípios básicos da herança genética e das mutações por Gregor J. Mendel, que estes mecanismos foram identificados (SILVA, 2005).

A Teoria da Evolução provocou uma grande discussão a respeito da origem e evolução da vida e revolucionou todo o pensamento científico, religioso, filosófico, político e econômico da época, influenciando não só o futuro da biologia, botânica e zoologia como também outros campos nas áreas das Ciências Exatas.

3.5.2 - A Origem dos Algoritmos Genéticos

De acordo com Mitchell (1998), nas décadas de 1950 e 1960 vários cientistas computacionais fizeram estudos independentes sobre sistemas evolucionários com o intuito de utilizar a evolução como uma ferramenta de otimização para problemas de engenharia. A idéia contida nesses sistemas era evoluir uma população de soluções candidatas para um dado problema, usando operadores inspirados pela variação genética natural e pela seleção natural.

Dentre esses estudos destacam-se Estratégias Evolucionárias (RECHENBERG, 1973; SCHWEFEL, 1975, 1977), Programação Evolucionária (FOGEL *et al.*, 1966; FOGEL, 1999) e os Algoritmos Genéticos (HOLLAND, 1975; GOLDBERG, 1989) os quais formam a coluna espinhal do campo da Computação Evolucionária (MITCHELL, 1998).

Os Algoritmos Genéticos (AG) foram desenvolvidos por John H. Holland e seus pesquisadores e alunos da Universidade de Michigan nos anos 60 e 70 (GOLDBERG, 1989). Segundo Mitchell (1998), o objetivo original de Holland foi estudar o fenômeno de adaptação como ele ocorre na natureza e desenvolver maneiras de importar esses mecanismos de adaptação natural para sistemas computacionais.

A utilização desta nova técnica teve grande impulso com um trabalho de David Goldberg publicado em 1989, no qual apresentou soluções para problemas de engenharia complexos usando este método, distinguindo-o de outros Algoritmos Evolutivos (CUNHA E PINTO, 2001).

Os AG são as técnicas mais estudadas e difundidas de Algoritmos Evolutivos graças a sua flexibilidade, relativa simplicidade de implementação e eficácia em realizar busca global em ambientes adversos (TANOMARU, 1995). Outra vantagem no uso dos AG é que estes não necessitam de uma função objetivo matematicamente explícita para realizar a busca pela solução do problema (SILVA, 2002).

Sua flexibilidade possibilita aplicações em áreas tão distintas tais como: engenharias, desenho industrial, pesquisa operacional, computação, bioquímica e biologia, composição musical, e ciências sociais (LOPES, 1999). Aplicações recentes dos AG têm sido feitas na manipulação de imagens, principalmente reconhecimento e busca de faces e olhos humanos (ERSI E HAJEBI, 2003; TELLER E VELOSO, 1995).

3.5.3 - Princípio de funcionamento

De maneira similar à teoria da evolução, os AG manipulam um conjunto de pontos, chamado de população, na superfície de resposta, ou seja, possíveis soluções para o problema proposto (indivíduos), de tal modo que as piores soluções desaparecem enquanto que as

melhores continuam a evoluir na busca da solução ótima, explorando simultaneamente diversas áreas da superfície de resposta (TANOMARU, 1995).

O primeiro passo para a aplicação de um AG é definir a representação da população. Assim, cada indivíduo ou possível solução é definido como um cromossomo representado por uma codificação, na maioria das vezes a binária. Por exemplo, considere-se o problema de maximização de uma função com quatro variáveis de decisão e precisão de seis bits cada, com $f: \mathfrak{R}_n \rightarrow \mathfrak{R}$ e um espaço de busca $S \subseteq \mathfrak{R}_n$, conforme **Equação 3.2**.

$$\text{Max } f(x,y,z,w) \text{ onde } x,y,z,w \in S \quad (3.2)$$

O número de genes desse cromossomo é igual ao número de variáveis do problema proposto e o número de nucleotídeos ou alelos (agora chamado *bit*) de cada gene é definido de acordo com a precisão requerida. A **Figura 3.3** mostra a representação de uma possível solução (cromossomo) para este problema.




Figura 3.3 – Representação binária de um cromossomo com quatro genes e seis bits cada gene. Fonte: Silva (2005).

O passo seguinte é a geração da população inicial. Normalmente a população inicial é formada por um conjunto aleatório de indivíduos, em alguns casos se utiliza alguma técnica heurística para definir os indivíduos, ou o uso conjunto de ambas as técnicas (TANOMARU, 1995).

O tamanho da população gerada é um aspecto importante a ser considerado, uma vez que afeta o desempenho global e a eficiência dos AG. Em uma população pequena o desempenho esperado pode não ser alcançado, pois ela fornece uma pequena cobertura na superfície de resposta. Por outro lado, uma grande população geralmente fornece uma cobertura representativa do problema, prevenindo convergências prematuras para soluções locais em vez de globais; porém, ao se trabalhar com grandes populações são necessários maiores recursos computacionais ou de tempo.

Em Genética, o termo genótipo designa todo o material genético de um indivíduo, enquanto que o fenótipo é a manifestação visível ou apenas detectável da ação conjunta do genótipo e do meio ambiente no qual este indivíduo está inserido (CAMPBELL *et al.*, 1999).

De maneira análoga, nos AG o fenótipo é a resposta de cada possível solução, ou seja, sua adaptabilidade junto ao ambiente. Esta adaptabilidade é definida através de uma função de adaptabilidade (em inglês, *fitness*) e determina o quão adaptável é um indivíduo em relação à população e ao ambiente. Muitas vezes esta função é a própria função objetivo, porém em alguns casos esta função necessita ser alterada para melhor representar a adaptabilidade de um indivíduo na população. Assim uma função de adaptabilidade para a **Equação 3.2** poderia ser representada como mostra a **Equação 3.3** (SILVA, 2005).

$$G[f(x, y, z, w)] \quad (3.3)$$

A seguir é feita a manipulação da população de respostas, tal manipulação tem como objetivo a criação de novos indivíduos com maior adaptabilidade através das gerações, utilizando para isso os operadores genéticos: seleção, cruzamento e mutação. O **Quadro 3.3** apresenta um exemplo de algoritmo genético.

```

inicializar população  $P$ ;
repita
  selecione uma subpopulação  $P'$ ; //pais da próxima geração
  para  $i \leftarrow 1$  até nr_cruzamento faça
    escolha  $S_1, S_2 \in P'$ , aleatoriamente;
    filho  $\leftarrow$  cruzamento( $S_1, S_2$ );
    se  $f(S_1) \geq f(S_2)$  então  $S_{aux} \leftarrow S_1$ ;
    senão  $S_{aux} \leftarrow S_2$ ;
    se  $f(S_{aux}) \geq f(\text{filho})$  então
      filho substitui  $S_{aux}$  em  $P$ ;
    fim_se;
  fim_para;
  para  $i \leftarrow 1$  até nr_mutações faça
    selecione um cromossomo  $S_j$  em  $P$ ;
     $S_j \leftarrow$  mutação( $S_j$ );
  fim_para;
até que critério parada seja satisfeito:

```

Quadro 3.3 – Algoritmo Genético. Fonte: Goldberg *et al.* (2005).

3.5.4 - Operadores genéticos

a) Seleção

A idéia principal deste operador é oferecer aos melhores indivíduos da população corrente preferência para o processo de reprodução, permitindo que estes indivíduos passem suas características às próximas gerações. O processo de seleção geralmente causa um

aumento no valor médio da adaptação dos indivíduos da população a cada geração (SILVA, 2005).

Entre os métodos de seleção encontra-se o método da Roleta, a Amostragem Universal Estocástica, Seleção Elitista, Seleção Baseada na Posição, Seleção por Torneio, Seleção Estado Estável, Seleção por Truncatura e Seleção local (SIMÕES, 1999). O método da Roleta, também designado por *amostragem estocástica com substituição* ou *seleção proporcional ao mérito*, foi utilizado no trabalho original de John Holland. Este método realiza uma escolha dos indivíduos que irão gerar a próxima geração, os quais têm uma probabilidade proporcional aos valores de aptidão de serem escolhidos, assim, indivíduos com maiores valores de aptidão ocupam maior espaço nesta roleta o que resulta numa maior probabilidade de serem selecionados, como mostra a **Equação 3.4**.

$$p(c_i) = \frac{\alpha(c_i)}{\sum_{i=1}^n \alpha(c_i)} \quad (3.4)$$

Onde:

$p(c_i)$ - probabilidade de ser escolhido o indivíduo c_i ;

$\alpha(c_i)$ - valor de adaptabilidade do indivíduo c_i ;

$\sum_{i=1}^n \alpha(c_i)$ - somatório da adaptabilidade de todos os indivíduos da população;

n - número de indivíduos.

Ou seja, o método da roleta pode ser visto como uma sucessão de segmentos de reta representando os indivíduos da população, e o tamanho de cada segmento é proporcional à razão entre o valor de aptidão do indivíduo e à somatória dos valores de aptidão dos indivíduos da população (SILVA, 2005).

O próximo passo é a geração de um número aleatório e o primeiro indivíduo cujo segmento ultrapassa o valor desse número é escolhido para a reprodução. Este processo é repetido n vezes, sendo n o número de indivíduos da população, ao fim do qual serão selecionados os indivíduos que irão gerar a próxima população. É importante ressaltar que este mecanismo funciona somente se todos os valores da função aptidão forem maiores que zero (SILVA, 2002), e que há possibilidade de um indivíduo ser escolhido várias vezes.

b) Cruzamento

O operador de cruzamento (*crossover* ou recombinação) cria novos indivíduos através da combinação de dois ou mais indivíduos. A idéia intuitiva por trás deste operador é a troca de informação entre diferentes soluções candidatas. Geralmente dois indivíduos progenitores são escolhidos da população para produzir dois novos indivíduos por um método aleatório com probabilidade definida por uma taxa de cruzamento (TANOMARU, 1995). O operador produz os dois descendentes ao escolher um ou mais pontos de corte nos cromossomos dos progenitores e depois cria uma combinação diferente das partes resultantes para gerar cada um dos descendentes. Segundo Izidoro (2001), os operadores de cruzamento mais frequentemente usados são: cruzamento de ponto único, cruzamento de dois pontos e cruzamento uniforme.

- cruzamento de ponto único – faz a seleção aleatória de uma posição de corte criando quatro seqüências que serão cruzadas formando os descendentes, **Figura 3.4**.




Figura 3.4 – Cruzamento de ponto único. Fonte: Izidoro (2001).

- cruzamento de dois pontos – seleciona aleatoriamente duas posições de corte, os alelos compreendidos entre estes dois pontos de corte serão cruzados para formar os descendentes, **Figura 3.5**.




Figura 3.5 – Cruzamento de dois pontos. Fonte: Izidoro (2001).

- cruzamento uniforme – usa-se uma máscara binária, gerada aleatoriamente, de comprimento igual ao dos cromossomos. Se na máscara houver o dígito 1 o alelo do pai 1 será transmitido ao descendente, se houver 0 será transmitido o alelo do pai 2. Após a formação do primeiro descendente o processo será repetido com os pais trocados e uma nova máscara para formar o segundo descendente, **Figura 3.6**.

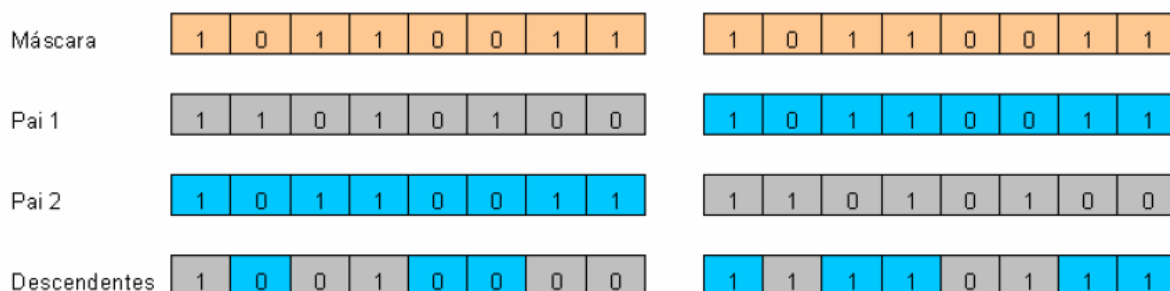


Figura 3.6 – Cruzamento uniforme. Fonte: Izidoro (2001).

c) Mutação

O operador de mutação usado nos AG tem o objetivo de alterar aleatoriamente a característica de um indivíduo, através da mudança do valor de um gene. Uma vez que as características dos “descendentes” são limitadas à constituição de seus “ancestrais”, a mutação possibilita o aparecimento de indivíduos com características até então não identificadas (CUNHA E PINTO, 2001). Esta alteração garante que a probabilidade de chegar a qualquer ponto da superfície de resposta nunca seja zero, além de contornar o problema de ótimos locais. Quando são utilizadas representações binárias, o operador de mutação escolhe aleatoriamente uma posição do cromossomo e altera-o de acordo com o procedimento ilustrado na **Figura 3.7** (TAVARES, 2000). Este operador não ocorre em todos os cromossomos, sendo sua aplicação determinada por uma “taxa de cruzamento”.




Figura 3.7 – Operador mutação. Fonte: Izidoro (2001).

3.5.5 - Parâmetros

Os AG dependem essencialmente de um conjunto de parâmetros que devem ser definidos. Os principais parâmetros, segundo Tavares (2000), são: taxa de cruzamento, taxa de mutação, taxa de substituição e critério de parada.

a) Taxa de Cruzamento

É definida como a medida da possibilidade de aplicação do operador de cruzamento a um dado par de indivíduos. Os valores típicos para esta taxa situam-se no intervalo de

0,6 a 1,0. Quanto maior for esta taxa, maior é a quantidade de indivíduos introduzidos na população. Para valores abaixo desta taxa, menos indivíduos são gerados em cada geração, o que pode causar um aumento do número de gerações necessárias para obter os mesmos resultados.

b) Taxa de Mutação

É uma medida da taxa de ocorrência da operação mutação sobre um dado cromossomo. Dado que uma taxa de mutação elevada tornará o processo essencialmente aleatório, é usual esta taxa assumir valores relativamente baixos que, tipicamente, estão no intervalo de 0,001 a 0,1.

c) Taxa de Substituição

Define qual a proporção de indivíduos da população será substituída em cada geração. Se a percentagem de indivíduos a substituir for de 100% todos os indivíduos da população atual são substituídos pelos novos indivíduos resultantes da reprodução. Quanto menor for o valor desta taxa, menor será a diferenciação genética entre gerações e deste modo existirá uma convergência do algoritmo mais lenta.

d) Critério de parada

Depende do problema e do esforço computacional exigido. Em face do tempo e dos recursos disponíveis, é necessário definir qual a qualidade da solução desejada. Um critério usado com frequência passa por definir o número máximo de gerações em que a evolução deve ocorrer. Um segundo critério possível passa pela definição de um valor mínimo para o desvio padrão do valor de aptidão dos indivíduos na população. Uma vez atingido esse valor mínimo o algoritmo para.

Outro critério bastante comum de parada consiste em fazer evoluir o algoritmo até se verificar que não se registram melhorias significativas das soluções ao longo de um dado número de gerações.

3.6 - Simrunner

3.6.1 - Principais características

O Simrunner é um otimizador que utiliza um algoritmo baseado nas estratégias evolutivas inicializado por um algoritmo genético (LAW E KELTON, 2000; PROMODEL, 2002).

3.6.2 - Procedimento de utilização

A criação do projeto de otimização do Simrunner é feita em três etapas sendo cada etapa composta por uma série de passos necessários para completá-la. As etapas são exibidas no painel superior da interface do Simrunner enquanto os passos de cada etapa são exibidos no painel esquerdo, **Figura 3.8**.

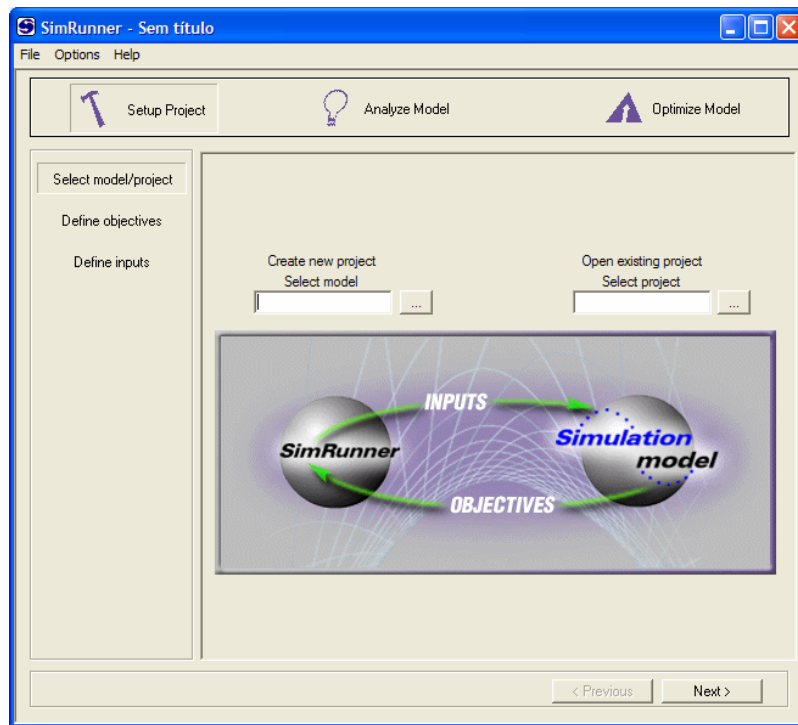


Figura 3.8 – Seleção do modelo ou projeto.

Inicia-se o Simrunner configurando o projeto de otimização. O primeiro passo é especificar o modelo do ProModel a ser otimizado. Isto pode ser feito criando um novo projeto ou abrindo um já existente. Em seguida define-se a função objetivo. No Simrunner, a função objetivo é composta de uma resposta estatística e de um peso específico aplicado a cada resposta estatística. Esta resposta pode ser minimizar ou maximizar o resultado ou ainda alcançar uma faixa desejada, **Figura 3.9**.

As entradas são as variáveis que o Simrunner variará para alterar o resultado da função objetivo. Somente macros podem ser usados como entradas para otimização, **Figura 3.10**.

Definindo-se as entradas encerra-se a etapa de configuração do projeto. A próxima etapa é a análise do modelo. Para modelos determinísticos, cada simulação fornece a mesma saída assim uma execução é suficiente para obter o resultado. Contudo, as saídas de modelos estocásticos fornecem apenas uma estimativa do resultado verdadeiro sendo necessárias várias replicações para o resultado ter valor estatístico.

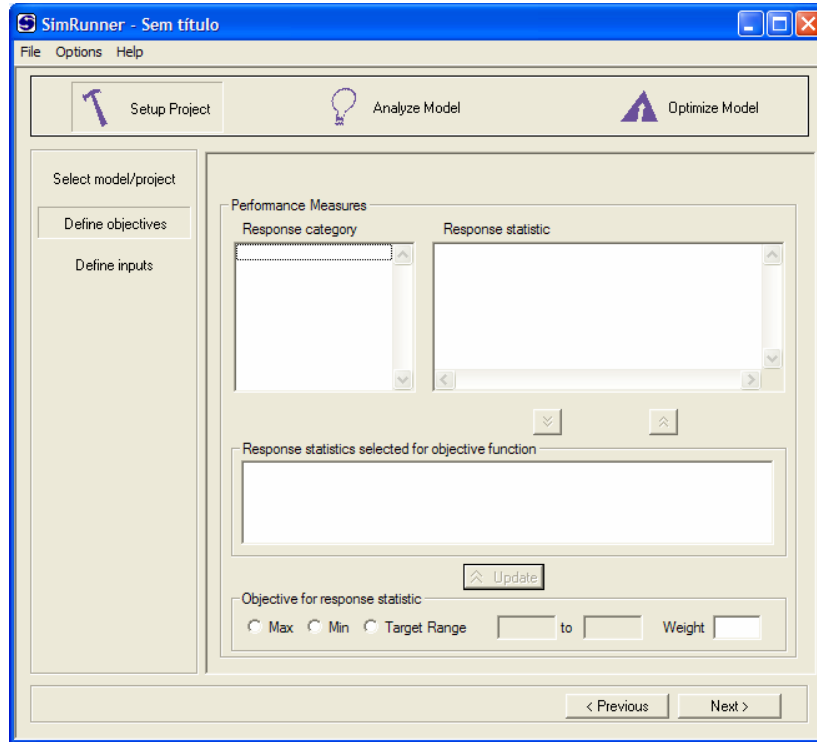


Figura 3.9 – Definição da função objetivo.

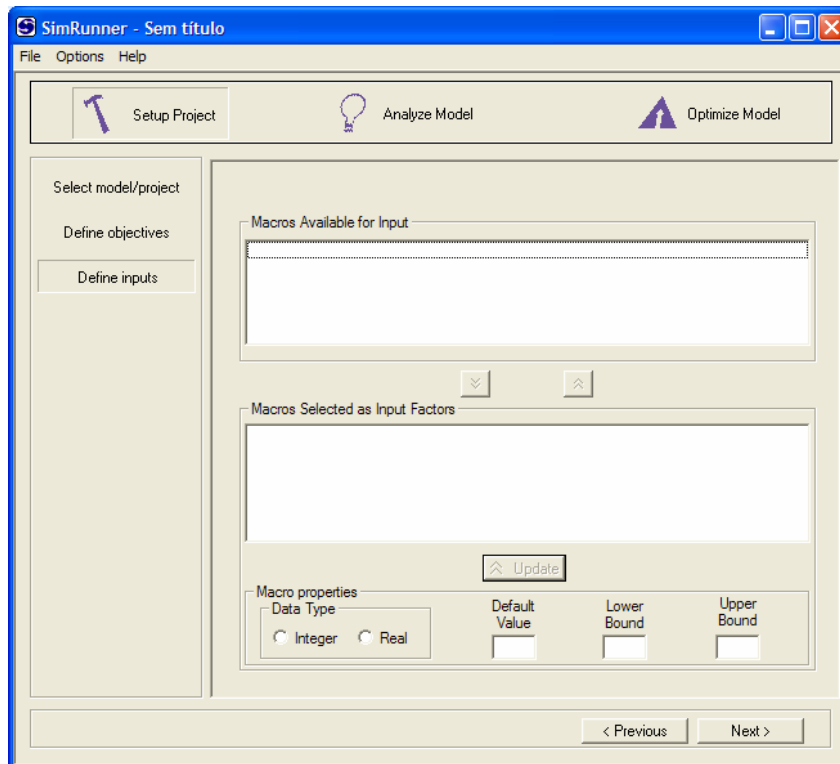


Figura 3.10 – Definição das entradas.

O Simrunner possui um módulo para auxiliar na especificação no número de replicações, e de tempo de aquecimento e tempo de execução para modelos não terminantes, **Figura 3.11**. Executa-se a análise após a definição dos parâmetros, o Simrunner calcula automaticamente o número de replicações em função do tempo de aquecimento, **Figura 3.12**.

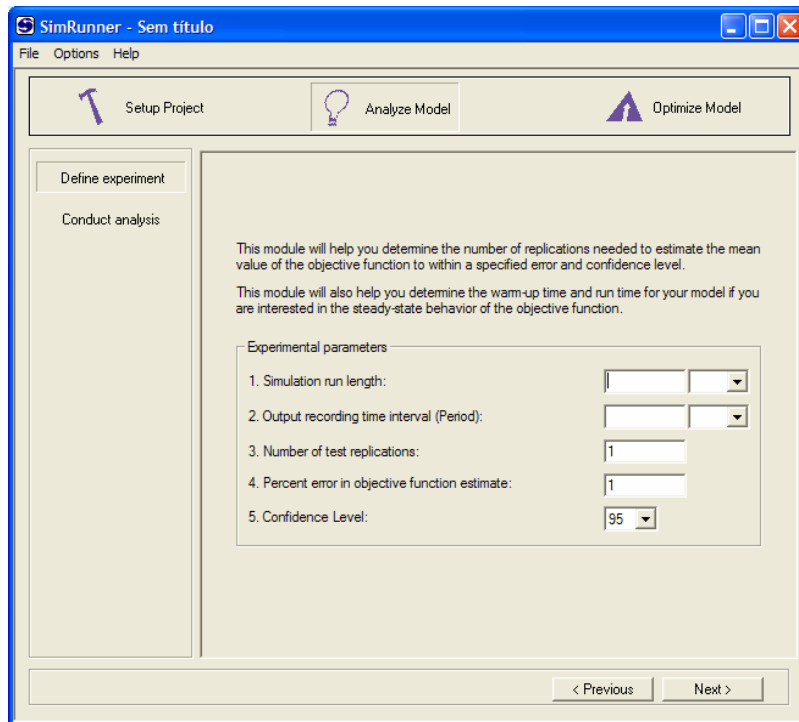


Figura 3.11 – Módulo de análise do modelo.

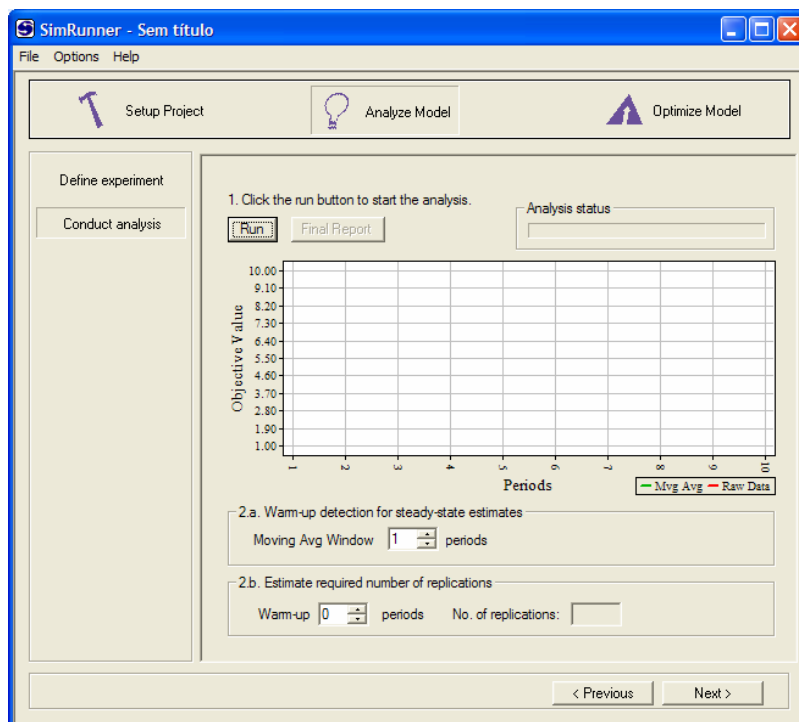


Figura 3.12 – Execução da análise.

Encerrada a análise do modelo, segue-se a definição das opções de otimização e da simulação, **Figura 3.13**. As opções de otimização são o perfil de otimização e percentual de convergência. O perfil de otimização é um dos dois fatores que afetam o critério de parada. As opções para o perfil de otimização são “Agressivo”, “Moderado” e “Cauteloso” correspondendo a três diferentes e crescentes tamanhos da população determinados internamente. Quando o tamanho da população aumenta, o algoritmo testa mais soluções candidatas aumentando a possibilidade de alcançar o ótimo global.

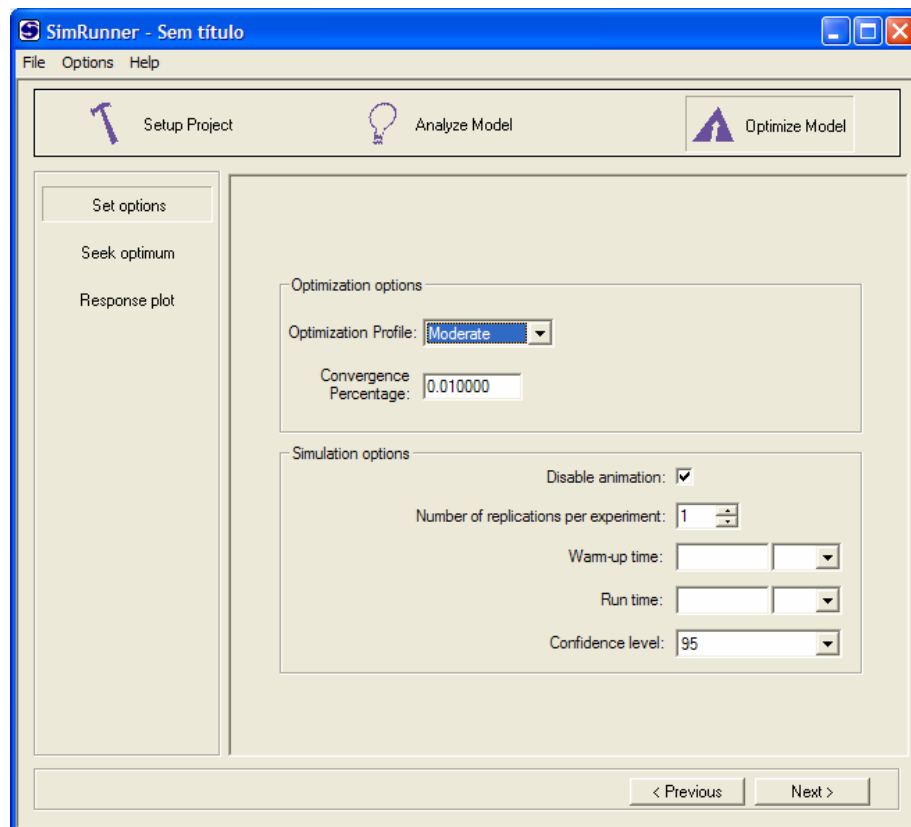


Figura 3.13 – Opções da otimização.

O percentual de convergência representa a precisão da função objetivo, que é o outro fator usado como critério de parada. O percentual de convergência representa o quão próximo o melhor valor da função objetivo (*BOF*) e a média do valor da função objetivo (*AOF*) para uma geração devem ser para o algoritmo terminar. Caso contrário, a próxima geração é selecionada e simulada, *BOF* e *AOF* são recalculados e refaz-se o teste de parada.

Após a definição das opções de otimização e de simulação, executa-se a otimização propriamente dita, **Figura 3.14**. É possível acompanhar o desenvolvimento da otimização através do gráfico da medida de desempenho, **Figura 3.15**.

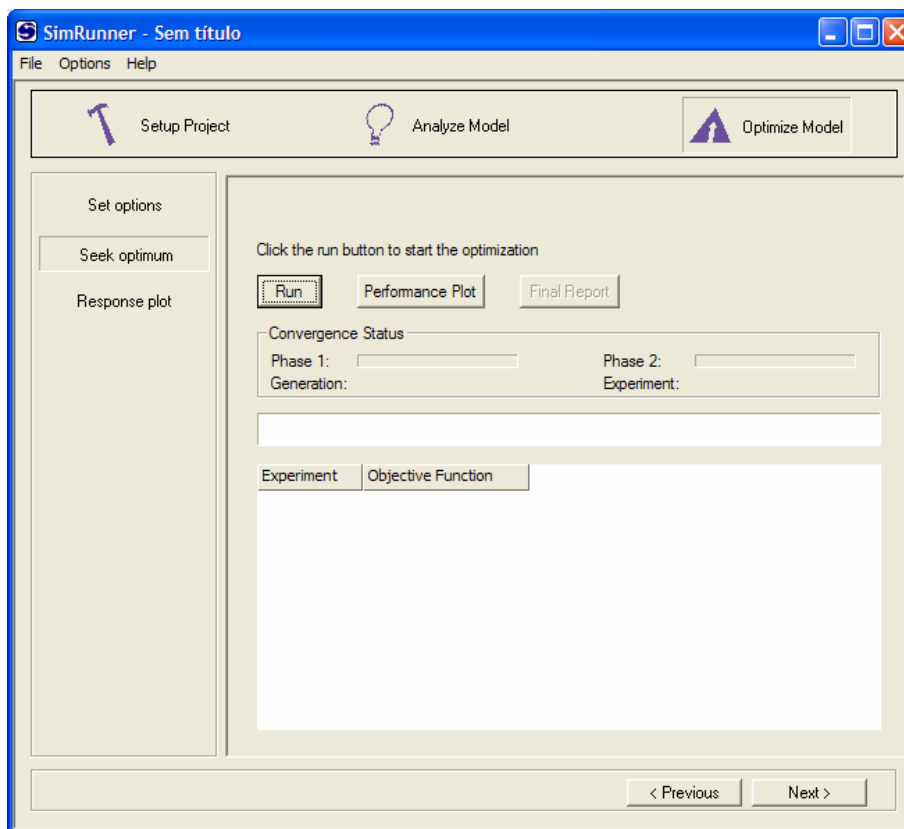


Figura 3.14 – Execução da otimização.

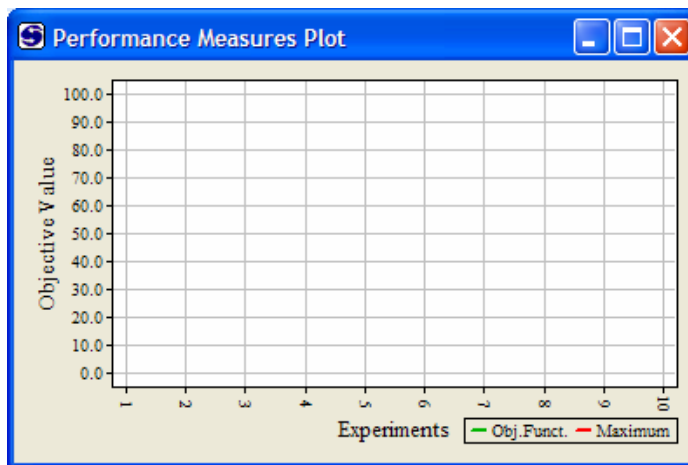


Figura 3.15 – Gráfico das medidas de desempenho.

Concluída a otimização do modelo pode-se exibir um gráfico de superfície de resposta entre duas variáveis, *Figura 3.16*.

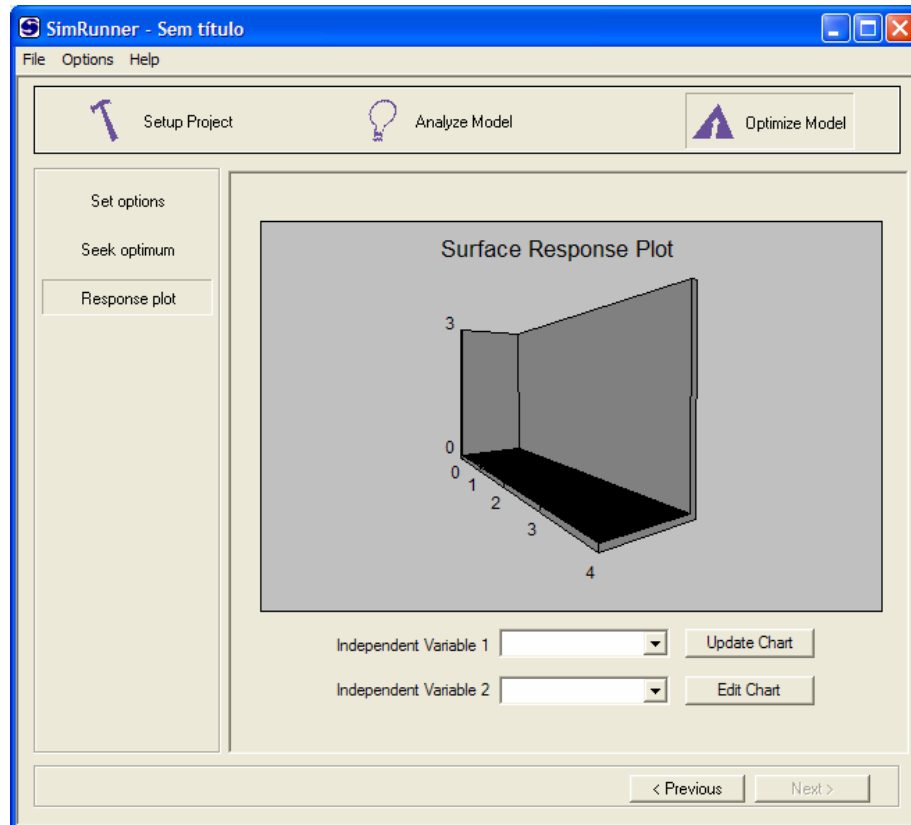


Figura 3.16 – Superfície de resposta.

3.7 - Considerações finais

Neste capítulo objetivou-se introduzir o conceito de otimização via simulação. As principais definições, as vantagens e desvantagens foram apresentadas. Foi dada ênfase na técnica de otimização baseada em algoritmos genéticos, ressaltando seus princípios, vantagens, desvantagens e os operadores genéticos.

CAPÍTULO 4 - PLANEJAMENTO DE EXPERIMENTOS

4.1 - Considerações iniciais

Na avaliação de sistemas complexos pode-se empregar a simulação de diversas formas. Um emprego bastante comum é a comparação de alternativas de configurações, no qual as configurações são pré-definidas e o objetivo ao simulá-las é comparar os resultados obtidos para cada uma delas. Nesta situação, as configurações alternativas são *especificadas externamente em virtude de restrições físicas, obrigações contratuais ou considerações políticas* (LAW E KELTON, 2000).

Contudo, neste capítulo, será visto o emprego da simulação na situação onde se deseja identificar entre os provavelmente muitos parâmetros e considerações estruturais quais têm os maiores efeitos nas medidas de desempenho ou qual conjunto de especificações do modelo conduz para o desempenho ótimo. Assim, este capítulo fornece uma introdução para o uso de planejamento estatístico de experimentos quando o experimento é a execução de um modelo de simulação.

4.2 - Estratégias de experimentação

A estratégia de experimentação é o método de planejamento e condução do experimento (MONTGOMERY, 2001). Segundo esse autor há diversos métodos para a realização de experimentos. Seguem abaixo alguns exemplos:

4.2.1 - Best-guess

Esta estratégia baseia-se no conhecimento técnico ou teórico de especialistas que alteram o valor de uma ou duas variáveis para o próximo teste em função do resultado obtido no teste anterior. Este procedimento apresenta pelos menos duas desvantagens. A primeira desvantagem ocorre se a configuração inicial não produzir o resultado desejado então o experimentalista deve procurar por outra configuração de valores das variáveis. Estas tentativas podem continuar indefinidamente e tomar muito tempo sem garantia de sucesso. A segunda desvantagem é que, supondo que a configuração inicial produza um resultado aceitável, o experimentalista será tentado a parar os testes embora não haja garantia que o melhor resultado tenha sido obtido.

4.2.2 - Um fator por vez

Esta estratégia consiste em selecionar um ponto de partida ou configuração de referência de valores para cada variável ou fator, então sucessivamente variar cada variável dentro da sua faixa mantendo as outras variáveis constantes no nível de referência. Depois de realizados todos os testes, uma série de gráficos é construída mostrando como a resposta é afetada pela variação de cada variável mantendo-se as outras constantes. A maior desvantagem desta estratégia é a incapacidade de detectar interações entre as variáveis, como esse fato é desconhecido por muitos experimentalistas ela é usada intensivamente (MONTGOMERY, 2001).

4.2.3 - Planejamento Fatorial

Segundo Montgomery (2001), quando o experimento envolve o estudo dos efeitos de dois ou mais fatores, a estratégia mais eficiente é o planejamento fatorial. Nesta estratégia, os fatores são variados juntos e não um por vez, ou seja, *em cada tentativa completa ou réplica do experimento, todas as combinações possíveis dos níveis são investigadas* (MONTGOMERY E RUNGER, 2003).

Esta estratégia é mais eficiente que a abordagem um fator por vez, pois permite que os efeitos de um fator sejam estimados em diversos níveis dos outros fatores conduzindo a conclusões que são válidas dentro da abrangência das condições experimentais (MONTGOMERY, 2001) e é a única forma de descobrir interações entre os fatores (MONTGOMERY, 2001; MONTGOMERY E RUNGER, 2003) evitando conclusões incorretas quando houver interações entre fatores. O problema central num planejamento fatorial é o crescimento exponencial das combinações de níveis com o aumento do número de fatores (KLEIJNEN, 1998).

4.2.4 - Metodologia de superfície de resposta (MSR)

A metodologia da superfície de resposta consiste em *uma coleção de técnicas matemáticas e estatísticas que são úteis para modelagem e análise nas aplicações em que a resposta de interesse seja influenciada por várias variáveis e o objetivo seja otimizar essa resposta* (MONTGOMERY E RUNGER, 2003). Segundo estes autores, a forma da relação entre a resposta e as variáveis independentes é desconhecida na maioria dos problemas.

Segundo Montgomery e Runger (2003), a primeira etapa da MSR é encontrar uma aproximação adequada para a verdadeira relação entre a resposta (Y) e as variáveis independentes. De um modo geral, polinômios de baixo grau são empregados para modelar

alguma região das variáveis independentes. Esses polinômios podem, por exemplo, ser uma função linear das variáveis independentes, então a função de aproximação será o modelo de primeira ordem da **Equação 4.1** onde β_i são os coeficientes das variáveis independentes e ε é o termo do erro aleatório.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (4.1)$$

Caso haja curvatura na superfície de resposta do sistema, pode-se usar um modelo de segunda ordem com a função de aproximação dada pela função quadrática da **Equação 4.2**.

$$Y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{\substack{i \\ i < j}} \sum_j \beta_{ij} x_i x_j + \varepsilon \quad (4.2)$$

4.3 - Planejamento estatístico de experimentos

Planejamento estatístico de experimentos *refere-se ao processo de planejar o experimento tal que dados apropriados que possam ser analisados por métodos estatísticos sejam coletados, resultando em conclusões válidas e objetivas* (MONTGOMERY, 2001). Para esse autor, a abordagem estatística para o planejamento de experimentos é necessária se se deseja obter conclusões significativas dos dados. Também, quando o problema envolve dados sujeitos a erros experimentais, esta é a única abordagem para uma análise objetiva do problema. Assim, devem-se considerar dois aspectos em qualquer problema experimental: o planejamento do experimento e a análise estatística dos dados, os quais estão intimamente relacionados porque o método de análises depende diretamente do planejamento empregado.

Law e Kelton (2000) apresentam o planejamento de experimentos, no contexto da simulação, como *uma maneira de decidir antes da realização dos experimentos quais configurações em particular simular de forma que a informação desejada pode ser obtida com a quantidade mínima de simulação*. De forma semelhante, Kleijnen (1998) diz que o planejamento de experimentos *pode ser definido como selecionar as combinações de níveis de fatores que serão realmente simuladas em um experimento com o modelo de simulação*.

A seguir são apresentados os três princípios básicos do planejamento estatístico de experimentos: replicação, aleatorização e blocagem.

4.3.1 - Replicação

Por replicação entende-se a repetição do experimento básico. Segundo Montgomery (2001), a replicação tem duas importantes propriedades. Primeiro, permite obter uma

estimativa do erro experimental, esta estimativa torna-se uma unidade básica de medida para determinar quando as diferenças observadas nos dados são estatisticamente diferentes. Segundo, a replicação permite obter uma estimativa mais precisa do efeito de um fator no experimento.

Montgomery (2001) chama a atenção para a distinção entre replicação e a repetição da medição. Esta última ocorre quando, por exemplo, a mesma amostra é medida diversas vezes ou quando diversas amostras são medidas para uma mesma configuração de parâmetros ou experimento.

4.3.2 - Aleatorização

A aleatorização é o pilar de apoio para o uso de métodos estatísticos no planejamento de experimentos. Por aleatorização entende-se que tanto a designação do material para a experiência quanto a ordem de realização dos experimentos ou testes são determinados aleatoriamente (MONTGOMERY, 2001).

4.3.3 - Blocagem

É a técnica de planejamento usada para aumentar a precisão com que as comparações entre fatores de interesse são feitas. A blocagem é usada para reduzir ou eliminar a variação transmitida pelos fatores incontroláveis ou ruídos (MONTGOMERY, 2001).

4.4 - Vantagens da experimentação por simulação

A experimentação através da simulação apresenta algumas vantagens peculiares sobre os experimentos físicos, industriais ou de laboratórios tradicionalmente usados como exemplos (LAW E KELTON, 2000):

- Através da simulação é possível controlar fatores que na realidade são incontroláveis, tal como a taxa de chegada de clientes;
- Em simulação é possível controlar a fonte de variação diferentemente dos experimentos físicos;
- Aleatorização em experimentos de simulação não é necessária considerando que o gerador de números aleatórios seja usado adequadamente.

4.5 - Principais conceitos

4.5.1 - Fator

Fatores são os parâmetros de entrada e as considerações estruturais que compõem um modelo. Segundo Kleijnen (1998), o fator é um parâmetro, uma variável de entrada ou um módulo de modelo de simulação. Por definição, os fatores são alterados durante um experimento; eles não são mantidos constantes durante todo o experimento. Conseqüentemente um fator toma no mínimo dois níveis ou valores durante o experimento.

Os fatores podem ser tanto quantitativos quanto qualitativos. Fatores quantitativos assumem valores numéricos enquanto fatores qualitativos representam tipicamente considerações estruturais que não são normalmente quantificadas (LAW E KELTON, 2000).

Os fatores podem ser classificados em controláveis ou incontroláveis dependendo quando eles representam opções de ação para gerentes dos sistemas reais correspondentes. Usualmente foca-se nos fatores controláveis nos experimentos de simulação, considerando que eles são mais relevantes para decisões que devem ser feitas sobre implementação de sistemas reais (LAW E KELTON, 2000). Contudo, fatores incontroláveis também são de interesse em experimentos de simulação, pois permitem verificar o efeito no sistema real (BILES, 1979).

Para Law e Kelton (2000), a decisão de quais parâmetros e considerações estruturais são considerados aspectos fixos do modelo e quais são fatores experimentais é conseqüência mais dos objetivos do estudo do que da forma de modelar o sistema.

4.5.2 - Resposta

Resposta ou variável de resposta é a medida de desempenho ou saída do modelo de simulação (HARREL *et al.*, 2000; LAW E KELTON, 2000), ou seja, os resultados obtidos de uma variável de saída de interesse para o estudo. As variáveis de resposta descrevem como o sistema responde para uma dada configuração de fatores (PROMODEL, 2002).

4.5.3 - Efeito

O efeito de um fator é definido como a mudança na resposta produzida pela mudança do nível do fator (MONTGOMERY, 2001; MONTGOMERY E RUNGER, 2003). O termo efeito principal é frequentemente utilizado ao se referir aos efeitos dos fatores primários do experimento (MONTGOMERY E RUNGER, 2003).

4.5.4 - Interação

Segundo Montgomery (2001), a interação é a falha de um fator em produzir o mesmo efeito na resposta a diferentes níveis de outro fator. Montgomery e Runger (2003) dizem que há interação quando *a diferença na resposta entre os níveis de um fator não é a mesma em todos os níveis dos outros fatores*. Assim, a interação faz com que a resposta à aplicação de dois tratamentos não seja a mera soma das respostas a cada tratamento. Quando a interação entre os fatores é grande, os efeitos principais correspondentes apresentam pouco significado prático, pois podem estar mascarados, assim, o conhecimento da interação é mais útil.

4.5.5 - Experimentos de seleção

Experimentos de seleção ou *screening* são experimentos nos quais muitos fatores são considerados e o objetivo é identificar aqueles fatores (se houver) que têm maiores efeitos (MONTGOMERY, 2001). Em particular, reduzindo o número de fatores reduz a dimensão do espaço de busca para os métodos de busca do ótimo (LAW E KELTON, 2000).

Tipicamente, experimentos de seleção usam planejamentos fatoriais fracionados e são realizados nas etapas iniciais do planejamento *quando é mais provável que muitos fatores inicialmente considerados tenham pouco ou nenhum efeito na resposta* (MONTGOMERY, 2001). Montgomery (2001) afirma que *nesta situação é usualmente melhor manter o número de níveis dos fatores baixo*.

4.5.6 - Análise de sensibilidade

No contexto de simulação a análise de sensibilidade é interpretada como a investigação sistemática da reação da resposta da simulação para valores extremos da entrada do modelo ou a mudanças drásticas na estrutura do modelo (KLEIJNEN, 1998).

A análise de sensibilidade pode ser usada para proceder à seleção das variáveis, assim, o objetivo da análise seria identificar para quais variáveis o sistema modelado é mais sensível eliminando do modelo as variáveis que não produzem efeitos significativos.

4.5.7 - Metamodelo

Segundo Kleijnen (1998), metamodelo é definido como um modelo de um modelo de simulação, ou seja, o metamodelo é uma aproximação da transformação entrada/saída, também chamada superfície de resposta, do programa de simulação. Um metamodelo trata o modelo de simulação como uma caixa preta: as entradas e saídas do modelo são observadas e os efeitos dos fatores no metamodelo são estimados.

O metamodelo é a base para análise de regressão ou análise de variância (ANOVA). Tipicamente, os metamodelos de regressão podem ser de uma das classes a seguir: polinômio de primeira ordem que consiste apenas da média global e dos efeitos principais; polinômio de primeira ordem aumentado com as interações entre pares de fatores e polinômio de segunda ordem o qual inclui efeitos puramente quadráticos (KLEIJNEN, 1998).

Kleijnen (1998) cita que a vantagem desta técnica é poder ser utilizada tanto para modelos de simulação determinísticos quanto estocásticos e fornecer melhores estimativas dos efeitos dos fatores que as abordagens intuitivas, especificamente a abordagem “um fator por vez” a qual é muito utilizada na prática. Ainda segundo este autor, as desvantagens são não tomar vantagem da estrutura específica de um dado modelo de simulação, e assim, realiza mais execuções de simulação que outras técnicas tais como a análise de perturbação (HO E CAO, 1991) e a *importance sampling* (GLYNN E IGLEHART, 1989) também conhecida como *likelihood ratio* ou *score function* (KLEIJNEN E RUBINSTEIN, 1996; RUBINSTEIN E SHAPIRO, 1993).

4.6 - Planejamento fatorial 2^k

O planejamento fatorial completo de dois níveis ou fatorial 2^k é o tipo de planejamento no qual se define para cada fator dois níveis de valores, nível alto e nível baixo, e testa-se cada combinação de fatores (HARREL *et al.*, 2000).

O planejamento fatorial 2^k é um dos mais importantes tipos de planejamento fatorial, segundo Montgomery e Runger (2003), *ele é particularmente útil nos estágios iniciais de um trabalho experimental quando muitos fatores são prováveis de serem investigados. Ele fornece o menor número de execuções para os quais os k fatores podem ser estudados em um planejamento fatorial completo.*

Um aspecto a ser considerado neste tipo de planejamento é que, como há somente dois níveis de cada fator, tem-se que supor que a resposta é aproximadamente linear na faixa dos níveis dos fatores escolhidos (MONTGOMERY E RUNGER, 2003). Outro aspecto importante é que para experimentos com um grande número de fatores sendo considerado, o fatorial completo resulta em um número extremamente grande de combinações para serem testadas. Nesta situação o planejamento fracionário é usado para estrategicamente selecionar um subconjunto de combinações para testar com o objetivo de identificar os fatores com pouca ou nenhuma importância no desempenho do sistema (HARREL *et al.*, 2000).

4.7 - Planejamento fatorial fracionário 2^{k-p}

Considere-se, por exemplo, um planejamento fatorial 2^5 , neste planejamento cinco graus de liberdade correspondem aos efeitos principais, dez graus de liberdade correspondem às interações de segunda ordem e dezesseis correspondem às interações de ordens mais altas. Nos estudos iniciais de um projeto ou sistemas, de um modo geral, há pouco interesse nessas interações de ordens mais altas (MONTGOMERY E RUNGER, 2003).

Segundo Montgomery e Runger (2003), se essas interações puderem ser negligenciadas, um planejamento fatorial fracionário envolvendo menos execuções que um conjunto completo de 2^k execuções pode ser usado para obter informações sobre os efeitos principais e as interações de ordens mais baixas.

Dessa forma, o planejamento fatorial fracionário fornece um meio de obter boas estimativas dos efeitos principais e talvez das interações de segunda ordem, mas com uma fração do esforço computacional requerido por um planejamento fatorial completo 2^k (LAW E KELTON, 2000).

Um planejamento fatorial fracionado é construído selecionando um subconjunto de tamanho 2^{k-p} de todos os pontos possíveis de um planejamento 2^k e executando a simulação somente para os pontos escolhidos (LAW E KELTON, 2000).

4.7.1 - Resolução

Segundo Montgomery e Runger (2003), o conceito de resolução de um planejamento é uma forma de catalogar planejamentos fatoriais fracionários de acordo com os padrões de associações que eles produzem.

A resolução de um planejamento é representada por um numeral romano sobrescrito, por exemplo, 2_{III}^{3-1} representa o planejamento fatorial de resolução III de fração um meio do planejamento 2^3 (MONTGOMERY, 2001). Os planejamentos de resolução III, IV e V são particularmente importantes e são detalhados a seguir (MONTGOMERY E RUNGER, 2003).

a) Planejamento de resolução III

Estes são planejamentos nos qual nenhum efeito principal está associado com outro efeito principal, mas os efeitos principais estão associados com interações de segunda ordem e interações de segunda ordem podem estar associadas entre si.

b) Planejamento de resolução IV

Estes são planejamentos nos qual nenhum efeito principal está associado com qualquer outro efeito principal ou qualquer interação de segunda ordem, mas interações de segunda ordem estão associadas ente si.

c) Planejamento de resolução V

Estes são planejamentos nos qual nenhum efeito principal ou interação de segunda ordem está associado com qualquer outro efeito principal ou interação de segunda ordem, mas interações de segunda ordem estão associadas com interações de terceira ordem.

4.8 - Verificação da validade do modelo experimental

O modelo matemático obtido através dos resultados experimentais deve ter sua validade verificada antes de ser usado. Considerando-se que as conclusões obtidas dos resultados experimentais baseiam-se em técnicas estatísticas, é importante assegurar que as hipóteses dessas técnicas sejam satisfeitas.

Por exemplo, para verificar se um fator tem efeito significativo utiliza-se a análise de variância (ANOVA). Esta técnica tem como hipótese que os termos relacionados aos erros são normal e independentemente distribuídos com média zero e variância constante (MONTGOMERY, 2001).

Assim faz-se necessário investigar se a hipótese de erros normal e independentemente distribuídos com média zero e variância constante, não é violada. As violações são investigadas examinando-se os resíduos e_{ij} , definidos como $e_{ij} = y_{ij} - \hat{y}_{ij}$, onde \hat{y}_{ij} é o valor ajustado ou estimado da observação y_{ij} correspondente. Mas, o valor ajustado \hat{y}_{ij} é igual à média das observações da i -ésima célula $\bar{y}_{i\cdot}$. tem-se que $e_{ij} = y_{ij} - \bar{y}_{i\cdot}$. (MONTGOMERY, 2001).

A seguir são apresentadas as técnicas de verificação da suposição de normalidade, de independência e de variância constante.

a) Suposição de normalidade

A verificação da suposição de normalidade pode ser feita através do histograma dos resíduos, contudo para pequenas amostras flutuações consideráveis podem ocorrer tornando a verificação por essa técnica imprecisa. Uma alternativa é o uso do gráfico

de probabilidade normal para os resíduos. Caso os resíduos sejam normalmente distribuídos, este gráfico assemelhar-se-á a uma linha reta.

b) Suposição de independência

A verificação da suposição de independência é realizada observando se há correlação entre os resíduos. Para isso, o gráfico dos resíduos em seqüência temporal é útil para detectar se há tendência de seqüências positivas e negativas dos resíduos, o que implicaria na violação da suposição de independência.

c) Variância não constante

Para verificar a suposição da igualdade da variância utiliza-se o gráfico dos resíduos versus os valores ajustados. A variabilidade nos resíduos não deve depender do valor de \bar{y}_{ij} , caso haja um padrão de comportamento, como por exemplo, o aumento da variância com o aumento do valor da observação, deve-se utilizar uma transformação estabilizadora de variância e executar a análise de variância sobre os dados transformados.

4.9 - Considerações finais

Neste capítulo tratou-se das principais estratégias de experimentação. Os princípios básicos dos planejamentos experimentais foram comentados e os principais conceitos, as vantagens e desvantagens foram apresentadas. Foi dada ênfase na técnica de planejamento fatorial e nos fundamentos de verificação da validade do modelo.

CAPÍTULO 5 - PRIMEIRA APLICAÇÃO

5.1 - Considerações iniciais

Este capítulo apresenta o primeiro projeto de simulação onde as técnicas de planejamento de experimento foram aplicadas, mais especificamente o planejamento fatorial fracionado. Essa aplicação foi desenvolvida na divisão de produção da Fábrica de Itajubá da Indústria de Material Bélico do Brasil – IMBEL e seguiu a proposta de Banks *et al.* (2005) para a execução de estudos por simulação, **Figura 2.4** (ver página 17). Nessa primeira aplicação o modelo utilizado foi determinístico.

5.2 - Objeto de estudo

O objeto de estudo é uma célula da linha de fabricação da armação monofilar, um dos componentes mais importantes da pistola. A pistola é um dos principais produtos de exportação da Fábrica de Itajubá, e a produtividade da linha da armação é o maior limitante para o atendimento pleno do mercado.

Dentro da linha da armação, identificou-se que uma célula específica é o gargalo para o aumento da produção da armação. Esta célula é chamada de Grupo 1. O problema a ser estudado é como melhorar de desempenho desta célula.

5.2.1 - A Fábrica de Itajubá (FI)

A Fábrica de Itajubá da Indústria de Material Bélico do Brasil (IMBEL/FI) é uma indústria do setor metal-mecânica que produz pistolas e fuzis. A IMBEL/FI produz pistolas derivadas do modelo Colt 1911 no calibre .45” para exportação e no calibre .40” para o mercado policial nacional e fuzis no calibre 5,56 mm e 7,62 mm para as forças armadas nacionais e estrangeiras e para as forças policiais estaduais. Para isso conta com um efetivo aproximado de 900 funcionários sendo que cerca de 500 atuam na área produtiva exercendo atividades de forjaria, fresamento, tornearia, estamparia, tratamento térmico, tratamento superficial, injeção de plástico, furação profunda e ferramentaria.

5.3 - Desenvolvimento da Aplicação 1

5.3.1 - Formulação do problema

O problema a ser estudado nesta aplicação consiste em aumentar a produção através do acréscimo de novas máquinas para cada operação. As máquinas novas seriam adquiridas

através de financiamento por isso o aumento na produção deve ser suficiente para compensar as parcelas do empréstimo.

5.3.2 - Definição dos objetivos e plano geral do projeto

Considerando o problema apresentado e as limitações impostas, definiu-se como objetivo selecionar a configuração ótima de equipamentos para a qual o aumento da receita compensa o custo de aquisição dos novos equipamentos dando o melhor retorno.

Para alcançar esse objetivo realizar-se-á uma análise de sensibilidade. O indicador de desempenho é a receita líquida determinada pela subtração da parcela do empréstimo do ganho mensal. Este último calculado pela multiplicação do ganho unitário pela produção mensal.

O escopo do trabalho está limitado ao Grupo 1 da linha da armação da pistola. Apenas um modelo de armação foi modelado uma vez que as diferenças entre os diversos modelos da armação não afetam o tempo de operação deste grupo e que não há distinção nos parâmetros das operações para usinagem das armações de aço carbono, aço inoxidável ou alumínio.

5.3.3 - Coleta e análise dos dados

Durante a etapa de coleta e análise dos dados foram obtidas informações a respeito da composição do Grupo 1 (locais), da quantidade de funcionários atualmente disponíveis (recursos), as atividades e respectivas durações, os horários de expedientes, a seqüência de operações das peças e a programação típica da célula. Estas informações estão resumidas na **Quadro 5.1**.

Locais	9 máquinas
Recursos	14 funcionários distribuídos entre os dois turnos
Atividades	37 atividades
Controles	Horários de expediente Seqüência de operações das peças Programação

Quadro 5.1 – Resumo dos elementos do sistema.

a) Descrição da célula

O grupo 1 é composto por sete centros de usinagem CNC, uma fresadora CNC de cabeçote duplo e uma furadeira horizontal para furação profunda. Todas as máquinas são automáticas e executam uma operação específica conforme **Figura 5.1**.

Para cada máquina há um operador dedicado para a execução da operação. O operador é responsável pela colocação e retirada das peças, pelo controle da operação, iniciando o ciclo

de usinagem e interrompendo-o se necessário e pela inspeção das peças. Uma característica deste grupo é que muitas operações possuem ciclos longos e processam várias peças simultaneamente, devido a isso, os operadores ficam ociosos parte do tempo do ciclo.

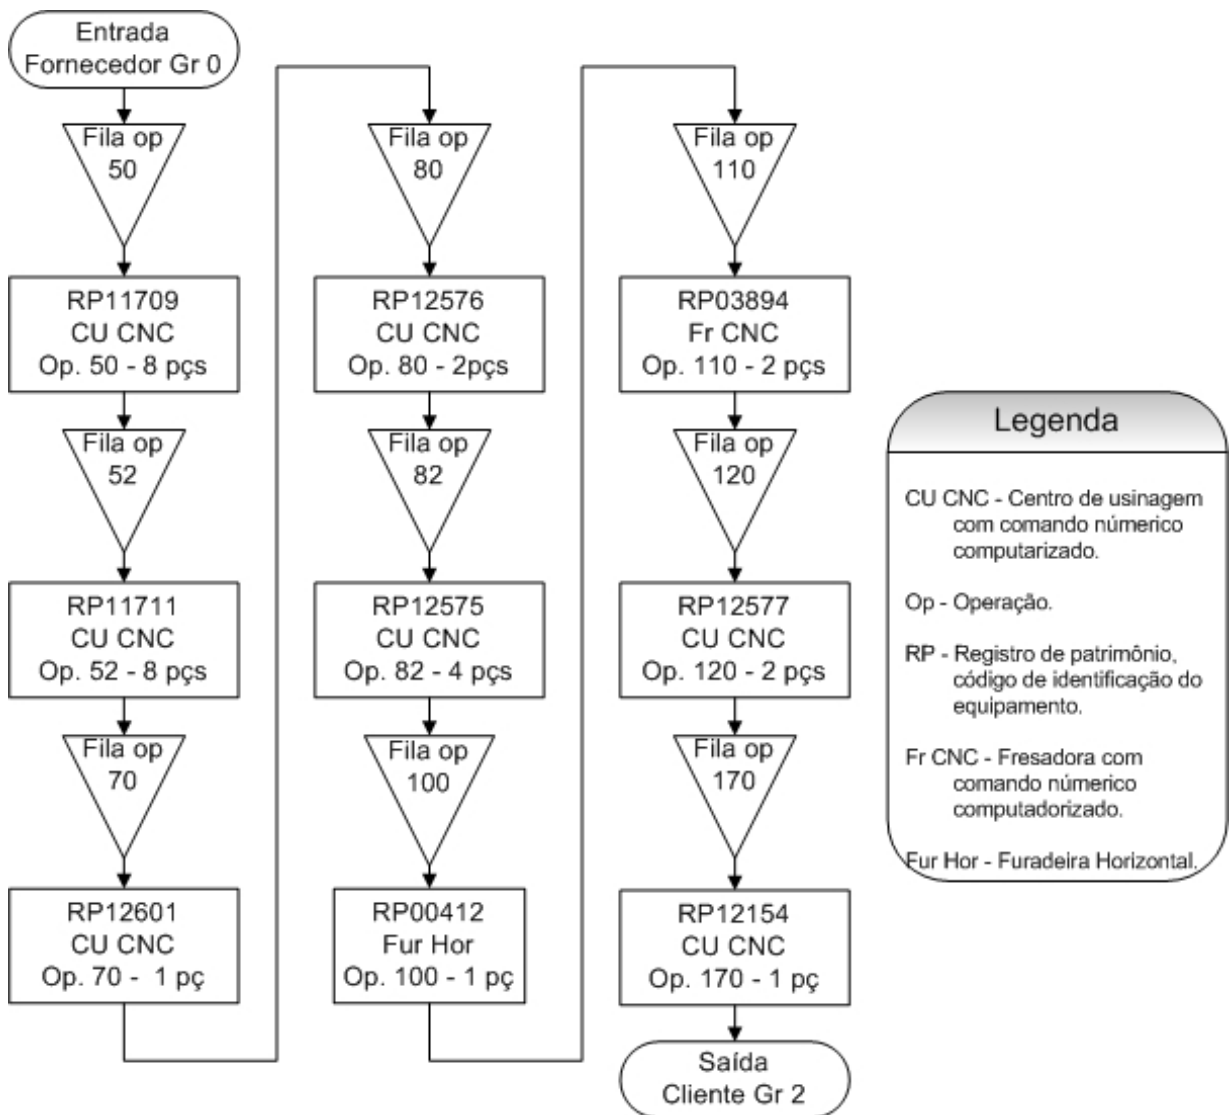


Figura 5.1 – Fluxograma do processo no grupo 1 para a aplicação 1.

As peças seguem de operação em operação e para cada operação há uma fila de peças aguardando para serem usinadas. Todas as operações desse grupo são executadas em todos os modelos de armação. O transporte das peças entre as operações ocorre de forma irregular. Usualmente, o operador da operação posterior pega as peças usinadas na bancada da operação anterior. A quantidade de peças transportada depende da capacidade do operador, sendo comum o transporte de quatro ou cinco peças por vez.

5.3.4 - Modelo conceitual

Uma simplificação adotada neste estudo é que a seqüência das operações é fixa enquanto que, de fato, em certas circunstâncias os operadores executam algumas operações antes de outras em função da ociosidade da máquina. Outras simplificações do modelo foram:

- Modelagem de apenas um modelo de armação devido à similaridade entre as operações dos diferentes tipos de armações;
- A desconsideração do efetivo responsável pela preparação das máquinas e dos tempos de preparação, pois as trocas de operação são relativamente rápidas devido à semelhança entre os modelos;
- A desconsideração de refugo por sê-lo reduzido;
- A não inclusão das paradas para manutenção e das substituições de ferramentas por não haver tempo suficiente para coletar esses dados;
- A não inclusão dos tempos de inspeções e movimentações pelo fato que estas atividades são executadas pelos operadores durante a execução da usinagem pelos equipamentos e como esses tempos são desprezíveis quando comparados ao tempo de usinagem o operador já estaria disponível ao término da usinagem para a remoção da peça.

a) Fatores de entrada

Como apenas um modelo de armação foi modelado, criou-se uma entidade denominada “armação”, que representa todos os modelos da armação. Estas peças entram no sistema diariamente às 07h00min, com quantidade de 350 unidades. O horário de trabalho foi definido considerando apenas o 1º turno, começando às 07h00min e encerrando às 17h00min, com intervalo de uma hora às 11h30min. A **Tabela 5.2** apresenta o mapa de processo da célula onde estão indicadas as atividades e a suas respectivas durações. O significado dos símbolos da **Tabela 5.2** é mostrado na **Tabela 5.3**. No **Quadro 5.2** estão resumidas as informações obtidas durante o mapeamento do processo.

Tempo (min)	○	⇒	□	◇	▽	Descrição da Etapa
		X				50 peças são movimentadas da entrada para fila da op. 50
				X		Aguardando movimentação para execução da op. 50
0,10		X				8 peças são movimentadas da fila da op. 50 para RP11709
20,03	X					8 peças são usinadas na RP11709
0,10		X				8 peças são movimentadas da RP11709 para fila da op. 52
				X		Aguardando movimentação para execução da op. 52

Tabela 5.1 – Detalhamento do processo da aplicação 1.

Tempo (min)	○	⇒	□	D	▽	Descrição da Etapa
0,10		X				8 peças são movimentadas da fila da op. 52 para RP11711
11,32	X					8 peças são usinadas na RP11711
0,10		X				8 peças são movimentadas da RP11711 para fila da op. 70
				X		Aguardando movimentação para execução da op. 70
0,10		X				1 peça é movimentada da fila da op. 70 para RP12601
2,56	X					1 peça é usinada na RP12601
0,10		X				1 peça é movimentada da RP12601 para fila da op. 80
				X		Aguardando movimentação para execução da op. 80
0,10		X				2 peças são movimentadas da fila da op. 80 para RP12576
6,50	X					2 peças são usinadas na RP11576
0,10		X				2 peças são movimentadas da RP11576 para fila da op. 82
				X		Aguardando movimentação para execução da op. 82
0,10		X				4 peças são movimentadas da fila da op. 82 para RP12575
13,40	X					4 peças são usinadas na RP12575
0,10		X				4 peças são movimentadas da RP12575 para fila da op. 100
				X		Aguardando movimentação para execução da op. 100
0,10		X				1 peça é movimentada da fila da op. 100 para RP00412
2,27	X					1 peça é furada na RP00412
0,10		X				1 peça é movimentada da RP00412 para fila da op. 110
				X		Aguardando movimentação para execução da op. 110
0,10		X				2 peças são movimentadas da fila da op. 110 para RP03894
5,32	X					2 peças são furadas na RP03894
0,10		X				2 peças são movimentadas da RP03894 para fila da op. 120
				X		Aguardando movimentação para execução da op. 120
0,10		X				2 peças são movimentadas da fila da op. 120 para RP12577
6,27	X					2 peças são usinadas na RP12577
0,10		X				2 peças são movimentadas da RP12577 para fila da op. 170
				X		Aguardando movimentação para execução da op. 170
0,10		X				1 peça é movimentada da fila da op. 170 para RP12154
1,66	X					1 peça é usinada na RP12154
		X				1 peça é movimentada da RP12154 para saída

Tabela 5.2 – Detalhamento do processo da aplicação 1 (cont.).

Símbolo	Significado	Descrição
○	Operação	Alguma coisa está sendo feita no momento.
⇒	Transporte	Há um movimento de um local para outro.
□	Inspeção	Observação para verificar qualidade e precisão.
D	Atraso	Espera antes de iniciar o próximo passo de um processo.
▽	Armazenagem	Há armazenagem de produtos acabados ou armazenagem de estoques em processo.

Tabela 5.3 – Simbologia utilizada e seu significado.

Número de operações	9
Número de transportes	19
Número de esperas	9
Total	37

Quadro 5.2 – Resumo do processo da aplicação 1.

b) Fatores experimentais

Os fatores experimentais, no contexto deste trabalho, são os fatores de entrada que são variados durante a etapa de experimentação. Conforme a formulação do problema, a opção de solução considerada foi a adição de novas máquinas para a execução das operações. Dessa forma, nove fatores experimentais foram definidos, cada um representando uma operação. No **Quadro 5.3** estão apresentados esses fatores e os valores que eles podem assumir.

Fatores experimentais	Descrição	Valores
Op050 Op052 Op070 Op080 Op082 Op100 Op110 Op120 Op170	Indicam a utilização de uma ou duas máquinas para a realização das respectivas operações	1 = uma máquina 2 = duas máquinas

Quadro 5.3 – Fatores experimentais para a aplicação 1.

c) Fatores de saída

O principal fator de saída é a quantidade de peças produzidas no período simulado. Outros fatores definidos são: a ocupação dos operadores, a formação de filas e o *lead-time*. Esses fatores foram definidos para facilitar a verificação e validação do modelo, mas não são utilizados nas etapas posteriores.

5.3.5 - Tradução do modelo

A **Figura 5.2** mostra o modelo computacional no ProModel conforme leiaute do Grupo 1. Neste modelo, os operadores estão distribuídos um para cada posto de trabalho e executam as tarefas de retirada e colocação das peças nos dispositivos de fixação e o acionamento dos equipamentos.

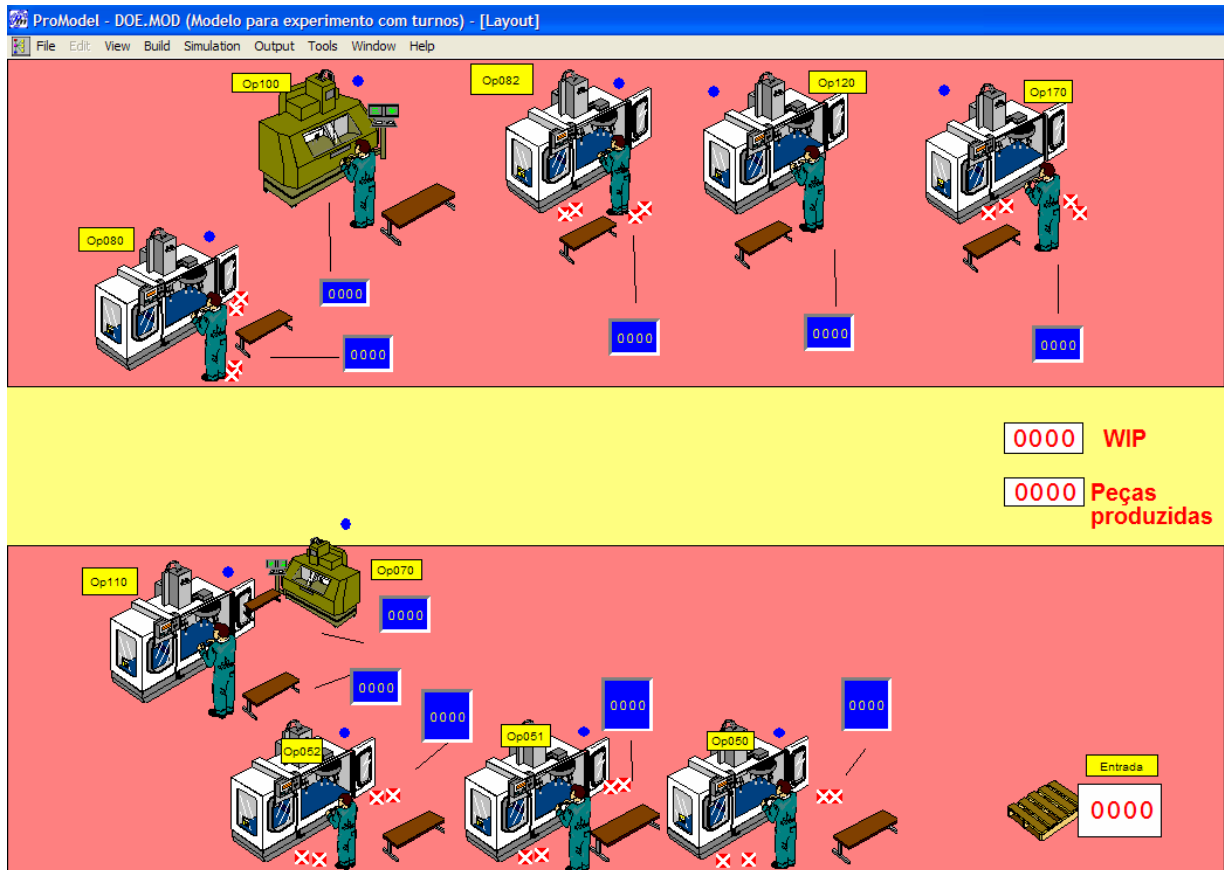


Figura 5.2 – Modelo do Grupo 1 da aplicação 1.

5.3.6 - Verificação e validação do modelo

O modelo foi verificado utilizando-se os recursos do depurador e a interface gráfica do ProModel. A interface gráfica auxiliou na verificação do fluxo das entidades e dos recursos. O depurador permitiu acompanhar a execução do modelo passo a passo e verificar os valores das variáveis. A verificação da lógica do processo foi realizada através da análise dos resultados das filas e da ociosidade dos equipamentos.

A validação do modelo ocorreu através da análise dos resultados da simulação de uma situação base. Os resultados obtidos foram comparados com dados históricos do Grupo 1 e a avaliação envolveu pessoas conhecedoras do processo.

5.3.7 - Delineamento dos experimentos

Foram definidos nove fatores experimentais conforme *Quadro 5.3* na página 58, podendo cada um dos fatores assumir dois níveis. Considerando o delineamento fatorial completo seriam necessários $2^9 = 512$ experimentos. Para reduzir a quantidade de experimentos a um nível aceitável, é utilizado um delineamento fatorial fracionado.

O *Quadro 5.4* apresenta cinco planejamentos fatoriais para nove fatores e suas resoluções. Como o objetivo da análise neste caso é identificar a sensibilidade do modelo aos

fatores optou-se por um delineamento de resolução IV onde não há associação entre os fatores principais nem entre esses fatores e as interações de segunda ordem.

Fração	Resolução	Planejamento	Execuções
1/2	V	$2^{(9-1)}$	256
1/4	V	$2^{(9-2)}$	128
1/8	IV	$2^{(9-3)}$	64
1/16	IV	$2^{(9-4)}$	32
1/32	III	$2^{(9-5)}$	16

Quadro 5.4 – Planejamentos fatoriais fracionados para nove fatores.

Entre os planejamentos de resolução IV apresentado no **Quadro 5.4**, optou-se pelo planejamento fatorial fracionado $2^{(9-4)}_{IV}$. Este planejamento, além de possuir menor número de execuções que o planejamento $2^{(9-3)}$, permite a redução para planejamentos fatoriais completos com cinco ou menos fatores sem a necessidade de novos experimentos, ou seja, poder-se-ia utilizar os resultados deste planejamento, por exemplo, em um planejamento fatorial completo com cinco ou menos fatores sem a necessidade de realizar experimentos adicionais. Como estudos preliminares identificaram cinco variáveis críticas (Op070, Op080, Op082, Op110 e Op120) entre as nove variáveis do modelo, este planejamento permitiria realizar uma análise detalhada desses cinco fatores.

O **Quadro 5.5** apresenta a distribuição das variáveis entre os fatores. Os geradores do planejamento são $F = \pm BCDE$; $G = \pm ACDE$; $H = \pm ABDE$ e $J = \pm ABCE$ (MONTGOMERY E RUNGER, 2003). As cinco variáveis críticas foram atribuídas aos fatores sem associação.

Fatores experimentais	Variáveis do modelo	Nível Baixo (-)	Nível Alto (+)
A	Op070	1	2
B	Op080	1	2
C	Op082	1	2
D	Op110	1	2
E	Op120	1	2
F	Op050	1	2
G	Op052	1	2
H	Op100	1	2
J	Op170	1	2

Quadro 5.5 – Distribuição das variáveis entre os fatores.

O **Quadro 5.6** apresenta a matriz do planejamento dos experimentos para a fração principal. As relações de definição são $I = BCDEF = ACDEG = ABDEH = ABCEJ = ABFG = ACFH = ADFJ = BCGH = BDGJ = CDHJ = DEFGH = CEFGJ = BEFHJ = AEFHJ = AEGHJ = ABCDFGHJ$ (MONTGOMERY, 2001).

Execução	A	B	C	D	E	F	G	H	J
1	-	-	-	-	-	-	-	-	-
2	+	-	-	-	-	+	+	+	+
3	-	+	-	-	-	-	-	+	+
4	+	+	-	-	-	+	+	-	-
5	-	-	+	-	-	+	+	-	-
6	+	-	+	-	-	-	-	+	+
7	-	+	+	-	-	+	+	+	+
8	+	+	+	-	-	-	-	-	-
9	-	-	-	+	-	-	+	+	-
10	+	-	-	+	-	+	-	-	+
11	-	+	-	+	-	-	+	-	+
12	+	+	-	+	-	+	-	+	-
13	-	-	+	+	-	+	-	+	-
14	+	-	+	+	-	-	+	-	+
15	-	+	+	+	-	+	-	-	+
16	+	+	+	+	-	-	+	+	-
17	-	-	-	-	+	+	-	-	+
18	+	-	-	-	+	-	+	+	-
19	-	+	-	-	+	+	-	+	-
20	+	+	-	-	+	-	+	-	+
21	-	-	+	-	+	-	+	-	+
22	+	-	+	-	+	+	-	+	-
23	-	+	+	-	+	-	+	+	-
24	+	+	+	-	+	+	-	-	+
25	-	-	-	+	+	+	+	+	+
26	+	-	-	+	+	-	-	-	-
27	-	+	-	+	+	+	+	-	-
28	+	+	-	+	+	-	-	+	+
29	-	-	+	+	+	-	-	+	+
30	+	-	+	+	+	+	+	-	-
31	-	+	+	+	+	-	-	-	-
32	+	+	+	+	+	+	+	+	+

Quadro 5.6 – Matriz do planejamento fatorial fracionado $2_{IV}^{(9-4)}$.

Os parâmetros de simulação foram definidos conforme **Quadro 5.7**.

Parâmetro	Valor
Sistema de tempo	Semanal
Tempo de execução	Início: Semana 1, segunda-feira, 07h00min Término: Semana 4, sábado, 02h30min
Tempo de aquecimento	Um dia
Tamanho da amostra	32
Número de replicações	1

Quadro 5.7 – Parâmetros da simulação.

5.3.8 - Resultados dos experimentos

A *Tabela 5.4* apresenta os resultados dos experimentos planejados. Analisando os efeitos principais de cada fator, *Gráfico 5.1*, observa-se que os fatores B = Op080, C = Op082 e E = Op120 apresentam forte efeito positivo sobre a produção, ou seja, alterando-os do nível baixo (-) para o nível alto (+) aumenta-se o resultado. Os outros fatores têm efeito negativo, ou seja, alterando-os do nível baixo (-) para o nível alto (+) diminui-se o resultado.

Execução	A	B	C	D	E	F=BCDE	G=ACDE	H=ABDE	J=ABCE	Resultado [R\$]
1	-	-	-	-	-	+	+	+	+	280036
2	+	-	-	-	-	+	-	-	-	299418
3	-	+	-	-	-	-	+	-	-	299518
4	+	+	-	-	-	-	-	+	+	280236
5	-	-	+	-	-	-	-	+	-	314818
6	+	-	+	-	-	-	+	-	+	295436
7	-	+	+	-	-	+	-	-	+	315036
8	+	+	+	-	-	+	+	+	-	295654
9	-	-	-	+	-	-	-	-	+	299418
10	+	-	-	+	-	-	+	+	-	280036
11	-	+	-	+	-	+	-	+	-	280136
12	+	+	-	+	-	+	+	-	+	260854
13	-	-	+	+	-	+	+	-	-	295436
14	+	-	+	+	-	+	-	+	+	276054
15	-	+	+	+	-	-	+	+	+	295654
16	+	+	+	+	-	-	-	-	-	315036
17	-	-	-	-	+	-	-	-	-	309109
18	+	-	-	-	+	-	+	+	+	270345
19	-	+	-	-	+	+	-	+	+	270545
20	+	+	-	-	+	+	+	-	-	270445
21	-	-	+	-	+	+	+	-	+	285845
22	+	-	+	-	+	+	-	+	-	285745
23	-	+	+	-	+	-	+	+	-	391945
24	+	+	+	-	+	-	-	-	+	391945
25	-	-	-	+	+	+	+	+	-	270345
26	+	-	-	+	+	+	-	-	+	270345
27	-	+	-	+	+	-	+	-	+	270545
28	+	+	-	+	+	-	-	+	-	270445
29	-	-	+	+	+	-	-	+	+	285945
30	+	-	+	+	+	-	+	-	-	285845
31	-	+	+	+	+	+	-	-	-	398545
32	+	+	+	+	+	+	+	+	+	359781

Tabela 5.4 – Resultados dos experimentos do planejamento $2_{IV}^{(9-4)}$.




Gráfico 5.1 – Efeitos principais para Resultado.

O **Gráfico 5.1** fornece indícios de quais fatores são significativos, contudo, para obter resultados conclusivos é necessário verificar as interações entre os fatores. As interações de 2ª ordem estão apresentadas no **Gráfico 5.2**. Neste gráfico é possível constatar a ocorrência de interações entre diversos fatores. As interações BC = Op080*Op082, BE = Op080*Op120, CE = Op082*Op120 conduzem a resultados melhores enquanto as interações DF = Op110*Op050, GH = Op052*Op100, AJ = Op070*Op170 conduzem a resultados piores.




Gráfico 5.2 – Interação de 2ª ordem entre os fatores.

Observando as interações DF, GH e AJ está claro que os fatores A, D, F, G, H e J devem ser mantidas no nível baixo e os fatores B, C e E devem ser alterados para o nível alto. Contudo, será esta a melhor solução? Esta questão é tratada a seguir, onde se realizarão otimizações do modelo para comparar os resultados obtidos e o efeito da redução do espaço de busca.

5.4 - Otimização da aplicação 1

Através da análise de sensibilidade identificaram-se três variáveis como sendo positivamente significativas. Considerando apenas esses resultados poder-se-ia supor que aumentar a quantidade de equipamentos das respectivas operações seria a melhor solução, contudo não há como garantir esta afirmação baseando-se apenas no resultado da análise de sensibilidade.

Uma forma de confirmar esses resultados é através da otimização. Assim, empregar-se-á a otimização como um meio de avaliar a eficiência dos planejamentos fatoriais fracionados na realização da análise de sensibilidade.

O procedimento adotado é otimizar esta aplicação de duas formas distintas: a primeira é utilizando apenas os fatores selecionados nas análises de sensibilidade. Ao fim, os resultados das otimizações são comparados de modo a verificar se as técnicas de planejamento de experimentos trouxeram vantagens para o processo de otimização.

A seguir são apresentados os resultados das otimizações da aplicação 1. Primeiramente utilizando os fatores selecionados e em seguida utilizando todos os fatores de entrada. Os parâmetros da otimização foram: perfil moderado e percentual de convergência igual a 0,01.

O número de replicações é 1, pois o modelo da aplicação 1 é determinístico. O intervalo de confiança não foi especificado. A função objetivo é dada pelo indicador de desempenho “Resultado”.

5.4.1 - Otimização com fatores selecionados

A análise de sensibilidade da aplicação 1 identificou três fatores com efeito significativamente positivo os quais são usados como entrada para a otimização, **Quadro 5.8**. As outras variáveis do modelo foram mantidas com seus valores originais.

Fatores	Variáveis	Faixa de valores
B	Op080	1 – 2
C	Op082	1 – 2
E	Op120	1 – 2

Quadro 5.8 – Fatores mais significativos da aplicação 1.

O Simrunner convergiu após 8 experimentos. O melhor resultado foi 411.327 obtido no experimento seis, *Gráfico 5.3*. Os valores dos fatores são mostrados no *Quadro 5.9*.




Gráfico 5.3 – Desempenho da otimização da aplicação 1 com fatores selecionados.

Fatores	Variáveis	Valor
B	Op080	2
C	Op082	2
E	Op120	2

Quadro 5.9 – Melhor solução da aplicação 1 com fatores selecionados.

5.4.2 - Otimização com todos os fatores

Utilizando-se todos os fatores, nesse caso nove, *Quadro 5.10*, o Simrunner convergiu com 98 experimentos. O melhor resultado foi 411.327 obtido no experimento 55, *Gráfico 5.4*. Os valores dos fatores são mostrados no *Quadro 5.11*.

Fatores	Variáveis	Faixa de valores
A	Op070	1 – 2
B	Op080	1 – 2
C	Op082	1 – 2
D	Op110	1 – 2
E	Op120	1 – 2
F	Op050	1 – 2
G	Op052	1 – 2
H	Op100	1 – 2
J	Op170	1 – 2

Quadro 5.10 – Fatores de entrada da otimização com todos os fatores da aplicação 1.




Gráfico 5.4 - Desempenho da otimização da aplicação 1 com todos os fatores.

Fatores	Variáveis	Valor
A	Op070	1
B	Op080	2
C	Op082	2
D	Op110	1
E	Op120	2
F	Op050	1
G	Op052	1
H	Op100	1
J	Op170	1

Quadro 5.11 – Melhor solução da aplicação 1 com todos os fatores.

5.4.3 - Comparação dos resultados

A *Tabela 5.5* apresenta os resultados obtidos pelos três procedimentos na aplicação 1. Observa-se que os três procedimentos conduziram aos mesmos resultados indicando coerência entre eles. Considerando o número de execuções necessárias para otimizar o modelo, é clara a vantagem de determinar previamente os parâmetros principais, e realizar a

otimização usando-os como fatores de entrada, em relação a realizar a otimização usando todos os fatores.

Parâmetros	Planejamento fatorial	Otimização com fatores selecionados	Otimização com todos os fatores
Op050	1	1 (*)	1
Op052	1	1 (*)	1
Op070	1	1 (*)	1
Op080	2	2	2
Op082	2	2	2
Op100	1	1 (*)	1
Op110	1	1 (*)	1
Op120	2	2	2
Op170	1	1 (*)	1
Resultado	411327	411327	411327
Número de execuções	32	8	98

Tabela 5.5 – Resultados obtidos na aplicação 1.

Para fazer a análise de sensibilidade, o planejamento experimental utilizou 32 execuções, somando com as execuções da otimização, oito execuções, tem-se um total de 40 execuções. A otimização sem seleção dos fatores convergiu com 98 execuções. Comparando os resultados verifica-se que o planejamento trouxe uma redução de 59% no número de execuções.

Comparando-se apenas as execuções do planejamento fatorial (32 execuções) com as execuções da otimização sem seleção dos fatores (98 execuções) observa-se uma redução maior ainda, alcançando aproximadamente 67%. Este resultado mostra uma possibilidade de utilizar os planejamentos experimentais para otimização. Esta possibilidade não foi explorada aqui por não ser este o objetivo deste trabalho, contudo diversos autores (MONTGOMERY, 2001; KLEIJNEN, 1998; LAW E KELTON, 2000; BANKS *et al.*, 2005) apresentam técnicas de otimização utilizando-se planejamentos experimentais.

5.5 - Considerações finais

Neste capítulo foi apresentada a primeira aplicação desenvolvida para verificar o emprego de planejamentos fatoriais. Foram apresentadas desde as etapas preparatórias do projeto de simulação até a obtenção dos resultados dos experimentos. Em seguida, estes resultados foram analisados, e confrontados com os resultados das otimizações do modelo. A

análise dos resultados mostrou uma redução de até 67% no número de execuções ao utilizar o planejamento fatorial neste modelo determinístico. No próximo capítulo, trabalhar-se-á uma aplicação estocástica para verificar-se o efeito do uso de planejamentos fatoriais.

CAPÍTULO 6 - SEGUNDA APLICAÇÃO

6.1 - Considerações iniciais

Este capítulo apresenta o segundo projeto de simulação desenvolvido na divisão de produção da Fábrica de Itajubá da Indústria de Material Bélico do Brasil – IMBEL. Novamente, a técnica de planejamento de experimento aplicada foi o planejamento fatorial fracionado, contudo o modelo utilizado foi estocástico.

6.2 - Desenvolvimento da Aplicação 2

6.2.1 - Formulação do problema

Nesta aplicação, deseja-se selecionar a melhor configuração de máquinas e distribuição da mão de obra entre os turnos considerando-se que há disponibilidade de três máquinas extras para emprego em três operações críticas e não há restrições quanto ao aumento de mão de obra, de forma a aumentar a produção da célula.

6.2.2 - Definição dos objetivos e plano geral do projeto

Pela formulação do problema torna-se claro que os objetivos do projeto são selecionar a configuração ótima dos equipamentos das três operações críticas e estabelecer as operações a serem executadas em turnos adicionais.

Da mesma forma que na aplicação 1, realizar-se-á uma análise de sensibilidade para alcançar esses objetivos. O indicador de desempenho é a produção de peças produzidas no período simulado.

Novamente o escopo do trabalho está limitado ao Grupo 1 da linha da armação da pistola. E apenas um modelo de armação foi modelado pelas mesmas considerações da aplicação 1.

6.2.3 - Coleta e análise dos dados

Durante a etapa de coleta e análise dos dados foram obtidas informações a respeito da composição do Grupo 1 (loais), da quantidade de funcionários atualmente disponíveis (recursos), as atividades e respectivas durações, os horários de expedientes, a seqüência de operações das peças e a programação típica da célula. Estas informações estão resumidas na *Quadro 6.1*.

Locais	10 máquinas
Recursos	14 funcionários distribuídos entre os dois turnos
Atividades	55 atividades
Controles	Horários de expediente Seqüência de operações das peças Programação

Quadro 6.1 – Resumo dos elementos do sistema.

a) Descrição da célula

Nesta aplicação, o grupo 1 é composto por sete centros de usinagem CNC, uma fresadora CNC de cabeçote duplo, uma furadeira para furação profunda e uma fresadora convencional automática. Cada máquina executa uma operação específica e todas as máquinas são automáticas. A **Figura 6.1** apresenta a seqüência das operações do grupo 1, a descrição da máquina utilizada e a quantidade de peças processadas por ciclo.

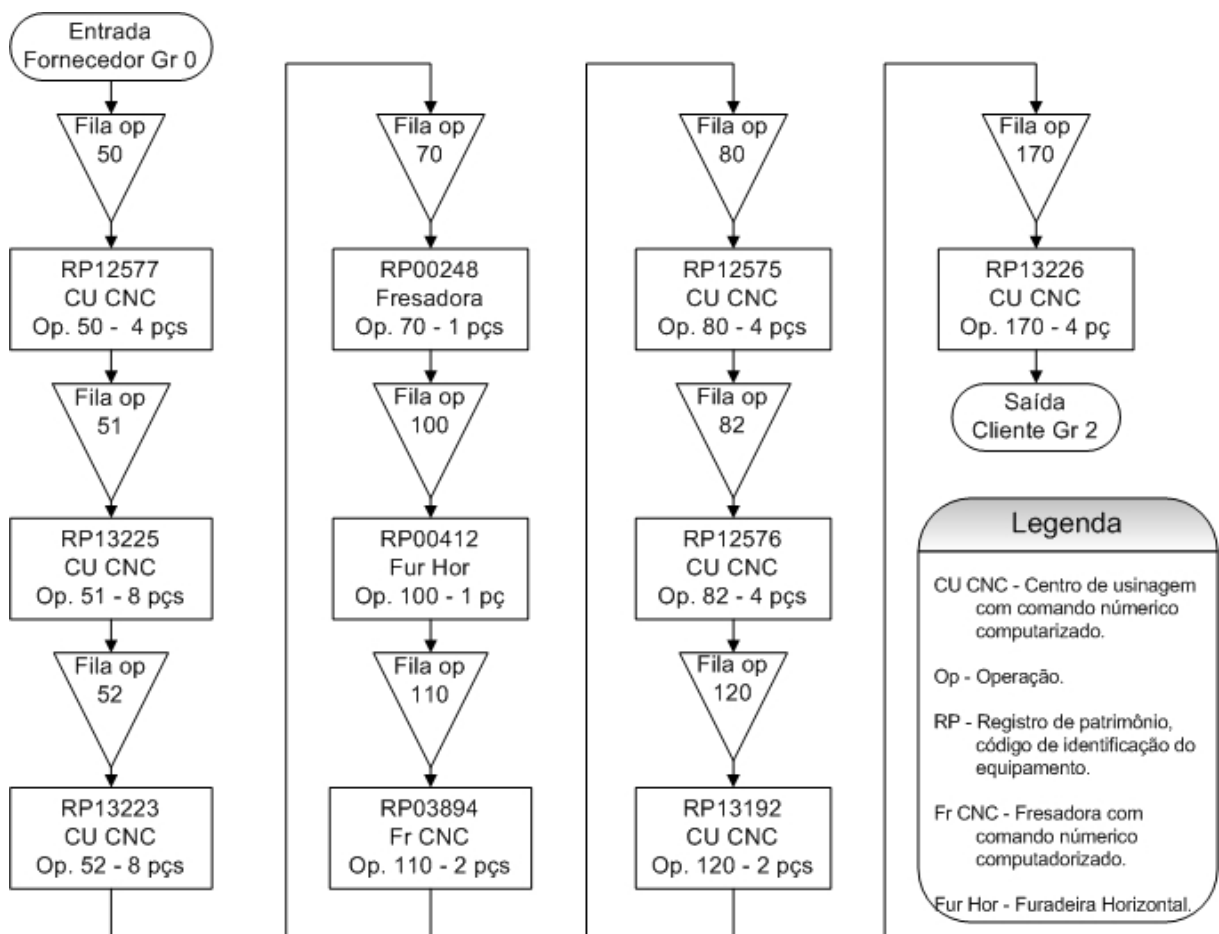


Figura 6.1 – Fluxograma do processo no grupo 1 para a aplicação 2.

Para cada máquina há um operador dedicado para a execução da operação. O operador é responsável pela colocação e retirada das peças, pelo controle da operação, iniciando o ciclo

de usinagem e interrompendo-o se necessário e pela inspeção das peças. Uma característica deste grupo é que muitas operações possuem ciclos longos e processam várias peças simultaneamente, devido a isso, os operadores ficam ociosos parte do tempo do ciclo.

As peças seguem de operação em operação e para cada operação há uma fila de peças aguardando para serem usinadas. Todas as operações desse grupo são executadas em todos os modelos de armação. O transporte das peças entre as operações ocorre de forma irregular. Usualmente, o operador da operação posterior pega as peças usinadas na bancada da operação anterior. A quantidade de peças transportada depende da capacidade do operador, sendo comum o transporte de quatro ou cinco peças por vez.

b) Procedimento da medição da duração das operações

Após a identificação do fluxo das peças, **Figura 6.1**, estudou-se detalhadamente cada etapa com o objetivo de identificar as atividades realizadas e estruturar o processo de medição dos tempos de execução delas. Desse estudo, foi observado que algumas operações apresentavam seqüências similares entre si de execução das atividades. O **Quadro 6.2** apresenta as quatro seqüências de execução das atividades e as operações correspondentes.

Seqüência	Atividades	Operações
1	1 Fixar peças no dispositivo 2 Usinar 3 Retirar peças e limpar dispositivo	50, 80, 82 e 170
2	1 Fixar 4 peças 2 Usinar 3 Retirar as 4 peças prontas 4 Limpar dispositivo e trocar a posição das 4 peças remanescentes	51 e 52
3	1 Fixar peças no dispositivo 2 Usinar 3 Retirar peças do dispositivo	70, 100 e 120
4	1 Fixar peças no dispositivo 2 Usinar primeira parte 3 Trocar a posição das peças 4 Usinar segunda parte 5 Retirar peças do dispositivo	110

Quadro 6.2 – Seqüência de execução das atividades das operações.

c) Procedimento de análise dos dados

Para a execução da análise dos dados foi usado o programa Minitab *release* 14.1 produzido pelo Minitab Inc. O procedimento seguido para análise dos tempos coletados nesta aplicação foi obter as estatísticas básicas: média, desvio padrão e coeficiente de variação e

identificar *outliers* através do Diagrama da Caixa (*Boxplot*). Havendo *outliers*, os mesmos eram retirados e o diagrama da caixa refeito. Este procedimento seria repetido até que não ocorressem novos *outliers*.

Após a remoção dos *outliers*, seguiu-se a identificação de uma distribuição de probabilidade para os tempos das atividades. Apenas as distribuições de probabilidade normal, lognormal, exponencial e Weibull foram consideradas por serem comuns tanto ao Minitab quanto ao ProModel.

Esse procedimento é ilustrado a seguir para a operação 52 executada na máquina RP13223. Após a coleta dos dados, determinam-se as estatísticas básicas, **Tabela 6.1**, utilizando-se o gráfico *boxplot* verifica-se a ocorrência de *outliers*, **Gráfico 6.1**. Ocorrendo *outliers*, os mesmos são retirados e um novo *boxplot* é traçado, **Gráfico 6.2**. Na **Tabela 6.1**, o *outlier* é identificado pelo (*).

Medições	Tempo (minutos)			
	Fixação	Usinagem	Remoção	Troca
1	0,899	6,033	0,438	0,473
2	0,780	6,033	0,448	0,446
3	0,866	6,037	0,556 (*)	0,270
4	0,833	6,036	0,457	0,346
5	0,839	6,039	0,417	0,349
6	0,806	6,040	0,415	0,369
7	0,955	6,032	0,397	0,367
8	0,828	6,017	0,478	0,456
9	0,778	6,017	0,402	0,368
10	0,799	6,018	0,393	0,294
Média	0,8383	6,0302	0,4272	0,3788
Desvio padrão	0,0556	0,0093	0,0296	0,0670
Coefficiente de variação	6,63	0,15	6,92	17,93

Tabela 6.1 – Tempos coletados da operação 52.

Após a remoção dos *outliers*, faz-se a identificação da distribuição de probabilidade dos dados. Para isso, geraram-se os gráficos de distribuição de probabilidade normal, lognormal, exponencial e Weibull para cada uma das atividades da operação: fixação (**Gráfico 6.3**), usinagem (**Gráfico 6.4**), remoção (**Gráfico 6.5**) e troca (**Gráfico 6.6**).




Gráfico 6.1 – *Boxplot* dos tempos da operação 52.

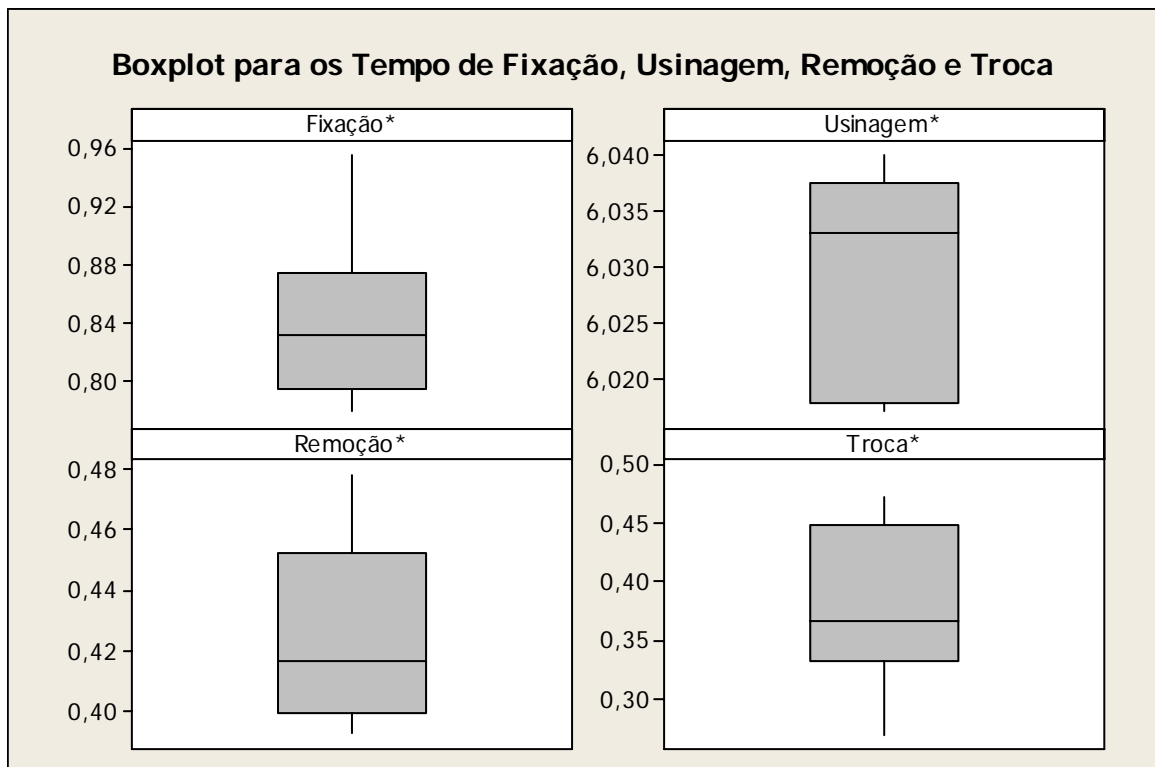


Gráfico 6.2 – *Boxplot* dos tempos da operação 52 sem outliers.

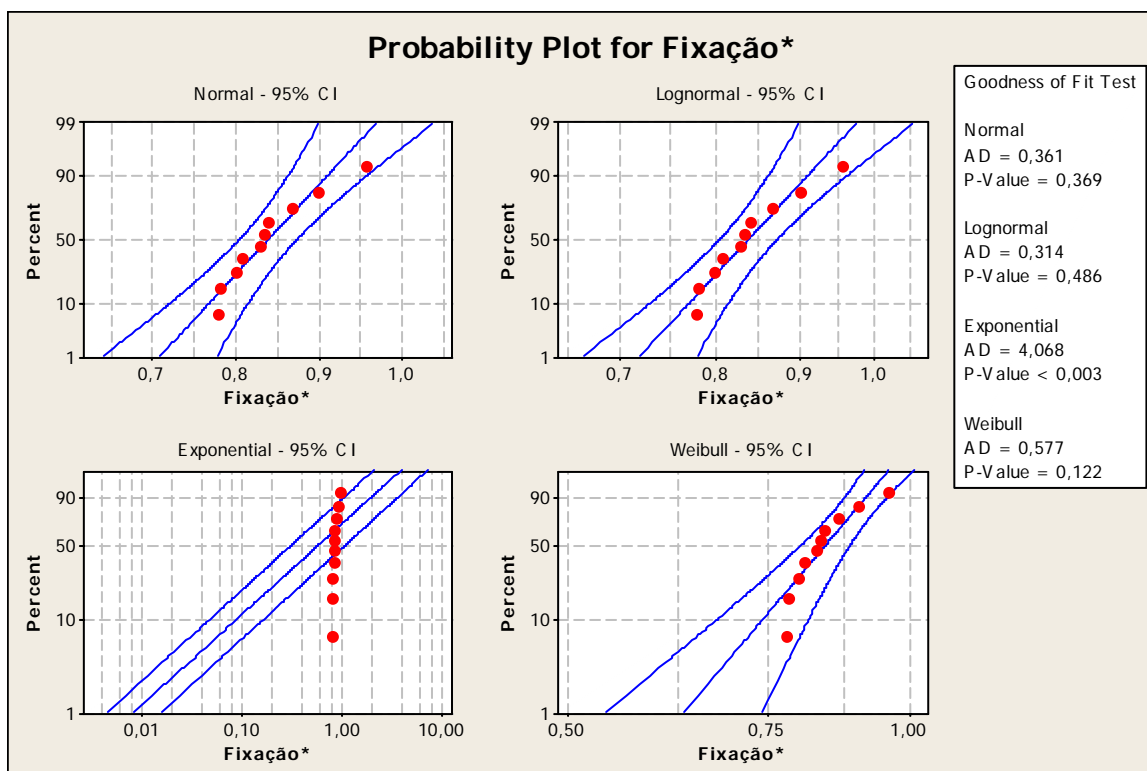


Gráfico 6.3 – Gráfico de probabilidade para tempo de fixação da operação 52.

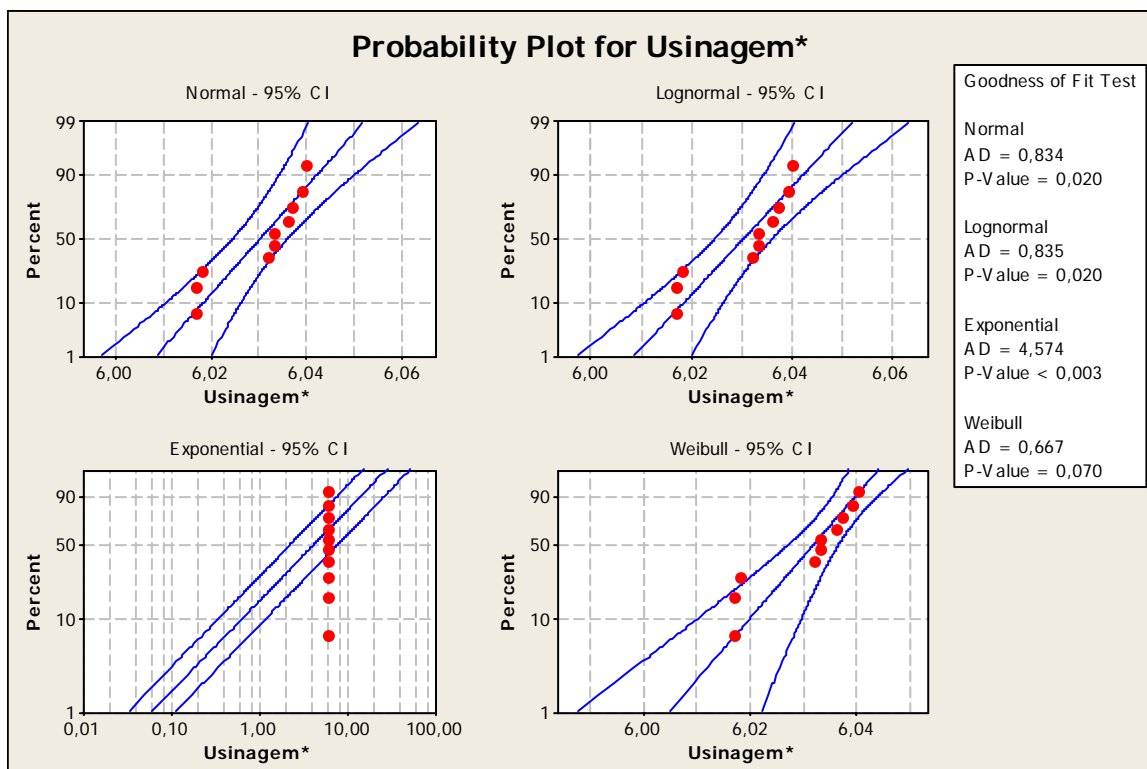


Gráfico 6.4 – Gráfico de probabilidade para tempo de usinagem da operação 52.




Gráfico 6.5 – Gráfico de probabilidade para tempo de remoção da operação 52.




Gráfico 6.6 – Gráfico de probabilidade para tempo de troca da operação 52.

As tabelas e gráficos dos dados coletados de todas as operações da aplicação 2 estão no Anexo A.

6.2.4 - Modelo conceitual

As simplificações adotadas na aplicação 1 foram adotadas nesta aplicação pelos mesmos motivos apresentados anteriormente.

a) Fatores de entrada

Como apenas um modelo de armação foi modelado, criou-se uma entidade denominada “armação”, que representa todos os modelos da armação. Estas peças entram no sistema diariamente às 07h00min, com quantidade de 350 unidades.

Dois horários de trabalho foram definidos representando o 1º e o 2º turno. O 1º horário começa às 07h00min e encerra-se às 17h00min, com intervalo de uma hora às 11h30min. O 2º horário começa às 07h00min e termina às 02h30min com dois intervalos de uma hora às 11h30min e 20h30min. A **Tabela 6.2** apresenta o detalhamento do processo onde estão indicadas as atividades e a suas respectivas durações. O tempo é dado através de uma distribuição de probabilidade onde $L(x; y)$ significa uma distribuição lognormal com média x e desvio padrão y e $W(x; y)$ uma distribuição Weibull com média x e desvio padrão y .

Tempo(min)	○	⇨	□	D	▽	Descrição da Etapa
		X				50 peças são movimentadas da entrada para fila da op. 50
				X		Aguardando na fila para execução da op. 50
L(0,55;0,086)	X					4 peças são fixadas no dispositivo da op. 50 na RP12577
W(222,75;5,52)	X					4 peças são usinadas na RP12577
L(0,37;0,042)	X					4 peças são retiradas do dispositivo da op. 50 na RP12577
		X				Peças são movimentadas da RP12577 para fila da op. 51
				X		Aguardando na fila para execução da op. 51
L(0,59;0,021)	X					4 peças são fixadas no dispositivo da op. 51 na RP13225
L(7,74;0,046)	X					8 peças são usinadas na RP13225
L(0,39;0,030)	X					4 peças prontas são retiradas do dispositivo da op. 51 na RP13225
L(0,29;0,017)	X					Dispositivo é limpo e as 4 peças remanescentes são trocadas de posição
		X				Peças são movimentadas da RP13225 para fila da op. 52
				X		Aguardando na fila para execução da op. 52
L(0,84;0,056)	X					4 peças são fixadas no dispositivo da op. 52 na RP13223
*W(942,71;6,03)	X					8 peças são usinadas na RP13223
L(0,43;0,030)	X					4 peças prontas são retiradas do dispositivo da op. 52 na RP13223
L(0,37;0,067)	X					Dispositivo é limpo e as 4 peças remanescentes são trocadas de posição
		X				Peças são movimentadas da RP13223 para fila da op. 70
				X		Aguardando na fila para execução da op. 70
L(0,21;0,073)	X					1 peça é fixada no dispositivo da op. 70 na RP00248
L(1,31;0,008)	X					1 peça é usinada na RP00248
W(6,09;0,21)	X					1 peça é retirada do dispositivo da op. 70 na RP00248

Tabela 6.2 – Detalhamento do processo da aplicação 2.

Tempo(min)	○	⇒	□	D	▽	Descrição da Etapa
		X				Peças são movimentadas da RP00248 para fila da op. 100
				X		Aguardando na fila para execução da op. 100
L(0,38;0,052)	X					1 peça é fixada no dispositivo da op. 100 na RP00412
L(1,88;0,005)	X					1 peça é usinada na RP00412
L(0,20;0,027)	X					1 peça é retirada do dispositivo da op. 100 na RP00412
		X				Peças são movimentadas da RP00412 para fila da op. 110
				X		Aguardando na fila para execução da op. 110
L(0,29;0,016)	X					2 peças são movimentadas da fila da op. 110 para RP03894
L(2,32;0,011)	X					As peças são parcialmente furadas na RP03894
L(0,62;0,037)	X					A posição das peças é trocada na RP03894
L(2,32;0,011)	X					A furação das peças é completada na RP03894
L(0,29;0,023)	X					2 peças são retiradas do dispositivo da op. 110 na RP03894
		X				Peças são movimentadas da RP03894 para fila da op. 80
				X		Aguardando na fila para execução da op. 80
L(1,05;0,066)	X					4 peças são fixadas no dispositivo da op. 80 na RP12575
L(5,52;0,007)	X					4 peças são usinadas na RP12575
L(0,63;0,041)	X					4 peças são retiradas do dispositivo da op. 80 na RP12575
		X				Peças são movimentadas da RP12575 para fila da op. 82
				X		Aguardando na fila para execução da op. 82
L(1,05;0,066)	X					4 peças são fixadas no dispositivo da op. 82 na RP12576
L(5,52;0,007)	X					4 peças são usinadas na RP12576
L(0,63;0,041)	X					4 peças são retiradas do dispositivo da op. 82 na RP12576
		X				Peças são movimentadas da RP12576 para fila da op. 120
				X		Aguardando na fila para execução da op. 120
L(0,33;0,067)	X					2 peças são fixadas no dispositivo da op. 120 na RP13192
W(1748,22;7,27)	X					2 peças são usinadas na RP13192
L(0,35;0,062)	X					2 peças são retiradas do dispositivo da op. 120 na RP13192
		X				Peças são movimentadas da RP13192 para fila da op. 170
				X		Aguardando na fila para execução da op. 170
L(1,22;0,252)	X					4 peças são fixadas no dispositivo da op. 170 na RP13226
L(5,74;0,079)	X					4 peças são usinadas na RP13226
L(1,04;0,201)	X					4 peças são retiradas do dispositivo da op. 170 na RP13226
		X				Peças são movimentadas da RP13226 para saída do sistema

Tabela 6.3 – Detalhamento do processo da aplicação 2 (cont.).

No **Quadro 6.3** estão resumidas as informações obtidas durante o mapeamento do processo.

Número de operações	34
Número de transportes	11
Número de esperas	10
Total	55

Quadro 6.3 – Resumo do processo da aplicação 2.

b) Fatores experimentais

Conforme a formulação do problema, duas opções de solução foram consideradas: a duplicação das máquinas e a execução das operações em dois turnos.

O número de fatores experimentais totalizou 12 fatores, sendo 3 fatores decorrentes da duplicação das máquinas das operações 100, 110 e 120 e, 9 fatores devido às opções de funcionamento em dois turnos. O **Quadro 6.4** apresenta os fatores experimentais e os valores que eles podem assumir.

Fatores experimentais	Descrição	Níveis	Valores
NEq_Op100 NEq_Op110 NEq_Op120	Indicam a utilização de uma ou duas máquina para a realização das respectivas operações	2	Nível baixo = 1 (uma máquina) Nível alto = 2 (duas máquinas)
T_Operador1 T_Operador2 T_Operador3 T_Operador4 T_Operador5 T_Operador6 T_Operador7 T_Operador8 T_Operador9	Indicam se as respectivas operações são executadas em um ou dois turnos	2	Nível baixo = 1 (operação executada em 1 turno) Nível alto = 2 (operação executada em 2 turnos)

Quadro 6.4 – Fatores experimentais.

c) Fatores de saída

O principal fator de saída é a quantidade de peças produzidas no período simulado. Outros fatores obtidos são: a ocupação dos operadores, a formação de filas e o *lead-time*. Esses fatores foram definidos para facilitar a verificação e validação do modelo, mas não são utilizados nas etapas posteriores.

6.2.5 - Tradução do modelo

A **Figura 6.2** mostra o modelo computacional no ProModel conforme leiaute do Grupo 1. Neste modelo, os operadores estão distribuídos um para cada posto de trabalho e executam as tarefas de retirada e colocação das peças nos dispositivos de fixação e o acionamento dos equipamentos.

6.2.6 - Verificação e validação do modelo

Da mesma forma que a aplicação 1, o modelo da aplicação 2 foi verificado utilizando-se os recursos do depurador e a interface gráfica do ProModel. A interface gráfica auxiliou na verificação do fluxo das entidades e dos recursos. O depurador permitiu acompanhar a execução do modelo passo a passo e verificar os valores das variáveis. A verificação da lógica do processo foi realizada através da análise dos resultados das filas e da ociosidade dos equipamentos.

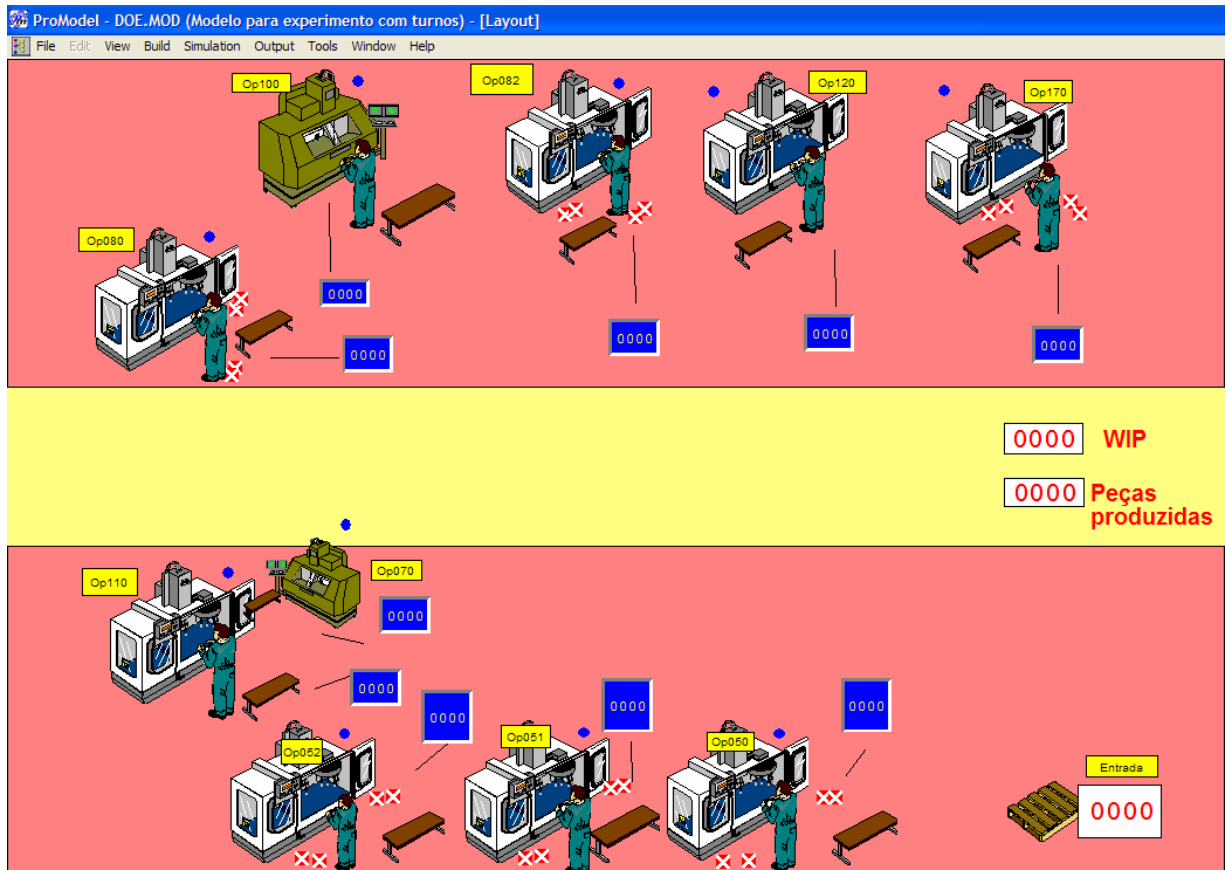


Figura 6.2 – Modelo do Grupo 1 da aplicação 2.

A validação do modelo ocorreu através da análise dos resultados da simulação de uma situação base. Os resultados obtidos foram comparados com dados históricos do Grupo 1 e a avaliação envolveu pessoas conhecedoras do processo.

6.2.7 - Delineamento dos experimentos

Foram definidos doze fatores experimentais conforme **Quadro 6.4** na página 78, podendo cada um dos fatores assumir dois níveis. Considerando o delineamento fatorial completo seriam necessários $2^{12} = 4096$ experimentos. Para reduzir a quantidade de experimentos a um nível aceitável, é utilizado um delineamento fatorial fracionado.

O **Quadro 6.5** apresenta quatro planejamentos fatoriais para doze fatores. Como o objetivo da análise neste caso é identificar a sensibilidade do modelo aos fatores optou-se por um delineamento de resolução IV onde não há associação entre os fatores principais nem entre estes fatores e as interações de segunda ordem. Entre os planejamentos de resolução IV apresentado no **Quadro 6.5**, optou-se pelo planejamento fatorial fracionado $2_{IV}^{(12-7)}$ por possuir menor número de execuções que os planejamentos $2_{IV}^{(12-6)}$ e $2_{IV}^{(12-5)}$.

Fração	Resolução	Planejamento	Execuções
1/256	III	$2^{(12-8)}$	16
1/128	IV	$2^{(12-7)}$	32
1/64	IV	$2^{(12-6)}$	64
1/32	IV	$2^{(12-5)}$	128

Quadro 6.5 – Planejamentos fatoriais fracionados para doze fatores.

O **Quadro 6.6** apresenta a distribuição das variáveis entre os fatores. Os três primeiros fatores representam a quantidade de equipamentos para executar as operações 100, 110 e 120. Os outros fatores representam o turno de trabalho dos operadores.

Fatores	Variáveis
A	NEq_Op100
B	NEq_Op110
C	NEq_Op120
D	T_Operador1
E	T_Operador2
F	T_Operador3
G	T_Operador4
H	T_Operador5
J	T_Operador6
K	T_Operador7
L	T_Operador8
M	T_Operador9

Quadro 6.6 – Distribuição das variáveis entre os fatores.

Os geradores do planejamento são $F = \pm ACE$; $G = \pm ACD$; $H = \pm ABD$; $J = \pm ABE$; $K = \pm CDE$; $L = \pm ABCDE$; $M = \pm ADE$. O **Quadro 6.7** apresenta a matriz do planejamento dos experimentos para a fração principal. O **Anexo B -Planejamento fracionado da aplicação 2** contem as relações de definição e a estrutura de associação desse planejamento.

Execução	A	B	C	D	E	F	G	H	J	K	L	M
1	-	-	-	-	-	-	-	-	-	-	-	-
2	+	-	-	-	-	+	+	+	+	-	+	+
3	-	+	-	-	-	-	-	+	+	-	+	-
4	+	+	-	-	-	+	+	-	-	-	-	+
5	-	-	+	-	-	+	+	-	-	+	+	-
6	+	-	+	-	-	-	-	+	+	+	-	+
7	-	+	+	-	-	+	+	+	+	+	-	-
8	+	+	+	-	-	-	-	-	-	+	+	+
9	-	-	-	+	-	-	+	+	-	+	+	+
10	+	-	-	+	-	+	-	-	+	+	-	-
11	-	+	-	+	-	-	+	-	+	+	-	+
12	+	+	-	+	-	+	-	+	-	+	+	-
13	-	-	+	+	-	+	-	+	-	-	-	+
14	+	-	+	+	-	-	+	-	+	-	+	-
15	-	+	+	+	-	+	-	-	+	-	+	+
16	+	+	+	+	-	-	+	+	-	-	-	-
17	-	-	-	-	+	+	-	-	+	+	+	+
18	+	-	-	-	+	-	+	+	-	+	-	-
19	-	+	-	-	+	+	-	+	-	+	-	+
20	+	+	-	-	+	-	+	-	+	+	+	-
21	-	-	+	-	+	-	+	-	+	-	-	+
22	+	-	+	-	+	+	-	+	-	-	+	-
23	-	+	+	-	+	-	+	+	-	-	+	+
24	+	+	+	-	+	+	-	-	+	-	-	-
25	-	-	-	+	+	+	+	+	+	-	-	-
26	+	-	-	+	+	-	-	-	-	-	+	+
27	-	+	-	+	+	+	+	-	-	-	+	-
28	+	+	-	+	+	-	-	+	+	-	-	+
29	-	-	+	+	+	-	-	+	+	+	+	-
30	+	-	+	+	+	+	+	-	-	+	-	+
31	-	+	+	+	+	-	-	-	-	+	-	-
32	+	+	+	+	+	+	+	+	+	+	+	+

Quadro 6.7 – Matriz do planejamento fracionado $2_{IV}^{(12-7)}$.

Os parâmetros de simulação foram definidos conforme **Quadro 6.8**

Parâmetro	Valor
Sistema de tempo	Semanal
Tempo de execução	Início: Semana 1, segunda-feira, 07h00min Término: Semana 4, sábado, 02h30min
Tempo de aquecimento	Um dia
Tamanho da amostra	32
Intervalo de confiança	95%
Número de replicações	2

Quadro 6.8 – Parâmetros da simulação.

6.2.8 - Resultados dos experimentos

A *Tabela 6.4* apresenta os resultados das replicações dos experimentos. A análise preliminar mostra a ocorrência de pouca variabilidade na produção de armação no período simulado. Apenas nove execuções, destacadas em negrito, tiveram replicações com resultados diferentes e mesmo nessas a diferença não ultrapassou seis unidades de peças produzidas.

Execução	A	B	C	D	E	F	G	H	J	K	L	M	Réplica 1	Réplica 2
1	-	-	-	-	-	-	-	-	-	-	-	-	2584	2584
2	+	-	-	-	-	+	+	+	+	-	+	+	4864	4864
3	-	+	-	-	-	-	-	+	+	-	+	-	4112	4116
4	+	+	-	-	-	+	+	-	-	-	-	+	2588	2584
5	-	-	+	-	-	+	+	-	-	+	+	-	3572	3572
6	+	-	+	-	-	-	-	+	+	+	-	+	3312	3308
7	-	+	+	-	-	+	+	+	+	+	-	-	4860	4860
8	+	+	+	-	-	-	-	-	-	+	+	+	3572	3572
9	-	-	-	+	-	-	+	+	-	+	+	+	4860	4864
10	+	-	-	+	-	+	-	-	+	+	-	-	2584	2584
11	-	+	-	+	-	-	+	-	+	+	-	+	2584	2584
12	+	+	-	+	-	+	-	+	-	+	+	-	4780	4780
13	-	-	+	+	-	+	-	+	-	-	-	+	3308	3308
14	+	-	+	+	-	-	+	-	+	-	+	-	3572	3572
15	-	+	+	+	-	+	-	-	+	-	+	+	3572	3572
16	+	+	+	+	-	-	+	+	-	-	-	-	4856	4860
17	-	-	-	-	+	+	-	-	+	+	+	+	3284	3280
18	+	-	-	-	+	-	+	+	-	+	-	-	2584	2584
19	-	+	-	-	+	+	-	+	-	+	-	+	2584	2584
20	+	+	-	-	+	-	+	-	+	+	+	-	3564	3564
21	-	-	+	-	+	-	+	-	+	-	-	+	3572	3568
22	+	-	+	-	+	+	-	+	-	-	+	-	3284	3288
23	-	+	+	-	+	-	+	+	-	-	+	+	4120	4120
24	+	+	+	-	+	+	-	-	+	-	-	-	3572	3572
25	-	-	-	+	+	+	+	+	+	-	-	-	2584	2584
26	+	-	-	+	+	-	-	-	-	-	+	+	3284	3284
27	-	+	-	+	+	+	+	-	-	-	+	-	3564	3564
28	+	+	-	+	+	-	-	+	+	-	-	+	2584	2588
29	-	-	+	+	+	-	-	+	+	+	+	-	3280	3280
30	+	-	+	+	+	+	+	-	-	+	-	+	3568	3568
31	-	+	+	+	+	-	-	-	-	+	-	-	3572	3572
32	+	+	+	+	+	+	+	+	+	+	+	+	6648	6648

Tabela 6.4 – Resultados dos experimentos da aplicação 2.

Essa pequena variação chama a atenção para a correção e validade do modelo. Contudo, através de uma observação mais detalhada dos eventos que ocorrem durante a simulação verifica-se a existência de variações onde os tempos envolvem distribuições de

probabilidade. Assim, a explicação para a pequena variação é que os maiores tempos, isto é, os tempos de usinagem, possuem os menores desvios padrão, fato confirmado pelo pequeno coeficiente de variação desses tempos. Os outros tempos, mesmo tendo grandes desvios padrões, são poucos significativos para o tempo total da operação.

Conforme visto no Capítulo 4 - Planejamento de Experimentos, a equação de regressão do modelo é determinada considerando-se a hipótese dos resultados seguirem uma distribuição normal independente e com variância constante. Através da análise dos resíduos, **Gráfico 6.7**, é possível verificar que a resposta obtida não segue uma distribuição normal e que os resíduos estão agrupados em quatro blocos praticamente simétricos.

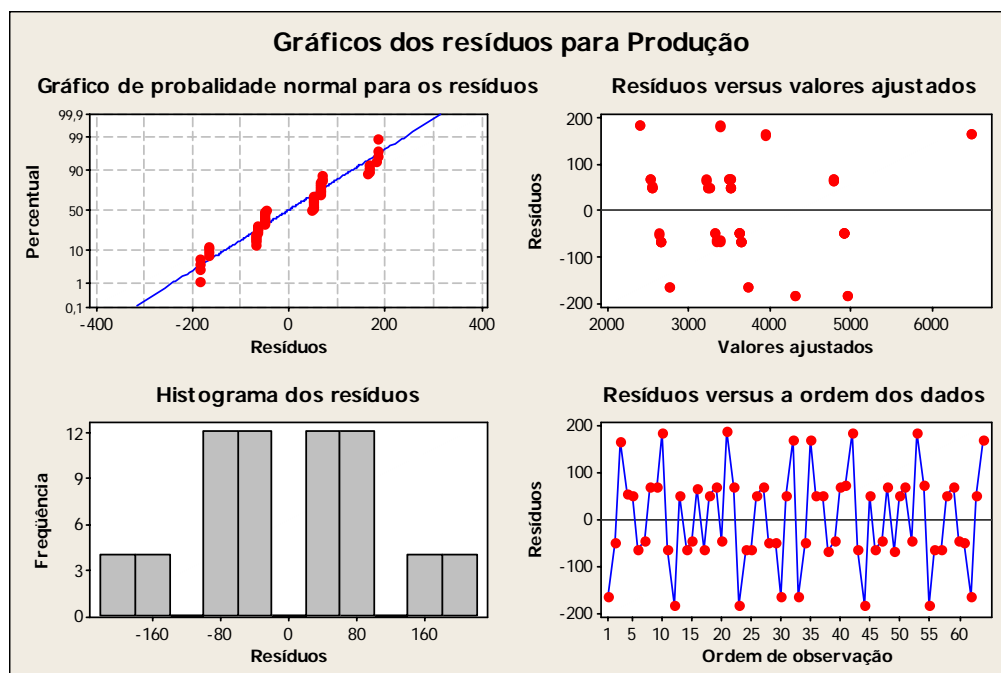


Gráfico 6.7 – Resíduos para a variável “Produção”.

A aplicação de uma transformação nos resultados não os normaliza, pois os dados continuam agrupados em blocos mesmo após a transformação. Sendo assim, não é possível tirar conclusões sobre a equação de regressão do modelo o que não invalida o estudo, pois o objetivo é a análise de sensibilidade dos fatores.

Analisando os efeitos principais de cada fator, **Gráfico 6.8**, observa-se que os fatores B=NEq_Op110, C=NEq_Op120, G=T_Operador4, H=T_Operador5 e L=T_Operador8 apresentam forte efeito positivo sobre a produção, ou seja, alterando-os do nível baixo (-) para o nível alto (+) aumenta-se o resultado. Estes fatores estão relacionados com as operações mais demoradas, ou seja, operação 120, 110 e 80, **Tabela 6.5**.

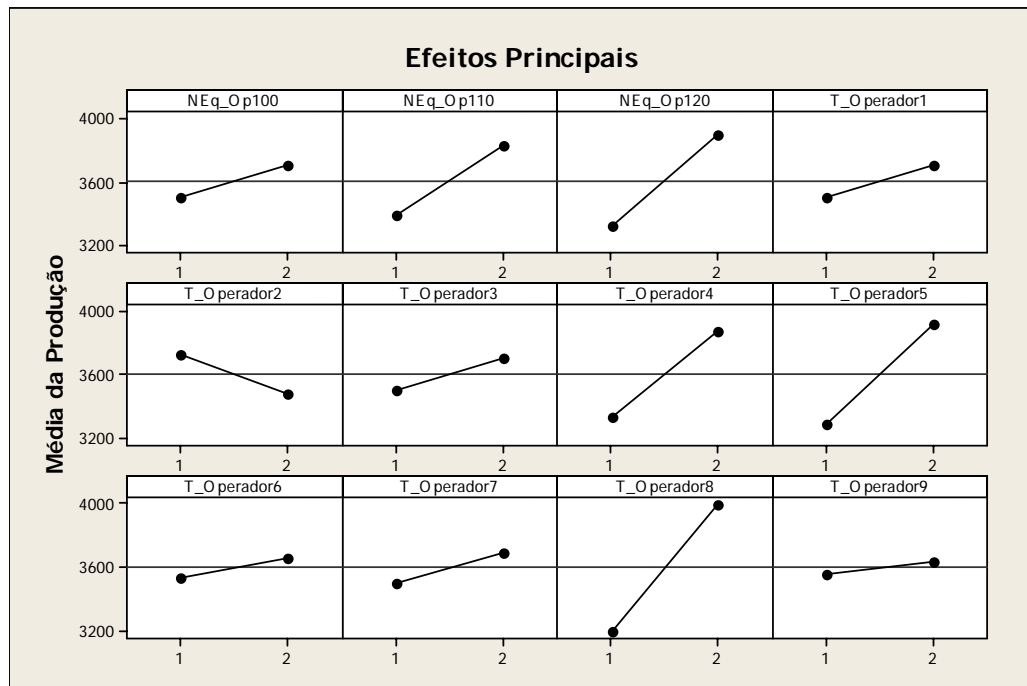


Gráfico 6.8 – Efeitos principais

Operação	Tempo total	Quantidade de peças	Tempo total por peça	Maior tempo
120	7,94	2	3,97	1
110	5,84	2	2,92	2
80	9,92	4	2,48	3
100	2,46	1	2,46	4
51	9,00	4	2,25	5
170	8,00	4	2,00	6
52	7,68	4	1,92	7
82	7,20	4	1,80	8
70	1,70	1	1,70	9
50	7,40	4	1,60	10

Tabela 6.5 – Classificação das operações mais longas.

O peso dos efeitos pode ser visualizado no **Gráfico 6.9** e no **Gráfico 6.10**. Nesses gráficos verifica-se que o fator L=T_Operador8 é mais significativo e seu efeito é positivo, seguido da interação BM= NEq_Op110*T_Operador9 cujo efeito é negativo e dos fatores H=T_Operador5, C=NEq_Op120, G=T_Operador4, da interação BC=NEq_Op110*NEq_Op120 e B=NEq_Op110 cujos efeitos são positivos. No **Gráfico 6.10** constata-se o grande afastamento dos pontos em relação à linha normal indicando que a resposta não segue uma distribuição normal.




Gráfico 6.9 – Pareto dos efeitos padronizados.




Gráfico 6.10 – Probabilidade normal dos efeitos.

Da análise do **Gráfico 6.9** e do **Gráfico 6.10** observam-se a existência de interações de 2ª ordem entre os fatores, como conseqüência, há a necessidade de analisá-las. O **Gráfico 6.11** apresenta as interações de 2ª ordem entre os fatores.

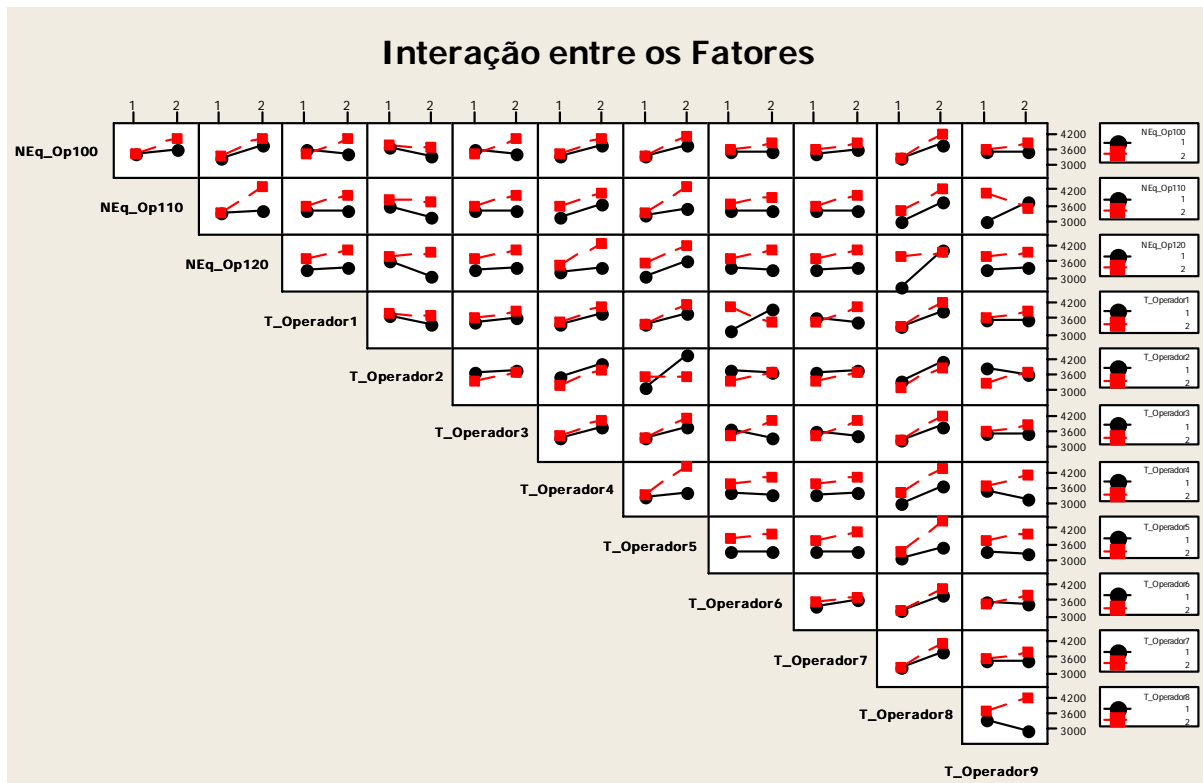


Gráfico 6.11 – Interação de 2ª ordem entre os fatores.

A análise das interações reforça a conclusão de se manter os fatores B=NEq_Op110, C=NEq_Op120, G=T_Operador4, H=T_Operador5 e L=T_Operador8 no nível alto (+), pois se observando o **Gráfico 6.11**, constata-se que os efeitos das interações BC=NEq_Op110*NEq_Op120, BG=NEq_Op110*T_Operador4, BH=NEq_Op110*T_Operador5, BL=NEq_Op110*T_Operador8, CG=NEq_Op120*T_Operador4, CH=NEq_Op120*T_Operador5, CL=NEq_Op120*T_Operador8, GH=T_Operador4*T_Operador5, GL=T_Operador4*T_Operador8 e HL= T_Operador5*T_Operador8 são positivos.

6.3 - Otimização da aplicação 2

A análise de sensibilidade da aplicação 2 identificou cinco variáveis como sendo positivamente significativas. Contudo, nessa aplicação, os efeitos das outras variáveis não ficaram claros devido às interações entre elas. A otimização, novamente, pode auxiliar na determinação da melhor configuração. Neste caso, a otimização buscará a melhor configuração dos fatores cujos efeitos não são claros e comparará o resultado com a otimização utilizando todos os fatores.

Os parâmetros da otimização foram: perfil moderado, percentual de convergência igual a 0,01 e número de replicações igual a 2. O intervalo de confiança especificado foi 95%. A função objetivo é dada pelo indicador de desempenho “Resultado”.

6.3.1 - Otimização com fatores selecionados

O *Quadro 6.9* apresenta os sete fatores utilizados na otimização da aplicação 2, estes fatores foram selecionados, pois seus efeitos não eram claros. Os cinco fatores restantes tiveram seus valores definidos durante a análise de sensibilidade.

Fatores	Variáveis	Faixa de valores
A	NEq_Op100	1 – 2
D	T_Operador1	1 – 2
E	T_Operador2	1 – 2
F	T_Operador3	1 – 2
J	T_Operador6	1 – 2
K	T_Operador7	1 – 2
M	T_Operador9	1 – 2

Quadro 6.9 – Fatores utilizados na otimização da aplicação 2.

Nesta aplicação o Simrunner convergiu após 60 experimentos. O melhor resultado obtido foi 3193 peças. Contudo, conforme *Tabela 6.6*, diversos experimentos com diferentes configurações apresentaram este resultado.

Melhores resultados	1	2	3	4	5	6	7	8	9
Experimento	1	2	3	6	7	9	10	12	15
Resultado	3193	3193	3193	3193	3193	3193	3193	3193	3193
NEq_Op100	2	2	2	2	2	2	2	2	2
T_Operador1	2	1	2	2	1	1	1	1	2
T_Operador2	1	2	2	2	1	2	2	2	2
T_Operador3	1	1	1	2	2	2	1	2	2
T_Operador6	2	1	2	2	1	1	2	1	2
T_Operador7	2	2	1	2	2	2	2	1	1
T_Operador9	1	1	2	1	2	2	2	1	2
Limite Inferior	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6
Limite Superior	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4

Tabela 6.6 – Melhores resultados da otimização da aplicação 2 com fatores selecionados.

O *Gráfico 6.12* apresenta o desempenho da otimização. Neste gráfico observa-se que os resultados obtidos alternam entre um valor máximo e um mínimo e que a diferença entre esses valores é pequena. O comportamento dos resultados da otimização, isto é, a pequena variação e a alternância entre os limites máximo e mínimo, causaram o maior número de experimentos realizados pelo fato deles não convergirem.

6.3.2 - Otimização com todos os fatores

Utilizando-se todos os fatores, o Simrunner convergiu com 57 experimentos. O melhor resultado foi 3193 peças, igual à otimização com fatores selecionados. E, da mesma forma, diversos experimentos apresentaram o mesmo resultado com diferentes configurações, **Tabela 6.7**. No **Gráfico 6.13** visualiza-se o desempenho da otimização.




Gráfico 6.12 – Desempenho da otimização da aplicação 2 com fatores selecionados.

Melhores resultados	1	2	3	4	5	6	7	8	9
Experimento	2	4	5	13	16	38	40	42	56
Resultado	3193	3193	3193	3193	3193	3193	3193	3193	3193
NEq Op100	2	2	2	2	2	2	2	2	2
NEq Op110	2	2	2	2	2	2	2	2	2
NEq Op120	2	2	2	2	2	2	2	2	2
T Operador1	2	2	2	1	1	2	2	1	1
T Operador2	2	1	2	2	2	2	1	2	1
T Operador3	2	2	1	2	1	2	2	2	2
T Operador4	2	2	2	2	2	1	2	2	2
T Operador5	2	2	1	2	2	1	1	2	1
T Operador6	2	2	1	1	2	1	1	2	1
T Operador7	2	2	1	2	1	1	2	1	2
T Operador8	2	1	1	2	2	1	1	2	1
T Operador9	2	1	1	2	2	2	2	1	2
Limite Inferior	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6	3167,6
Limite Superior	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4	3218,4

Tabela 6.7 – Melhores resultados da otimização da aplicação 2 com todos os fatores.




Gráfico 6.13 – Desempenho da otimização da aplicação 2 com todos os fatores.

6.3.3 - Comparação dos resultados

A *Tabela 6.8* apresenta a comparação do número de execuções da otimização da aplicação 2. Considerando o número de execuções, verifica-se que foram necessárias 92 execuções para a otimização com fatores selecionados enquanto a otimização com todos os fatores convergiu com 57 execuções. Por esses resultados observa-se que a otimização com fatores selecionados exigiu mais execuções que a otimização com todos os fatores indicando que a análise de sensibilidade não trouxe benefício para a otimização. A seguir, esses resultados são analisados para encontrar as razões desse aumento de execuções.

	Planejamento fatorial fracionado	Otimização com fatores selecionados	Otimização com todos os fatores
Número de execuções	32	60	57

Tabela 6.8 – Comparativo do número de execuções da aplicação 2.

Uma das razões é que, apesar de o modelo ser estocástico, seu comportamento em muitas situações foi similar a um modelo determinístico. Um motivo para esse comportamento é que as etapas com maior tempo de processo possuem as menores variações dos tempos por serem executadas em equipamentos automáticos, enquanto as maiores variações de tempo ocorrem nas etapas que são realizadas por operador, mas estas etapas possuem os menores tempos de execução. Nas tabelas de coleta de dados, *Anexo A*, pode-se verificar esta característica examinando o coeficiente de variação desses tempos.

Outra observação pertinente deve-se a faixa de resultados obtidos. Os resultados encontram-se claramente limitados tanto inferior quanto superiormente. Considerando que a

aplicação 2 modela uma linha de produção seriada, essa restrição indica a existência de um gargalo na linha de produção. Assim, qualquer alteração que não seja para melhorar o desempenho do gargalo não afeta o desempenho global do sistema.

Essa observação pode ser constatada na **Tabela 6.5** onde se verifica que a operação 120 possui tempo médio de execução 33% superior que a operação 110, a segunda operação mais demorada.

6.4 - Considerações finais

Comparando-se as conclusões obtidas para cada aplicação, observa-se que a análise de sensibilidade, e conseqüentemente o planejamento experimental, teve efeito diferenciado entre elas. Enquanto, o resultado foi vantajoso para a primeira aplicação, reduzindo significativamente o número de execuções, para a segunda aplicação não houve vantagem nenhuma.

Essa diferença de resultado pode ser atribuída às diferenças entre as aplicações. Entre elas, o indicador de desempenho da primeira aplicação é um valor monetário baseado em receita e custo enquanto na segunda aplicação o indicador é um valor que indica a quantidade de peças produzidas.

Assim, o primeiro indicador penaliza o aumento de equipamentos que não geram receitas compatíveis. Por outro lado, o segundo indicador não penaliza as opções que aumentam as despesas, o que pode ser entendido como uma falha da modelagem da segunda aplicação por não considerar o aspecto econômico das decisões.

CAPÍTULO 7 - CONCLUSÕES

7.1 - Considerações iniciais

A presente pesquisa propôs-se a estudar o emprego das técnicas estatísticas de planejamento fatorial fracionado na identificação das variáveis mais importantes de modelos de simulação de eventos discretos objetivando a redução do espaço de busca da fase de otimização.

Para desenvolver esse estudo foram apresentados ao longo desta pesquisa os principais conceitos de simulação, otimização e planejamento de experimentos. Em seguida, duas aplicações foram desenvolvidas para verificar como as técnicas de planejamento fatorial fracionado podem ser empregadas na análise de sensibilidade de modelos de simulação, identificando as suas vantagens e desvantagens e efeitos na otimização desses modelos.

Para a otimização, a identificação das variáveis mais significativas é importante já que permite a redução do espaço de busca, pois quanto maior o número de variáveis do espaço de busca mais demorada torna-se a fase de otimização.

A otimização das duas aplicações foi realizada de duas formas distintas. A primeira forma realizou a análise de sensibilidade das variáveis do modelo utilizando planejamentos fatoriais fracionados. Após a identificação das variáveis mais significativas, a otimização do modelo é realizada utilizando esse espaço de busca reduzido.

A segunda forma consistia na otimização pura e simples do modelo. Nesta abordagem não foi feito nenhum estudo para determinar se todas as variáveis do modelo têm o mesmo efeito no resultado final.

Através dessas aplicações verificou-se o emprego das técnicas de planejamento fatorial fracionado apontando as suas vantagens e desvantagens e efeitos na otimização das aplicações.

7.2 - Conclusões e contribuições da pesquisa

As questões propostas nessa pesquisa foram:

1. O emprego das técnicas de planejamento fatorial fracionado em modelo de simulação é possível e eficaz?
2. As técnicas de planejamento fatorial fracionado permitem a análise de sensibilidade das variáveis de um modelo de simulação?

3. A identificação das variáveis mais significativas de um modelo de simulação acelera a otimização deste modelo?

Para a primeira questão, mostrou-se no Capítulo 2 - Simulação que a simulação é uma forma de realizar experimentos. Num projeto de simulação têm-se três etapas críticas: coleta dos dados, validação e verificação do modelo, onde as técnicas estatísticas de planejamento experimental são importantes para a confiabilidade do modelo.

Assim, as técnicas de planejamento fatorial fracionado em modelos de simulações, bem como de outras formas de planejamento de experimentos, são perfeitamente aplicáveis e de fundamental importância para a obtenção de conclusões válidas sob o ponto de vista estatístico.

Para a segunda questão, mostrou-se a análise de sensibilidade realizada através de planejamentos fatoriais fracionado de duas aplicações distintas. Para a primeira aplicação a análise de sensibilidade forneceu resultados claros de quais variáveis tinham efeito positivo e quais tinham efeito negativo. Para a segunda aplicação os resultados não foram conclusivos devido às interações entre as variáveis, mas mesmo assim podem-se identificar algumas variáveis que apresentavam efeitos significativos.

Logo, as técnicas de planejamento fatorial fracionado permitem a análise de sensibilidade das variáveis dos modelos de simulação, contudo são afetadas pela complexidade do modelo, pelo número de variáveis, pelas interações entre as variáveis e pela resolução do planejamento da mesma forma que ocorre com experimentos reais.

Para a terceira questão, mostrou-se que a otimização das duas aplicações com o espaço de busca reduzido, ou seja, com os fatores selecionados, apresentaram resultados diferentes em termos da quantidade de execuções quando comparados com a otimização utilizando todos os fatores. Enquanto para a primeira aplicação a quantidade de execuções foi menor, para a segunda houve aumento em relação à otimização com todos os fatores.

Assim, sobre a questão se a identificação das variáveis mais significativas de um modelo de simulação acelera a otimização deste modelo não foi possível obter conclusões definitivas. As possíveis razões para o planejamento fatorial fracionado, utilizado na análise de sensibilidade, não ter apresentado um resultado conclusivo são:

- Tratava-se da modelagem de uma linha de fabricação onde melhorias em determinados pontos eram limitadas pelas restrições existentes na linha o que “mascara” o resultado;
- A modelagem do sistema da aplicação 2 não foi adequada para o problema proposto;

- A escolha dos fatores de entrada da aplicação 2 pode não ter sido a adequada para o problema em questão;
- A não utilização de indicador de desempenho como custo ou receita na aplicação 2 tornou inócua a melhor utilização dos seus recursos;
- O resultado não normal limitou a análise estatística dos resultados da aplicação 2.

Apesar do resultado não conclusivo sobre o efeito da redução do espaço de busca na otimização de modelos de simulação, a pesquisa trouxe como contribuição o emprego das técnicas de planejamento experimental para modelos de simulação e otimização, divulgando a sua utilização principalmente como uma ferramenta de apoio à tomada de decisão em situações do dia a dia das empresas.

Além da técnica de planejamento experimental, o mapeamento de processo e técnicas estatísticas para análise dos tempos coletados e identificação de distribuições de probabilidade também foram utilizadas na pesquisa.

7.3 - Sugestões para trabalhos futuros

Seguindo a mesma linha da presente pesquisa têm-se como sugestões para trabalhos futuros:

- Modelar a aplicação 2 incluindo os custos dos recursos e as receitas da produção;
- Incluir nos modelos as paradas para troca de ferramentas, as quebras de equipamento e o absenteísmo para verificar o efeito no desempenho da célula;
- Pesquisar o emprego de técnicas como análise de perturbação (HO E CAO, 1991) e *importance sampling* (GLYNN E IGLEHART, 1989) na análise de modelos de simulação.

Uma proposta de trabalho na linha de Pesquisa Operacional é estudar o desempenho dos AG em função da quantidade de variáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, E. L. (1989). *Introdução à pesquisa operacional*. Rio de Janeiro: LTC. p. 156-171.

ANDRADÓTTIR, S. (1998). Simulation optimization. In: BANKS, J. (Ed.) (1998). *Handbook of Simulation*. New York: John Wiley & Sons. cap. 9, p. 307-333. ISBN 0-471-13403-1.

BANKS, J. (1998). Principles of simulation. In: BANKS, J. (Ed.) (1998). *Handbook of Simulation*. New York: John Wiley & Sons. cap. 1, p. 3-30. ISBN 0-471-13403-1.

BANKS, J.; CARSON, J. S.; NELSON, B. L.; NICOL, D. M. (2005). *Discrete-event system simulation*. 4th ed. New Jersey: Prentice Hall. 608 p. ISBN 0-13-144679-7.

BERTRAND, J. W. M.; FRANSOO, J. C. (2002). Modeling and simulation. Operations management research methodologies using quantitative modeling. *International Journal of Operations & Production Management*, v. 22, n. 2, p. 241-264.

BILES, W. E. (1979). Experimental design in computer simulation. In: WINTER SIMULATION CONFERENCE, 1979, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 3-9.

_____ (1984). Experimental design in computer simulation. In: WINTER SIMULATION CONFERENCE, 1984, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 99-104.

BLANCHARD, B. S. (1991). *System engineering management*. New York: John Wiley & Sons. 416 p. ISBN 0471506761.

BRYMAN, A. (1989). Experimental research. In: _____. *Research methods and organization studies*. London: Unwin Hyman. cap. 3, p. 71-103. ISBN 0-415-08404-0

CAMPBELL, N. A.; MITCHELL, L. G.; REECE, J. B. (1999). *Biology: concepts & connections*. 3rd ed. Los Angeles: Addison Wesley Longman.

- CARRIE, A. (1988). *Simulation of manufacturing systems*. 1st ed. New York: John Wiley & Sons.
- CUNHA, A. S.; PINTO, R. L. U. F. (2001). Uma técnica para ajuste dos parâmetros de um Algoritmo Genético. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 33., 2001, Campos do Jordão. *Anais...* Campos do Jordão: SBPO. CD-ROM.
- DOLOI, H.; JAAFARI, A. (2002). Conceptual simulation model for strategic decision evaluation in project management. *Logistics Information Management*, v. 15, n. 2, p. 88-104.
- DUARTE, R. N. (2003). *Simulação computacional: Análise de uma célula de manufatura em lotes do setor de auto-peças*. 168 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá, Itajubá.
- ERSI, E. F.; HAJEBI, K. (2003). Graph matching for face recognition using genetic algorithms. In: INTERNATIONAL CONFERENCE ON VISION INTERFACE, 16., 2003, Halifax. *Proceedings...* Halifax: Institute of Electrical and Electronics Engineers.
- FOGEL, L. J. (1999). *Artificial intelligence through simulated evolution. forty years of evolutionary programming*. New York: John Wiley & Sons. 162 p. ISBN 0-471-33250-X.
- FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. (1966). *Artificial intelligence through simulated evolution*. New York: John Wiley & Sons.
- FU, M. C. (2002). Optimization for simulation: theory vs. practice. *INFORMS Journal on Computing*, v.14, n.3, p. 192-215, Summer.
- GASS, S. I.; HARRIS, C. M. (Ed.) (2000). *Encyclopedia of Operations Research and Management Science*. 2nd ed. Boston: Kluwer Academic. 968 p. ISBN 0-7923-7827-X.
- GIL, A. C. (1991). *Como elaborar projetos de pesquisa*. São Paulo: Atlas, 1991.
- GIL, A. C. (1999). *Métodos e técnicas de pesquisa social*. 5. ed. São Paulo: Atlas. 208 p. ISBN 8522422702.
- GLYNN, P. W.; IGLEHART, D. (1989). Importance Sampling for Stochastic Simulations. *Management Science*, v. 35, n. 11, p. 1367-1392, Nov.

- GOLDBARG, M. C., GOLDBARG, E. F. G., MEDEIROS NETO, F. D. (2005). Algoritmos evolucionários na determinação da configuração de custo mínimo de sistemas de co-geração de energia com base no gás natural. *Pesquisa Operacional*, v. 25, n. 2, p. 231-259, May/Aug. ISSN 0101-7438.
- GOLDBERG, D. E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Boston: Addison-Wesley Longman. 432 p. ISBN 0201157675.
- HARRELL, C.; GHOSH, B. K.; BOWDEN, R. (2000). *Simulation using Promodel*, 3rd ed. Boston: McGraw-Hill. 603 p. ISBN 0-07-234144-0.
- HO, Y. C.; CAO, X. R. (1991). *Perturbation analysis of discrete event dynamic systems*. Boston: Kluwer Academic. 464 p. ISBN 0-7923-9174-8.
- HOLLAND, J. H. (1975). *Adaptation in natural and artificial systems*. Michigan: University of Michigan.
- IZIDORO, S. C. (2001). *Determinação do número de agrupamentos em conjunto de dados multidimensionais utilizando algoritmos genéticos*. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Itajubá, Itajubá.
- JOHNSON, L. A.; MONTGOMERY, D. C. (1974). *Operations research in production planning, scheduling, and inventory control*. New York: John Wiley & Sons. 525 p. ISBN 0-471-44618-1.
- KLEIJNEN, J. P. C. (1998). 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.
- KLEIJNEN, J. P. C.; RUBINSTEIN, R. Y. (1996). Optimization and sensitivity analysis of computer simulation models by the score function method. *European Journal of Operational Research*, v. 88, p. 1-15.
- LAW, A. M.; KELTON, W. D. (2000). *Simulation modeling and analysis*. 3rd ed. New York: McGraw-Hill. 760 p. ISBN 0-07-059292-6.

- LAW, A. M.; MCCOMAS, M. G. (1998). Simulation of manufacturing systems. In: WINTER SIMULATION CONFERENCE, 1998, Piscataway, NJ. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 49-52.
- LEAL, F. (2003). *Um diagnóstico do processo de atendimento a clientes em uma agência bancária através de mapeamento do processo e simulação computacional*. 223 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá, Itajubá.
- LOPES, H. S. (1999). Algoritmos genéticos em projetos de engenharia: aplicações e perspectivas futuras. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 4., 1999, São Paulo. *Anais...* São Paulo: [s.n]. p. 64-74.
- MITCHELL, M. (1998). *An introduction to genetic algorithms*. Reprint ed. Cambridge: MIT. 224 p. ISBN 0262631857.
- MONTGOMERY, D. C. (2001). *Design and analysis of experiments*. 5th ed. New York: John Wiley & Sons. 684 p. ISBN 0-471-31649-0.
- MONTGOMERY, D. C.; RUNGER, G. C. (2003). *Estatística aplicada e probabilidade para engenheiros*. 2. ed. Rio de Janeiro: LTC. 463 p. ISBN 85-216-1360-1.
- MOREIRA, C. M. (2001). *Estratégias de reposição de estoques em supermercados: avaliação por meio de simulação*. 148 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Santa Catarina, Florianópolis.
- MUSSELMAN, K. J. (1998). Guidelines for success. In: BANKS, J. (Ed). (1998). *Handbook of Simulation*. New York: John Wiley & Sons.
- O'KANE, J. F.; SPENCELEY, J. R.; TAYLOR, R. (2000). Simulation as an essential tool for advanced manufacturing technology problems. *Journal of Materials Processing Technology*, v. 107, p. 412-424.
- OLIVEIRA, F. A. (2003). *A Gestão Baseada em Atividade aplicada em ambientes celulares: uma abordagem metodológica*. 137 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá, Itajubá.

- PEREIRA, I. C. (2000). *Proposta de sistematização da simulação para fabricação em lotes*. 154 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá, Itajubá.
- PIDD, M. (1996). Five simple principles of simulation modeling. In: WINTER SIMULATION CONFERENCE, 1996, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers.
- PRICE, R. N.; HARREL, C. R. (1999). Simulation modeling and optimization using Promodel. In: WINTER SIMULATION CONFERENCE, 1999, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 208-214.
- PROMODEL CORPORATION. (2002). *Promodel user guide*. [S.L.: s.n.]. 732 p.
- RECHENBERG, I. (1973). *Evolutionstrategie: Optimierung technischer systeme nach prinzipien der biologischen evolution*. Stuttgart: Frommann-Holzboog.
- RUBINSTEIN, R.Y.; SHAPIRO, A. (1993). *Discrete event systems: sensitivity analysis and stochastic optimization by the score function method*. New York: John Wiley & Sons. ISBN 0471934194.
- SARAMAGO, S. F. P. (2003). *Métodos de otimização randômica: Algoritmos genéticos e simulated annealing*. 1. ed. São Carlos: SBMAC. v. 6, 35 p.
- SCHRIBER, T. J.; BRUNNER, D. T. (1998). Inside discrete-event simulation software: How it works and why it matters. In: WINTER SIMULATION CONFERENCE, 1998, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 77-85.
- SCHWEFEL, H. P. (1975). *Evolutionstrategie und numerische optimierung*. PhD thesis. Technische Universität Berlin, Berlin.
- _____ (1977). *Numerische optimierung von computer-modellen mittels der evolutionstrategie*. Basel: Birkhauser.
- SHANNON, R. E. (1998) Introduction to the art and science of Simulation. In: WINTER SIMULATION CONFERENCE, 1998, Piscataway. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 7-14.

- SILVA, E. L.; MENEZES, E. M. (2005). *Metodologia da pesquisa e elaboração de dissertação*, 4ª ed. rev. atual. Florianópolis: UFSC. 138 p.
- SILVA, A. P. A. (2002). Tutorial: Genetic Algorithms. *Learning and Nonlinear Models – Revista da Sociedade Brasileira de Redes Neurais*, v. 1, n. 1, p. 43-58.
- SILVA, W. A. (2005). *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.
- SILVA, W. A.; MONTEVECHI, J. A. B. (2004). Verificação do custeio de uma célula de manufatura usando simulação e otimização. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 36., 2004, São João del Rei. São João Del Rei. *Anais...* 23 a 26 nov. 2004. CD-ROM.
- SIMÕES, A. B. (1999). *Transposição: estudo de um novo operador genético inspirado biologicamente*. Dissertação (Mestrado em Informática). Universidade de Coimbra, Coimbra.
- SIMULAÇÃO. In: DICIONÁRIO Houaiss da língua portuguesa. Disponível em: <<http://houaiss.uol.com.br/busca.jhtm?verbete=simula%E7%E3o&stype=k&x=10&y=10>>. Acesso em: 25 jul. 2006.
- STRACK, J. (1984). *GPSS: modelagem e simulação de sistemas*. Rio de Janeiro: LTC.
- TANOMARU, J. (1995). Motivação, fundamentos e aplicações de algoritmos genéticos. In: CONGRESSO BRASILEIRO DE REDES NEURAI, 2., 1995, Curitiba. *Anais...* Curitiba: [s.n], p. 373-403.
- TAVARES, J. A. R. (2000). *Geração de Configurações de Sistemas Industriais com o Recurso à Tecnologia das Restrições e Computação Evolucionária*. Tese (Doutorado em Informática). Universidade de Minho, Braga.
- TAVEIRA, R. A. (1997). *Uma metodologia para aperfeiçoamento da mudança para um sistema de produção Just-in-Time em uma indústria Metalúrgica, usando simulação discreta e técnicas de projeto de experimentos de Taguchi*. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Santa Catarina, Florianópolis.

TELLER, A.; VELOSO, M. (1995). Algorithm Evolution for Face Recognition: What Makes a Picture Difficult. In: INTERNATIONAL CONFERENCE ON EVOLUTIONARY COMPUTATION, 2., 1995, Perth. *Proceedings...* Perth: Institute of Electrical and Electronics Engineers. p. 608-613.

ANEXO A - COLETA DOS DADOS

Neste anexo são detalhados os dados coletados durante o mapeamento do processo.

a) Operação 50

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	0,463	5,514	0,463
2	0,530	5,548	0,530
3	0,472	5,515	0,472
4	0,478	5,511	0,478
5	0,459	5,528	0,459
6	0,501	5,528	0,501
7	0,662	5,473	0,662
8	0,579	5,478	0,579
9	0,679	5,464	0,679
10	0,630	5,470	0,630
Média	0,5453	5,5029	0,3666
Desvio padrão	0,0857	0,0293	0,0421
Coefficiente de variação	15,72%	0,53%	11,48%

Tabela A.1 – Tempos coletados da operação 50.




Gráfico A.1 – *Boxplot* dos tempos da operação 50.




Gráfico A.2 – Gráfico de probabilidade para tempo de fixação da operação 50.




Gráfico A.3 – Gráfico de probabilidade para tempo de usinagem da operação 50.

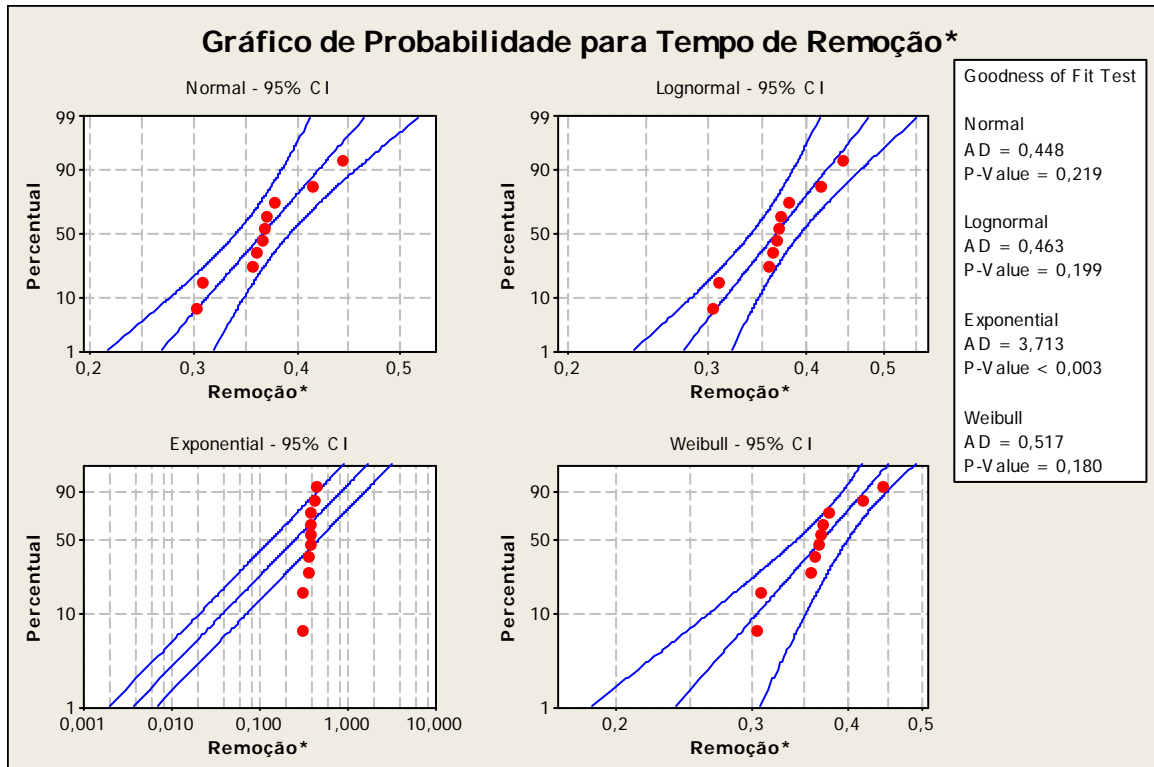


Gráfico A.4 – Gráfico de probabilidade para tempo de remoção da operação 50.

b) Operação 51

	Tempo (minutos)			
	Fixação	Usinagem	Remoção	Troca
1	0,577	7,772	0,420	0,300
2	0,631	7,774	0,409	0,279
3	0,559	7,766	0,407	0,258
4	0,610	7,806	0,349	0,306
5	0,583	7,700	0,418	0,287
6	0,568	7,699	0,332	0,265
7	0,587	7,776	0,419	0,309
8	0,598	7,689	0,401	0,275
9	0,577	7,759	0,397	0,283
10	0,590	7,673	0,381	0,288
Média	0,5880	7,7414	0,3933	0,2850
Desvio padrão	0,0209	0,0462	0,0305	0,0168
Coefficiente de variação	3,56%	0,6%	7,75%	5,88%

Tabela A.2 – Tempos coletados da operação 51.




Gráfico A.5 – Boxplot dos tempos da operação 51.

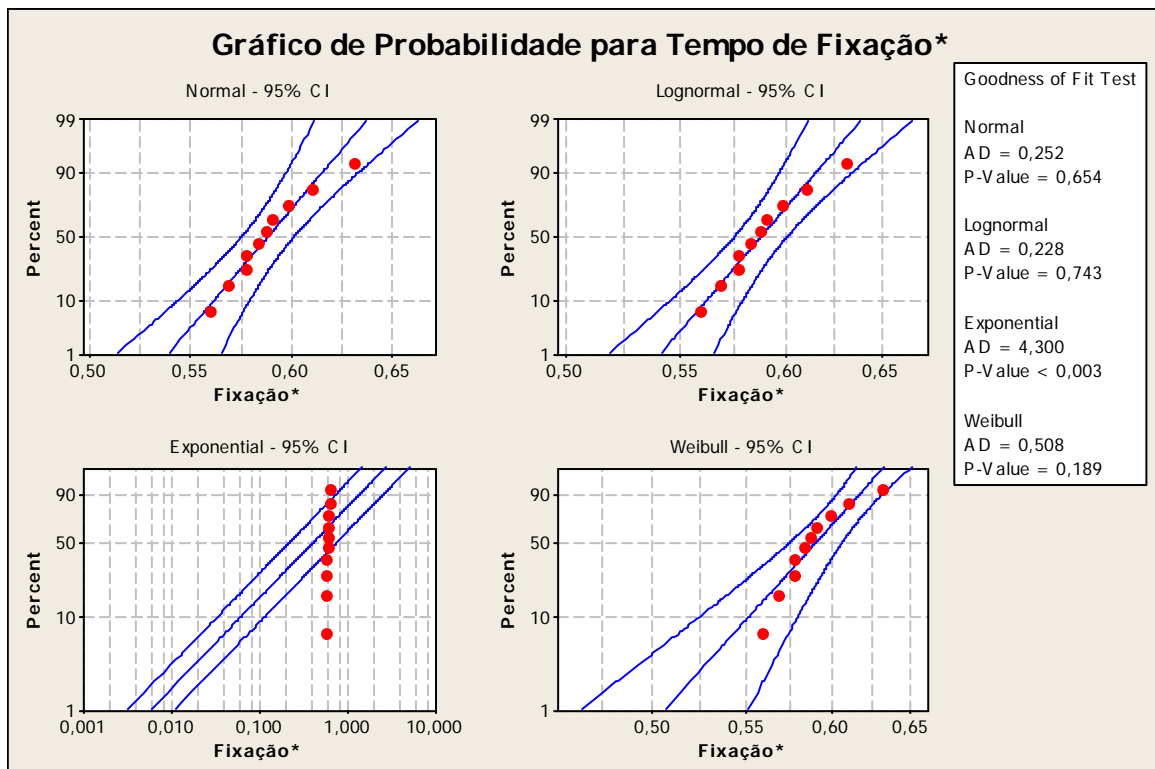


Gráfico A.6 – Gráfico de probabilidade para tempo de fixação da operação 51.




Gráfico A.7 – Gráfico de probabilidade para tempo de usinagem da operação 51.




Gráfico A.8 – Gráfico de probabilidade para tempo de remoção da operação 51.

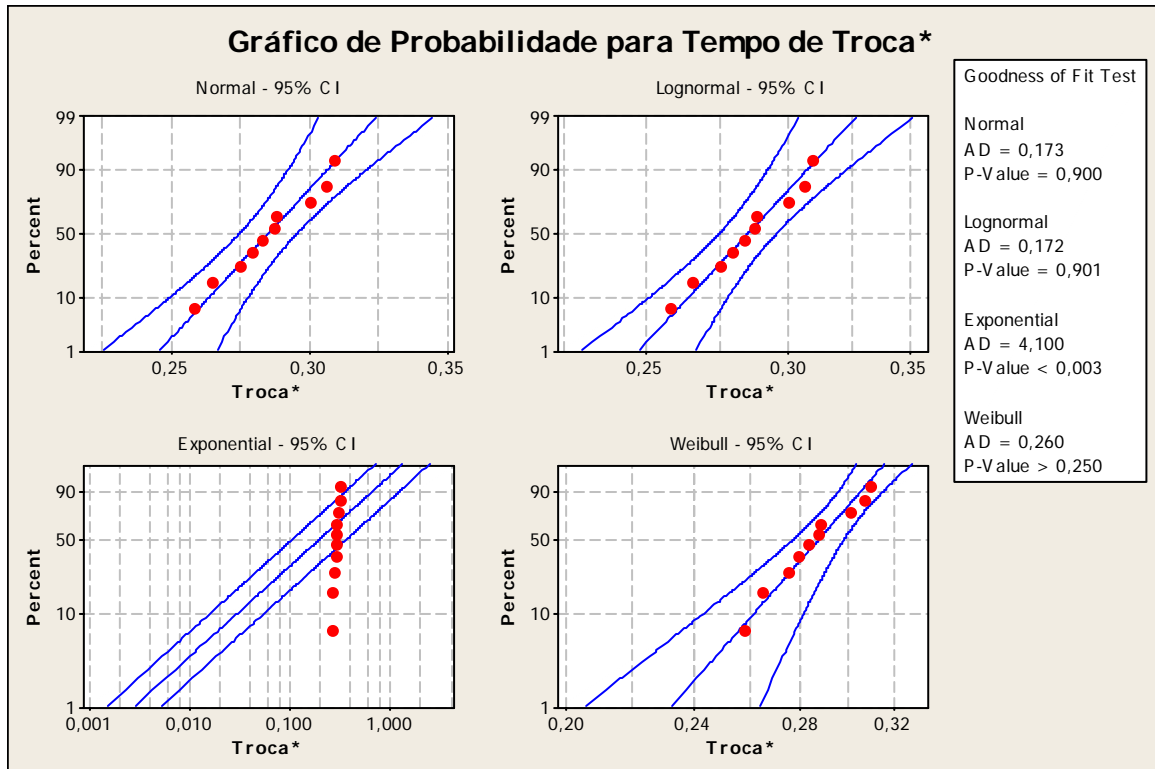


Gráfico A.9 – Gráfico de probabilidade para tempo de troca da operação 51.

c) Operação 52

	Tempo (minutos)			
	Fixação	Usinagem	Remoção	Troca
1	0,899	6,033	0,438	0,473
2	0,780	6,033	0,448	0,446
3	0,866	6,037	0,556 (*)	0,270
4	0,833	6,036	0,457	0,346
5	0,839	6,039	0,417	0,349
6	0,806	6,040	0,415	0,369
7	0,955	6,032	0,397	0,367
8	0,828	6,017	0,478	0,456
9	0,778	6,017	0,402	0,368
10	0,799	6,018	0,393	0,294
Média	0,8383	6,0302	0,4272	0,3788
Desvio padrão	0,0556	0,0093	0,0296	0,0670
Coefficiente de variação	6,63%	0,15%	6,92%	17,93%

Tabela A.3 – Tempos coletados da operação 52.




Gráfico A.10 – *Boxplot* dos tempos da operação 52.




Gráfico A.11 – *Boxplot* dos tempos da operação 52 sem outliers.




Gráfico A.12 – Gráfico de probabilidade para tempo de fixação da operação 52.

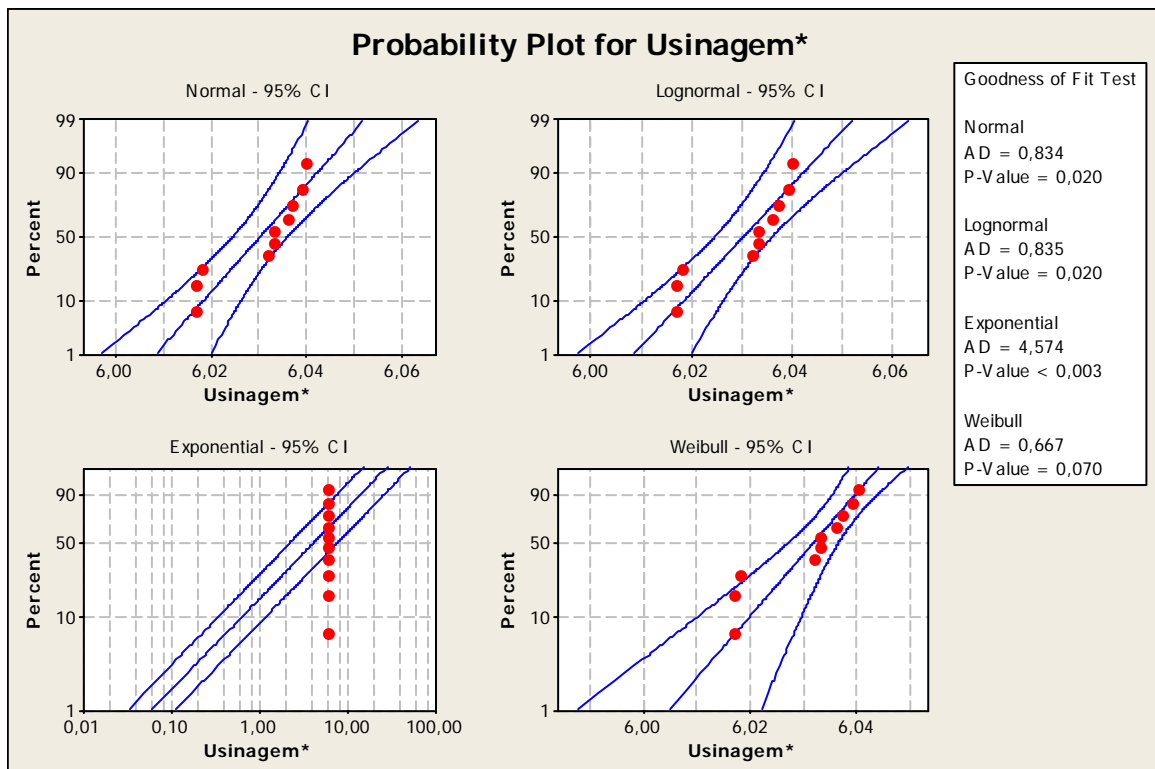


Gráfico A.13 – Gráfico de probabilidade para tempo de usinagem da operação 52.




Gráfico A.14 – Gráfico de probabilidade para tempo de remoção da operação 52.

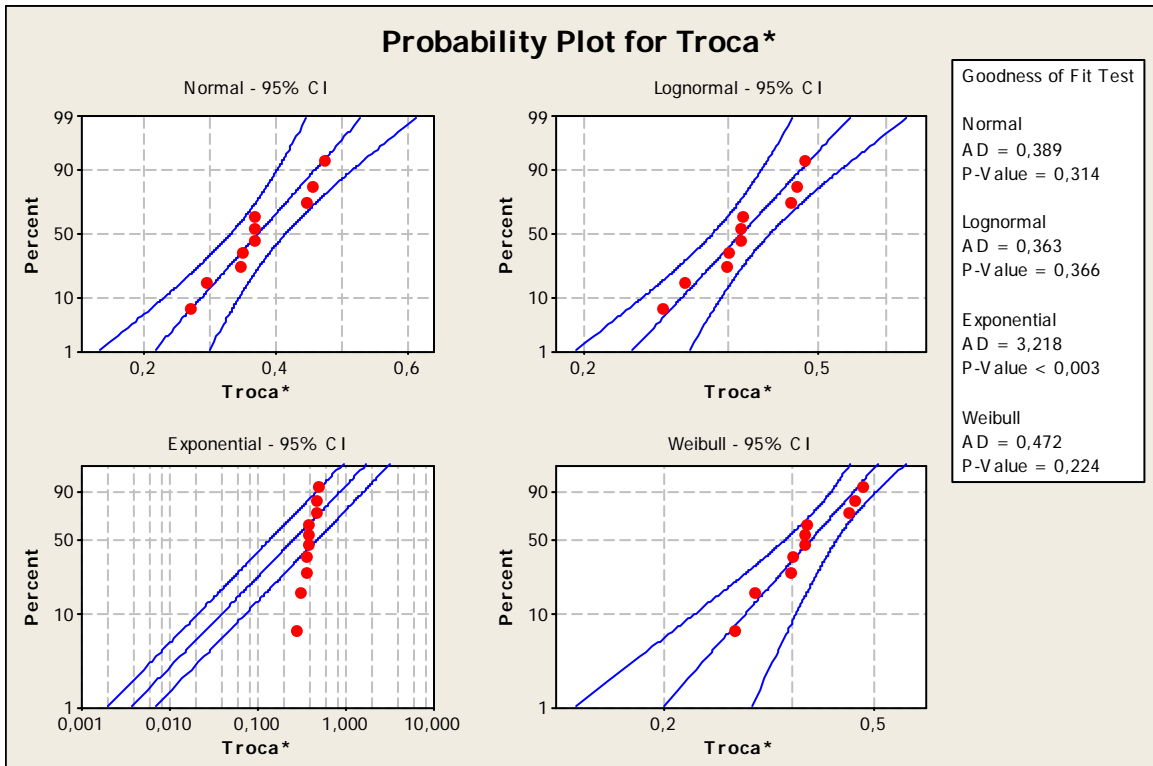



Gráfico A.15 – Gráfico de probabilidade para tempo de troca da operação 52.

d) Operação 70

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	0,104	1,355 (*)	0,141
2	0,130	1,299	0,123
3	0,136	1,316	0,156
4	0,143	1,314	0,196
5	0,224	1,299	0,217
6	0,259	1,309	0,192
7	0,252	1,305	0,240
8	0,229	1,314	0,244
9	0,326	1,298	0,199
10	0,265	1,298	0,209
Média	0,2068	1,3058	0,1917
Desvio padrão	0,0736	0,0076	0,0403
Coefficiente de variação	35,57%	0,58%	21,04%

Tabela A.4 – Tempos coletados da operação 70.

Gráfico A.16 – *Boxplot* dos tempos da operação 70.

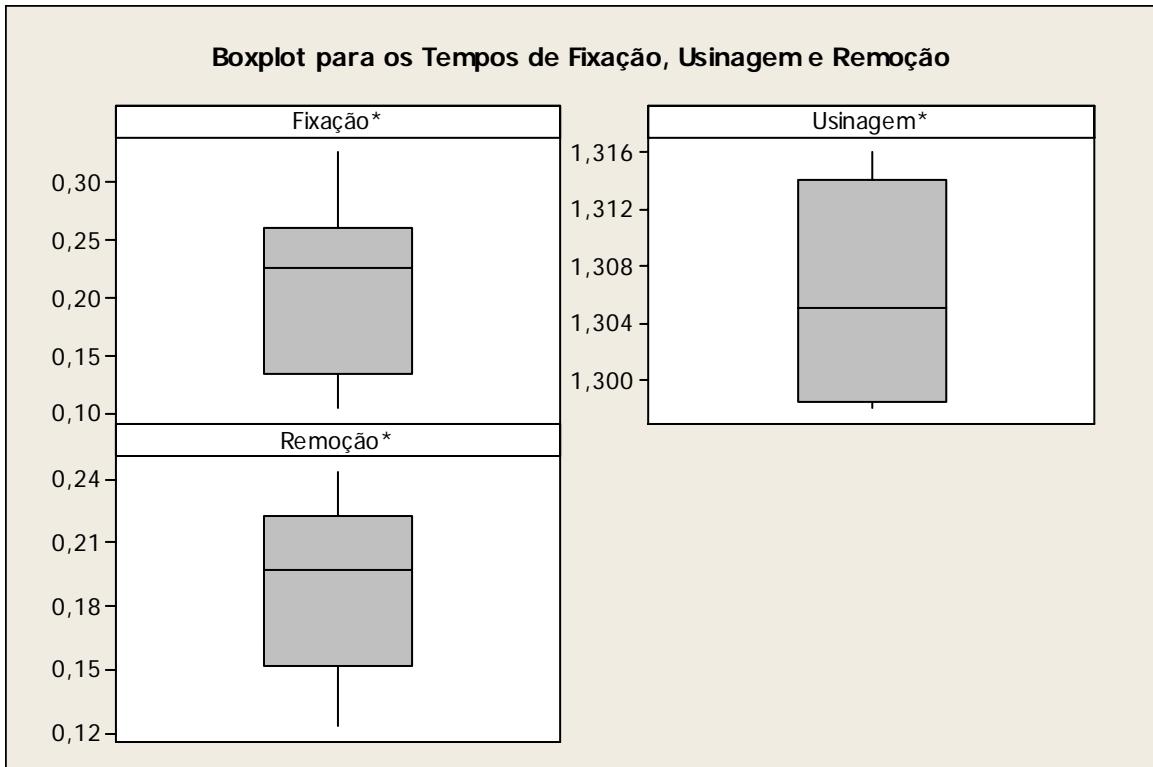


Gráfico A.17 – Boxplot dos tempos da operação 70 sem outliers.




Gráfico A.18 – Gráfico de probabilidade para tempo de fixação da operação 70.




Gráfico A.19 – Gráfico de probabilidade para tempo de usinagem da operação 70.


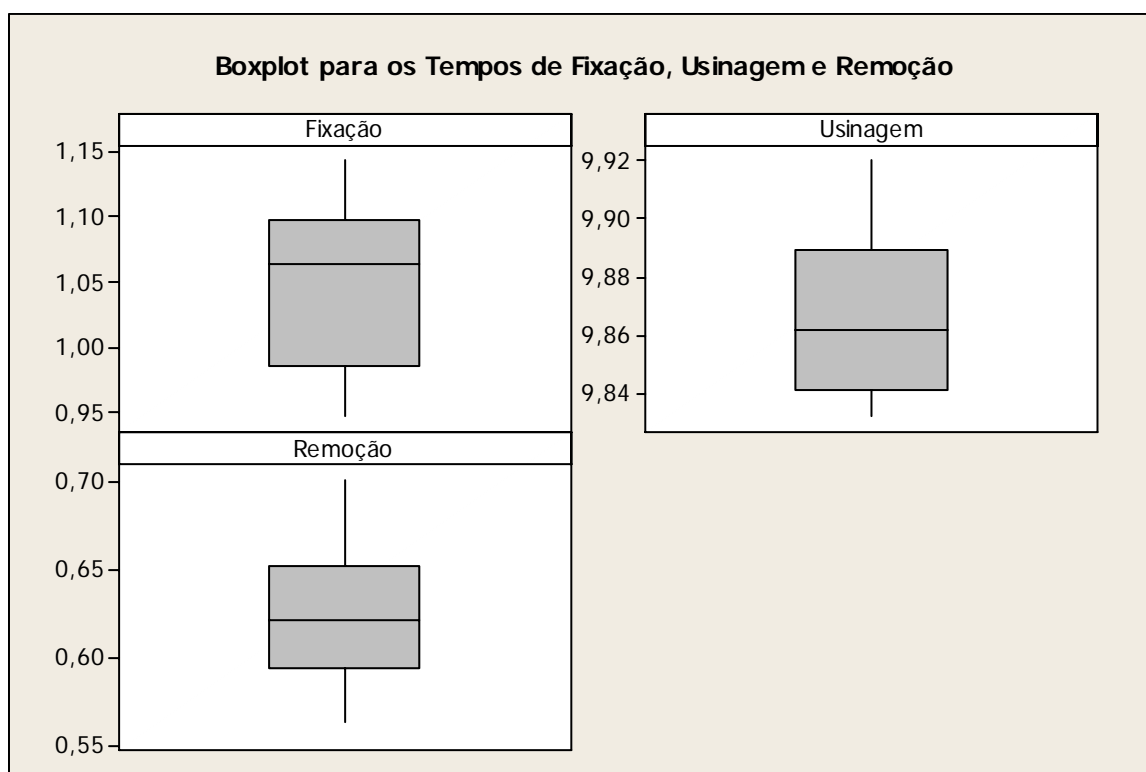


Gráfico A.20 – Gráfico de probabilidade para tempo de remoção da operação 70.

e) Operação 80

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	1,006	9,839	0,661
2	1,099	9,832	0,702
3	0,960	9,870	0,650
4	1,047	9,842	0,584
5	1,084	9,920	0,624
6	0,947	9,900	0,620
7	1,096	9,886	0,563
8	0,995	9,847	0,597
9	1,143	9,853	0,648
10	1,081	9,873	0,606
Média	1,0458	9,866	0,6255
Desvio padrão	0,0656	0,0289	0,0409
Coefficiente de variação	6,28%	0,29%	6,54%

Tabela A.5 – Tempos coletados da operação 80.

Gráfico A.21 – *Boxplot* dos tempos da operação 80.




Gráfico A.22 – Gráfico de probabilidade para tempo de fixação da operação 80.




Gráfico A.23 – Gráfico de probabilidade para tempo de usinagem da operação 80.




Gráfico A.24 – Gráfico de probabilidade para tempo de remoção da operação 80.

f) Operação 82

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	1,006	5,516	0,661
2	1,099	5,515	0,702
3	0,960	5,515	0,650
4	1,047	5,520	0,584
5	1,084	5,529	0,624
6	0,947	5,530	0,620
7	1,096	5,528	0,563
8	0,995	5,528	0,597
9	1,143	5,493(*)	0,648
10	1,081	5,556(*)	0,606
Média	1,0458	5,5226	0,6255
Desvio padrão	0,0656	0,0068	0,0409
Coefficiente de variação	6,28%	0,12%	6,54%

Tabela A.6 – Tempos coletados da operação 82.




Gráfico A.25 – *Boxplot* dos tempos da operação 82.




Gráfico A.26 – *Boxplot* dos tempos da operação 82 sem outliers.




Gráfico A.27 – Gráfico de probabilidade para tempo de fixação da operação 82.

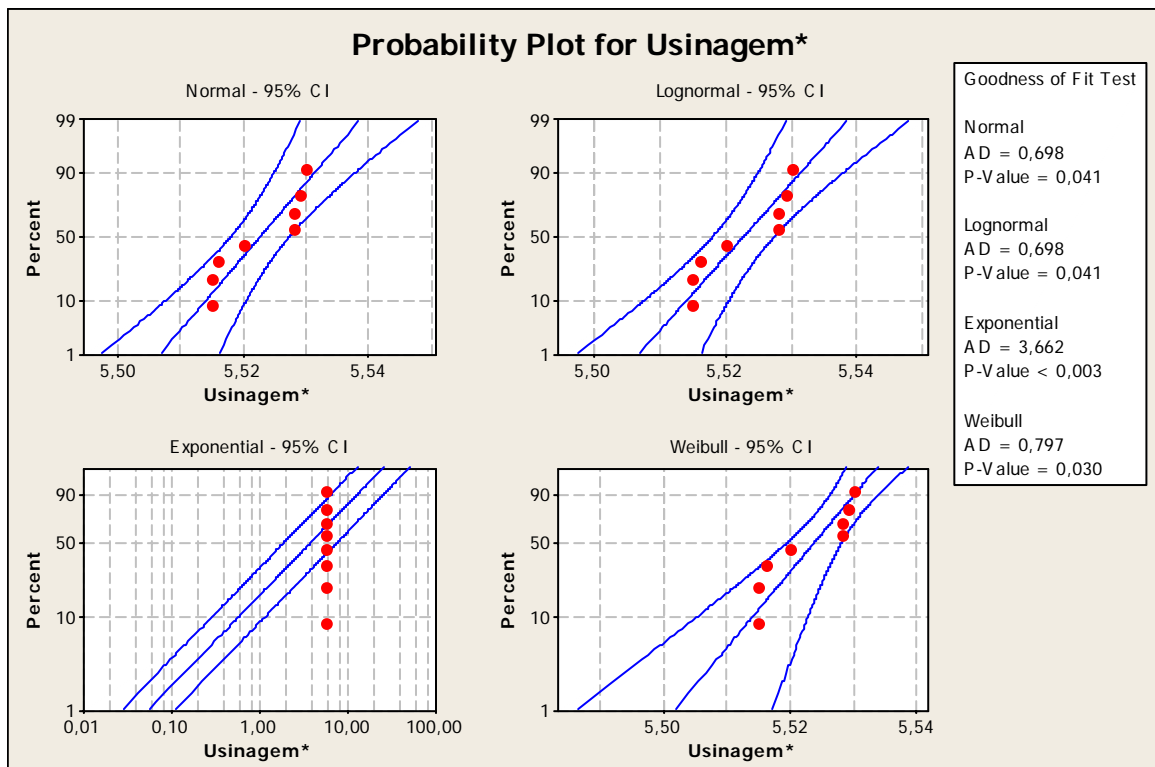


Gráfico A.28 – Gráfico de probabilidade para tempo de usinagem da operação 82.




Gráfico A.29 – Gráfico de probabilidade para tempo de remoção da operação 82.

g) Operação 100

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	0,338	1,893	0,227
2	0,316	1,889	0,161
3	0,403	1,882	0,207
4	0,391	1,887	0,176
5	0,342	1,905(*)	0,176
6	0,332	1,881	0,238
7	0,365	1,880	0,217
8	0,443	1,876	0,186
9	0,625(*)	1,884	0,191
10	0,463	1,886	0,234
Média	0,3770	1,8842	0,2013
Desvio padrão	0,0516	0,0051	0,0271
Coefficiente de variação	13,67%	0,27%	13,45%

Tabela A.7 – Tempos coletados da operação 100.




Gráfico A.30 – *Boxplot* dos tempos da operação 100.




Gráfico A.31 – *Boxplot* dos tempos da operação 100 sem outliers.




Gráfico A.32 – Gráfico de probabilidade para tempo de fixação da operação 100.




Gráfico A.33 – Gráfico de probabilidade para tempo de usinagem da operação 100.

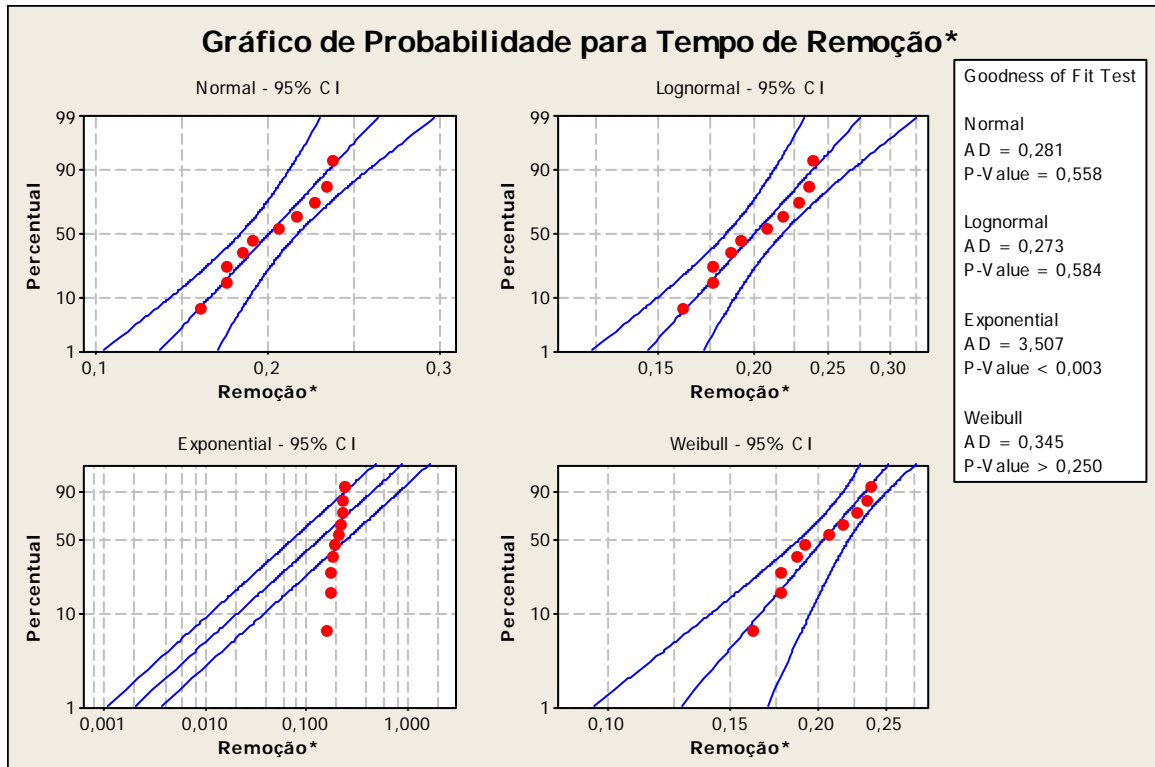


Gráfico A.34 – Gráfico de probabilidade para tempo de remoção da operação 100.

h) Operação 110

	Tempo (minutos)				
	Fixação	Usinagem	Troca	Usinagem	Remoção
1	0,272	2,326	0,649	2,326	0,278
2	0,298	2,331	0,565	2,331	0,256
3	0,294	2,332	0,599	2,316	0,314
4	0,275	2,326	0,615	2,326	0,316
5	0,316	2,344	0,632	2,328	0,301
6	0,272	2,318	0,612	2,318	0,321
7	0,281	2,308	0,619	2,319	0,289
8	0,295	2,318	0,678	2,310	0,269
9	0,304	2,310	0,563	2,314	0,274
10	0,266	2,317	0,654	2,354 (*)	0,273
Média	0,2873	2,3230	0,6186	2,3242	0,2891
Desvio padrão	0,0165	0,0110	0,0370	0,0124	0,0226
Coefficiente de variação	5,72%	0,47%	5,97%	0,54%	7,83%

Tabela A.8 – Tempos coletados da operação 110.




Gráfico A.35 – *Boxplot* dos tempos da operação 110.




Gráfico A.36 – *Boxplot* dos tempos da operação 110 sem *outliers*.




Gráfico A.37 – Gráfico de probabilidade para tempo de fixação da operação 110.




Gráfico A.38 – Gráfico de probabilidade para tempo de usinagem da operação 110.




Gráfico A.39 – Gráfico de probabilidade para tempo de troca da operação 110.





Gráfico A.40 – Gráfico de probabilidade para tempo de remoção da operação 110.

i) Operação 120

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	0,364	7,274	0,333
2	0,374	7,291 (*)	0,319
3	0,348	7,255	0,372
4	0,309	7,267	0,480
5	0,312	7,267	0,320
6	0,313	7,264	0,321
7	0,236	7,271	0,414
8	0,255	7,270	0,287
9	0,307	7,266	0,353
10	0,474	7,264	0,274
Média	0,3292	7,2664	0,3473
Desvio padrão	0,0668	0,0054	0,0616
Coefficiente de variação	20,30%	0,07%	17,74%

Tabela A.9 – Tempos coletados da operação 120.

Gráfico A.41 – *Boxplot* dos tempos da operação 120.

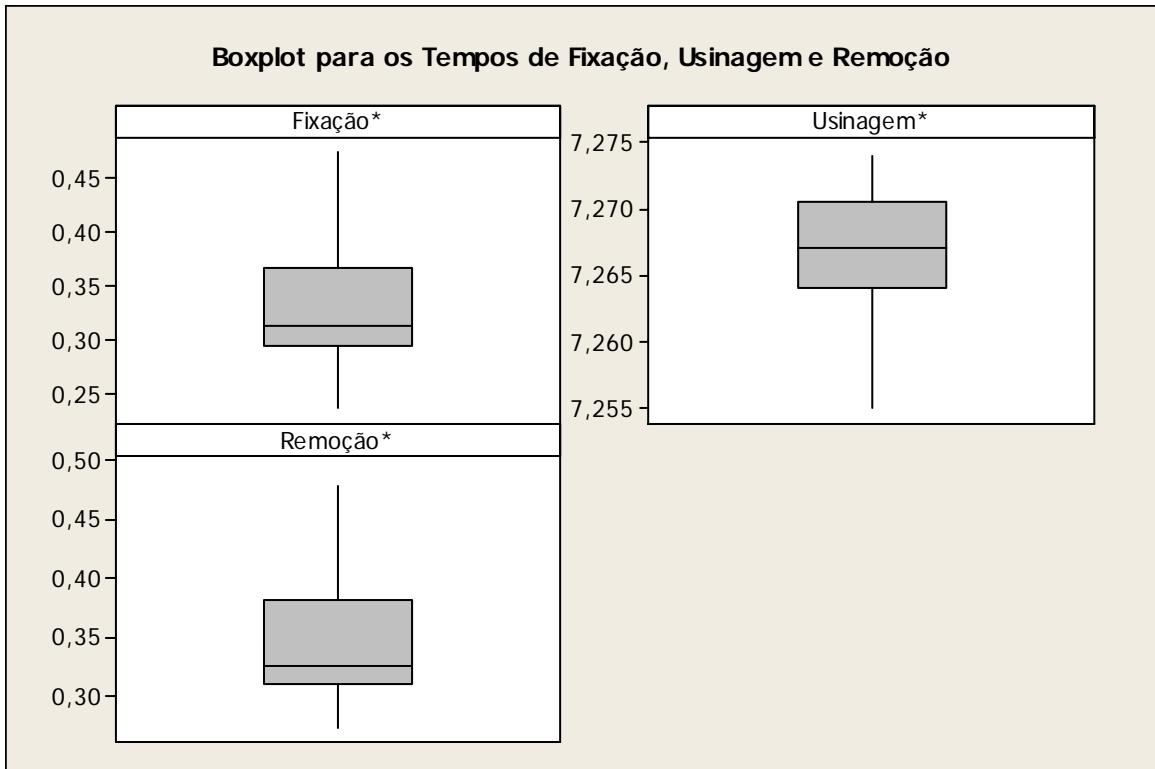


Gráfico A.42 – Boxplot dos tempos da operação 120 sem outliers.




Gráfico A.43 – Gráfico de probabilidade para tempo de fixação da operação 120.




Gráfico A.44 – Gráfico de probabilidade para tempo de usinagem da operação 120.





Gráfico A.45 – Gráfico de probabilidade para tempo de remoção da operação 120.

j) Operação 170

	Tempo (minutos)		
	Fixação	Usinagem	Remoção
1	0,997	5,677	0,881
2	1,070	5,698	0,934
3	0,998	5,660	0,822
4	1,375	5,682	0,879
5	0,973	5,690	0,991
6	0,924	5,861	0,840
7	1,477	5,781	1,215
8	1,402	5,881	1,228
9	1,579	5,720	1,334
10	1,446	5,783	1,281
Média	1,2241	5,7433	1,0405
Desvio padrão	0,2524	0,0791	0,2008
Coefficiente de variação	20,62%	1,38%	19,30%

Tabela A.10 – Tempos coletados da operação 170.

Gráfico A.46 – *Boxplot* dos tempos da operação 170.

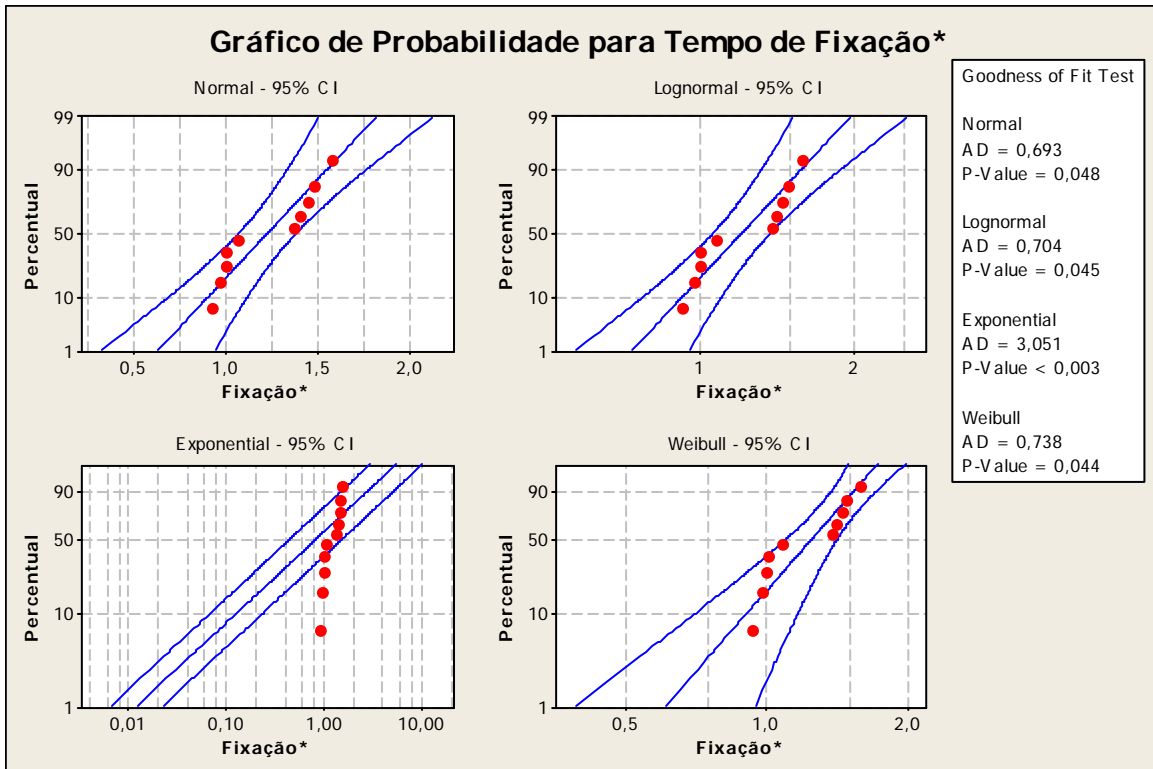


Gráfico A.47 – Gráfico de probabilidade para tempo de fixação da operação 170.

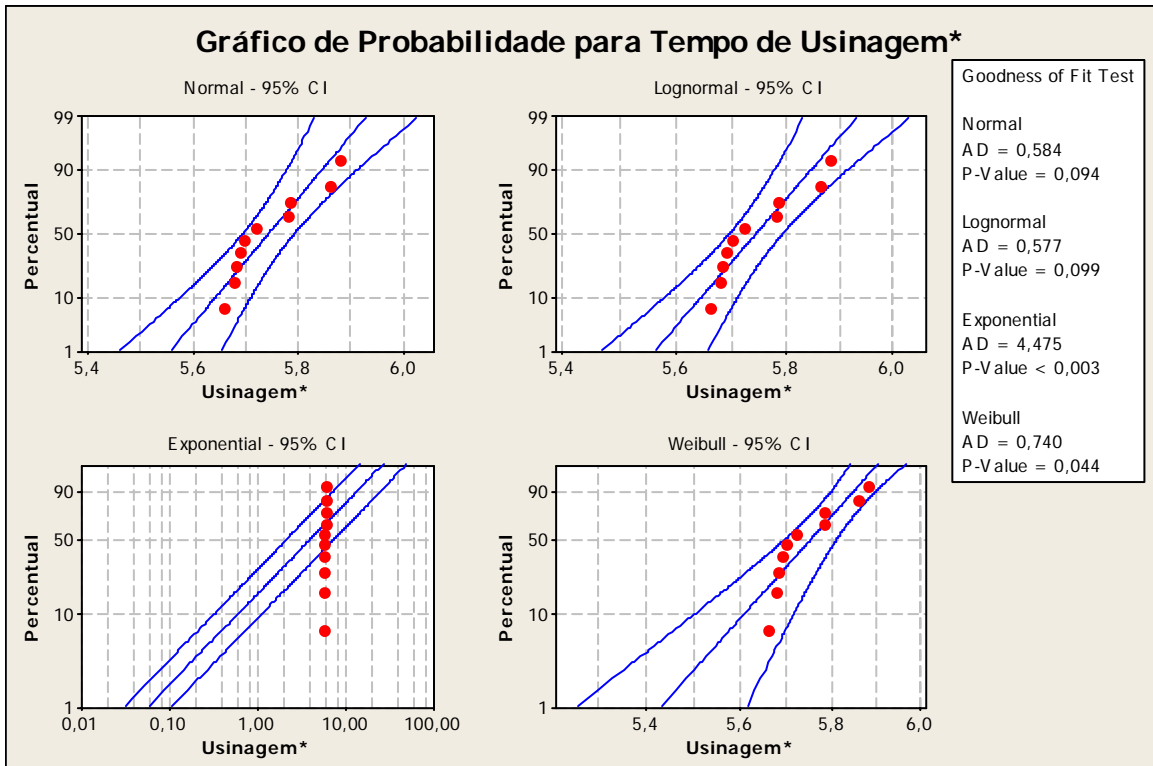


Gráfico A.48 – Gráfico de probabilidade para tempo de usinagem da operação 170.

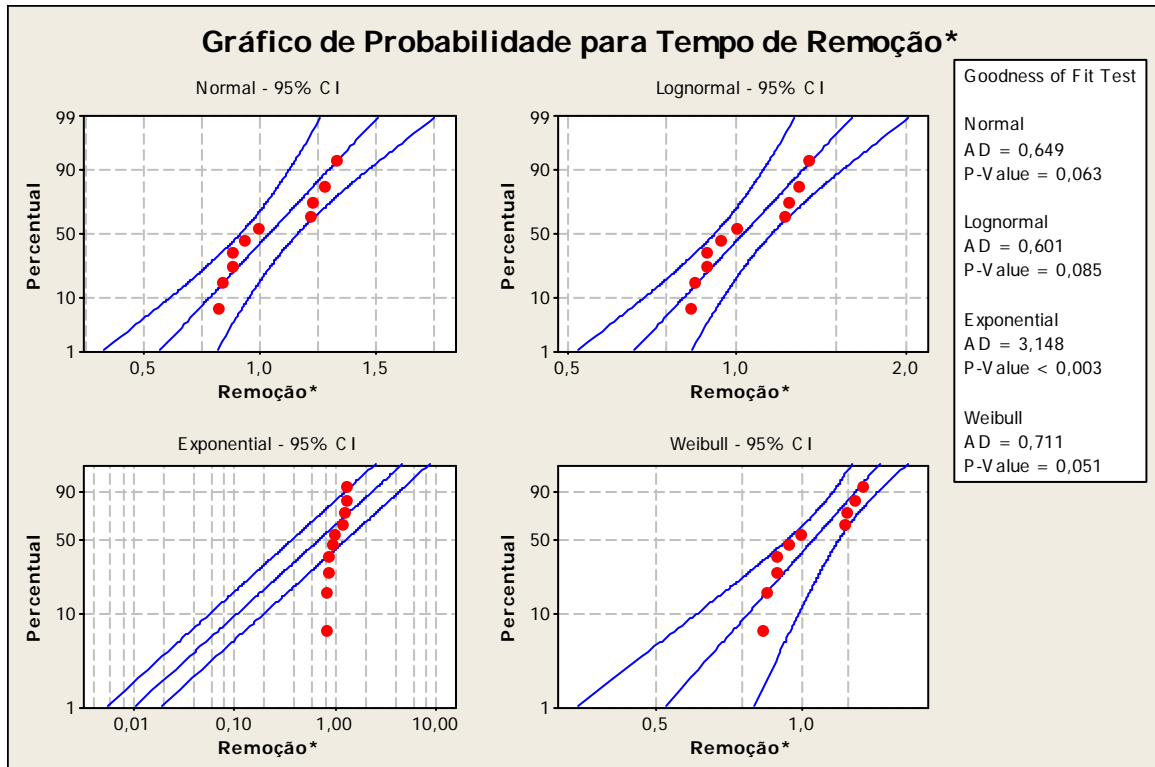


Gráfico A.49 – Gráfico de probabilidade para tempo de remoção da operação 170.

ANEXO B - PLANEJAMENTO FRACIONADO DA APLICAÇÃO 2

a) Relação de definição

$I = ACEF = ACDG = ABDH = ABEJ = CDEK = ABCDEL = ADEM = DEFG = BCDEFH =$
 $BCFJ = ADFK = BDFL = CDFM = BCGH = BCDEGJ = AEGK = BEGL = CEGM = DEHJ$
 $= ABCEHK = CEHL = BEHM = ABCDJK = CDJL = BDJM = ABKL = ACKM = BCLM =$
 $ABEFGH = ABDFGJ = CFGK = ABCFGL = AFGM = ACDFHJ = BFHK = AFHL =$
 $ABCFHM = BDEFJK = ADEFJL = ABCDEFJM = BCEFKL = EFKM = ABEFML =$
 $ACEGHJ = BDEGHK = ADEGHL = ABCDEGHM = BGJK = AGJL = ABCGJM =$
 $BCDGKL = DGKM = ABDGLM = CHJK = ABCHJL = AHJM = DHKL = BCDHKM =$
 $ACDHLM = EJKL = BCEJKM = ACEJLM = BDEKLM = FGHJ = ABCDFGHK =$
 $CDFGHL = BDFGHM = ABCEFGJK = CEFGJL = BEFGJM = ABDEFGKL =$
 $ACDEFGKM = BCDEFGLM = AEFHJK = BEFHJL = CEFHJM = ACDEFHKL =$
 $ABDEFHKM = DEFHLM = ACFJKL = ABFJKM = FJLM = ABCDFKLM = ADGHJK =$
 $BDGHJL = CDGHJM = ACGHKL = ABGHKM = GHLM = ACDEGJKL = ABDEGJKM =$
 $DEGJLM = ABCEGKLM = ABDEHJKL = ACDEHJKM = BCDEHJLM = AEHKLM =$
 $ADJKLM = CDEFGHJK = ABCDEFGHJL = ADEFGHJM = EFGHKL = BCEFGHKM =$
 $ACEFGHLM = DFGJKL = BCDFGJKM = ACDFGJLM = BFGKLM = BCDFHJKL =$
 $DFHJKM = ABDFHJLM = CFHKLM = CDEFJKLM = BCEGHJKL = EGHJKM =$
 $ABEGHJLM = CDEGHKLM = CGJKLM = BHJKLM = ABFGHJKL = ACFGHJKM =$
 $BCFGHJLM = ADFGHKLM = ACFGJKLM = ABCEFHKLM = ABCDGHJKLM =$
 $BDEFGHJKLM$

b) Estrutura de associação (até 3 fatores)

$I = A + BDH + BEJ + BKL + CDG + CEF + CKM + DEM + DFK + EGK + FGM + FHL +$
 $GJL + HJM$
 $I = B + ADH + AEJ + AKL + CFJ + CGH + CLM + DFL + DJM + EGL + EHM + FHK +$
 GJK
 $I = C + ADG + AEF + AKM + BFJ + BGH + BLM + DEK + DFM + DJL + EGM + EHL +$
 $FGK + HJK$

I=D + ABH + ACG + AEM + AFK + BFL + BJM + CEK + CFM + CJL + EFG + EHJ + GKM + HKL

I=E + ABJ + ACF + ADM + AGK + BGL + BHM + CDK + CGM + CHL + DFG + DHJ + FKM + JKL

I=F + ACE + ADK + AGM + AHL + BCJ + BDL + BHK + CDM + CGK + DEG + EKM + GHJ + JLM

I=G + ACD + AEK + AFM + AJL + BCH + BEL + BJK + CEM + CFK + DEF + DKM + FHJ + HLM

I=H + ABD + AFL + AJM + BCG + BEM + BFK + CEL + CJK + DEJ + DKL + FGJ + GLM

I=J + ABE + AGL + AHM + BCF + BDM + BGK + CDL + CHK + DEH + EKL + FGH + FLM

I=K + ABL + ACM + ADF + AEG + BFH + BGJ + CDE + CFG + CHJ + DGM + DHL + EFM + EKL

I=L + ABK + AFH + AGJ + BCM + BDF + BEG + CDJ + CEH + DHK + EJK + FJM + GHM

I=M + ACK + ADE + AFG + AHJ + BCL + BDJ + BEH + CDF + CEG + DGK + EFK + FJL + GHL

I=AB + DH + EJ + KL

I=AC + DG + EF + KM

I=AD + BH + CG + EM + FK

I=AE + BJ + CF + DM + GK

I=AF + CE + DK + GM + HL

I=AG + CD + EK + FM + JL

I=AH + BD + FL + JM

I=AJ + BE + GL + HM

I=AK + BL + CM + DF + EG

I=AL + BK + FH + GJ

I=AM + CK + DE + FG + HJ

I=BC + FJ + GH + LM

I=BF + CJ + DL + HK

I=BG + CH + EL + JK

I=BM + CL + DJ + EH

I=ABC + AFJ + AGH + ALM + BDG + BEF + BKM + CDH + CEJ + CKL + DEL + DJK +
EHK + FGL + FHM + GJM + HJL

I=ABF + ACJ + ADL + AHK + BCE + BDK + BGM + BHL + CGL + CHM + DFH + DGJ
+ EFJ + EGH + ELM + FKL + JKM

I=ABG + ACH + AEL + AJK + BCD + BEK + BFM + BJL + CFL + CJM + DFJ + DGH +
DLM + EFH + EGJ + GKL + HKM

I=ABM + ACL + ADJ + AEH + BCK + BDE + BFG + BHJ + CFH + CGJ + DGL + DHM +
EFL + EJM + FJK + GHK + KLM

ANEXO C - ARTIGOS ORIGINADOS DESTA PESQUISA

ALMEIDA FILHO, R. G.; MONTEVECHI, J. A. B.; MEDEIROS, A. L. (2005). Simulação de uma célula de manufatura de uma empresa de material de defesa para avaliação de desempenho e análise de alternativas. In: SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA, 8., 2005, Rio de Janeiro. *Anais...* Rio de Janeiro: [s.n.].

ALMEIDA FILHO, R. G.; MONTEVECHI, J. A. B.; MEDEIROS, A. L. (2005). Simulação de uma célula de manufatura de uma empresa de material de defesa para análise de desempenho e avaliação de alternativas. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, 12., 2005, Bauru. *Anais...* Bauru: UNESP.

ALMEIDA FILHO, R. G.; MONTEVECHI, J. A. B.; MEDEIROS, A. L. (2006). Emprego da simulação de eventos discretos na avaliação da distribuição de mão de obra em turnos e roteiros de fabricação de uma célula de manufatura. In: SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, LOGÍSTICA E OPERAÇÕES INTERNACIONAIS, 9., 2009, São Paulo. *Anais...* São Paulo: FGV/EAESP.

MEDEIROS, A. L.; MONTEVECHI, J. A. B.; ALMEIDA FILHO, R. G. (2005). Simulação de eventos discretos na análise do planejamento produtivo de uma empresa de material de defesa. In: SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, LOGÍSTICA E OPERAÇÕES INTERNACIONAIS, 8., 2005, São Paulo. *Anais...* São Paulo: FGV/EAESP.

MEDEIROS, A. L.; MONTEVECHI, J. A. B.; ALMEIDA FILHO, R. G. (2005). Análise do planejamento produtivo de uma indústria de material de defesa através da simulação de eventos discretos. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 25., 2005, Porto Alegre. *Anais...* Porto Alegre: ABEPRO.

MONTEVECHI, J. A. B.; ALMEIDA FILHO, R. G.; MEDEIROS, A. L. (2006). Application of factorial designs for reducing factors to optimization via discrete-event simulation. In: WINTER SIMULATION CONFERENCE, 2006. *Proceedings...* Piscataway: Institute of Electrical and Electronics Engineers, p. 1977-1984.