

ALEXANDRE FERREIRA DE PINHO

METODOLOGIA PARA UTILIZAÇÃO DE ALGORITMOS GENÉTICOS EM
MODELOS DE SIMULAÇÃO COMPUTACIONAL EM AMBIENTES DE
MANUFATURA

Tese apresentada à Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, para a obtenção do título de Doutor em Engenharia Mecânica na área de Transmissão e Conversão de Energia.

Orientador: Prof. Dr. José Arnaldo Barra Montevechi (UNIFEI)

Co-orientador: Prof. Dr. Fernando Augusto Silva Marins (UNESP-FEG)

Guaratinguetá

2008

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

UNESP  UNIVERSIDADE ESTADUAL PAULISTA

Faculdade de Engenharia do Campus de Guaratinguetá

**"METODOLOGIA PARA UTILIZAÇÃO DE ALGORITMOS GENÉTICOS
EM MODELOS DE SIMULAÇÃO COMPUTACIONAL EM AMBIENTES DE
MANUFATURA"**

ALEXANDRE FERREIRA DE PINHO

ESTA TESE FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
"DOUTOR EM ENGENHARIA MECÂNICA"

PROGRAMA: ENGENHARIA MECÂNICA

ÁREA: TRANSMISSÃO E CONVERSÃO DE ENERGIA

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO

Prof. Dr. João Andrade de Carvalho Júnior

Coordenador

BANCA EXAMINADORA:

Prof. Dr. JOSÉ ARNALDO BARRA MONTEVECHI

Orientador/UNIFEI

Prof. Dr. VALÉRIO ANTÔNIO PAMPLONA SALOMON

UNESP-FEG

Prof. Dr. EDUARDO SALIBY

COPPEAD/UFRJ

Prof. Dr. DAGOBERTO ALVES DE ALMEIDA

UNIFEI

Prof. Dr. LEONARDO CHWIF

SIMULATE

Dezembro de 2008

DADOS CURRICULARES

ALEXANDRE FERREIRA DE PINHO

NASCIMENTO	30.07.1971 – Rio de Janeiro / RJ
FILIAÇÃO	Paulo César dos Santos Pinho Maria Helena Kehde Ferreira Pinho
1990/1995	Curso de Graduação Universidade Federal de Itajubá – Engenharia Mecânica
1996/1999	Curso de Pós-Graduação em Engenharia de Produção, nível de Mestrado, na Universidade Federal de Itajubá, MG.
1999/2000	Curso de Pós-Graduação em Análise, Projeto e Gerenciamento de Sistemas de Informação, nível de Especialização, na Pontifícia Universidade Católica de Minas Gerais.

DEDICATÓRIA

À minha esposa, Elenice, incentivadora e sempre compreensiva com o pouco tempo que está tese de doutorado permitiu-me dedicar-lhe neste último ano.

AGRADECIMENTOS

Gostaria de expressar meus sinceros agradecimentos a todas as pessoas que contribuíram de alguma forma, direta ou indiretamente, na realização deste trabalho.

Também gostaria de agradecer aos meus orientadores, Prof. Dr. José Arnaldo Barra Montevechi e Prof. Dr. Fernando Augusto Silva Marins, pelas diretrizes e apoio durante a realização deste trabalho.

Em particular, gostaria de agradecer ao amigo José Arnaldo Barra Montevechi, orientador não só deste doutoramento, mais também orientador de minha iniciação científica e mestrado. Nossas inúmeras horas de conversas e discussões contribuíram ao meu amadurecimento profissional e pessoal. Um amadurecimento que levarei comigo pelo resto de minha vida.

Também gostaria de agradecer ao grande amigo Fabiano Leal, pelas sugestões e opiniões decisivas na conclusão desse trabalho.

Aos amigos e alunos Bruno Torga e Rafael Florêncio, pela imensa ajuda na elaboração dos modelos computacionais utilizados nesta tese.

A empresa PadTec pelo apoio a pesquisa científica.

Finalmente, gostaria de agradecer a todos os membros do NEAAD (Núcleo de Estudos Avançados de Apoio à Decisão) da Universidade Federal de Itajubá, pelo apoio e sugestões durante as etapas do doutoramento.

EPÍGRAFE

“The method that proceeds without analysis
is like the groping of a blind man”

Socrates

PINHO, A.F.de. **Metodologia para utilização de algoritmos genéticos em modelos de simulação computacional em ambientes de manufatura**. 2008. 189 f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2008.

RESUMO

Métodos de otimização combinados com a simulação computacional a eventos discretos têm sido utilizados em diversas aplicações na manufatura. Entretanto, estes métodos possuem baixo desempenho, em relação ao tempo computacional, ao manipularem mais de uma variável de decisão. Desta forma, o objetivo desta tese de doutorado é propor um método para otimização de modelos de simulação a eventos discretos com maior eficiência em relação ao tempo de processamento quando comparado a uma ferramenta comercial conhecida. Cabe ressaltar que a qualidade da variável de resposta não será alterada, ou seja, o método proposto manterá a eficácia das soluções encontradas. Será mostrado que a melhora neste desempenho é obtida através de uma melhor percepção do comportamento dos parâmetros existentes nos algoritmos genéticos, em especial o parâmetro tamanho da população. A comparação entre o método desenvolvido com a ferramenta de otimização existente no mercado se dará através de uma metodologia já consolidada disponível na literatura. As conclusões serão apresentadas comprovando a eficácia do método proposto.

PALAVRAS-CHAVE: Simulação a Eventos Discretos, Método de Otimização, Algoritmos genéticos.

PINHO, A.F.de. **Methodology for use of genetic algorithms in models of computational simulation in manufacture environments**. 2008. 189 f. Thesis (Doctorate in Mechanical Engineering) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2008.

ABSTRACT

Optimization methods combined with discrete events simulation have been used in many manufacturing applications. However, these methods have poor performance considering the computational time, when manipulating more than one decision variable. In this way, the aim of this thesis is to propose a method for optimizing discrete events simulation models with higher efficiency in relation to the processing time when compared to a known commercial tool. Besides, the optimization quality will not be altered, *i. e.*, the proposed method will keep the effectiveness of the achieved solutions. It will be shown that the performance improvement is obtained by means of a better perception of the behavior of all parameters presented in the genetic algorithms, particularly the population size parameter. The comparison between the developed method and the optimization tool will be accomplished by means of a consolidated methodology available in the simulation literature. The conclusions will be presented proving the effectiveness of the developed method.

KEYWORDS: Discrete events simulation, optimization method, Genetic Algorithm.

SUMÁRIO

CAPÍTULO 1 – INTRODUÇÃO	16
1.1 CONSIDERAÇÕES INICIAIS	16
1.2 RELEVÂNCIA DA PESQUISA.....	16
1.3 OBJETIVOS DA PESQUISA	19
1.4 CONDIÇÕES DE CONTORNO DA PESQUISA.....	20
1.5 METODOLOGIA DE PESQUISA	22
1.6 ESTRUTURA DA TESE	25
CAPÍTULO 02 - SIMULAÇÃO COMPUTACIONAL	26
2.1 CONSIDERAÇÕES INICIAIS	26
2.2 A EVOLUÇÃO DA SIMULAÇÃO	26
2.3 VANTAGENS E DESVANTAGENS DA SIMULAÇÃO.....	28
2.4 SIMULAÇÃO COMPUTACIONAL	31
2.4.1 Simulação estática e dinâmica	32
2.4.2 Simulação determinística ou estocástica	33
2.4.3 Simulação discreta e contínua	33
2.5 A SIMULAÇÃO COMPUTACIONAL EM AMBIENTES DE MANUFATURA	34
2.6 METODOLOGIAS PARA SIMULAÇÃO COMPUTACIONAL	36
2.8 SIMULAÇÃO COMBINADA A TÉCNICA DE OTIMIZAÇÃO.....	38
2.8.1 Princípio de Funcionamento	40
2.8.2 Metodologia para otimização via simulação	41
2.9 CASOS NA LITERATURA	43
2.10 CONSIDERAÇÕES FINAIS.....	44
CAPÍTULO 03 – ALGORITMO GENÉTICO	45
3.1 CONSIDERAÇÕES INICIAIS	45
3.2 A TEORIA DA EVOLUÇÃO	45
3.3 ALGORITMOS EVOLUTIVOS.....	46
3.4 ALGORITMOS GENÉTICOS	48
3.4.1 Componentes Básicos dos Algoritmos Genéticos	50
3.4.2 Estrutura dos Algoritmos Genéticos	52
3.4.3 Gerações da População Inicial	53
3.4.4 Relação entre tamanho do indivíduo e tamanho da população	53
3.4.5 Função Aptidão e Avaliação da População	55
3.4.6 Representação não binária do cromossomo	56
3.5 OPERADORES DE SELEÇÃO.....	57
3.5.1 Roleta simples ou seleção proporcional	57
3.5.2 Roleta ponderada ou seleção por ordenação	58
3.5.3 Seleção elitista	58
3.5.4 Seleção por Torneio	59
3.6 OPERADORES GENÉTICOS	59
3.6.1 Recombinação	59
3.6.2 Mutação	62
3.7 PARÂMETROS DOS ALGORITMOS GENÉTICOS	63

3.7.1 Tamanho da População.....	64
3.7.2 Número de Gerações	65
3.7.3 Taxa de Cruzamento	66
3.7.4 Taxa de Mutação	67
3.8 TÉCNICAS DE ADAPTAÇÃO NOS PARÂMETROS DOS AG.....	68
3.9 APLICAÇÕES DOS ALGORITMOS GENÉTICOS.....	69
3.10 CONSIDERAÇÕES FINAIS.....	71
CAPÍTULO 4 – PROJETO DE EXPERIMENTOS	72
4.1 CONSIDERAÇÕES INICIAIS	72
4.2 CONCEITOS GERAIS SOBRE EXPERIMENTAÇÃO.....	72
4.2.1 Fator.....	75
4.2.2 Variável de Resposta	75
4.2.3 Efeito.....	75
4.2.4 Interação.....	76
4.2.5 Replicação.....	76
4.2.5 Aleatorização.....	76
4.2.6 Blocação.....	77
4.3 METODOLOGIAS APLICADAS A PROJETOS DE EXPERIMENTOS.....	77
4.4 TÉCNICAS DE PLANEJAMENTO E ANÁLISE DE EXPERIMENTOS	79
4.4.1 Planejamento fatorial completo (2^k)	79
4.4.2 Análise de variância para o planejamento fatorial completo (2^k).....	83
4.4.3 Análise de resíduos das respostas.....	86
4.5 CONSIDERAÇÕES FINAIS.....	87
CAPÍTULO 5 – ANÁLISE DOS PARÂMETROS DO ALGORITMO GENÉTICO	88
5.1 CONSIDERAÇÕES INICIAIS	88
5.2 ANÁLISE DOS PARÂMETROS DO AG NO TEMPO DE CONVERGÊNCIA ..	89
5.3 ANÁLISE NOS PARÂMETROS DO AG NA QUALIDADE DA RESPOSTA ..	91
5.3.1 Metodologia utilizada neste capítulo	91
5.3.2 Reconhecimento e definição do problema.....	93
5.3.3 Escolha dos fatores, níveis e variações.....	94
5.3.4 Seleção da variável de resposta	95
5.3.5 Escolha do projeto experimental.....	95
5.3.6 Execução dos experimentos	96
5.3.7 Análise estatística dos dados.....	99
5.3.8 Conclusões e recomendações	109
5.4 CONSIDERAÇÕES FINAIS.....	110
CAPÍTULO 6 – DESENVOLVIMENTO DO MÉTODO DE OTIMIZAÇÃO	111
6.1 CONSIDERAÇÕES INICIAIS	111
6.2 ADAPTAÇÕES NA ESTRUTURA DO ALGORITMO GENÉTICO.....	112
6.3 ADAPTAÇÕES NO PARÂMETRO TAMANHO DA POPULAÇÃO	113
6.4 CONSIDERAÇÕES SOBRE O PARÂMETRO NÚMERO DE GERAÇÕES	118
6.5 CONSIDERAÇÕES SOBRE OS PARÂMETROS TAXA DE CRUZAMENTO E TAXA DE MUTAÇÃO	118
6.6 MÉTODO PARA OTIMIZAÇÃO DE MODELOS DE SIMULAÇÃO	119
6.7 FERRAMENTA COMPUTACIONAL DESENVOLVIDA.....	122

6.8 CONSIDERAÇÕES FINAIS	123
CAPÍTULO 7 – APLICAÇÃO DO MÉTODO DE OTIMIZAÇÃO PROPOSTO	125
7.1 CONSIDERAÇÕES INICIAIS	125
7.2 JUSTIFICATIVA DO USO DO PROMODEL® / SIMRUNNER®	126
7.3 METODOLOGIA UTILIZADA NESTE CAPÍTULO	127
7.4 OBJETOS DE ESTUDO	128
7.4.1 Primeiro objeto de estudo	128
7.4.2 Segundo objeto de estudo	129
7.4.3 Terceiro objeto de estudo	130
7.4.4 Quarto objeto de estudo	131
7.5 OTIMIZAÇÃO DOS OBJETOS DE ESTUDO	132
7.5.1 Primeiro objeto de estudo	133
7.5.2 Segundo objeto de estudo	139
7.5.3 Terceiro objeto de estudo	146
7.5.4 Quarto objeto de estudo	153
7.6 ANÁLISE DOS RESULTADOS	162
7.7 CONSIDERAÇÕES FINAIS	167
CAPÍTULO 8 – CONCLUSÕES	168
8.1 CONSIDERAÇÕES INICIAIS	168
8.2 CONCLUSÕES E CONTRIBUIÇÕES DA PESQUISA	169
8.3 CONSIDERAÇÕES FINAIS	171
8.4 SUGESTÕES PARA TRABALHOS FUTUROS	172
REFERÊNCIAS BIBLIOGRÁFICAS	173
APÊNDICE A – PUBLICAÇÕES ORIGINADAS	188

LISTA DE FIGURAS

Figura 1.1 – Modelo de Pesquisa para Simulação.....	24
Figura 2.1 – Simulação Determinística comparada com a Simulação Estocástica	33
Figura 2.2 – Simulação Discreta (parte inferior) comparada com a Simulação Contínua (parte superior).....	34
Figura 2.3 – Metodologia de Simulação.....	37
Figura 2.4 – Questionamentos na modelagem, simulação e otimização.....	40
Figura 2.5 – Otimização em simulação	41
Figura 3.1 - Exemplo de codificação de cromossomo	50
Figura 3.3 – Relação entre tamanho da população e tamanho do indivíduo.....	54
Figura 3.4 – Possibilidade de valores para um indivíduo de 5 bits	54
Figura 3.5 – Exemplo de Cruzamento Uniforme	60
Figura 3.6 – Exemplo de um Cruzamento de um Ponto	60
Figura 3.7 – Exemplo de um Cruzamento de dois Pontos	61
Figura 3.8 – Exemplo de um Position Based Crossover	61
Figura 3.9 – Exemplo de Mutação Binária Simples.....	62
Figura 3.10 – Exemplo de Mutação por Troca.....	63
Figura 4.1 – Modelo geral de um sistema de transformação.....	73
Figura 4.2 – Passos propostos para a realização de um projeto de experimentos.....	78
Figura 4.3 – Gráfico do efeito principal – planejamento fatorial 2^k	82
Figura 4.4 – Gráfico de efeitos de interação.....	83
Figura 4.5 - Regiões de rejeição e não-rejeição para uma distribuição F	85
Figura 4.6 – Gráfico de probabilidade normal	87
Figura 5.1 – Fase de conceitualização.....	89
Figura 5.3 – Princípio de funcionamento do AG aplicado a otimização de funções	92
Figura 5.4 – Gráfico dos efeitos principais	100
Figura 5.5 – Análise de variância	100
Figura 5.6 – Gráfico de Pareto para os efeitos padronizados.....	101
Figura 5.7 – Gráfico dos efeitos principais	102
Figura 5.8 – Análise de variância	102
Figura 5.9 – Gráfico de Pareto para os efeitos padronizados.....	103
Figura 5.10 – Gráfico dos efeitos principais	104
Figura 5.11 – Análise de variância.....	104
Figura 5.12 – Gráfico de Pareto para os efeitos padronizados.....	105
Figura 5.13 – Gráfico dos efeitos principais	106
Figura 5.14 – Análise de variância	106
Figura 5.15 – Gráfico de Pareto para os efeitos padronizados.....	107
Figura 5.16 – Gráfico dos efeitos principais	108
Figura 5.17 – Análise de variância.....	108
Figura 5.18 – Gráfico de Pareto para os efeitos padronizados.....	109
Figura 6.1 – Fase de modelagem.....	111
Figura 6.2 – Adaptações na estrutura do Algoritmo Genético.....	112
Figura 6.3 – Adaptação proposta para o parâmetro tamanho da população	117
Figura 6.4 – Fluxograma da primeira fase do método de otimização proposto	120

Figura 6.5 – Fluxograma da segunda fase do método de otimização proposto	121
Figura 6.7 - Comunicação entre a ferramenta desenvolvida e o simulador	123
Figura 7.1 – Fase de modelo de solução.....	125
Figura 7.2 – metodologia para otimização de modelos de simulação.....	127
Figura 7.3 – Ambiente de construção do modelo computacional no ProModel® para o primeiro objeto de estudo	129
Figura 7.4 – Ambiente de construção do modelo computacional no ProModel® para o segundo objeto de estudo	130
Figura 7.5 – Ambiente de construção do modelo computacional do ProModel® para o terceiro objeto de estudo	131
Figura 7.6 – Ambiente de construção do modelo computacional do ProModel® para o quarto objeto de estudo	132
Figura 7.7 – Gráfico com a comparação da qualidade da resposta encontrada na otimização	136
Figura 7.8 – Gráfico com a comparação entre os tempos de processamento da otimização	139
Figura 7.9 – Gráfico com a comparação da qualidade da resposta encontrada na otimização	143
Figura 7.10 – Gráfico com a comparação entre os tempos de processamento da otimização	145
Figura 7.11 – Gráfico com a comparação da qualidade da resposta encontrada na otimização	150
Figura 7.12 – Gráfico com a comparação entre os tempos de processamento da otimização	152
Figura 7.13 – Gráfico com a comparação da qualidade da resposta encontrada na otimização	159
Figura 7.14 – Gráfico com a comparação entre os tempos de processamento da otimização	162
Figura 7.15 – Gráfico com os tempos de processamento da otimização para uma variável de decisão	163
Figura 7.16 – Gráfico com a comparação entre os tempos de processamento da otimização	164
Figura 7.17 – Gráfico com a comparação entre os tempos de processamento da otimização	164
Figura 7.18 – Gráfico com a comparação entre os tempos de processamento da otimização	165
Figura 7.19 – Gráfico com a comparação entre os tempos de processamento da otimização	166
Figura 8.1 – Fase de implementação	168

LISTA DE TABELAS

Tabela 1.1 – Trabalhos pesquisados com a simulação aplicada ao ambiente da manufatura	21
Tabela 2.1 – Softwares de Otimização	39
Tabela 3.1 – Relação da terminologia do AG com a biologia	50
Tabela 4.1 – Matriz de planejamento do experimento 2^3	80
Tabela 5.1 – Fatores, níveis e variações do projeto de experimentos	94
Tabela 5.2 – Matriz com o planejamento dos experimentos	95
Tabela 5.3 – Execução do experimento para a função representada pela Equação 5.1	97
Tabela 5.4 – Execução do experimento para a função representada pela Equação 5.2	97
Tabela 5.5 – Execução do experimento para a função representada pela Equação 5.3	98
Tabela 5.6 – Execução do experimento para a função representada pela Equação 5.4	98
Tabela 5.7 – Execução do experimento para a função representada pela Equação 5.5	99
Tabela 6.1 – Tamanho do indivíduo em relação a variação entre os limites inferior e superior	114
Tabela 6.2 – Relação entre tamanho do indivíduo e tamanho da população	115
Tabela 7.1 – Resultados da otimização do primeiro objeto de estudo no perfil agressivo do <i>SimRunner</i> ®	134
Tabela 7.2 – Resultados da otimização do primeiro objeto de estudo no perfil moderado do <i>SimRunner</i> ®	135
Tabela 7.3 – Resultados da otimização do primeiro objeto de estudo no perfil cauteloso do <i>SimRunner</i> ®	135
Tabela 7.4 – Resultados da otimização do primeiro objeto de estudo pelo método de otimização proposto	135
Tabela 7.6 – Resultados da otimização do segundo objeto de estudo no perfil agressivo do <i>SimRunner</i> ®	141
Tabela 7.7 – Resultados da otimização do segundo objeto de estudo no perfil moderado do <i>SimRunner</i> ®	141
Tabela 7.8 – Resultados da otimização do segundo objeto de estudo no perfil cauteloso do <i>SimRunner</i> ®	142
Tabela 7.9 – Resultados da otimização do segundo objeto de estudo pelo método de otimização proposto	142
Tabela 7.11 – Resultados da otimização do terceiro objeto de estudo no perfil agressivo do <i>SimRunner</i> ®	147
Tabela 7.12 – Resultados da otimização do terceiro objeto de estudo no perfil moderado do <i>SimRunner</i> ®	148
Tabela 7.13 – Resultados da otimização do terceiro objeto de estudo no perfil cauteloso do <i>SimRunner</i> ®	148
Tabela 7.14 – Resultados da otimização do terceiro objeto de estudo pelo método de otimização proposto	149
Tabela 7.16 – Resultados da otimização do quarto objeto de estudo no perfil agressivo do <i>SimRunner</i> ®	155
Tabela 7.17 – Resultados da otimização do quarto objeto de estudo no perfil moderado do <i>SimRunner</i> ®	156

Tabela 7.18 – Resultados da otimização do quarto objeto de estudo no perfil cauteloso do <i>SimRunner</i> ®.....	157
Tabela 7.19 – Resultados da otimização do quarto objeto de estudo pelo método de otimização proposto.....	158

CAPÍTULO 1 – INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é fazer uma apresentação inicial dos principais aspectos relacionados ao tema de pesquisa abordado. Inicialmente, será apresentada a relevância do tema, seguida da definição do objetivo principal, dos objetivos específicos e das condições de contorno deste trabalho.

Na seqüência, será apresentada a metodologia de pesquisa utilizada para a elaboração desta tese de doutorado. Finalmente, será apresentada a estrutura da tese, enfatizando o conteúdo de cada capítulo.

1.2 RELEVÂNCIA DA PESQUISA

Segundo Harrel, Ghosh e Bowden (2000), simulação computacional é a imitação de um sistema real ou hipotético, modelado em computador, para avaliação e melhoria de seu desempenho. Ou seja, simulação é a importação da realidade para um ambiente controlado onde se pode estudar o comportamento do mesmo, sob diversas condições, sem riscos físicos e/ou grandes custos envolvidos. Já Banks (2000) afirma que a simulação computacional envolve a criação de uma história artificial da realidade e, com base nesta história artificial, são realizadas observações e inferências nas características de operação do sistema real representado.

Para Shannon (1998) a simulação computacional é uma poderosa ferramenta na análise de processos e sistemas complexos, tornando possível o estudo, análise e avaliação de situações que não seriam possíveis na vida real. Em um mundo em crescente competição, tem se tornado uma metodologia indispensável de resolução de problemas para os tomadores de decisão nas mais diversas áreas.

Segundo Banks *et al.* (2005), a simulação computacional é mais amplamente utilizada em sistemas de manufatura do que em qualquer outra área. Adicionalmente,

O'kane, Spenceley e Taylor (2000) afirmam que a simulação tem se tornado uma das técnicas mais populares para se analisar problemas complexos em ambientes da manufatura. Algumas razões podem ser enumeradas:

- O aumento da produtividade e qualidade na indústria é um resultado direto da automação, melhor analisada pela simulação;
- Os custos de equipamentos e instalações são enormes;
- Os custos dos computadores estão cada vez mais baixos e mais rápidos;
- Melhorias nos softwares de simulação reduziram o tempo de desenvolvimento de modelos;
- A disponibilidade de animação resultou em maior compreensão e utilização dos gestores da manufatura.

Adicionalmente, Ryan e Heavey (2006) afirmam que a maioria dos sistemas de manufatura são complexos e de difícil operacionalização de forma eficiente. Devido à sua grande versatilidade, flexibilidade e poder de análise, a simulação é uma das técnicas mais amplamente utilizadas nestes tipos de sistemas.

Segundo Cheng, Feng e Hsu (2006) existem duas formas de usar a simulação na avaliação e melhoria do desempenho de um processo. Uma delas é selecionar todas as configurações de recursos disponíveis e então executar a simulação para cada uma delas, analisando os resultados encontrados. Tal processo pode ser muito tedioso e consumir muito tempo. Outra forma de avaliação consiste em testar algumas combinações de recursos, com base em algum critério de seleção, na tentativa de otimizar o desempenho do processo avaliado.

Harrel, Ghosh e Bowden (2000) definem otimização como o processo de testar diferentes combinações de valores para variáveis que podem ser controladas em ordem de procurar a combinação de valores que fornece o resultado mais desejável do modelo de simulação.

A otimização de modelos de simulação computacional a eventos discretos tem se tornado cada vez mais comum. Fu (2002) afirma que durante a década de 90, a simulação e a otimização eram mantidas separadamente na prática. Atualmente, essa

integração tem se mostrado bastante difundida, principalmente pelo fato de alguns pacotes de simulação incluírem rotinas de otimização. Adicionalmente, Hao e Shen (2008) afirmam que a otimização combinada à simulação tem sido utilizada em diversas aplicações de sistemas produtivos, uma vez que a otimização destes sistemas é bastante complexa para ser resolvida utilizando-se apenas de abordagens matemáticas.

Para Banks *et al.* (2005), a existência de uma variabilidade na amostragem das variáveis de entrada utilizadas, força a otimização via simulação a possuir uma heurística de busca bastante robusta. Muitas heurísticas têm sido desenvolvidas para problemas de otimização que, apesar de não garantirem encontrar a solução ótima, mostram-se muito eficientes em difíceis problemas práticos.

Segundo Fu (2002), as rotinas de otimização implantadas nos programas de simulação são, em maioria, baseadas em metaheurísticas com predominância dos algoritmos evolutivos, tais como os Algoritmos Genéticos, os quais interagem numa família de soluções em vez de um único ponto. De fato, o uso de Algoritmos Genéticos para a otimização é encontrado em alguns pacotes comerciais existentes, tais como ProModel® e AutoMod® (LAW e KELTON, 2000).

Entretanto, uma crítica que se faz aos softwares existentes para a otimização de modelos de simulação é que estes, ao manipularem mais de uma variável de entrada, tornam-se muito lentos (HARREL, GHOSH e BOWDEN, 2000). De fato, a grande limitação para o uso da otimização em simulação é o número de variáveis, sendo seu desempenho reduzido enormemente diante de um modelo com alto número de variáveis a serem manipuladas pela otimização (BANKS, 2001; APRIL *et al.*, 2003; SILVA, 2005; TORGA, 2007).

Adicionalmente, Tyni e Ylinen (2006) afirmam que o tempo de convergência é a restrição mais significativa para se atingir a eficiência computacional do algoritmo de otimização.

1.3 OBJETIVOS DA PESQUISA

O objetivo principal desta pesquisa é desenvolver um método para otimização de modelos de simulação a eventos discretos aplicados a sistemas de manufatura, capaz de atingir os resultados de forma mais rápida, ou seja, mais eficiente, quando comparado a uma ferramenta de otimização comercial. Cabe ressaltar que a qualidade da variável de resposta não será alterada, ou seja, o método desenvolvido manterá a eficácia das soluções encontradas.

Os objetivos específicos desta pesquisa são:

1. Analisar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência desses algoritmos;

A intenção deste objetivo específico é analisar quais dos parâmetros do algoritmo genético (tamanho da população, número de gerações, taxa de cruzamento e taxa de mutação) possuem maior influência no tempo de convergência desses algoritmos. A análise da influência desses parâmetros será realizada através de um levantamento bibliográfico.

2. Analisar a influência dos parâmetros dos algoritmos genéticos na qualidade da variável de resposta desses algoritmos;

A intenção deste objetivo específico é analisar os efeitos principais de cada parâmetro do algoritmo genético, assim como os efeitos de suas interações, na qualidade de resposta desses algoritmos. Também se espera com este objetivo específico verificar qual o peso, ou seja, qual a proporção da importância individual de cada um desses parâmetros na obtenção da qualidade das variáveis de resposta durante o processo de otimização.

A análise desses parâmetros será realizada através da técnica de projeto de experimentos aplicada a algumas funções matemáticas selecionadas. Cabe ressaltar

que este objetivo específico só será possível através do desenvolvimento de uma ferramenta computacional capaz de permitir a manipulação desses parâmetros durante o processo de otimização destas funções.

3. Desenvolver uma ferramenta computacional capaz de operacionalizar o método de otimização proposto no objetivo principal desta tese de doutorado;

A intenção deste objetivo específico é desenvolver uma ferramenta computacional capaz de executar, automaticamente, os procedimentos necessários para a aplicação do método de otimização proposto. Além disso, tal ferramenta computacional permitirá a comparação do método de otimização proposto com um software de otimização comercial.

1.4 CONDIÇÕES DE CONTORNO DA PESQUISA

A Tabela 1.1, mostra um resumo de alguns trabalhos pesquisados que também possuem aplicações focadas no ambiente da manufatura.

Nota-se, nos trabalhos apresentados nesta tabela, que as variáveis de entrada utilizadas na simulação são, em sua grande maioria, de natureza discreta, determinística e do tipo inteira. De fato, das variáveis listadas, apenas a demanda não atende a estas características.

Outra constatação é que estas variáveis possuem uma pequena variação entre seus limites inferiores e superiores, ou seja, dificilmente tem-se alguma dessas variáveis assumindo uma faixa de valores muito grande. Por exemplo: número de operadores pode variar de 1 a 5; número de máquinas pode variar de 2 a 4; número de *kanbans* pode variar de 15 a 25; etc.

Tabela 1.1 - Trabalhos pesquisados com a simulação aplicada ao ambiente da manufatura

Aplicação da Simulação	Variáveis de entrada utilizadas	Trabalhos
Otimização de um processo produtivo (produzir um conjunto de tarefas no menor tempo possível e com menor custo).	Número de máquinas, número de ferramentas e tipo de operação.	Drstvensek <i>et al.</i> (2004)
Otimização da utilização dos recursos disponíveis em um projeto de edificação.	Recursos disponíveis (operários, equipamentos, etc.)	Zhang e Li (2004)
Balanceamento de uma linha de montagem.	Número de estações de trabalho e número de operadores.	Mendes <i>et al.</i> (2005)
Aplicação da simulação e da otimização em uma célula de manufatura, fazendo uso do Custeio Baseado em Atividades (ABC) para encontrar o menor custo de produção.	Número de operadores e número de máquinas.	Silva (2005)
Controle de produção de um sistema de produção puxado.	Número de <i>kanbans</i> .	Treadwell e Herrmann (2005)
Otimização da fase de planejamento do projeto de uma nova linha de manufatura.	Número de operadores, número de inspetores e quantidade de <i>buffers</i> .	Brighenti (2006)
Analisar e projetar as operações em uma construção civil para otimização da performance.	Recursos disponíveis: guindastes, operadores, caminhões, etc.	Cheng, Feng e Hsu (2006)
Análise da capacidade de produção e dimensionamento de estoque.	Número de operadores, tipo de operação, local de execução da atividade.	Leal <i>et al.</i> (2006)
Balanceamento de linha.	Máquina nova com características diferentes.	Masood (2006)
Aumento de produtividade em uma linha de montagem de chassis.	Número de operadores e quantidade de postos de trabalho	Pinho <i>et al.</i> (2006)
Análise do fluxo de processo de uma célula de manufatura combinando as inspeções de qualidade com a programação da produção.	Número de máquinas e número de inspeções.	Siemiatkowski e Przybylski (2006)
Problemas de roteirização.	Número de ônibus existentes e demanda	Bachelet eYon (2007)
Avaliação de um processo produtivo.	Número de mesas de montagem e capacidade do buffer	Montevechi <i>et al.</i> (2007)
Desenvolvimento de um novo sistema de manufatura.	Número de funcionários e local de trabalho.	Oliveira (2007)
Análise de valor em uma cadeia de suprimentos.	Demanda de produtos, característica de um novo produto e um novo processo.	Rabelo <i>et al.</i> (2007)
Otimização na redução do número de <i>kanbans</i> de produção de um sistema de manufatura puxado.	Número de <i>kanbans</i> .	Torga (2007)
Redução no número de inspeções mantendo a qualidade do produto final.	Existência ou não de um estágio de inspeção	Volsem, Dullaert e Van Landeghem (2007)
Avaliação de um processo produtivo.	Número de máquinas, número de turnos e número de operadores.	Montevechi <i>et al.</i> (2008a)
Avaliação de um processo produtivo	Número de operadores, número de bancadas com <i>setup</i> e número de bancadas sem <i>setup</i> .	Montevechi <i>et al.</i> (2008b)

Desta forma, pode-se afirmar que o método de otimização desenvolvido nesta pesquisa restringe-se a modelos de simulação computacional a eventos discretos, cujas variáveis de entrada são do tipo discretas, determinísticas e inteiras, além de possuir uma pequena variação entre seus limites inferiores e superiores.

Esta limitação não inviabiliza a pesquisa. Ao contrário, conforme observado na Tabela 1.1, diversas aplicações enquadram-se dentro destas limitações. Cabe ressaltar que já foi desenvolvido pelo grupo de trabalho, ao qual o pesquisador faz parte, diversos trabalhos de simulação a eventos discretos em empresas da região. Todos os trabalhos realizados pelo pesquisador obedecem às condições de contorno aqui estabelecidas.

1.5 METODOLOGIA DE PESQUISA

Gil (1999) afirma que toda 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. Desta forma, tem-se que a pesquisa é a construção de conhecimento original de acordo com certas exigências científicas. A pesquisa científica deve ser coerente, consistente, original e objetiva.

Conforme Jung (2003), a execução de uma pesquisa depende das técnicas e procedimentos a serem adotados para a coleta e análise dos dados, sua natureza e objetivos requerem ferramentas adequadas para a resolução dos problemas de pesquisa. Isso significa que existem vários tipos de pesquisas que são adotados em função das necessidades práticas de execução.

Portanto, em relação aos procedimentos de execução desta pesquisa, pode-se classificar esta tese como *Simulação*, pois segundo Bertrand e Fransoo (2002), a simulação deve ser usada quando se deseja prever o efeito de mudanças no sistema ou avaliar seu desempenho ou comportamento. É utilizada na resolução de problemas reais, durante o gerenciamento de operações, que envolve processos de projeto, planejamento, controle e operação, seja em indústrias de manufatura ou de serviços.

Adicionalmente, Bertrand e Fransoo (2002) definem modelos quantitativos como modelos que são baseados em conjuntos de variáveis que se alteram sobre um domínio específico. Estes mesmos autores dividem as metodologias de pesquisa para modelagens quantitativas em duas classes: pesquisas axiomáticas e pesquisas empíricas. Nas pesquisas axiomáticas a preocupação primária do pesquisador é obter soluções dentro do modelo definido. A pesquisa axiomática produz conhecimento sobre o comportamento de certas variáveis neste modelo. Enquanto que na pesquisa empírica a preocupação primária do pesquisador é assegurar que existe um modelo ajustado entre as observações e as ações da realidade.

Ainda segundo os mesmos autores, as pesquisas Axiomáticas e Empíricas podem ser classificadas como Descritivas e Normativas.

- Empírica Descritiva: a principal preocupação é criar um modelo que descrevas as relações causais existentes na realidade, a fim de permitir um maior entendimento do processo;
- Empírica Normativa: A principal preocupação é desenvolver políticas, estratégias e ações para melhorar a situação atual;
- Axiomática Descritiva: o pesquisador busca um modelo conceitual (normalmente da literatura) e desenvolve um modelo científico;
- Axiomática Normativa: A pesquisa central se dá através do modelo de solução do processo.

Em metodologias de pesquisas envolvendo a simulação, tem-se, também, o modelo de pesquisa desenvolvido por Mitroff *et al.* (1974), mostrado na Figura 1.1.

Na fase de conceitualização, o pesquisador desenvolve um modelo conceitual do problema que gostaria de estudar. Definem-se, nesta fase, as variáveis relevantes do problema. Na fase de modelagem, constrói-se um modelo quantitativo que define as relações causais entre as variáveis selecionadas na primeira fase. Na fase de modelo de solução, utiliza-se um modelo de resolução de processos, através de regras matemáticas. Finalmente, na fase de implementação, os resultados do modelo são aplicados.

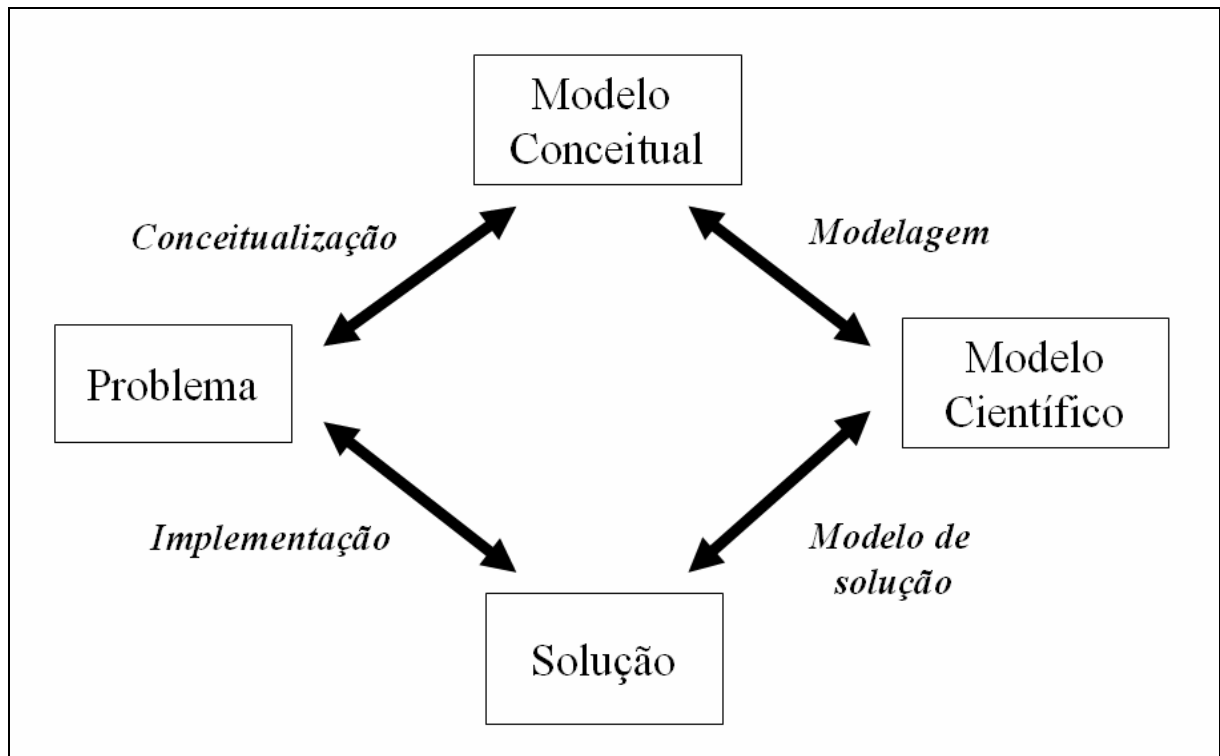


Figura 1.1 – Modelo de Pesquisa para Simulação

Fonte: Adaptado de Mitroff *et al.* (1974)

Adicionalmente, Bertrand e Fransoo (2002) afirmam que nas pesquisas Axiomáticas Descritivas, os pesquisadores não passam pela fase de resolução de problemas. Nas Axiomáticas Normativas, os pesquisadores desenvolvem a modelagem e o modelo de solução. Nas Empíricas Descritivas, os pesquisadores desenvolvem a conceitualização, modelagem e a validação. E finalmente nas Empíricas Normativas, todo o ciclo é desenvolvido, sendo a mais completa das pesquisas.

De acordo com o que foi citado anteriormente, pode-se afirmar que a metodologia de pesquisa utilizada nesta tese é a *Empírica Normativa*. Optou-se por esta metodologia, pois este trabalho preocupa-se em melhorar uma situação atual, ou seja, o desempenho do processo de otimização em modelos de simulação a eventos discretos, e todo o ciclo de Mitroff *et al.* (1974) será considerado.

1.6 ESTRUTURA DA TESE

Esta tese está dividida em oito capítulos, sendo que no capítulo 1, tem-se a introdução. A revisão bibliográfica está dividida entre os capítulos 2, 3 e 4, correspondendo aos capítulos sobre simulação computacional, algoritmos genéticos e projeto de experimentos respectivamente.

O capítulo 5 faz uma análise da influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade da resposta desses algoritmos.

Na seqüência, tem-se o capítulo 6, que apresenta a proposta de um método de otimização para modelos de simulação a eventos discretos aplicados a sistemas de manufatura.

Já o capítulo 7 mostra a aplicação do método de otimização proposto aplicado a quatro objetos de estudo distintos. Este capítulo também faz uma comparação entre o método de otimização proposto e o *SimRunner*®, uma ferramenta de otimização conhecida comercialmente.

Finalmente, o capítulo 8 traz as conclusões obtidas nesta tese de doutorado.

CAPÍTULO 02 - SIMULAÇÃO COMPUTACIONAL

2.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é apresentar uma revisão bibliográfica a respeito da simulação computacional. Inicialmente será levantado o histórico e a evolução da simulação computacional, além das vantagens e desvantagens da utilização da simulação.

Em seguida, serão apresentados os principais aspectos sobre a simulação computacional, seguido de sua aplicação nos sistemas de manufatura. Também será apresentada uma abordagem metodológica para se trabalhar com simulação computacional.

Finalmente, os principais fundamentos da combinação da otimização com a simulação serão apresentados, com destaque a uma pesquisa realizada em aplicações atuais da simulação computacional combinada com a otimização.

2.2 A EVOLUÇÃO DA SIMULAÇÃO

Pinho *et al.* (2006) destacam que a simulação computacional é a representação de um sistema em um modelo através do computador, com a vantagem de se poder visualizar o funcionamento desse sistema e de implementar mudanças, além de responder a questões do tipo: “o que aconteceria se”, economizando desta maneira recursos econômicos e tempo.

A aplicação da simulação computacional teve início na década de 60 juntamente com a introdução dos primeiros computadores no mercado, já que devido ao grande número de cálculos matemáticos necessários à simulação numérica, sua utilização sem o auxílio de um computador seria inviável. As primeiras aplicações desta ferramenta foram na área militar, tendo como objetivo principal o planejamento da distribuição de suprimentos nas frentes de batalha e alocação de recursos (TORGA, 2007).

A simulação computacional foi desenvolvida primeiramente utilizando-se de linguagens de programação, principalmente *Fortran* e *Pascal* (GAVIRA, 2003). No entanto, sistemas de maior complexidade apresentavam limitações tanto na modelagem computacional como na execução da simulação tornando a utilização da ferramenta, através destas linguagens de programação, em alguns casos inviável (CHWIF e MEDINA, 2006).

Essa evolução a partir da década de 60 se deu em função da necessidade de desenvolvimento de ferramentas mais efetivas como consequência de uma demanda maior em termos de resultados mais confiáveis e de uma melhor visualização de seus benefícios por parte dos usuários. O surgimento de softwares específicos acoplados a simuladores capazes de reproduzir graficamente o funcionamento de sistemas ilustra essa idéia. Dentre as vantagens da utilização dos softwares de simulação pode-se citar a facilidade de compreensão, o treinamento de pessoal e uma melhor visualização do sistema produtivo das indústrias (SILVA, 2005).

Mesmo após o reconhecimento relativo à eficiência da simulação computacional, seu uso ainda demanda muito tempo de treinamento, caso os usuários não tenham um conhecimento prévio. A construção dos modelos e animações é demorada, e os analistas precisam ter conhecimento do sistema que estão simulando. Em função disso, tem sido proposta uma nova tecnologia, conhecida como VIS - *Visual Interactive Simulation* (GAVIRA, 2003).

Esta nova tecnologia, base dos atuais softwares de simulação, realiza a modelagem através de ícones agrupando comandos das linguagens tradicionais de simulação, e tornando o trabalho de desenvolvimento mais fácil, através de uma interface semelhante à do *Windows*, mas muito mais amigável, reduzindo drasticamente o tempo de treinamento.

Embora as linguagens de programação utilizadas até então ainda possam ser utilizadas, isso raramente ocorre. Existem pacotes de simulação disponíveis no mercado que atualmente apresentam inúmeras vantagens em termos de facilidade de uso, eficiência e eficácia dos resultados obtidos. Dentre as vantagens em se usar os pacotes de simulação pode-se ressaltar (SHANNON, 1998):

- Redução na tarefa de programar;
- Aumento da flexibilidade de realizar mudanças nos modelos;
- Menos erros de programação;
- Análise de dados estatísticos.

O objetivo dos pacotes de simulação é diminuir o espaço entre a conceituação que o usuário tem do modelo e sua forma executável. Os pacotes de simulação são divididos em duas categorias: uma de propósito geral e outra de propósito específico. Na primeira categoria estão os pacotes que podem resolver problemas em geral de simulação a eventos discretos, como ARENA®, AweSim®, GPSS/H™, Simscript II.5®, Extend™ etc. Na segunda categoria estão os pacotes utilizados na simulação de problemas específicos, tais como sistemas de manufatura e manuseio de material. Os pacotes SimFactory, ProModel®, AutoMod™, Taylor II® e Witness® se enquadram nesta categoria, assim como os pacotes designados para a condução de estudos de reengenharia de processos, como BPSimulator™, processModel™, SIMPROCESS® e Extend+BPR. Outros pacotes possuem o objetivo de simular áreas como a da saúde, como o MedModel®, ou redes de comunicação, como o COMNET II.5 (SHANNON, 1998).

2.3 VANTAGENS E DESVANTAGENS DA SIMULAÇÃO

Os modelos de simulação apresentam inúmeras vantagens em relação aos modelos analíticos. Sua conceituação é de mais fácil compreensão principalmente na gerência da organização. Além disso, é capaz de comparar o modelo virtual com a situação real e assim proporcionar maiores contribuições para o objeto de estudo.

Lacksonen (2001) destaca que a simulação é uma importante ferramenta de análise para projetos de sistemas produtivos complexos.

Já Kelton (1999) afirma que o uso da simulação na realização de experimentos possibilita um conjunto de oportunidades, muitas vezes impossível em situações do dia a dia de uma empresa.

Banks *et al.* (2005) destacam algumas vantagens da simulação, tais como:

- Tomada de decisão: a simulação possibilita testar todos os aspectos de uma proposta de mudança com menor gasto de recursos;
- Desacelerar e acelerar o tempo: podem-se analisar fenômenos variando a velocidade do tempo de simulação;
- Entendimento do porquê: gestores freqüentemente querem saber o porquê de certos fenômenos ocorrerem em um sistema real. Com a simulação, é possível determinar as respostas das questões reconstruindo a situação;
- Explorar possibilidades: uma das grandes vantagens da simulação, uma vez que se tenha desenvolvido um modelo de simulação válido, é a possibilidade de explorar novas políticas, processos operacionais, ou métodos, sem uma experimentação direta no sistema real, o que certamente envolveria maiores custos;
- Diagnóstico de problemas: as modernas fábricas de manufatura ou organizações de serviços possuem processos complexos, sendo impossível considerar todas as interações que ocorrem em um local em dado momento. Com a simulação é possível avaliar os efeitos das variáveis e suas interações sobre o sistema;
- Identificação das restrições: a presença de gargalos na produção causa efeitos indesejados. A simulação é capaz de conduzir o analista do problema às causas das esperas dos materiais, das informações, do trabalho em si, etc.;
- Desenvolvimento do conhecimento: o estudo de simulação promove o entendimento sobre como o sistema realmente funciona, ao invés de uma informação prescritiva;
- Visualização da planta: dependendo do software utilizado, é possível visualizar as operações sob diferentes pontos de vista;
- Construção de um consenso: é possível, com a simulação, evitar inferências feitas para aprovar ou reprovar projetos, pois estas podem ser simuladas e seus efeitos demonstrados. Além disto, tendo um modelo testado, validado e visualmente representado, torna-se mais fácil aceitar os resultados da simulação do que a opinião isolada de uma pessoa;

- Preparação para mudanças: respondendo as questões “o que aconteceria se”, cria-se uma situação desejável tanto para desenvolvedores de novos sistemas quanto ao reprojeto de sistemas já existentes;
- Investimentos com sabedoria: o custo típico de um estudo de simulação é substancialmente menor do que a quantia total gasta na implementação de projetos ou reprojeto;
- Treinamento da equipe: modelos de simulação podem proporcionar excelentes treinamentos quando projetados para tal. Esta estratégia é mais barata e menos problemática que o treinamento *on the job*;
- Especificação das necessidades: a simulação pode ser utilizada para especificar necessidades para um projeto de sistema.

Apesar das inúmeras vantagens de sua utilização, a simulação apresenta algumas desvantagens, como se pode observar a seguir.

Segundo Law e Kelton (2000) as desvantagens da simulação são:

- Os modelos de simulação são, em geral, caros e consomem tempo para serem desenvolvidos;
- Cada rodada de cada modelo de simulação estocástico só estima as características verdadeiras do mesmo para um número particular de parâmetros de entrada. Assim, serão necessárias várias rodadas independentes para cada conjunto de parâmetros a serem estudados. Por essa razão é que os modelos de simulação geralmente não são tão eficientes em relação a otimização;
- A grande quantidade de dados gerados por um estudo de simulação faz com que as pessoas confiem no modelo mais do que deveriam. Se um modelo não for a representação adequada de um sistema, não importa o tipo de informação que será obtida, a real utilidade será mínima.

Já de acordo com Banks *et al.* (2005), as desvantagens da simulação são as seguintes:

- A construção de modelos requer treinamento especial: esta é uma arte aprendida com a experiência na realização desta tarefa. É altamente improvável que, dois modelos do mesmo sistema, construídos por pessoas diferentes, sejam iguais;
- A modelagem e a análise podem tomar muito tempo, acarretando um alto valor financeiro: restringindo indevidamente os recursos para a modelagem e análise, podem-se obter resultados insuficientes para as questões a serem respondidas;
- A simulação pode ser utilizada inapropriadamente: neste caso, a simulação é utilizada em casos onde uma solução analítica é possível, ou mesmo preferível.

Outra desvantagem refere-se aos conceitos utilizados em simulação. Segundo Habchi e Berchet (2003), em muitos casos, as ferramentas de simulação usam conceitos ainda muito complexos para a maioria dos usuários em potencial.

2.4 SIMULAÇÃO COMPUTACIONAL

Balci (2003) define a simulação computacional destacando a importante função de realizar experimentos. Segundo o autor a simulação é o ato de experimentar ou executar um modelo ou um número de modelos sob diversos objetivos, como aquisições de dados, análises e treinamentos.

Para Shannon (1998), a simulação computacional tem se tornado uma metodologia indispensável de resolução de problemas nas mais diversas áreas. Johansson (2002) reforça esta diversidade de áreas de aplicação mostrando como a simulação tem sido utilizada desde a representação de operações militares, operações logísticas, linhas de manufatura até operações na área de saúde.

Para Law e Kelton (2000), simulação computacional é a representação de um sistema real através de um computador para a posterior realização de experimentos para avaliação e melhoria de seu desempenho. Isto significa a importação da realidade para um ambiente controlado onde se pode estudar seu comportamento sob diversas condições, sem os riscos físicos e/ou custos envolvidos em um estudo convencional.

Já para Banks (1998), a simulação é uma metodologia indispensável de solução para números problemas da vida real. A simulação é utilizada para descrever e analisar o comportamento dos sistemas através de questões “o que aconteceria se” em relação a situação real.

Strack (1984) recomenda a utilização da simulação quando:

- Não há uma formulação matemática completa para o problema;
- Não há método analítico para a resolução do modelo matemático;
- Resultados são mais fáceis de serem obtidos por simulação que por qualquer outro método analítico;
- Não existe habilidade técnica para a resolução do modelo matemático por técnica analítica ou numérica;
- Torna-se necessário observar o desenvolvimento do processo desde o início até o seu término;
- Quando são necessários detalhes específicos do sistema;
- Quando a experimentação na situação real apresenta inúmeros obstáculos ou não é possível.

A maneira como a simulação computacional do sistema trabalha, seja com o uso de distribuições estatísticas, considerando-se o tempo ou não, ou através do uso de variáveis discretas ou contínuas, está diretamente relacionada com o tipo de simulação utilizada (HARREL, GHOSH e BOWDEN, 2000). As classificações mais usuais são: dinâmica ou estática; determinística ou estocástica; discreta ou contínua. A seguir são apresentados com mais detalhes essas classificações.

2.4.1 Simulação estática e dinâmica

Para Law e Kelton (2000), simulação estática é a representação de um sistema em um dado momento. Um exemplo é a simulação de Monte Carlo, bastante utilizada na área financeira e na área de estoques.

Os mesmos autores definem a simulação dinâmica como a representação de um sistema no decorrer do tempo. Esse tipo de simulação é apropriado para a análise de

sistemas de manufatura e serviços que sofrem influência do tempo. Um exemplo é a simulação das atividades ocorridas em um banco ao longo de suas oito horas de funcionamento diárias.

2.4.2 Simulação determinística ou estocástica

Para Pereira (2000), os modelos de simulação são determinísticos quando as variáveis de entrada assumem valores exatos, assim, os resultados (saídas) desse tipo de simulação serão sempre os mesmos, independentemente do número de replicações.

Os modelos estocásticos permitem que as variáveis de entrada assumam valores dentro de uma distribuição de probabilidades a ser definida pelo modelador. Os resultados gerados pelos modelos estocásticos são diferentes a cada replicação, em função da natureza aleatória das variáveis de entrada no modelo.

A Figura 2.1 mostra a diferença existente entre a simulação com dados de entrada determinístico e estocástico.

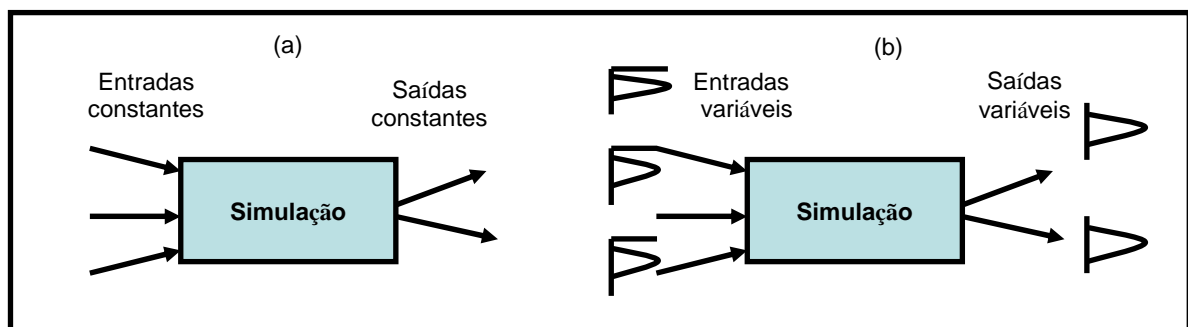


Figura 2.1 – Simulação Determinística (a) comparada com a Simulação Estocástica (b)

Fonte: DUARTE (2003)

2.4.3 Simulação discreta e contínua

Para Strack (1984), a simulação contínua modela sistemas em que suas variáveis mudam continuamente de valor. É utilizada em estudos que consideram os sistemas constituídos por um fluxo contínuo de informações ou itens.

Já a simulação discreta caracteriza-se por variáveis de estado onde as mudanças ocorrem de maneira descontínua, ou seja, sofrem mudanças bruscas. A Figura 2.2

ilustra a diferença entre os tipos de simulação discreta e contínua.




Figura 2.2 – Simulação Discreta (parte inferior) comparada com a Simulação Contínua (parte superior)

Fonte: DUARTE (2003)

2.5 A SIMULAÇÃO COMPUTACIONAL EM AMBIENTES DE MANUFATURA

Diversos autores (HARREL, GHOSH e BOWDEN, 2000; LAW e KELTON, 2000; BANKS, 2000; BALCI, 2003; JOHANSSON, 2002) concordam sobre a possibilidade de aplicação da simulação nas mais diferentes áreas, desde a área de saúde, até a militar. No entanto, neste trabalho a linha de estudo é a manufatura.

Segundo Banks *et al.* (2005), a simulação é uma das ferramentas mais amplamente utilizada em sistemas de manufatura do que em qualquer outra área.

O’Kane, Spenceley e Taylor (2000) afirmam que a simulação tem se tornado uma das técnicas mais populares para se analisar problemas complexos em ambientes da manufatura. A simulação é uma ferramenta muito útil, uma vez que prevê o comportamento de sistemas complexos, indicando os movimentos e interações dos componentes deste sistema.

Seguindo uma linha de raciocínio similar a de Banks *et al.* (2005), Ryan e Heavey (2006) afirmam que a maioria dos sistemas de manufatura são complexos e difíceis, no que tange ao seu entendimento e a sua operacionalização de forma eficiente. Devido à sua grande versatilidade, flexibilidade e poder de análise, a simulação é uma das técnicas mais amplamente utilizadas nestes tipos de sistemas.

Alguns exemplos de estudos que podem ser realizados na manufatura através da simulação são (LAW e MCCOMAS, 1999):

1. Necessidade extra de material e pessoal:

- Número, tipo e layout das máquinas para um determinado objetivo;
- Necessidade de abastecedores, *conveyors* e outros equipamentos de suporte (*pallets* e fixadores);
- Localização e tamanho dos estoques;
- Avaliação de possíveis mudanças no volume dos produtos ou no *mix*;
- Avaliação dos efeitos de introdução de novos equipamentos em um sistema de produção;
- Avaliação de investimentos de capital;
- Planejamento das necessidades de mão de obra;
- Número de carregamentos.

2. Avaliação de desempenho:

- Análise do fluxo dos produtos;
- Análise de tempo do sistema;
- Análise de gargalo.

3. Avaliação dos procedimentos operacionais:

- Programação da produção;
- Políticas de inventário;
- Estratégias de controle;
- Políticas de controle da qualidade.

Algumas das medidas de desempenho mais comuns que podem ser avaliadas com a simulação da manufatura são:

- O tempo das peças no sistema;
- O tempo das peças em espera/fila;

- O tamanho das filas;
- Tempo de entrega;
- Utilização dos equipamentos e pessoas.

2.6 METODOLOGIAS PARA SIMULAÇÃO COMPUTACIONAL

Segundo Silva (2005), a modelagem computacional de um sistema é uma tarefa que exige muito esforço por parte do modelador, porém se conduzida com raciocínio cuidadoso e planejado, poderá trazer benefícios muito proveitosos. A simulação computacional envolve mais do que a utilização de um software. Trata-se de um projeto que requer um planejamento prévio de cada uma de suas etapas e, além disso, um conhecimento do sistema a ser simulado e das pessoas envolvidas.

Segundo Strack (1984), os resultados insatisfatórios do uso da ferramenta ocorrem em função da não valorização do aspecto humano da simulação. O sucesso depende da habilidade do usuário em analisar as saídas, identificar alternativas de projeto e novas configurações para melhoria do modelo.

Grande parte dos trabalhos de simulações mal sucedidos tem como causa a ausência de um planejamento condizente com a importância de seu estudo. Por isso, simular requer mais do que o conhecimento de um *software* específico, mas também, pessoas com conhecimento dos passos a serem seguidos, bem como experiência analítica, estatística e organizacional (SILVA, 2005).

A metodologia nos trabalhos de simulação busca sistematizar as atividades de desenvolvimento, facilitando a integração entre *software*, modelador e usuário, e evitando desperdício de tempo, dinheiro e resultados frustrantes. A visualização das etapas e da complexidade de se criar uma representação do sistema real implicam em grandes responsabilidades para o profissional desta área. Resultados podem ser alcançados de maneira muito proveitosa, desde é claro que se siga a metodologia recomendada.

Um exemplo de uma metodologia de simulação foi proposto por Chwif (1999) e Chwif e Medina (2006). Nesta metodologia, os autores afirmam que o

desenvolvimento de um modelo de simulação compõe-se de três grandes etapas: concepção ou formulação do modelo, implementação do modelo e análise dos resultados do modelo. Esta metodologia de simulação é mostrada na Figura 2.3.

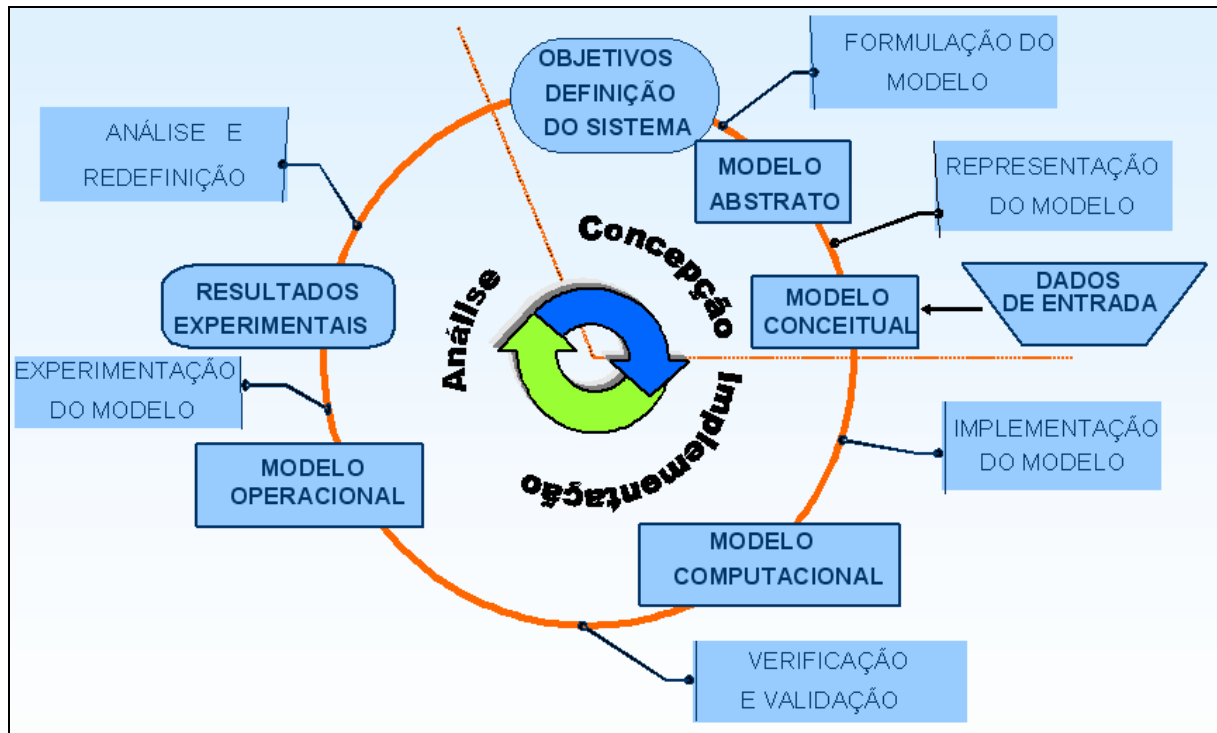


Figura 2.3 – Metodologia de Simulação

Fonte: Chwif e Medina (2006)

Na fase de *concepção* deve-se entender claramente o sistema a ser simulado e os seus objetivos. Deve-se, também, decidir com clareza qual será o escopo do modelo, suas hipóteses e seu nível de detalhamento. Os dados de entrada também são coletados nesta fase. Ainda nesta fase, o modelo que está na mente do analista (modelo abstrato) deve ser desenhado de acordo com alguma técnica de representação de modelos de simulação, a fim de torná-lo um *modelo conceitual*, de modo que outras pessoas envolvidas no projeto possam entendê-lo.

Na segunda fase, *implementação*, o modelo conceitual é convertido em um *modelo computacional* através da utilização de alguma linguagem de simulação ou de um simulador comercial. Com o avanço tecnológico dos simuladores atuais, a etapa de implementação já não consome tanto tempo como no passado. O modelo computacional implementado deve ser comparado frente ao modelo conceitual, com a

finalidade de avaliar se a sua operação atende ao que foi estabelecido na etapa de concepção. Alguns resultados devem ser gerados para a verificação e validação do modelo computacional.

Na terceira fase, *análise*, o modelo computacional está pronto para a realização dos experimentos, dando origem ao *modelo experimental* ou *modelo operacional*. Nesta etapa são efetuadas várias rodadas do modelo e os resultados da simulação são analisados e documentados. A partir dos resultados, conclusões e recomendações sobre o sistema podem ser geradas. Caso necessário, se o resultado da simulação não for satisfatório, o modelo pode ser modificado, e este ciclo é reiniciado.

Chwif e Medina (2006) destacam que as fases mostradas na Figura 2.3 não devem ser interpretadas como uma seqüência linear. Em um estudo prático podem ocorrer diversas iterações e realimentações no processo, à medida que o entendimento do problema muda.

Ainda segundo os autores, a melhor maneira é imaginar que o projeto de simulação desenvolve-se em forma espiral, em que as etapas são repetidas na seqüência apresentada na Figura 2.3.

2.8 SIMULAÇÃO COMBINADA A TÉCNICA DE OTIMIZAÇÃO

Conforme descrito anteriormente, dentre as vantagens de se utilizar a simulação está a possibilidade de se responder a questões do tipo “o que aconteceria se...?”, ou seja, avaliando os resultados do modelo para determinadas condições. Assim, para usar a simulação na avaliação e melhoria do desempenho de um processo, é necessário construir cenários e logo em seguida executar a simulação para cada uma deles, analisando os resultados encontrados (OPTQUEST FOR ARENA USER’S GUIDE, 2002). Tal processo, apesar de ser capaz de gerar bons resultados, pode ser muito cansativo e consumir muito tempo, além disso, não garante na maioria das vezes que as melhores configurações sejam experimentadas.

O intuito de se associar as técnicas de otimização e simulação é justamente resolver tais problemas. Esta associação envolve algumas terminologias como

“otimização para simulação”, “otimização via simulação” e “otimização em simulação”, sendo estas duas últimas as mais utilizadas (FU, 2002).

A Tabela 2.1 apresenta exemplos de alguns *softwares* de otimização existentes no mercado, assim como os pacotes de simulação aos quais estão incluídos. Apresentam-se, também, as técnicas de otimização utilizadas por esses pacotes.

Tabela 2.1 – Softwares de Otimização

Fonte: Law e Kelton (2000)

Software de otimização	Pacote de simulação	Técnica de otimização
AutoStat	AutoMod	Algoritmos Evolutivos e Algoritmos genéticos
OptQuest	Arena, Crystal Ball, etc.	Busca <i>Scatter</i> , Tabu e Redes Neurais
OPTIMIZ	SIMUL8	Redes Neurais
SimRunner	ProModel	Algoritmos Evolutivos e Algoritmos genéticos
Optimizer	WITNESS	<i>Simulated annealing</i> e busca tabu

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

Segundo FU (2002), até a última década, a simulação e a otimização eram mantidas separadamente na prática. Atualmente, essa integração tem se mostrado bastante difundida, principalmente pelo fato de alguns pacotes de simulação incluírem rotinas de otimização.

2.8.1 Princípio de Funcionamento

Um sistema pode ser descrito como uma relação *entrada-saída*, onde X é a *entrada*, Y a *saída* e M é uma representação a qual correlaciona as informações de entrada e saída. A partir deste conceito de sistema é possível fazer uma comparação entre modelagem, simulação e otimização: a modelagem é a busca das inter-relações existentes entre os dados de entrada e de saída de um determinado sistema, ou seja, uma representação de seu comportamento; a simulação manipula as entradas de um modelo e verifica suas diferentes saídas; já a otimização busca obter uma saída ótima, previamente definido, alterando a composição das entradas (PROTIL, 2001).

Tal comparação é apresentada na Figura 2.4.

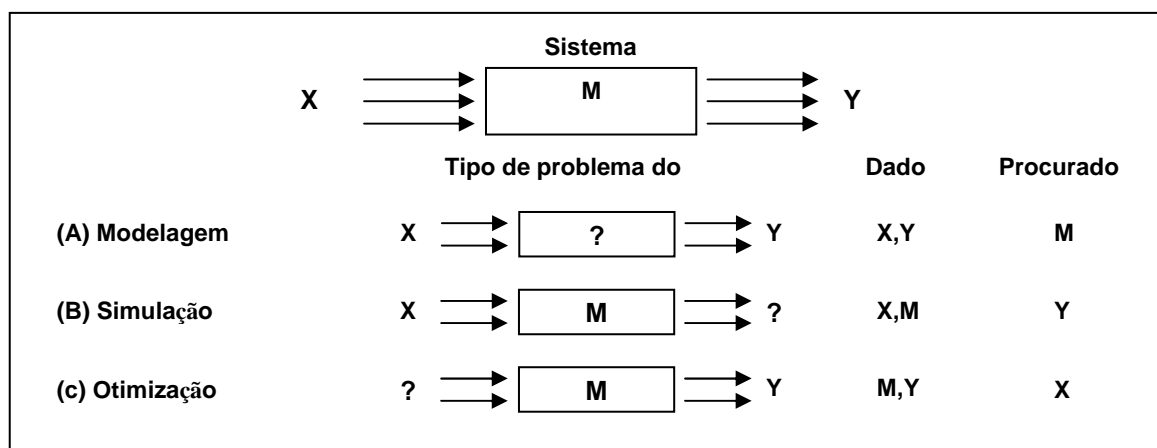


Figura 2.4 – Questionamentos na modelagem, simulação e otimização

Fonte: Adaptado de PROTIL (2001)

O processo de otimização testa várias combinações de valores para variáveis que podem ser controladas (variáveis independentes), na tentativa de busca da solução ótima. Em muitos casos não é possível avaliar todas as combinações prováveis de variáveis devido ao grande número de combinações possíveis. Nestes casos o uso de algoritmos heurísticos de otimização devem ser utilizados. Para FU (2002), a otimização deve ocorrer de maneira complementar a simulação, fornecendo as variáveis de uma possível solução (*inputs*) à simulação, e esta, fornecendo respostas (*outputs*) para a situação proposta, que retornam ao processo de otimização, caso a solução não seja considerada satisfatória.

A otimização gera novos valores para as variáveis, utilizando técnicas de otimização específicas, que serão novamente testadas pela simulação. Este ciclo, representado na Figura 2.5, é repetido até sua parada, definida de acordo com o método de otimização utilizado. Quando o método de otimização é baseado em algoritmos de busca, para cada possível solução é efetuada uma tentativa, ou seja, um ciclo.

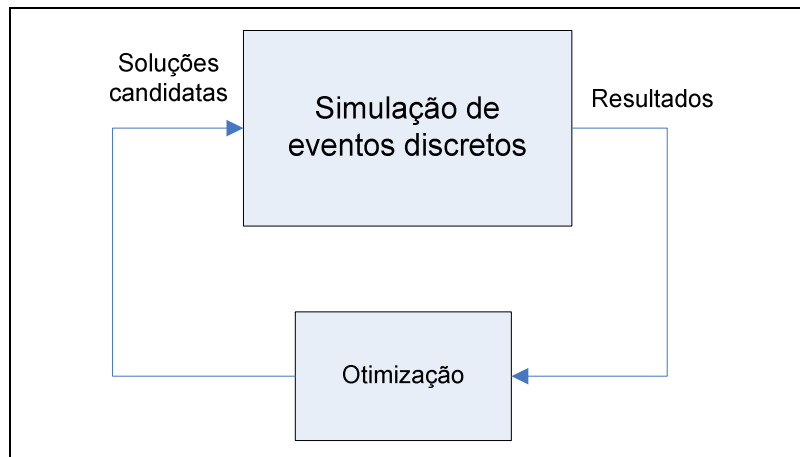


Figura 2.5 – Otimização em simulação

Fonte: FU (2002).

A grande limitação para o uso da otimização em simulação é o número de variáveis, sendo seu desempenho reduzido enormemente diante de um modelo com alto número de variáveis a serem manipuladas pela otimização.

2.8.2 Metodologia para otimização via simulação

Geralmente as metodologias de otimização em simulação partem de um modelo já existente e validado. O primeiro passo é a definição das variáveis de decisão, ou seja, as variáveis que afetam a função objetivo do problema. Em seguida se define a função objetivo, que pode ser de maximização ou minimização, cujo resultado será avaliado pelos algoritmos de otimização na busca de um valor ótimo. O passo seguinte é a definição das restrições do problema seguido pela configuração de alguns parâmetros, como: número de replicações, precisão e critério de parada (SILVA, 2005).

Harrel, Ghosh e Bowden (2000) propuseram uma metodologia específica para o uso do SimRunner®. Segundo os autores, após a construção e validação de um modelo, são necessários alguns passos para uma otimização bem sucedida. Estes passos são listados a seguir.

1. Definir as variáveis que afetarão as respostas do modelo e que serão testadas pelo algoritmo de otimização. São estas variáveis que terão o valor alterado a cada rodada de simulação;
2. Definir o tipo de variável (real ou inteira) e limites inferiores e superiores. Durante a busca, o algoritmo de otimização gera soluções respeitando o tipo das variáveis e seus limites. O número de variáveis de decisão e a gama de valores possíveis afetam o tamanho do espaço de busca, alterando a dificuldade e o tempo consumido para identificar a solução ótima. É por isso que se recomenda que somente as variáveis que afetem significativamente o modelo sejam usadas;
3. Definir a função objetivo para avaliar as soluções testadas pelo algoritmo. Na verdade, a função objetivo já poderia ter sido estabelecida durante a fase de projeto do estudo de simulação. Esta função pode ser construída tendo por base peças, equipamentos, operários entre outros, buscando minimizar, maximizar ou fazer uso de ambos em diferentes variáveis, dando inclusive pesos diferentes para compor a função objetivo;
4. Selecionar o tamanho da população do algoritmo evolutivo. O tamanho da população de soluções usado para conduzir o estudo afeta a confiabilidade e o tempo requerido para a condução da busca, assim, é necessário que haja um equilíbrio entre o tempo requerido e o resultado esperado da otimização. Nesta fase também é importante definir outros parâmetros como: precisão requerida, nível de significância e número de replicações;
5. Após a conclusão da busca um analista deve estudar as soluções encontradas, uma vez que, além da solução ótima, o algoritmo encontra várias outras soluções competitivas. Uma boa prática é comparar todas as soluções tendo como base a função objetivo.

Cabe ressaltar que mesmo seguindo metodologias para a execução da otimização em simulação alguns fatores afetam diretamente o desempenho da busca, entre eles: precisão do modelo, número de variáveis, complexidade da função objetivo, valores iniciais das variáveis e seus limites (OPTQUEST FOR ARENA USER'S GUIDE, 2002).

2.9 CASOS NA LITERATURA

Zhang e Li (2004) integraram a simulação de eventos discretos com um algoritmo heurístico no modelo de otimização proposto. A intenção foi otimizar a alocação dos recursos disponíveis em projetos de construção de edificações.

Silva (2005), em sua dissertação de mestrado utiliza a simulação para aplicar o sistema ABC de custeio em uma linha de produção, verificando as mudanças encontradas nos custos para uma nova configuração do sistema produtivo. Além disso, utilizou a otimização para a redução de tais custos. O software de simulação utilizado foi o PROMODEL e o software de otimização foi o SIMRUNNER.

Cheng, Feng e Hsu (2006) realizaram um trabalho de simulação nas operações de construção de edificações. O objetivo era a otimização, através dos algoritmos genéticos, do desempenho do sistema de produtivo da construção, com melhor utilização compartilhada dos recursos disponíveis.

Bachelet e Yon (2007) combinaram as técnicas de otimização e simulação com o intuito de melhorar a solução alcançada através da modelagem matemática. Esta proposta foi aplicada em um problema de roteirização.

Volsem, Dullaert e Van Landeghem (2007) otimizaram um procedimento de inspeção de um processo produtivo, para redução de custos, através da simulação de eventos discretos. A otimização proposta foi realizada através de algoritmos evolucionários.

Yang, Fu e Yang (2007) realizam uma pesquisa direcionada para o uso de algoritmos evolucionário como técnica de otimização combinada com a simulação. A intenção foi a redução do WIP (*work in process*).

Torga (2007) verifica a real potencialidade do uso conjunto da simulação e da otimização na redução do número de *kanbans* de produção de um sistema de manufatura puxado. O trabalho desenvolvido mostrou-se uma boa alternativa para a análise de dimensionamento de estoques.

2.10 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os principais aspectos relacionados a simulação computacional, principalmente quando aplicada em ambientes de manufatura, além de destacar a utilização de metodologias aplicadas em projeto de simulação computacional.

O maior destaque deste capítulo refere-se a simulação computacional combinada a técnica de otimização. Mostrou-se o crescente uso dessas duas técnicas combinadas, além de uma metodologia para otimização via simulação.

CAPÍTULO 03 – ALGORITMO GENÉTICO

3.1 CONSIDERAÇÕES INICIAIS

Inicialmente, neste capítulo, será mostrado como a teoria da evolução deu origem aos algoritmos evolutivos e aos algoritmos genéticos, com destaque aos aspectos principais desses algoritmos. Em seguida, será mostrado o princípio de funcionamento dos operadores de seleção, evidenciando sua importância no funcionamento dos algoritmos genéticos. Na sequência, serão apresentados os operadores genéticos para cruzamento e mutação.

Posteriormente, serão apresentados os fundamentos sobre os parâmetros dos algoritmos genéticos, e como esses parâmetros interferem no resultado final do problema. Será dado um especial destaque às divergências de suas configurações existentes na literatura.

Será mostrado, também, como as técnicas de adaptações nos algoritmos genéticos têm sido usadas para melhorar o desempenho desses algoritmos. Por fim, será apresentada uma pesquisa realizada em aplicações atuais dos algoritmos genéticos.

3.2 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 (TORGA, 2007).

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 é 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.

3.3 ALGORITMOS EVOLUTIVOS

Algoritmos evolutivos (EA) são uma classe de técnicas de procura direta baseados na teoria da evolução. Estes algoritmos simulam o processo de evolução onde os seres vivos se adaptam ao meio ambiente para sobreviver. Também manipulam uma população de soluções de forma que as piores soluções desapareçam e as melhores evoluam em busca da solução ótima. Técnicas de procura baseadas nesse conceito possuem grande robustez e tem sido utilizada para resolver inúmeros problemas de grande complexidade (ZHANG e ISHIKAWA, 2004).

As teorias evolucionárias mais amplamente aceitas baseiam-se no paradigma neo-Darwiniano (FOGEL, 1994). Tais teorias afirmam que a história da vida pode ser completamente descrita por processos físicos (reprodução, mutação, competição e seleção) que operam sobre ou entre populações e espécies. Os indivíduos e as espécies podem ser vistos como uma combinação de sua programação genética (genótipo) e a expressão de seu comportamento (fenótipo), determinado pelas condições ambientais, sobre os quais estes processos físicos agem. A evolução é vista como um processo que age em busca do ótimo, pois a seleção produz fenótipos tão próximos do ótimo quanto

possível, a partir da especificação de um estado inicial e das restrições ambientais (CHEN e LIN, 2007).

Segundo Harrel, Ghosh e Bowden (2000), os algoritmos evolutivos diferem das técnicas não lineares de otimização em vários aspectos. As diferenças mais significativas estão na forma como eles conduzem a busca pela superfície de resposta utilizando uma população de soluções ao invés de utilizar somente um valor, permitindo a coleta de informações sobre a superfície de resposta de diversas formas simultaneamente. Tal abordagem aumenta as chances de se encontrar a solução ótima.

Os algoritmos evolutivos são divididos, de uma forma geral, nos seguintes grupos: estratégias evolutivas e programação evolutiva.

As *estratégias evolutivas* foram desenvolvidas pelos alemães Ingo Rechenberg e Hans-Paul Schwefel em meados da década de 70, com o objetivo inicial de solucionar problemas complexos, discretos e contínuos, principalmente experimentais (BÄCK, HAMMEL e SCHWEFEL, 1997).

Ao contrário dos algoritmos genéticos, que também empregam cruzamentos, este método emprega apenas operadores de mutação. Em um esquema bem simplificado da estratégia evolutiva, um indivíduo-pai gera um só filho através de aplicação de mutações de distribuição Gaussiana, média zero e variância variável, de modo que pequenas mutações ocorram mais frequentemente que mutações mais radicais. Sempre que um filho “melhor” que o pai é gerado, o pai é substituído e o processo é reiniciado (TANOMARU, 1995).

Os métodos de *programação evolutiva* (também chamados de programação evolucionária) foram desenvolvidos por Lawrence J. Fogel em 1962, e foi originalmente concebido como uma tentativa de criar inteligência artificial (BÄCK, HAMMEL e SCHWEFEL, 1997). Porém este método tem sido também usado em problemas de otimização e é, neste caso, virtualmente equivalente às estratégias evolutivas, diferenciando-se apenas nos procedimentos de seleção e codificação de indivíduos.

Segundo Tanomaru (1995), na programação evolutiva há uma população de n indivíduos que são copiados na totalidade numa população temporária e sofrem mutações variáveis. Um torneio estocástico é realizado para extrair a população

seguinte desse grupo de indivíduos. Não há nenhuma restrição que implique em um tamanho de população constante e não há recombinação entre os indivíduos.

3.4 ALGORITMOS GENÉTICOS

O algoritmo genético (AG) foi inicialmente proposto por Holland (1975), inspirando-se no mecanismo da evolução das espécies, tendo como base os trabalhos de Darwin sobre a origem das espécies e a genética natural devida principalmente a Mendel (FRAILE-ARDANUY e ZUFIRIA, 2007).

De acordo com a teoria da evolução das espécies de Darwin, uma população sujeita a um ambiente qualquer, sofrerá influências deste, de tal forma que os mais aptos terão probabilidade de sobreviver a este ambiente. Já os trabalhos de Mendel mostram como o material genético dos pais pode ser passado aos seus descendentes. Desta forma, a cada nova geração tem-se uma população mais adaptada ao ambiente em questão.

Em contraste com estratégias evolutivas e programação evolutiva, o objetivo original de Holland (1975) não foi criar algoritmos para solucionar problemas específicos, mas formalizar o estudo do fenômeno de adaptação como acontece na natureza, e desenvolver métodos de adaptação natural para que sejam inseridos em sistemas computacionais.

No entanto, segundo Goldberg e Luna (2000), ao representar o processo evolutivo tendo como partida o modelo de cromossomos, Holland foi capaz de encontrar um método de grande e imediata aplicação prática em problemas como máximos e mínimos de funções matemáticas, facilitando a aceitação do algoritmo genético no meio acadêmico.

Dentre as definições de AG que se encontram na literatura tem-se a de Costa *et al.* (2007), que define o AG como um método computacional de busca baseado em mecanismos de evolução natural e de genética. Em um AG, uma população de possíveis soluções para o problema em questão evolui de acordo com operadores probabilísticos concebidos a partir de metáforas biológicas, de modo que há uma

tendência de que os indivíduos representem soluções cada vez melhores à medida que o processo evolui.

Cabe ressaltar que, apesar de determinar o conjunto de pontos a ser percorrido de forma aleatória, os algoritmos genéticos não podem ser chamados de buscas aleatórias não-direcionadas, pois exploram informações históricas para encontrar novos pontos de busca onde são esperados bons desempenhos (CARVALHO, BRAGA e LUDEMIR, 2003).

O AG é considerado muito eficiente na busca de soluções ótimas, ou quase ótimas, para uma grande variedade de problemas, pois não impõem tantas limitações como ocorre nos métodos tradicionais (FÜHNER e JUNG, 2004).

Rivera *et al.* (2006) afirmam que o algoritmo genético supera diversas técnicas e ferramentas de auxílio à tomada de decisão, tendo-se tornado bastante poderoso e eficaz em diversas aplicações de engenharia.

Miranda (2005) destaca que uma das vantagens do AG é permitir a simplificação na formulação e solução de problemas de otimização, sendo assim indicados para a solução de problemas complexos envolvendo um grande número de variáveis e, conseqüentemente, espaços de soluções de dimensões elevadas.

Tanomaru (1995) classificou o AG como método probabilístico de busca e otimização, sendo mais eficiente que algoritmos aleatórios devido à combinação de métodos de buscas diretas e estocásticas, tornando-os suficientemente complexos para fornecer mecanismos de busca mais poderosos e robustos em relação aos já existentes.

Segundo Goldbarg, Goldbarg e Medeiros Neto (2004), o AG difere dos métodos tradicionais pelas seguintes características:

- Opera sobre uma população de pontos e não sobre um ponto isolado;
- Opera em um espaço de soluções codificadas e não em um espaço de busca diretamente;
- Necessita somente de informação sobre o valor de uma função objetivo para cada membro da população sem qualquer outro tipo de conhecimento;
- Usam-se transições probabilísticas e não regras determinísticas.

3.4.1 Componentes Básicos dos Algoritmos Genéticos

O AG adota uma terminologia original usada na teoria da evolução natural e da genética, onde um indivíduo de uma população pode ser formado por um ou mais cromossomos. Pode se utilizar o termo indivíduo ou cromossomo indistintamente para o caso de um indivíduo ser representado por um único cromossomo. O cromossomo pode ser denominado de *string* e, em geral, implementados como vetores, onde cada elemento do vetor é conhecido como gene, conforme mostra a Figura 3.1. Os possíveis valores que cada gene pode assumir é denominado de alelo, possuindo um local fixo no cromossomo denominado de lócus. Genes e alelos em conjunto formam então o genótipo, com suas características tratadas de fenótipo.




Figura 3.1 - Exemplo de codificação de cromossomo

A relação entre a terminologia dos algoritmos genéticos e a biologia, segundo Barboza (2005), aparece resumida na Tabela 3.1.

Tabela 3.1 – Relação da terminologia do AG com a biologia

Fonte: (Barboza, 2005)

Biologia	Algoritmo Genético
Cromossomo	Indivíduo (<i>string</i>)
Gene	Bit
Alelo	Valor do Bit
Lócus	Posição de um bit específico no indivíduo
Genótipo	Indivíduo candidato à solução – x
Fenótipo	Valor da função para um dado indivíduo – $f(x)$

Em uma aplicação de AG o primeiro passo consiste em representar uma possível solução em um espaço de busca como uma seqüência de símbolos (cromossomo),

gerados a partir de um alfabeto finito, que no caso mais simples usa-se o alfabeto binário $\{0,1\}$. A representação desse alfabeto varia dependendo do problema em questão.

Um fluxograma genérico capaz de englobar a maioria dos Algoritmos Genéticos existentes é apresentado na Figura 3.2.

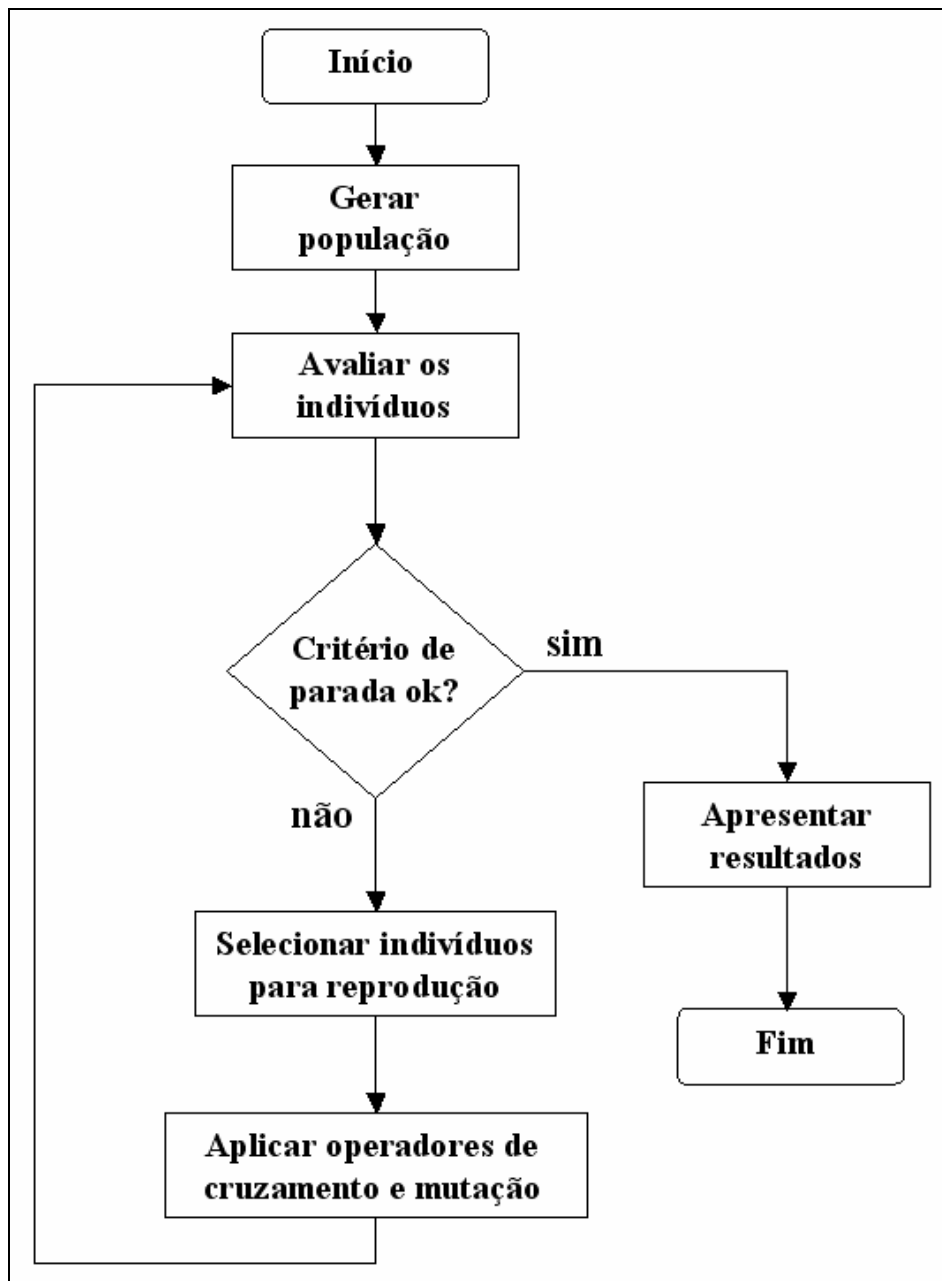


Figura 3.2 – AG genérico (fluxograma)

No AG trabalha-se com um conjunto de indivíduos denominado de população, onde cada elemento desta população é candidato a solução do problema. A função a ser otimizada representará o ambiente onde a população inicial se insere, e espera-se

que através de mecanismos da evolução das espécies e da genética natural, indivíduos mais adaptados tenham maior probabilidade de se reproduzirem, assim uma nova geração mais adaptada ao ambiente se formará. A próxima geração será uma evolução da anterior e, para que isso ocorra, os indivíduos mais adaptados deverão possuir uma maior probabilidade de serem selecionados para darem origem à nova geração, não descartando que alguns indivíduos pouco adaptados podem ser selecionados.

Esse mecanismo que faz a escolha seletiva dos indivíduos é denominado de seleção, e o próximo passo após a seleção é aplicar os operadores genéticos sobre os genótipos dos indivíduos selecionados produzindo novos indivíduos, também denominados de mecanismos de busca (SUMMANWAR *et al.*, 2002). Dentre os mecanismos mais comuns empregados são o cruzamento ou recombinação e a mutação. Se as operações de seleção, recombinação e mutação forem bem realizadas, espera-se que a nova geração seja em média, melhor do que a lhe deu origem.

3.4.2 Estrutura dos Algoritmos Genéticos

Existem inúmeras estruturas de AG. O que se distingue uma estrutura da outra são as variações que ocorrem com relação aos procedimentos e operadores empregados (CASTRO, 2001). Há dois tipos de AG que podem ser citados, o geracional e o de estado estacionário, os quais diferem em relação à maneira como os indivíduos criados são inseridos na população.

Em uma estrutura *geracional* toda geração anterior (pais) é inteiramente substituída pela outra (filhos), não existindo convivência, ocorrendo desta forma uma perda dos bons indivíduos envolvidos no processo. Por este motivo, especialmente em problemas de otimização, um método frequentemente empregado é o que chamamos de elitismo, onde os melhores indivíduos de uma geração são preservados e repassados à geração seguinte.

Já em uma estrutura de *estado estacionário* apenas um indivíduo é criado de cada vez, e depois de sua avaliação, este será ou não inserido na população, em substituição a algum outro elemento, como por exemplo, em substituição a aquele elemento que tiver menor valor de aptidão. Em geral, nesse tipo de estrutura, costuma-se ordenar os

elemento que compõem a população pelo valor da aptidão, para facilitar a substituição do pior elemento.

3.4.3 Gerações da População Inicial

Como já dito, os algoritmos genéticos manipulam um conjunto de caracteres dos cromossomos (indivíduo). Desta forma, deve-se especificar muito bem a codificação desse cromossomo, para que este represente de forma correta elementos do espaço de busca do problema. Na maioria das aplicações a população inicial é gerada aleatoriamente ou através de algum processo heurístico que evite indivíduos infactíveis.

Reeves (1995) relata que ao direcionar a população inicial com o auxílio de alguma heurística, de modo a obter indivíduos de boa qualidade, o AG pode então chegar a soluções melhores mais rapidamente comparado ao processo de geração aleatória dos cromossomos. Por outro lado, pode ocorrer um processo de convergência prematura, o que não é conveniente para a resolução do problema. É importante lembrar que a população inicial deve cobrir a maior parte do espaço de busca da solução.

Cabe ressaltar que o tamanho da população inicial é considerado um dos quatro parâmetros existentes no algoritmo genético, juntamente com a quantidade máxima de gerações, a taxa de cruzamento e a taxa de mutação. Estes parâmetros serão mais detalhados no item 3.7 deste capítulo.

3.4.4 Relação entre tamanho do indivíduo e tamanho da população

Um indivíduo da população é a representação, de uma possível solução, em forma de uma seqüência de símbolos, que no caso desta tese de doutorado, usou-se o alfabeto binário $\{0,1\}$. O tamanho da população é representado pelo conjunto de indivíduos.

A relação entre tamanho da população e o tamanho do indivíduo de uma população é representada na Figura 3.3.

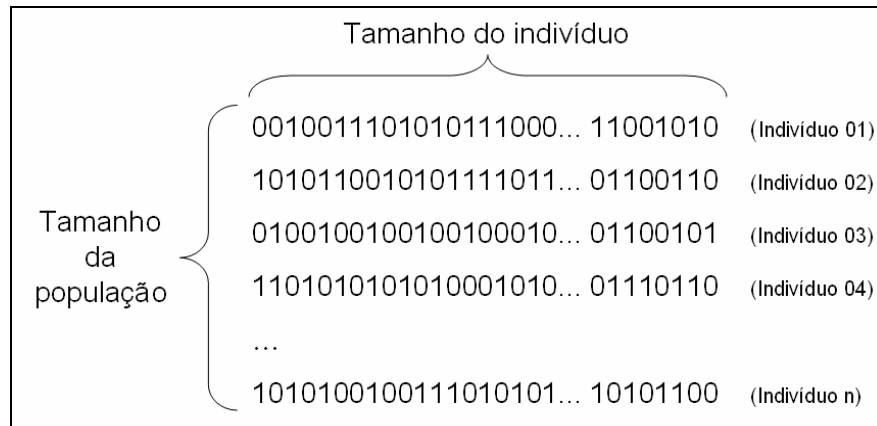


Figura 3.3 – Relação entre tamanho da população e tamanho do indivíduo

Davis (1991) afirma que o tamanho do indivíduo pode ser representado, nos algoritmos genéticos, através da quantidade de *bits*. Desta forma, um indivíduo com 5 *bits* de tamanho poderia assumir 2^5 , ou seja, 32 valores diferentes. A Figura 3.4 mostra as possibilidades de valores para um indivíduo com 5 *bits* de tamanho.

Indivíduo com 5 bits	Valores que cada indivíduo pode assumir
0 0 0 0 0	= 0
0 0 0 0 1	= 1
0 0 0 1 0	= 2
0 0 0 1 1	= 3
0 0 1 0 0	= 4
...	
1 1 1 1 1	= 31

Figura 3.4 – Possibilidade de valores para um indivíduo de 5 bits

Segundo Linden (2006), deve-se escolher a quantidade de *bits* necessária para o tamanho do indivíduo com base na variação entre seus limites inferiores e superiores e na precisão desejada. A Equação 3.1, retirada de Mitchell (1996), mostra a relação entre estes fatores.

$$\text{Precisão} = \frac{\text{sup}_i - \text{inf}_i}{2^k - 1} \tag{3.1}$$

Sendo:

k – número de bits do cromossomo;

$[inf_i, sup_i]$ – limites inferior e superior da faixa de operação (variação).

Por exemplo, para uma variação de $[-100, 100]$ e uma precisão de 0,0001, a quantidade de *bits* necessária para o indivíduo será:

$$0,0001 = \frac{100 - (-100)}{2^k - 1} \Rightarrow k = 20,93 \Rightarrow k = 21 \quad (3.2)$$

Ou seja, para as condições estabelecidas anteriormente, serão necessários 21 *bits* para o tamanho do indivíduo.

Adicionalmente, Linden (2006) estabelece que para a representação de mais de um número dentro do mesmo indivíduo, coloca-se estes números lado a lado, como uma concatenação de textos. Assim, os primeiros k_1 *bits* representam x_1 , os k_2 *bits* seguintes representam x_2 e assim por diante. É normal que $k_1 = k_2 = \dots = k_n$, mas é possível que as necessidades de precisão para cada número sejam diferentes, o que faz com que esta igualdade não seja obrigatória.

3.4.5 Função Aptidão e Avaliação da População

O grau de aptidão do indivíduo é conhecido como aptidão ou *fitness*, e é obtida através de uma função a ser otimizada ao avaliar o cromossomo (indivíduo), ou seja, a aptidão é um valor obtido com a aplicação desta função, que pode ser conhecido através da quantificação da aptidão do indivíduo. Se o objetivo for maximizar, a aptidão é diretamente proporcional ao valor da função, caso for minimizar, a aptidão é inversamente proporcional ao valor da função, este último não é bem aceito por alguns pesquisadores biológicos, pois os indivíduos mais aptos é que devem ter maiores chances de sobreviver (SILVA e BISCAIA JR, 2003).

Segundo Koza, Keane e Streeter (2003), a função de avaliação deve refletir os objetivos a serem alcançados na resolução de um problema e é derivada diretamente

das condições impostas por esse problema. Por exemplo, se um engenheiro tem um problema que consiste em criar um circuito que tenha um desempenho 1000 vezes melhor que um circuito padrão, a função de avaliação deve avaliar quão perto deste fator o circuito criado chegou. Assim, um circuito que maximize o desempenho em 990 vezes é melhor que um circuito que atinja um desempenho em 980.

Quanto maior for o valor da aptidão, maiores serão as chances do indivíduo sobreviver no ambiente e reproduzir-se, passando seu material genético para futuras gerações.

Segundo Falcão e Borges (2001), nos problemas de otimização sem restrições, o valor da aptidão do indivíduo pode corresponder ao valor da função objetivo, diferente dos problemas com restrições, onde uma abordagem comum seria a utilização da função aptidão associada a uma função de penalidade.

A avaliação da população é processada após cada aplicação dos operadores de seleção, recombinação e mutação, determinando o grau de adaptação da população atual para análise da convergência ou continuidade do processo. Quando o grau de adaptação for aceitável, o melhor indivíduo desta população provavelmente será a solução desejada. Este grau de adaptação pode ser obtido pela diferença entre a aptidão do primeiro e a do último elemento da lista de cromossomos.

A definição desta lista de cromossomos, esta intimamente ligada ao conhecimento do problema (LINDEN, 2006).

3.4.6 Representação não binária do cromossomo

A representação binária para cromossomos é historicamente importante, uma vez que foi utilizado nos trabalhos pioneiros de Holland (1975). É a representação tradicional, sendo fácil de utilizar e manipular, como também é simples de analisar teoricamente. Contudo, se um problema tem parâmetros contínuos e o usuário quer trabalhar com boa precisão numérica, ele precisará armazenar cromossomos relativamente longos na memória.

Herrera, Lozano e Verdegay (1998) chamam a atenção três situações onde a representação binária não é a mais adequada:

- Quando se utilizam múltiplas dimensões de variáveis contínuas, especialmente quando uma grande precisão é necessária;
- Quando existe um número finito de estados distintos para um parâmetro que não é múltiplo de dois;
- Os operadores de cruzamento e mutação binários operam em nível local, por isto têm dificuldades em lidar com cromossomos em que valores não podem ser repetidos, como por exemplo, aqueles que representam listas de valores.

Quando há muitos parâmetros, obtém-se longas cadeias de bits que podem fazer o algoritmo convergir vagarosamente. Além disso, não existe uniformidade nos operadores. Por exemplo, mutação nos primeiros bits do gene afeta mais a aptidão que mutação nos últimos bits do gene.

3.5 OPERADORES DE SELEÇÃO

O operador denominado de seleção é considerado um operador Darwiniano, pois é inspirado nas teorias de Darwin (1859). Segundo Bäck, Fogel e Michalewicz (2000), o operador de seleção é usado para direcionar o processo para melhores regiões no espaço de busca, sendo que sua principal função é selecionar indivíduos melhores adaptados ao ambiente para a reprodução. Alguns operadores de seleção são apresentados a seguir.

3.5.1 Roleta simples ou seleção proporcional

Este método foi proposto inicialmente por Holland (1975), e até hoje é um dos mais usados. Esta técnica considera que a probabilidade de um indivíduo da população vir a ser selecionado é proporcional à sua aptidão relativa. Uma vez definida a forma de quantificação da probabilidade de sobrevivência de cada indivíduo da população, aplica-se o “método da roleta”, que nada mais é do que a forma como cada indivíduo é

representado proporcionalmente a seu valor de aptidão. Assim indivíduos com alta aptidão recebem uma porção maior na roleta, enquanto que os de baixa aptidão recebem uma porção menor na roleta. O sorteio da roleta é efetuado n vezes, para escolher os indivíduos que farão parte da população na próxima geração.

O método da roleta tem a desvantagem de possuir uma alta variância, podendo levar sorteios de um mesmo cromossomo que possui alto valor de aptidão, o que faz diminuir a diversidade da população. Esta falha pode ocasionar uma convergência prematura do algoritmo para uma solução local, por outro lado, quando a evolução está avançada, observa-se uma estagnação do algoritmo (BARBOZA, 2005).

3.5.2 Roleta ponderada ou seleção por ordenação

Esta técnica apresenta os indivíduos ordenados conforme desempenho. Contudo, a distância entre os indivíduos próximos é reduzida, ou seja, a pressão seletiva é atenuada. Cada indivíduo recebe uma nota, sendo que o pior recebe nota “1” e o melhor recebe uma nota no valor do tamanho da população (distância “1” entre cada indivíduo vizinho), portanto o primeiro em aptidão tem a maior probabilidade de ser selecionado, visto que agora a pressão seletiva é atenuada (BARBOZA, 2005).

3.5.3 Seleção elitista

Este tipo de seleção é geralmente acoplado a outros métodos de seleção, no qual consiste em copiar ou reproduzir os indivíduos melhores adaptados de uma população atual para futuras gerações, garantindo que estes cromossomos não sejam destruídos nas etapas de recombinação e mutação.

O método elitista tem como principal vantagem garantir a convergência, de tal forma que se o melhor resultado da busca for alcançado, o AG deve convergir para tal solução, e tem como desvantagem, a possibilidade de forçar a busca, pela presença de mais de uma cópia do melhor indivíduo em direção a algum bom resultado, mas que tenha sido descoberto antes do melhor resultado, embora normalmente o AG consiga escapar de tais armadilhas. O que poderia ser feito é armazenar temporariamente o

melhor resultado encontrado durante a evolução, para que no final, este seja designado como o melhor indivíduo encontrado, mesmo que não esteja presente na última geração do processo (BARBOZA, 2005).

3.5.4 Seleção por Torneio

O método do torneio, como o próprio nome diz, consiste em selecionar uma série de indivíduos da população e fazer com que eles entrem em competição direta pelo direito de ser pai, usando como arma a sua avaliação (LINDEN, 2006).

Nesta forma de seleção, a competição não ocorre entre todos os indivíduos da população, mas em um subconjunto desta população. A idéia consiste em escolher-se k indivíduos da população, extrair o melhor indivíduo deste grupo para uma população intermediária. Este procedimento é repetido até que a população intermediária tenha o mesmo número de indivíduos da população da geração anterior (BARBOZA, 2005).

3.6 OPERADORES GENÉTICOS

Os operadores genéticos são mecanismos de busca designados para a manipulação dos indivíduos que foram selecionados de uma geração anterior, como o objetivo de obter os indivíduos mais adaptados ao ambiente. Estes operadores são basicamente de dois tipos, o de recombinação (*crossover*) e mutação.

3.6.1 Recombinação

A recombinação, também conhecida como cruzamento ou do inglês *crossover*, é o operador responsável pela propagação das características dos indivíduos mais adaptados de uma população (pais), através de um método de troca de segmentos de informações entre eles, dando origem a novos indivíduos. Existem vários métodos de recombinação, e eles diferem entre si, pela escolha do locus do cromossomo a ser trocado entre os cromossomos pais, e pela maneira com será feita essa troca. A seguir

são listados os tipos mais comuns de recombinação encontrados na literatura.

3.6.1.1 Cruzamento Uniforme

Esta recombinação consiste no emparelhamento de dois cromossomos pais, no qual cada locus do cromossomo tem 50% de chance de ser trocado (LINDEN, 2006). Observa-se o exemplo da Figura 3.5, onde um determinado cromossomo que possui 8 loci, sofre um cruzamento no primeiro, quarto e quinto locus.

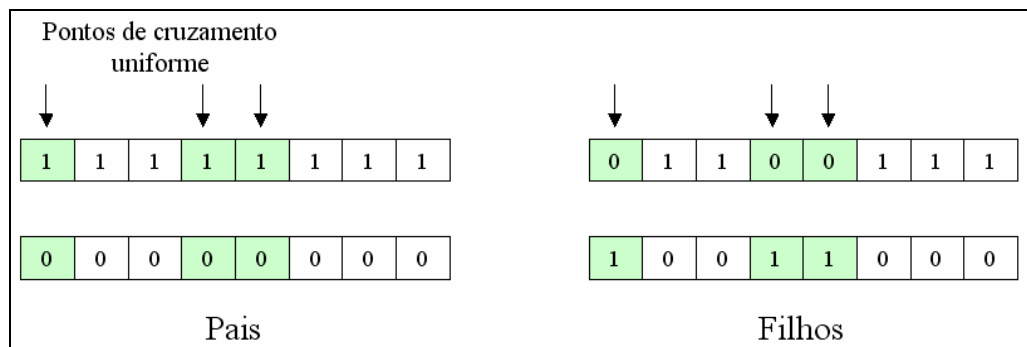


Figura 3.5 – Exemplo de Cruzamento Uniforme

3.6.1.2 Cruzamento de um Ponto

Nesta recombinação um ponto de corte é escolhido aleatoriamente, e a partir deste ponto as informações do código genético dos pais serão trocados. Os filhos serão gerados de acordo com as informações anteriores a este ponto de um dos pais, e completados com as informações posteriores a este ponto do outro pai (BARBOZA, 2005). A Figura 3.6 mostra um exemplo de funcionamento do cruzamento de um ponto.

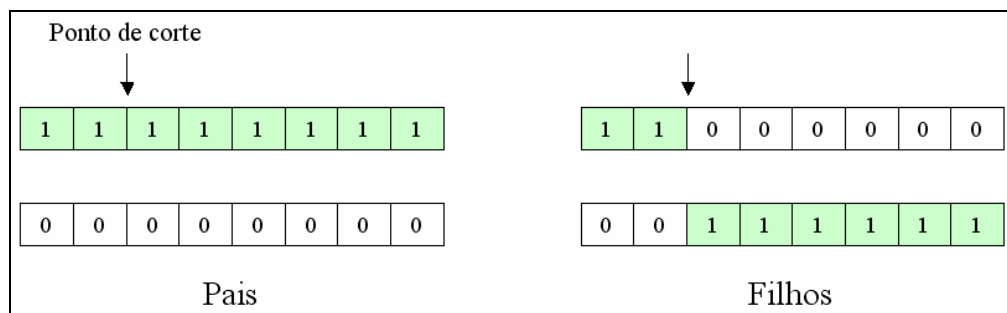


Figura 3.6 – Exemplo de um Cruzamento de um Ponto

3.6.1.3 Cruzamento de dois Pontos

Agora dois pontos são escolhidos aleatoriamente, e a partir desses pontos, as informações dos pais serão trocadas. Todos os materiais genéticos dos pais existentes limitados pelos pontos serão trocados entre eles, e o restante do material genético permanecerá inalterado (LINDEN, 2006). A Figura 3.7 mostra um exemplo de funcionamento do cruzamento de dois pontos.

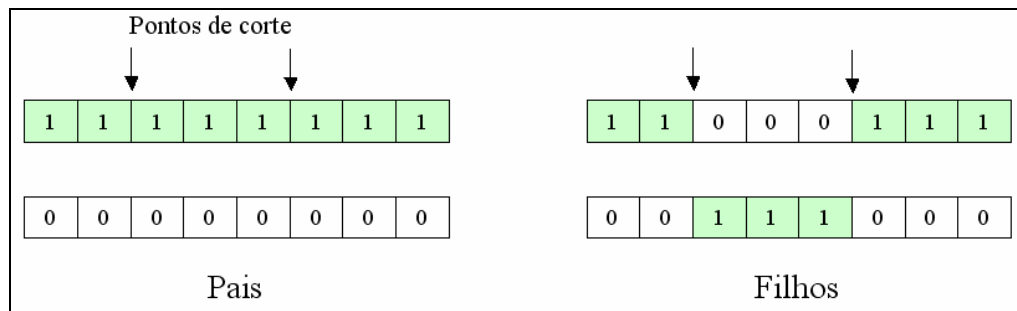


Figura 3.7 – Exemplo de um Cruzamento de dois Pontos

3.6.1.4 Cruzamento Baseado em Maioria

A operação básica dessa recombinação consiste em sortear n pais e fazer com que cada posição k do filho seja igual ao valor da maioria dos pais selecionados. Este tipo de recombinação não é muito utilizada, pois tem a tendência de fazer com que a convergência genética ocorra rapidamente (LINDEN, 2006). A Figura 3.8 mostra um exemplo de funcionamento do cruzamento baseado em maioria.




Figura 3.8 – Exemplo de um Position Based Crossover

No exemplo mostrado na Figura 3.8 foram selecionados três pais, e cada vez que um gene é igual em pelo menos dois indivíduos, este é passado para o filho.

3.6.2 Mutação

Goldberg (1989) afirma que, no AG, o operador de mutação, executa um papel secundário, porém muito importante, possibilitando a restauração da diversidade do código genético que foi eventualmente perdida durante a evolução.

O operador de mutação equivale à uma busca aleatória. Basicamente, ele seleciona uma posição e muda o valor do gene aleatoriamente para um outro gene de um outro alelo possível. Desta forma novos elementos podem ser inseridos na população, sendo então conhecido como o operador genético mais simples de ser implementado.

É importante que esse operador seja implementado, para que ocorra a introdução e manutenção da diversidade genética na população, possibilitando a recuperação de algum código genético que tenha sido perdido após sucessivas recombinações (BARBOZA, 2005).

A seguir são apresentados alguns mecanismos de alteração genética que recebem o nome de mutação.

3.6.2.1 Mutação Binária Simples

Neste tipo de mutação têm-se posições do cromossomo são sorteadas e os genes correspondentes são invertido, ou seja, se o valor do gene for “1”, então muda-se este valor para “0”, e vice-versa (MITCHELL, 1996).

A Figura 3.9 mostra o funcionamento deste operador de mutação.




Figura 3.9 – Exemplo de Mutação Binária Simples

3.6.2.2 Mutação por Troca (*Swap*)

Neste tipo de mutação ocorre uma troca aleatória de posições entre dois genes (SOUZA, 2004). A Figura 3.10 mostra o funcionamento deste operador de mutação.

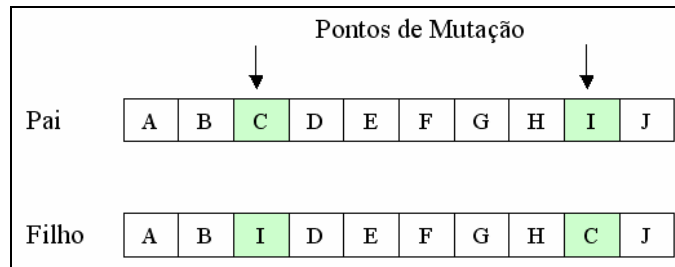


Figura 3.10 – Exemplo de Mutação por Troca

3.7 PARÂMETROS DOS ALGORITMOS GENÉTICOS

Além da escolha do método de codificação do cromossomo, do tipo de função de aptidão, do método de geração da população, dos operadores de seleção, dos operadores de cruzamento e dos operadores de mutação, existem quatro parâmetros que podem ser escolhidos pra melhorar o desempenho do algoritmo genético. Estes parâmetros são: tamanho da população, número de gerações, taxa de cruzamento e taxa de mutação.

Há na literatura uma grande discussão sobre a determinação dos parâmetros dos algoritmos genéticos. Como exemplo, pode-se citar Cunha e Pinto (2001), que afirmam que não existem parâmetros ótimos para os operadores genéticos. Eles são especificados para cada problema, não podendo ser adotado de forma genérica, uma vez que comprometem o desempenho global do algoritmo. Semelhantemente, Núñez-Letamendia (2007) afirma que não existe na literatura um consenso a respeito das definições dos parâmetros dos algoritmos genéticos.

Em um trabalho publicado recentemente Khalik *et al.* (2007) mostram a importância na definição dos parâmetros dos algoritmos genéticos, concluindo que a escolha desses parâmetros não deve ser feita a esmo, pois variações na definição desses parâmetros podem prejudicar o resultado final.

Conhecer o problema que está sendo tratado é importante, pois cada parâmetro

influência diretamente no desempenho do AG. Infelizmente, não há regras, que definem sobre a escolha desses parâmetros.

3.7.1 Tamanho da População

Georgy e Basily (2008) afirmam que a determinação correta do tamanho da população necessário para a resolução do problema em análise é um processo de tentativa e erro baseado na experiência do pesquisador em outros problemas de otimização.

De fato, diversos autores divergem quanto a escolha do tamanho da população. Goldberg (1989) relata que para populações em problemas usando cromossomos binários de comprimento l , o tamanho ótimo deveria ser uma função exponencial de l dada pela Equação 3.3.

$$\text{Tamanho da população} = 1,65 \cdot 2^{0,21 \cdot k} \quad (3.3)$$

Sendo:

k – número de *bits* do cromossomo (tamanho do indivíduo);

Já Tanomaru (1995) afirma que na prática, populações entre 50 a 200 cromossomos resolvem a maior parte dos problemas, e que populações maiores podem ser necessárias em problemas mais complexos. Em problemas onde a avaliação de um cromossomo é extremamente lenta, é mais conveniente o uso de populações menores.

Experimentos realizados por Michel (1996) indicam que o melhor tamanho de uma população está entre 50 e 100 indivíduos. O autor afirma que esta é a faixa mais comum usada em aplicações de AG.

Lobo e Goldeberg (2004) utilizaram em seus experimentos um tamanho de população igual 100, assim como Núñez-Letamendia (2007), Al-Aomar e Al-Okaily (2006) e Zhang e Ishikawa (2004). Já Hwang e He (2006) trabalharam com 40 indivíduos em sua população, enquanto que Myers e Handcock (1997) utilizaram 30 e Kamei e Ishikawa (2004, 2007) utilizaram 75.

Rees e Koehler (2006) realizaram diversos experimentos variando o tamanho da

população dentro de uma faixa de valores entre 20 e 50. Khalik *et al.* (2007) também trabalharam com uma faixa de valores entre 50 e 80 para o tamanho da população. Já Azadeh e Tarverdian (2007) trabalharam com um faixa entre 50 e 100. Cheng e Chang (2007) utilizaram valores entre 20 e 40 para o tamanho da população.

3.7.2 Número de Gerações

O número de gerações varia de acordo com a complexidade do problema em questão e deve ser determinado experimentalmente. Como o AG resolve problemas de otimização, o ideal seria que o algoritmo terminasse assim que o ponto ótimo fosse encontrado (YUN e GEN, 2003).

Na prática, na maioria das aplicações, não se pode afirmar com certeza, que um dado ponto ótimo encontrado seja considerado um ótimo global. Desta forma algum critério deve ser adotado, para o término do processamento do algoritmo. Normalmente, usa-se o critério do número máximo de gerações ou tempo limite de processamento para o encerramento do processo.

Outro critério que pode ser utilizado é o de estagnação, onde o processo é encerrado quando não se observa melhoria na população após várias gerações consecutivas. Neste caso, pode ser feita a análise da convergência através de vários fatores como: valores máximo, mínimo, médio, desvio padrão e outros.

Diversos autores também divergem quanto a escolha do número de gerações ideal. Goldberg (1989) considera o desvio padrão dos valores de aptidão dos indivíduos como sendo um dos fatores mais interessantes. Assim, tem-se uma comparação do desempenho da geração atual com a anterior, e se o desvio padrão for igual ou menor que o estabelecido como aproximação aceitável, o processo então é encerrado. Neste caso o número de gerações não é fornecido no início do processo, e é conhecido somente quando o critério de parada for aceito.

Já Hwang e He (2006) definem um número de gerações igual a 600, enquanto que Núñez-Letamendia (2007) definem esse valor em 25, Zhang e Ishikawa (2004) utilizaram 10 gerações e Kamei e Ishikawa (2004) trabalham com 100.

Khalik *et al.* (2007) realizam diversos experimentos variando o número de

gerações dentro de uma faixa de valores entre 100 e 300.

De forma um pouco diferente, Al-Aomar e Al-Okaily (2006) trabalham com dois critérios. Inicialmente os autores definem um máximo de 1000 gerações, entretanto o algoritmo é encerrado a qualquer momento quando percebe-se que não há melhorias de uma geração para a outra.

3.7.3 Taxa de Cruzamento

A taxa de cruzamento determina se será feito o cruzamento entre dois cromossomos de uma certa população. Isto é, gera-se um número aleatório entre 0 e 1, e se esse valor sorteado for menor que a taxa, o cruzamento entre estes cromossomos é realizado.

Pode-se observar experimentalmente que quanto maior for essa taxa, mais rapidamente novos indivíduos serão introduzidos na população, mas se esta taxa for muito alta, a maior parte da população será substituída, e pode ocorrer perda de estruturas de boa aptidão, já com um valor muito baixo, o algoritmo pode se tornar muito lento.

Barboza (2005) afirma que normalmente são encontrados valores entre 0,6 e 0,65 para a taxa de cruzamento.

Entretanto, Tanomaru (1995) relata que em relação a taxa de cruzamento, estudos empíricos têm mostrado que bons resultados geralmente são obtidos com valores maiores que 0,7. Já Mitchell (1996) sugere uma taxa de 0,6, assim como Leboreiro e Acevedo (2002, 2004).

Lobo e Goldberg (2004) utilizaram em seus experimentos um valor de 0,7 para a taxa de cruzamento, assim como Hwang e He (2006). Já Núñez-Letamendia (2007) definiram esse valor em 0,95, assim como Grefenstette (1986).

Todoroki e Ishikawa (2004) trabalharam com um valor igual a 0,8, enquanto Zhang e Ishikawa (2004) utilizaram 0.75.

Myers e Handcock (1997) realizaram diversos experimentos variando a taxa de cruzamento entre os valores 0,6 e 0.9. Já Rees e Koehler (2006) variaram essa taxa entre 0,1 e 0,9, enquanto que Al-Aomar e Al-Okaily (2006) utilizaram valores entre

0,6 e 1.

Azadeh e Tarverdian (2007) também trabalharam com faixas de valores para a taxa de cruzamento, variando-as entre 0,2 e 0,8. Já Cheng e Chang (2007) utilizaram valores entre 0,4 e 0,8.

3.7.4 Taxa de Mutação

Esta taxa determina se os genes dos cromossomos sofrerão mutação ou não. Isto é, gera-se um número aleatório entre 0 e 1 para cada um dos genes dos cromossomos e compara-se com a taxa de mutação. Caso esse valor seja menor que a taxa, realiza-se a mutação.

Em relação aos valores da taxa de mutação, pode-se observar que para uma taxa de mutação muito baixa, pode acontecer que a busca fique estagnada em um valor, ou seja, um ótimo local. Em contra partida, com uma taxa muito alta, a busca torna-se essencialmente aleatória.

Segundo Barboza (2005), os valores encontrados para taxa de mutação, geralmente ficam em torno de 0,001 a 0,05.

Tanomaru (1995) sugere para taxa de mutação, valores menores que 0,01, já Mitchell (1996) sugere que a taxa seja de 0,001.

Lobo e Goldberg (2004) utilizaram em seus experimentos um valor de 0,01 para a taxa de mutação, assim como Hwang e He (2006) e Núñez-Letamendia (2007). Já Myers e Handcock (1997) definem a taxa de mutação em 0,02, enquanto Zhang e Ishikawa (2004) utilizam o valor 0,1.

Rees e Koehler (2006) variaram a taxa de mutação entre os valores 0,001 e 0,1. Já Al-Aomar e Al-Okaily (2006) variam essa taxa entre os valores 0,001 e 0,05, enquanto Azadeh e Tarverdian (2007) utilizam valores entre 0,01 e 0,05. Leboreiro e Acevedo (2002, 2004) por sua vez trabalham com valores entre 0,005 e 0,01.

Um valor encontrado para taxa de mutação, bastante incomum quando comparado com os demais, foi no trabalho de Todoroki e Ishikawa (2004). Neste trabalho os autores definem essa taxa em 0,8.

3.8 TÉCNICAS DE ADAPTAÇÃO NOS PARÂMETROS DOS AG

Linden (2006) afirma que as técnicas de adaptação nos parâmetros dos algoritmos genéticos consistem em efetuar algum tipo de mudança nestes parâmetros de acordo com o progresso do algoritmo.

Segundo Hinterding, Michalewicz e Eiben (1997), as técnicas de adaptação consistem em efetuar mudanças nos valores dos parâmetros através de alguma regra determinística, que modifica os parâmetros a cada geração. Por exemplo, aumentar o tamanho da população em 25% a cada geração decorrida.

Técnicas de adaptação nos parâmetros do algoritmo genético têm sido utilizadas por diversos autores na intenção de melhorar o desempenho destes algoritmos. De fato, Herrera e Lozano (2000) utilizaram diferentes combinações de parâmetros para cada geração que o algoritmo genético executa.

Tongchim e Chongstitvatana (2002) fazem ajustes no parâmetro tamanho da população conforme o desempenho do algoritmo observado na geração anterior. Esses ajustes são realizados a cada 5 gerações. De forma semelhante, Hwang e He (2006) fazem modificações nos operadores de cruzamento e mutação do algoritmo genético, ao longo das gerações, de tal forma a melhorar a convergência para o ótimo global.

Recentemente, Yu, Zhu e Diao (2008) adaptaram cada indivíduo da população do algoritmo para trabalhar com partes binárias e reais simultaneamente. Isto reduziu o tamanho necessário de cada indivíduo da população.

Já Togan e Daloglu (2008) criaram uma nova estratégia para a formação da população inicial do algoritmo genético. Esta estratégia consiste em criar ajustes nos indivíduos da população com a intenção de escapar dos ótimos locais e direcionar estes indivíduos para o ótimo global. Os autores afirmam que começar com indivíduos específicos, ao invés de utilizar a aleatoriedade para a formação da população inicial, faz com que o algoritmo atinja o resultado de forma mais rápida.

Outros tipos de adaptações em algoritmo genético, não apenas nos parâmetros, têm sido propostas ao longo do tempo. Por exemplo, propostas de adaptação na função de aptidão, nos tipos de operadores de cruzamento, nos tipos de operadores de mutação e na forma como o algoritmo genético faz sua evolução (COELLO, 2000;

NANAKORN e MEESOMKLIN, 2001; BARBOSA e LEMONGE, 2003; TOGAN e DALOGLU, 2006; RAHAMI, KAVEH e GHOLIPOUR, 2008; MA e ZHANG, 2008).

3.9 APLICAÇÕES DOS ALGORITMOS GENÉTICOS

Desde os conceitos básicos definidos por Holland (1975), inúmeras aplicações têm sido desenvolvidas em várias áreas de pesquisas, obtendo resultados satisfatórios. No geral o AG, tem sido utilizado na solução de problemas de otimização, principalmente pela sua versatilidade na obtenção de boas soluções.

Pode-se citar o trabalho de Hwang e He (2006) que utilizaram AG em conjunto com recozimento simulado (*simulated annealing*) em problemas de engenharia.

Poojari e Varghese (2008) combinaram algoritmos genéticos com simulação de Monte Carlo. Foi totalmente implementado na linguagem C++ e a intenção dos autores era a resolução de problemas não lineares e de natureza não convexa. Fizeram o teste em sete problemas.

Dedieu *et al.* (2003) desenvolveram uma metodologia capaz de resolver problemas com mais de uma função objetivo. O algoritmo foi aplicado no projeto e reestruturação de instalações de manufatura.

Pendharkar (2007) desenvolveu em seu trabalho um algoritmo genético para resolução de problemas de programação da produção. Utilizou, também, algumas técnicas de simulação para atingir os resultados desejados.

Akhtar e Lin-shu (2007) melhoram a convergência do algoritmo genético introduzindo uma população inicial baseada na técnica de projeto de experimentos. O objetivo do trabalho era melhorar o sistema de propulsão de foguetes através do aperfeiçoamento da massa de combustível.

James, Barkhi e Johnson (2006) desenvolveram um algoritmo genético para manipular funções objetivos com diversas restrições. Acrescentaram certas características de programação nesses algoritmos que permitiram com que o algoritmo tirasse proveito de computadores com vários processadores.

Roy (2006) combinou algoritmo genético com lógica *fuzzy* para uma aplicação

em sistemas especialistas. O objetivo era garantir uma superfície de ultra-precisão em diamantes. O sistema desenvolvido fornecia informações tais como: parâmetros de corte, velocidade do eixo e profundidade do corte.

Yun e Gen (2003) também inseriram conceitos sobre lógica *fuzzy* em algoritmos genéticos. Os autores afirmaram que ocorreram melhorias no desempenho do algoritmo.

Barboza (2005) cita como exemplos de aplicações do AG:

- Problemas de otimização complexos: problemas com muitas variáveis e espaços de soluções de dimensões elevadas;
- Otimização evolutiva multi-critério: otimização de funções com múltiplos objetivos conflitantes entre si;
- Mineração de dados (*data mining*);
- Robótica: robôs utilizam AG para tomar decisões;
- Redes neurais: AG é combinado com redes neurais para treiná-las ou para encontrar sua topologia;
- Ciências biológicas: modelagem de processos biológicos para o entendimento do comportamento de estruturas genéticas;
- Engenharia de construções: possui aplicações na otimização discreta de estruturas;
- Síntese de circuitos analógicos: o AG é utilizado para gerar a topologia, o tipo e o valor dos componentes do circuito;
- Síntese de protocolos: determina as funções de protocolos de hardware e de software para que um certo desempenho seja alcançado;
- Gerenciamento de rede de comunicação: O AG faz a supervisão de tráfego nos *links* e das filas nos *buffers* de roteadores para descobrir caminhos ótimos e para reconfigurar as rotas existentes no caso de falha de algum *link*;
- Outras áreas: evolução interativa de imagens, composição musical e outras.

3.10 CONSIDERAÇÕES FINAIS

Este capítulo apresentou o princípio de funcionamento e os principais aspectos relacionados aos algoritmos genéticos, além de mostrar diversos operadores de seleção, de cruzamento e de mutação existentes para esses algoritmos.

Mostrou-se, também, que os parâmetros desses algoritmos são importantes na determinação da variável de resposta e como não há na literatura um consenso sobre os valores desses parâmetros. Por exemplo, para a maioria dos trabalhos analisados, encontraram-se para o parâmetro tamanho da população valores entre 50 e 200. Já para o número de gerações encontraram-se valores entre 50 e 100. Para a taxa de cruzamento encontraram-se valores entre 10% e 80%. Já para a taxa de mutação encontraram-se valores entre 1% e 10%.

Por fim, foi mostrado o crescente estudo sobre as técnicas de adaptação nos algoritmos genéticos, que possuem a intenção de melhorar o desempenho desses algoritmos, além de diversas aplicações dos algoritmos genéticos.

CAPÍTULO 4 – PROJETO DE EXPERIMENTOS

4.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é mostrar os principais aspectos relacionados aos projetos de experimento utilizado no desenvolvimento desta pesquisa.

Inicialmente, serão apresentados os conceitos gerais sobre experimentação, destacando-se os principais termos utilizados. Na seqüência, serão mostradas algumas metodologias aplicadas a projeto de experimentos.

Finalmente, serão contextualizadas algumas técnicas aplicadas aos projetos de experimentos, com destaque ao planejamento fatorial completo, análise de variância e análise de resíduos das respostas.

4.2 CONCEITOS GERAIS SOBRE EXPERIMENTAÇÃO

Segundo Montgomery (2005), o projeto de experimentos (*design of experiments* – DOE) é uma estratégia de planejamento, condução, análise e interpretação de experimentos, capaz de gerar conclusões de forma eficiente, eficaz e econômica.

De acordo com Sanchez (2006), um experimento bem projetado permite ao analista examinar muito mais fatores do que um experimento sem um bom projeto, além de constatações que não poderiam ser feitas pela abordagem de tentativa-e-erro.

Ozcelikt e Erzurumlu (2005) afirmam que o projeto de experimento é uma abordagem eficiente para otimizar os vários parâmetros de processos existentes em um experimento.

Cox e Reid (2000) utilizam a palavra experimento de forma bastante precisa para indicar uma investigação onde o sistema sob estudo está sob o controle do investigador. Ao contrário, para um estudo observacional, algumas características estão fora do controle do investigador.

Galdámez (2002) afirma que o planejamento de experimentos é um teste ou uma

série de testes nos quais se induzem mudanças deliberadas ou estímulos nas variáveis de entrada (*inputs*) do processo ou sistema, de tal forma que é possível observar e identificar os efeitos nas respostas ou nas variáveis de saída (*outputs*). O processo ou sistema de transformação é representado pela combinação de máquinas, métodos, pessoas e outros recursos que transformam uma entrada em produtos acabados, com características ou parâmetros específicos, conforme mostra a Figura 4.1.

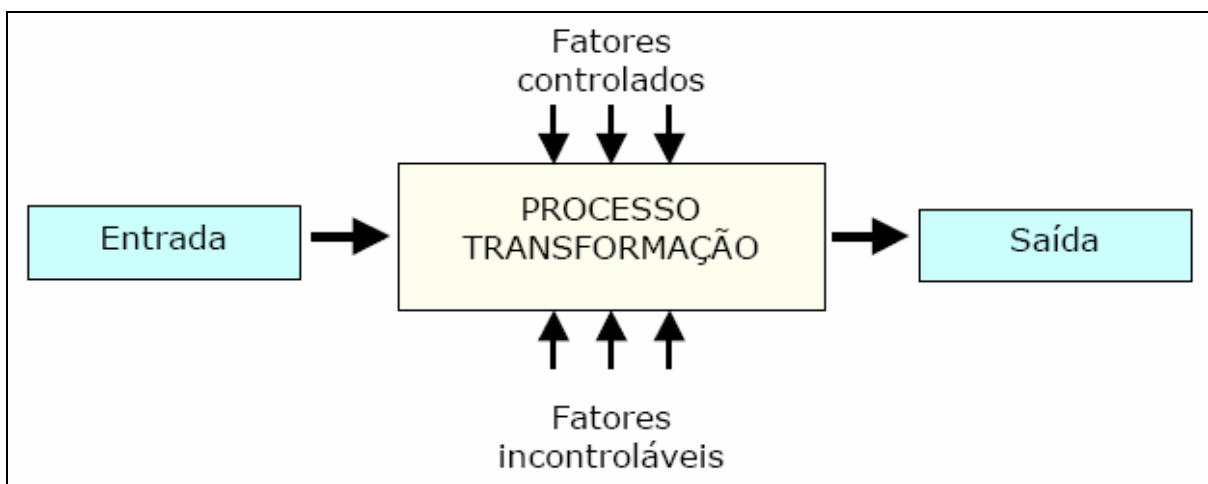


Figura 4.1 – Modelo geral de um sistema de transformação

Fonte: Montgomery (2005) e Galdámez (2002)

Segundo Montgomery (2005), o planejamento de experimentos possui como principal vantagem a redução do número de ensaios necessários para a realização de um estudo sob um conjunto de fatores, além de permitir a detecção de interações entre esses fatores.

Ainda, segundo o mesmo autor, as técnicas de planejamento e análise de experimentos são utilizadas basicamente para melhorar as características de qualidade dos produtos ou processos de fabricação, reduzir o número de testes e otimizar o uso de recursos da empresa (material, tempo, equipamentos, etc.). Esse objetivo pode ser dividido em outros objetivos secundários:

- Identificar as variáveis (fatores de controle) do processo que mais influem nos parâmetros de resposta;

- Atribuir valores às variáveis influentes do processo de modo que a variabilidade da resposta de interesse seja mínima ou que o valor do resultado seja próximo do valor nominal;
- Atribuir valores às variáveis influentes do processo de modo que o efeito das variáveis não controláveis seja reduzido.

Segundo Galdámez (2002), nos processos de fabricação das indústrias existem vários fatores e níveis de regulação, que influenciam as características de qualidade dos produtos. Um problema comum encontrado pelas empresas ao realizar um experimento é a necessidade de avaliar simultaneamente o efeito desses fatores com diferentes níveis de regulação. Neste caso, observa-se que o número de testes requeridos para a experimentação tende a crescer a medida que a quantidade de fatores aumenta. Isso torna os experimentos industriais inviáveis nas empresas, porque os custos e o tempo de execução são elevados.

Ao mesmo tempo experimentos industriais são realizados pelas empresas, principalmente, para se resolver os problemas críticos do produto ou processos de fabricação. Com esses testes procura-se reduzir o número de produtos com defeitos fabricados e responder a uma série de questões relacionadas aos níveis e parâmetros que influenciam o desempenho do produto final. Antony, Kate e Frangou (1998) sugerem que a solução dos problemas pode ser alcançada com mais facilidade quando os experimentos são planejados e as respostas analisadas com métodos ou técnicas estatísticas.

Nesse sentido, Kar, Banerjee e Bhattacharyya (2002) ressaltam que ao realizar as atividades dos experimentos industriais de forma planejada, as informações obtidas dos produtos ou dos processos de fabricação tornam-se mais confiáveis e, com isso ações de melhorias mais eficientes podem ser tomadas pelos funcionários da empresa.

A seguir apresentam-se alguns termos fundamentais para a aplicação das técnicas de planejamento e análise de experimentos.

4.2.1 Fator

Fatores são os parâmetros de entrada e as considerações estruturais que compõem um experimento (KLEIJNEN *et al.*, 2005). Por definição, os fatores são alterados durante um experimento. Conseqüentemente um fator assume 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 quantificadas naturalmente (LAW E KELTON, 2000).

Os fatores podem ser classificados em controláveis ou incontroláveis dependendo se eles representam opções de ação para gerentes dos sistemas reais correspondentes.

4.2.2 Variável de Resposta

São as variáveis dependentes que sofrem algum efeito nos testes, quando estímulos são introduzidos propositalmente nos fatores. Nos experimentos, podem existir uma ou mais variáveis de resposta (y) que são importantes de se avaliar.

A variável de resposta é a medida de desempenho ou saída do projeto de experimento (HARREL, GHOSH e BOWDEN, 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.

4.2.3 Efeito

O efeito de um fator é definido como a mudança na resposta produzida pela mudança do nível do fator. Segundo Montgomery (2005), o termo efeito principal é freqüentemente utilizado porque se refere aos fatores de interesse primários no experimento.

4.2.4. Interação

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.

Chung (2004) define interação como o evento que ocorre quando os fatores apresentam algum tipo de sinergia. Pode-se verificar que o efeito da soma dos fatores pode ser superior que a soma do efeito isolado de cada um.

4.2.5 Replicação

Por replicação entende-se a repetição do experimento. Segundo Montgomery (2005), a replicação tem duas importantes propriedades. Primeiro, permite-se 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 (2005) 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.

4.2.5 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 (MONTGOMEY, 2005).

4.2.6 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 existentes no processo (MONTGOMERY, 2005).

4.3 METODOLOGIAS APLICADAS A PROJETOS DE EXPERIMENTOS

Segundo Montgomery (2005), antes de iniciar qualquer experimentação, é importante estabelecer o planejamento dos testes. O autor ressalta a importância do domínio do problema por todas as pessoas envolvidas e recomenda que durante os experimentos, o processo seja cuidadosamente monitorado, para garantir que tudo seja realizado de acordo com os planos, pois erros no procedimento experimental muito provavelmente invalidarão os resultados.

Trabalhos como Steinberg e Hunter (1984) e Sanchez, Moeenib e Sanchez (2006), afirmam que o plano experimental ajuda a desenvolver e conduzir efetivamente as atividades já definidas e, principalmente, permite maximizar as respostas das questões formuladas pela equipe de trabalho.

De forma semelhante, Coleman e Montgomery (1993), Antony, Kate e Frangou (1998) e Galdámez (2002) recomendam que durante o processo de experimentação seja feito um plano estratégico para coordenar as atividades.

Uma metodologia aplicada a projeto de experimentos pode ser encontrada em Montgomery (2005). Nesta metodologia o autor também propõe alguns passos para um planejamento do experimento, como mostra a Figura 4.2.

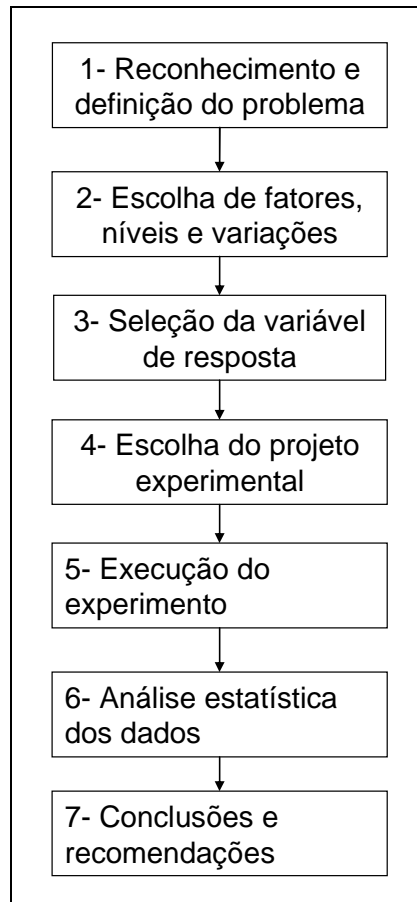


Figura 4.2 – Passos propostos para a realização de um projeto de experimentos

Fonte: Montgomery (2005)

A seguir, tem-se uma descrição sucinta de cada um desses passos.

1. Reconhecimento e definição do problema: nesta fase deve-se gerar uma descrição clara sobre o problema em análise. É necessária a definição de todos os objetivos do experimento;
2. Escolha de fatores, níveis e variações: nesta fase devem-se considerar os fatores que podem influenciar no desempenho do processo que se está estudando, selecionando-se seus níveis e suas variações;
3. Seleção da variável de resposta: nesta fase, o analista deve se certificar que a variável de resposta adotada realmente contém todas as informações necessárias sobre o processo que se está estudando;
4. Escolha do projeto experimental: nesta fase deve-se escolher qual a técnica de planejamento que será utilizada, o número de replicações e a ordenação dos experimentos;

5. Execução do experimento: nesta fase deve-se monitorar o processo de experimentação, de tal forma a garantir que o experimento ocorra conforme o planejado;
6. Análise estatística dos dados: nesta fase deve-se utilizar de métodos estatísticos para analisar os resultados;
7. Conclusões e recomendações: nesta fase, o analista deve concluir sobre os resultados analisados e recomendar possíveis ações de melhorias.

4.4 TÉCNICAS DE PLANEJAMENTO E ANÁLISE DE EXPERIMENTOS

Os experimentos devem ser planejados em uma matriz experimental. A construção dessa matriz corresponde a etapa número 4 da Figura 4.2 mostrada anteriormente. O objetivo dessa atividade é garantir que as informações obtidas sejam confiáveis e que os recursos disponíveis para experimentação sejam bem utilizados (MONTGOMERY, 2005).

É importante ressaltar que não é a intenção desta pesquisa abordar todas as técnicas que existem na literatura para planejamento e análise de experimentos. A técnica adotada nesta tese foi o planejamento fatorial completo (2^k), pois segundo Paiva (2006), o planejamento fatorial completo cobre todo o espaço experimental e correspondem ao arranjo experimental mais comum. Tal técnica permite avaliar não somente os efeitos principais dos fatores como também os efeitos de interação entre os mesmos.

4.4.1 Planejamento Fatorial Completo (2^k)

Segundo Harrel, Ghosh e Bowden (2000), o planejamento fatorial completo 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.

Segundo Pontes *et al.* (2007), o número de experimentos é igual ao número de níveis experimentais elevado ao número de fatores. Desta forma, o número de corridas

experimentais (n) para se avaliar os k fatores é dado por $n = 2^k$. Logo, enquanto o número de fatores cresce linearmente, o número de corridas cresce exponencialmente.

Para ilustrar o procedimento dessa técnica considere um experimento com três fatores (x_1 , x_2 e x_3), sendo que cada um desses parâmetros foi testado com dois níveis (-1 e +1). A matriz de planejamento para este experimento (2^3 – dois níveis e três fatores) é representada pela Tabela 4.1.

Tabela 4.1 – Matriz de planejamento do experimento 2^3

Fonte: Montgomery (2005)

Nº do Teste	Fatores de controle			Ordem do teste	Resposta (y_i)
	x_1	x_2	x_3		
1	-1	-1	-1	6	y_1
2	+1	-1	-1	8	y_2
3	-1	+1	-1	1	y_3
4	+1	+1	-1	2	y_4
5	-1	-1	+1	5	y_5
6	+1	-1	+1	3	y_6
7	-1	+1	+1	4	y_7
8	+1	+1	+1	7	y_8

A resposta de cada experimento é descrita pela coluna y_i . Cabe ressaltar que para esses experimentos a ordem de realização dos testes foi definida aleatoriamente, pois conforme já mencionado a aleatorização é o pilar de apoio para o uso de métodos estatísticos no planejamento de experimentos (MONTGOMERY, 2005).

Em uma matriz de planejamento de experimentos genérica, as colunas representam o conjunto de fatores investigados (x_1 , x_2 , x_3 , ..., x_k), e as linhas representam os diferentes níveis: mínimo (-1) ou máximo (+1). Os cinco passos necessários para a construção da matriz de planejamento de experimentos de forma genérica são apresentados a seguir:

1. Para x_1 , a coluna será definida pela combinação dos níveis: -1, +1, -1, +1, -1, +1, ..., ou seja, o sinal dessa coluna se alterna em grupos de $2^0=1$;
2. Para x_2 , a coluna será definida pela combinação dos níveis: -1, -1, +1, +1, -1, -1, +1, +1, ..., ou seja, o sinal dessa coluna se alterna em grupos de $2^1=2$;
3. Para x_3 , a coluna será definida pela combinação dos níveis: -1, -1, -1, -1, +1, +1, +1, +1, -1, -1, -1, -1 ..., ou seja, o sinal dessa coluna se alterna em grupos de $2^2=4$;
4. Para x_4 , o sinal alterna em grupos de 8 ($2^3=8$);
5. O procedimento será igual para $x_5, x_6, x_7, \dots, x_k$. Para x_k , o sinal alterna em grupos de $2^{(k-1)}$, ou seja, $2^{(k-1)}$ vezes (-1), seguido de $2^{(k-1)}$ vezes (+1).

O processo experimental consiste em realizar testes com cada uma das combinações da matriz experimental, mostrada na Tabela 4.1. A intenção é determinar e interpretar os efeitos principais e de interação dos fatores investigados e assim, poder identificar as melhores condições experimentais.

Os efeitos principais correspondem à mudança da resposta média quando o nível de um fator é alterado de -1 para +1, mantendo os outros fatores constantes. O procedimento consiste em multiplicar os resultados da coluna y_i pelos valores ± 1 associados a coluna x_i da matriz experimental correspondente ao efeito principal que se deseja estimar (Tabela 4.1). Em seguida, os valores obtidos devem ser somados e divididos pela metade do número de ensaios realizados, conforme ilustrado pela Equação 4.1.

$$E_i = \frac{\sum y_i \cdot x_i}{n/2} \quad (4.1)$$

Sendo:

E_i – Efeito estimado;

n – Total de observações;

$\Sigma y_i \cdot x_i$ – É a soma dos resultados y_i do experimento, multiplicados pela coluna x_i .

Para determinar o efeito de interação, primeiramente devem ser construídas as colunas das interações da matriz de planejamento. Essas colunas são formadas por meio da multiplicação das colunas dos efeitos principais. Segundo Montgomery (2005), para representar e interpretar graficamente os efeitos principais e de interação é necessário definir duas propriedades:

- O sinal (\pm) indica a direção do efeito, isto é, se a resposta aumenta ou decresce com a variação do nível de (-1) para (+1);
- A magnitude indica a intensidade do efeito.

A forma gráfica do efeito principal E_i é representada pela Figura 4.3. Esse gráfico linear ilustra a variação média das respostas em função da mudança do nível de -1 para +1 de um fator x_i , mantendo os outros fatores constantes.




Figura 4.3 – Gráfico do efeito principal – planejamento fatorial 2^k

Fonte: Montgomery (2005)

Os gráficos dos efeitos de interação descrevem a variação média de um fator em função dos níveis de outros fatores. Por exemplo, a Figura 4.4 (a) ilustra que o efeito provocado pela mudança de nível do fator x_1 na resposta depende do nível do fator x_2 , portanto existe interação entre os fatores x_1 e x_2 . A Figura 4.4 (b) demonstra que o

efeito provocado pela mudança do nível do fator x_1 na resposta é independente do nível do fator x_2 , portanto não existe interação entre esses dois fatores.




Figura 4.4 – Gráfico de efeitos de interação

Fonte: Montgomery (2005)

4.4.2 Análise de Variância para o Planejamento Fatorial Completo (2^k)

As técnicas estatísticas são utilizadas, principalmente, para analisar e interpretar as informações dos experimentos planejados. O princípio básico dessas técnicas é combinar os conceitos matemáticos de estatísticas com as informações obtidas nos experimentos realizados.

Com os dados analisados matematicamente e com os testes planejados corretamente é possível rejeitar ou aceitar as hipóteses formuladas na condução do experimento.

Antes de ser apresentada a análise de variância propriamente dita, serão apresentados dois conceitos fundamentais para uma melhor compreensão desta análise de variância. Estes conceitos são: teste de hipótese e nível de significância.

4.4.2.1 Teste de hipótese

Montgomery (2005) propõe três passos que pode ser utilizados para conduzir o teste de hipótese de experimentos. Estes passos se dividem em:

- Formulação das hipóteses;
- Determinação do valor crítico da estatística de teste;
- Análise dos riscos na tomada de decisão.

A *formulação das hipóteses* consiste em considerar duas hipóteses sobre determinados parâmetros. A primeira é a hipótese nula (H_0). Essa hipótese parte do princípio que não existe nenhuma diferença significativa entre os fatores analisados de uma população e será sempre a hipótese testada no experimento. A segunda é a hipótese alternativa (H_1) e parte do princípio que será verdadeira caso a hipótese nula seja considerada falsa.

O segundo passo do teste de hipótese consiste em *determinar o valor crítico da estatística de teste*. Ao desenvolver as hipóteses dos experimentos é necessário que seja calculada uma estatística específica, com base em um determinado resultado da amostra. Tais valores podem ser determinados com auxílio de software estatístico. Montgomery (2005) apresenta várias distribuições estatísticas (*t-student*, *F-Fisher*, entre outras) que podem ser utilizadas para se determinar a probabilidade de uma hipótese nula ser verdadeira.

O terceiro e último passo do teste de hipótese consiste em *analisar os riscos na tomada de decisão* por meio da metodologia do teste de hipótese. Dois erros podem ser cometidos ao se utilizar uma estatística para se concluir sobre o resultado dos experimentos. O primeiro erro (erro tipo I) ocorre se a hipótese nula for rejeitada quando esta é verdadeira. O erro tipo II ocorre quando a hipótese nula não é rejeitada sendo falsa.

4.4.2.2 Nível de significância

A probabilidade de se cometer o erro tipo I é identificada como o nível de significância (α) do teste estatístico. Normalmente pode-se controlar a probabilidade do erro tipo I decidindo-se o nível de risco α que se está disposto a tolerar, em termos de rejeitar a hipótese nula quando esta for verdadeira. Montgomery (2005) recomenda selecionar os níveis de α em 0,1 ou menos. Com isso, os valores críticos que dividem

as regiões de rejeição e não-rejeição podem ser determinados, conforme apresentado na Figura 4.5, para uma distribuição estatística F.




Figura 4.5 - regiões de rejeição e não-rejeição para uma distribuição F

Fonte: Montgomery (2005)

4.4.3.3 Análise de Variância

A análise de variância, também conhecida como ANOVA (*analysis of variance*) é utilizada para aceitar ou rejeitar, estatisticamente, as hipóteses investigadas com o projeto de experimentos (LANDSHEER, VAN DEN WITTENBOER E MAASSEN, 2006). O objetivo dessa técnica é analisar a variação média dos resultados dos testes e demonstrar quais são os fatores que realmente produzem efeitos (principais e de interação) significativos nas variáveis de resposta de um sistema.

A interpretação dos resultados da análise de variância (ANOVA) pode ser dividida em duas categorias:

- Os parâmetros que possuam razão F_0 maior que a estatística F crítica, são os fatores que exercem influência sobre o valor da média de resultados. A estatística F, que segue uma distribuição com v_1 (numerador) e v_2 (denominador) graus de liberdade, para um dado nível de significância α , são retiradas de tabelas estatísticas.
- Os fatores que possuam razão F_0 menor que F crítica não causam efeitos significativos sobre a média, portanto, a hipótese nula é verdadeira.

É importante ressaltar que a ANOVA é facilmente realizada através de softwares estatísticos. Além dessa vantagem, na maioria dos programas computacionais está incluído o valor p (p -value). Esse valor corresponde a área sob a qual a estatística F é limite da razão F_0 calculada. Com esse parâmetro estatístico é possível concluir sobre as hipóteses nulas sem precisar recorrer a uma tabela de valores críticos da distribuição F . Isto é, se o valor p for menor que o nível de significância escolhido α , a hipótese nula é rejeitada (RODRIGUES, TOLEDO e MACIEL FILHO, 2002).

4.4.3 Análise de Resíduos das respostas

Para a análise da variância comentada anteriormente assume-se que as observações utilizadas no projeto de experimentos são independentes e distribuídas segundo uma curva normal com mesma variância (MONTGOMERY e RUNGER, 2003). Desta forma antes da análise de variância ser executada é imprescindível a realização da análise de resíduos (NOORDIN *et al.*, 2004).

Entende-se por resíduos, a diferença entre uma observação y_{ij} e o valor estimado do modelo estatístico que está sendo estudado (\hat{y}_{ij}). Para um projeto de experimento completamente aleatorizado tem-se que $\hat{y}_{ij} = \bar{y}_{ij}$, portanto cada resíduo é calculado pela Equação 4.2, sendo esta, a diferença entre uma observação e a média dos valores observados.

$$e_{ij} = y_{ij} - \bar{y}_{ij} \quad (4.2)$$

Montgomery (2005) afirma que com a Equação 4.2 é possível verificar se os resíduos contêm alguma variabilidade inesperada.

A verificação da normalidade pode ser através da construção do gráfico de probabilidade normal. Para a construção desse gráfico, assume-se que as variâncias são iguais para cada nível dos fatores, e desenham-se os resíduos para os níveis destes fatores. Cabe ressaltar que a maioria dos *softwares* de estatística constrói esse tipo de gráfico.

Um exemplo desse tipo de gráfico pode ser visto na Figura 4.6. Nota-se neste gráfico que os resíduos situam-se aproximadamente sobre a linha reta, ou seja, não há uma indicação de *outliers*. Desta forma, pode-se considerar que não existem problemas com a normalidade dos dados.

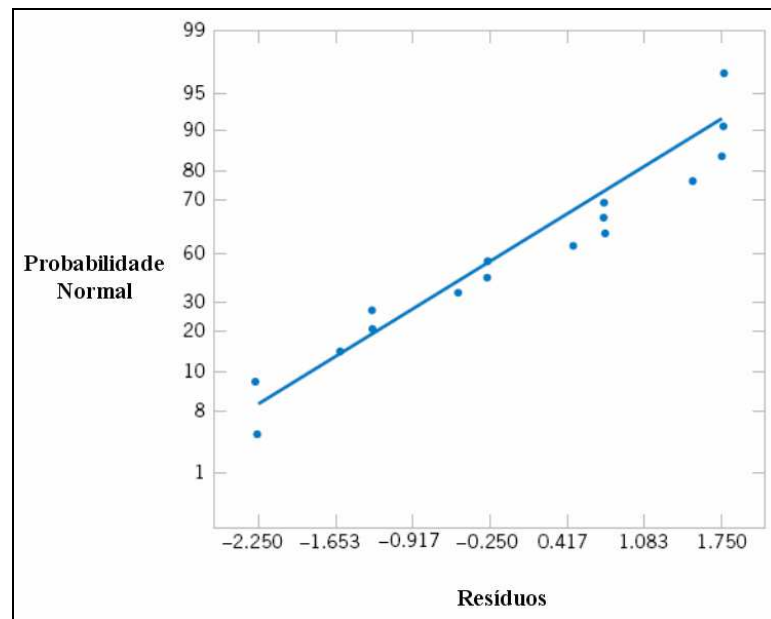


Figura 4.6 – Gráfico de probabilidade normal

4.5 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os principais aspectos relacionados ao planejamento e projeto de experimentos, além de mostrar uma metodologia aplicada a estes tipos de projetos.

O destaque maior desse capítulo foi mostrar a técnica de planejamento fatorial completo acompanhada da análise de variância. Para uma melhor compreensão da análise de variância, alguns conceitos foram apresentados, tais como: teste de hipótese, nível de significância e análise de resíduos das respostas.

CAPÍTULO 5 – ANÁLISE DOS PARÂMETROS DO ALGORITMO GENÉTICO

5.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é apresentar um estudo sobre o comportamento dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade da resposta destes algoritmos. Inicialmente, apresenta-se a análise sobre o tempo de convergência dos algoritmos genéticos baseada em um levantamento bibliográfico realizado.

Na seqüência, mostra-se a análise na qualidade da resposta desses algoritmos através da técnica de projeto de experimentos. Para tal, é apresentada a metodologia adotada para a realização dos experimentos, seguidos dos passos executados para se atingir os objetivos esperados. Posteriormente, as principais conclusões e recomendações sobre o projeto de experimento realizado são apresentadas.

Finalmente, as considerações finais sobre a influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade da resposta destes algoritmos são apresentadas.

Cabe ressaltar que este capítulo refere-se, em relação ao modelo de Mitroff *et al.* (1974), a fase de conceitualização. Bertrand e Fransoo (2002) afirmam que nesta fase, o pesquisador desenvolve um modelo conceitual do problema que gostaria de estudar, ou seja, definem-se, nesta fase, as variáveis relevantes do problema. A Figura 5.1 destaca a fase do modelo de Mitroff *et al.* (1974) pertinente a este capítulo.

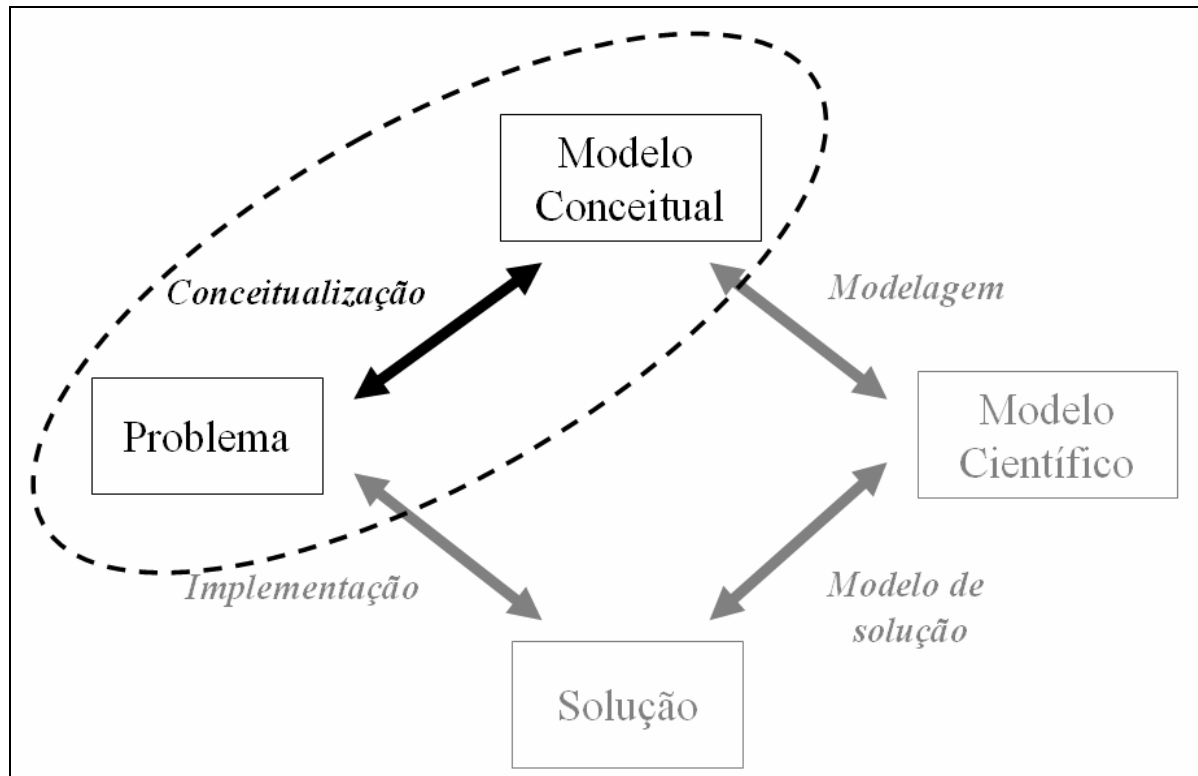


Figura 5.1 – Fase de conceitualização

Fonte: Adaptado de Mitroff *et al.* (1974)

5.2 ANÁLISE DOS PARÂMETROS DO AG NO TEMPO DE CONVERGÊNCIA

Kaveh e Shahrouzi (2007) afirmam que a eficiência dos algoritmos genéticos, ou seja, a velocidade no tempo de convergência, é diretamente dependente do tamanho da população, mais do que qualquer outro parâmetro.

De fato, Lobo e Goldberg (2004) afirmam que o tamanho da população, afeta diretamente o desempenho global e a eficiência do algoritmo genético. Pequenas populações podem provocar um sério risco de não obter cobertura do espaço de busca, enquanto que grandes populações podem exigir um grande esforço computacional para a solução do problema. A Figura 5.2 mostra esses dois problemas que podem ocorrer com uma definição errada para o tamanho da população.




Figura 5.2 – Dois problemas relacionados ao Tamanho da População em algoritmos genéticos

Fonte: Lobo e Goldberg (2004)

Nota-se que se o tamanho da população não for grande o suficiente, o algoritmo genético pode convergir para um ótimo local e não o ótimo global, ocasionando perda de qualidade. Em contrapartida, se o tamanho da população for muito grande o algoritmo gastará um tempo computacional desnecessário na busca da solução ótima, ocasionando perda de tempo.

Adicionalmente, Mori, Castro e Cavalca (2007) afirmam que o crescimento populacional exerce uma forte influência no tempo de convergência do algoritmo genético. Os autores combinaram *Simulated Annealing* (recozimento simulado) com algoritmos genéticos, com a intenção de reduzir o valor necessário para o tamanho da população e garantir, assim, uma convergência mais rápida.

De forma semelhante, Tongchim e Chongstitvatana (2002) provam que um tamanho de população menor ajuda a reduzir o tempo computacional necessário para se atingir o resultado. Os autores também afirmam que uma correta escolha para o tamanho da população é necessário para se atingir um bom desempenho dos algoritmos genéticos.

Gong *et al.* (2007) utilizam diferentes tamanhos de população a cada geração. A intenção, segundo os autores, é evitar a convergência prematura e melhorar a busca pela solução ótima global. Já Biesbroek e Ancarola (2003) mostram que valores

elevados para o tamanho da população faz com que o algoritmo genético trabalhe além do que é realmente necessário.

Ma e Zhang (2008) desenvolveram um método para a formação da população inicial e conseqüente evolução dos algoritmos genéticos, que visava à redução do tamanho da população necessária para manipular o problema em análise. O método desenvolvido possibilitou a redução no tempo de convergência desses algoritmos. De forma semelhante, Togan e Daloglu (2008) também utilizaram uma estratégia para a criação da população inicial. Segundo estes autores, essa estratégia ajuda a reduzir o número de buscas necessárias no espaço solução, permitindo, assim, uma maior velocidade de convergência.

Yu, Zhu e Diao (2008) representaram o indivíduo da população através da combinação entre números binários e reais, ou seja, utilizaram uma multi-codificação para representar os indivíduos da população. Com isso, os autores afirmam ter reduzido o tamanho do indivíduo e conseqüentemente reduzir o tamanho da população necessário para a manipulação do problema.

5.3 ANÁLISE NOS PARÂMETROS DO AG NA QUALIDADE DA RESPOSTA

A análise na qualidade da resposta dos algoritmos genéticos, apresentada nesta tese de doutorado é realizada através da técnica de projeto de experimentos. A seguir, tem-se a metodologia adotada para a realização destes experimentos.

5.3.1 metodologia utilizada neste capítulo

A avaliação na qualidade da resposta dos algoritmos genéticos será realizada através de cinco funções matemáticas. Estas funções agem diretamente na avaliação de cada indivíduo da população do algoritmo genético, como pode ser observado na Figura 5.3.




Figura 5.3 – Princípio de funcionamento do AG aplicado a otimização de funções

A Figura 5.3 também mostra de que forma os parâmetros dos algoritmos genéticos agem para a obtenção da solução. O tamanho da população define quantos indivíduos existirão em cada geração. O número de gerações estabelece a parada do algoritmo, ou seja, o algoritmo será executado o número de vezes determinado por esse parâmetro. A taxa de cruzamento é a probabilidade de dois indivíduos da população efetuarem ou não o cruzamento. Da forma semelhante, a taxa de mutação é a probabilidade de um indivíduo da população sofrer ou não mutação. O item 5.3.3, deste capítulo, apresenta as variações consideradas nestes parâmetros.

A metodologia proposta por Montgomery (2005), apresentada no capítulo 4, será adotada para a realização dos projetos de experimentos. Esta metodologia é dividida em sete passos:

- Reconhecimento e definição do problema;
- Escolha dos fatores, níveis e variações;
- Seleção da variável de resposta;

- Escolha do projeto experimental;
- Execução do experimento;
- Análise estatística dos dados;
- Conclusões e recomendações.

Os itens a seguir descrevem como estes sete passos foram conduzidos para a elaboração desta pesquisa.

5.3.2 Reconhecimento e definição do problema

Deseja-se otimizar as funções matemáticas apresentadas pelas Equações numeradas de 5.1 a 5.5 a seguir. O objetivo desse projeto de experimentos é analisar quais parâmetros do algoritmo genético mais influenciam na precisão do resultado, ou seja, na qualidade da resposta destes algoritmos.

$$F(x, y) = 0,5 - \frac{\left(\sin \sqrt{x^2 + y^2}\right)^2 - 0,5}{\left(1,0 + 0,001(x^2 + y^2)\right)^2} \quad (5.1)$$

$$F(x) = x \sin(10\pi x) + 1 \quad (5.2)$$

$$F(x, y) = \sqrt[0,1]{\left((x-10)^2 + (y-10)^2\right)} \quad (5.3)$$

$$F(x, y) = x^2 + (x + y)^2 \quad (5.4)$$

$$F(x) = \exp \frac{-4(\ln 2)(x-0,0667)^2}{0,64} \cdot \sin(5,1\pi x + 0,5)^6 \quad (5.5)$$

A Equação 5.1 possui vários pontos de máximos locais. Entretanto, esta função possui um ponto de ótimo conhecido e igual a 1, para x e y assumindo o valor de 0. Ou seja, $F(0,0) = 1$.

A Equação 5.2, assim como a primeira, também possui vários pontos de máximos locais. Entretanto, esta função possui um ponto de ótimo conhecido e igual a 2,8504, para x assumindo o valor de 1,8511. Ou seja, $F(1,811) = 2,8504$.

A Equação 5.3 possui um ponto de mínimo global conhecido e igual a zero, para x e y assumindo o valor de 10. Ou seja, $F(10, 10) = 0$.

A Equação 5.4, assim como a anterior, também possui um ponto de mínimo global conhecido e igual a zero, para x e y assumindo o valor de 0. Ou seja, $F(0, 0) = 0$.

A Equação 5.5 possui vários pontos de máximos locais. Entretanto esta função possui um ponto de ótimo conhecido e igual a 1, para x assumindo o valor de 0,06691. Ou seja, $F(0,06691) = 1$.

5.3.3 Escolha dos fatores, níveis e variações

Os fatores selecionados para o projeto de experimentos são os parâmetros dos algoritmos genéticos (tamanho da população, número de gerações, taxa de cruzamento e taxa de mutação), discutidos no capítulo 3. Optou-se em trabalhar com dois níveis para cada fator. Esses níveis e suas variações são apresentados na Tabela 5.1.

Tabela 5.1 – Fatores, níveis e variações do projeto de experimentos

Fatores		Níveis	
		-	+
A	Tamanho da População	50	200
B	Número de Gerações	50	100
C	Taxa de Cruzamento	10%	80%
D	Taxa de Mutação	1%	10%

Cabe ressaltar que esses valores foram adotados com base no levantamento bibliográfico realizado para cada uma desses parâmetros, apresentados no capítulo 3. Nesta atribuição de valores, levaram-se em consideração as divergências encontradas na estimativa desses parâmetros.

Esta mesma faixa de valores para os parâmetros dos algoritmos genéticos será utilizada nos experimentos das cinco funções representadas pelas Equações 5.1 a 5.5 listadas anteriormente.

5.3.4 Seleção da variável de resposta

Para as funções representadas pelas Equações 5.1, 5.2 e 5.5, a variável de resposta para o projeto de experimentos será o valor máximo dessas funções. Já para as funções representadas pelas Equações 5.3 e 5.4, a variável de resposta para o projeto de experimentos será o valor mínimo dessas funções.

5.3.5 Escolha do projeto experimental

Como observado anteriormente, este projeto possui quatro fatores com dois níveis cada. Desta forma, optou-se pelo uso do fatorial completo, pois conforme Montgomery (2005), as vantagens do uso de um fatorial completo se dão na maior eficiência em estimar os efeitos principais dos fatores sob a variável em análise, e, principalmente, a definição da interação entre todos os fatores.

A matriz com o planejamento dos experimentos é mostrada na Tabela 5.2. Nota-se que para um experimento de fatorial completo e com dois níveis cada, serão necessários dezesseis experimentos ($2^4 = 16$).

Tabela 5.2 – Matriz com o planejamento dos experimentos

Experimentos	A	B	C	D
1	-	-	-	-
2	+	-	-	-
3	-	+	-	-
4	+	+	-	-
5	-	-	+	-
6	+	-	+	-
7	-	+	+	-
8	+	+	+	-
9	-	-	-	+
10	+	-	-	+
11	-	+	-	+
12	+	+	-	+
13	-	-	+	+
14	+	-	+	+
15	-	+	+	+
16	+	+	+	+

Na Tabela 5.2, A representa o fator Tamanho da população, B representa o fator Número de Gerações, C representa o fator Taxa de cruzamento e D representa o fator Taxa de Mutação.

Cabe ressaltar que este planejamento dos experimentos será realizado para cada uma das cinco funções representadas pelas equações (5.1) a (5.5) listadas anteriormente, conforme será visto no próximo item.

5.3.6 Execução dos experimentos

Para a execução dos experimentos foi necessário desenvolver uma ferramenta computacional capaz de operacionalizar os procedimentos existentes para o algoritmo genético. Além disso, tal ferramenta, permite a manipulação dos parâmetros do algoritmo genético durante o processo de otimização das funções matemáticas. Este *software* desenvolvido trabalha na busca dos pontos de máximo ou dos pontos de mínimo de funções matemáticas, conforme anteriormente esquematizado na Figura 5.3.

Para a execução do experimento os operadores genéticos, tais como operadores de seleção, operadores de cruzamento e operadores de mutação foram mantidos constantes para as cinco funções matemáticas. Apenas os parâmetros do algoritmo genético foram se alterando conforme a matriz de planejamento de experimentos apresentada anteriormente na Tabela 5.2.

O resultado encontrado para cada experimento, realizado em cada uma das cinco funções, são mostrados nas tabelas 5.3, 5.4, 5.5, 5.6 e 5.7 respectivamente. Nota-se que cada experimento foi executado cinco vezes (Y1 a Y5).

Tabela 5.3 – Execução do experimento para a função representada pela Equação 5.1

Exp	A	B	C	D	Y1	Y2	Y3	Y4	Y5
1	-	-	-	-	0,947375	0,988164	0,962597	0,9888	0,953488
2	+	-	-	-	0,990265	0,99027	0,990091	0,957144	0,990246
3	-	+	-	-	0,964108	0,976914	0,918793	0,95615	0,961193
4	+	+	-	-	0,990227	0,985476	0,979396	0,961802	0,987604
5	-	-	+	-	0,921746	0,958089	0,961591	0,921444	0,959764
6	+	-	+	-	0,990284	0,990284	0,99028	0,990283	0,990283
7	-	+	+	-	0,974284	0,962615	0,962574	0,962217	0,965603
8	+	+	+	-	0,96267	0,986435	0,990245	0,984225	0,962764
9	-	-	-	+	0,962775	0,977262	0,962489	0,915795	0,958229
10	+	-	-	+	0,990245	0,990283	0,990167	0,988079	0,99028
11	-	+	-	+	0,987116	0,974643	0,962774	0,956339	0,990069
12	+	+	-	+	0,962776	0,96277	0,988228	0,990284	0,990281
13	-	-	+	+	0,971229	0,962732	0,962764	0,985956	0,99011
14	+	-	+	+	0,990284	0,990022	0,989763	0,974842	0,990231
15	-	+	+	+	0,921713	0,918181	0,961068	0,92181	0,9867
16	+	+	+	+	0,989524	0,990272	0,990284	0,990283	0,962775

Tabela 5.4 – Execução do experimento para a função representada pela Equação 5.2

Exp	A	B	C	D	Y1	Y2	Y3	Y4	Y5
1	-	-	-	-	1,955131	2,796514	2,250309	2,249574	2,717014
2	+	-	-	-	2,849692	2,84253	2,832748	2,850314	2,649622
3	-	+	-	-	2,843618	2,414725	2,831901	2,848268	2,772774
4	+	+	-	-	2,850276	2,844575	2,784472	2,84253	2,847676
5	-	-	+	-	2,850308	2,646785	1,849172	2,050466	2,648296
6	+	-	+	-	2,848215	2,848086	2,848215	2,832274	2,848215
7	-	+	+	-	2,847383	2,840354	2,440407	2,649429	2,550295
8	+	+	+	-	2,850314	2,850327	2,85024	2,850328	2,850325
9	-	-	-	+	2,850276	2,83556	2,850319	2,850294	2,850325
10	+	-	-	+	2,850212	2,845878	2,850042	2,850322	2,850319
11	-	+	-	+	2,829189	2,848141	2,84339	2,849578	2,850328
12	+	+	-	+	2,850322	2,84911	2,848693	2,84976	2,850322
13	-	-	+	+	2,847953	2,841779	2,848009	2,846982	2,849621
14	+	-	+	+	2,850327	2,850181	2,850228	2,850319	2,850308
15	-	+	+	+	2,849419	2,849334	2,84874	2,84976	2,850319
16	+	+	+	+	2,850328	2,850199	2,849621	2,850264	2,850308

Tabela 5.5 – Execução do experimento para a função representada pela Equação 5.3

Exp	A	B	C	D	Y1	Y2	Y3	Y4	Y5
1	-	-	-	-	1,535792	2,052209	1,559344	1,245731	1,449701
2	+	-	-	-	1,148698	1,319508	1,446126	1	1,327532
3	-	+	-	-	2,018902	1,888503	1,463259	2,058924	1,518068
4	+	+	-	-	1,446126	1,319508	1,231144	1,231144	1,551846
5	-	-	+	-	1,148698	1,327532	1,37973	1,148698	1
6	+	-	+	-	1,148698	0	1,430969	1	1,245731
7	-	+	+	-	1,148698	1,148698	1,245731	1,292392	0
8	+	+	+	-	0	0	0	1	0
9	-	-	-	+	1,071773	1,148698	1,449701	1,327532	1,553751
10	+	-	-	+	0	1	1	1,071773	1
11	-	+	-	+	1,518068	1,945799	1,446126	1,349283	1,258925
12	+	+	-	+	0	1	1	0	0
13	-	-	+	+	1,841724	1,478758	1	1,292392	1,537883
14	+	-	+	+	0	1,148698	0	1,071773	1,148698
15	-	+	+	+	1,349283	1	1,327532	1,327532	1,430969
16	+	+	+	+	1,174619	1,148698	1,148698	1	1,071773

Tabela 5.6 – Execução do experimento para a função representada pela Equação 5.4

Exp	A	B	C	D	Y1	Y2	Y3	Y4	Y5
1	-	-	-	-	1250	2005	832	3133	225
2	+	-	-	-	144	68	8	40	9
3	-	+	-	-	2132	725	74	1348	288
4	+	+	-	-	292	74	661	260	52
5	-	-	+	-	36	74	3250	3362	234
6	+	-	+	-	0	4	0	0	0
7	-	+	+	-	5	53	34	0	85
8	+	+	+	-	0	0	0	0	0
9	-	-	-	+	4745	3233	425	10280	2466
10	+	-	-	+	1	185	296	162	0
11	-	+	-	+	1313	2009	5860	2920	697
12	+	+	-	+	40	13	2	90	41
13	-	-	+	+	1765	1745	468	3284	169
14	+	-	+	+	0	4	50	10	0
15	-	+	+	+	1109	4930	10	5210	2650
16	+	+	+	+	36	2	169	4	2

Tabela 5.7 – Execução do experimento para a função representada pela Equação 5.5

Exp	A	B	C	D	Y1	Y2	Y3	Y4	Y5
1	-	-	-	-	0,839698	0,84878	0,96264	0,84711	0,90519
2	+	-	-	-	0,999978	0,999373	0,968469	0,990087	0,999492
3	-	+	-	-	0,93421	0,929584	0,994741	0,945799	0,978495
4	+	+	-	-	0,997277	0,999752	0,994741	0,998987	0,983994
5	-	-	+	-	0,990575	0,945799	0,84711	0,987773	0,945799
6	+	-	+	-	0,980416	0,999667	0,999373	0,999995	0,999995
7	-	+	+	-	0,871728	0,978495	0,999995	0,998159	0,998987
8	+	+	+	-	0,998987	0,999667	0,967595	0,999995	0,983994
9	-	-	-	+	0,999869	0,999978	0,999869	0,84703	0,99992
10	+	-	-	+	0,999995	0,999995	0,999869	0,999995	0,999995
11	-	+	-	+	0,983994	0,999995	0,980416	0,999978	0,999978
12	+	+	-	+	0,999978	0,999995	0,999978	0,999995	0,99992
13	-	-	+	+	0,999373	0,999667	0,999995	0,999978	0,999995
14	+	-	+	+	0,999978	0,999978	0,999995	0,999995	0,983994
15	-	+	+	+	0,999667	0,843131	0,999978	0,997277	0,999995
16	+	+	+	+	0,999995	0,999995	0,999995	0,999995	0,99992

5.3.7 Análise estatística dos dados

A seguir é apresentada uma análise estatística dos dados para cada uma das cinco funções descritas anteriormente.

Cabe ressaltar que, de acordo com Montgomery (2005) e Noordin *et al.* (2004), antes de realizar a análise de sensibilidade em projeto de experimentos, deve-se realizar a análise dos resíduos das respostas. Segundo Montgomery (2005), os resíduos devem ser normais, independentes (não-correlacionados) e identicamente distribuídos. Caso a distribuição estatística associada aos resíduos não seja normal, não é possível utilizar os resultados da análise de variância. Desta forma, realizaram-se os testes de normalidade para todas as funções apresentadas neste capítulo, e todas elas passaram no teste.

5.3.7.1 Função representada pela Equação 5.1

A análise dos efeitos principais de cada fator, apresentada na Figura 5.4, mostra que o fator Tamanho da população possui forte efeito positivo sobre a resposta final,

ou seja, o valor máximo da função. Isso significa que a alteração do nível (-) para o nível (+) melhora o resultado final. Já os fatores Número de gerações, Taxa de cruzamento e Taxa de mutação não possuem efeitos significativos sobre o resultado final.

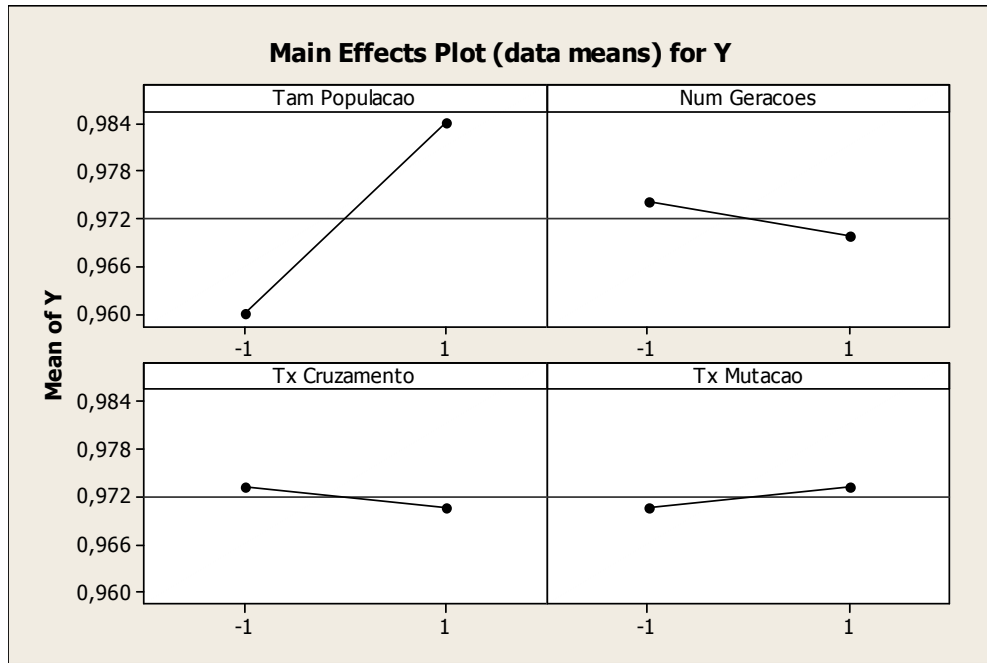


Figura 5.4 – Gráfico dos efeitos principais

Fonte: MiniTab 14.1®

A análise de variância para um nível de significância $\alpha = 0,05$ pode ser vista na Figura 5.5. Nota-se que os efeitos principais e as interações de quarta ordem são consideradas significativas para um *p-value* de 0,05.

Analysis of Variance for Y (coded units)						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	0,0122724	0,0122724	0,0030681	11,91	0,000
2-Way Interactions	6	0,0007538	0,0007538	0,0001256	0,49	0,815
3-Way Interactions	4	0,0016411	0,0016411	0,0004103	1,59	0,187
4-Way Interactions	1	0,0033788	0,0033788	0,0033788	13,11	0,001
Residual Error	64	0,0164912	0,0164912	0,0002577		
Pure Error	64	0,0164912	0,0164912	0,0002577		
Total	79	0,0345372				

Figura 5.5 – Análise de variância

Fonte: MiniTab 14.1®

O peso dos efeitos desses fatores pode ser visualizado no gráfico de *Pareto* para os efeitos padronizados, mostrado na Figura 5.6.




Figura 5.6 – Gráfico de Pareto para os efeitos padronizados

Fonte: MiniTab 14.1®

No gráfico apresentado na Figura 5.6, verifica-se que o fator A (Tamanho da população) tem uma importância relativa bem maior que a dos outros fatores principais, para um grau de 95% de confiança ($\alpha = 0,05$).

Um destaque especial para a interação entre os fatores ABCD (Tamanho da população * Número de Gerações * Taxa de cruzamento * Taxa de mutação). Esta interação de quarta ordem aparece em segundo lugar em importância relativa.

5.3.7.2 Função representada pela Equação 5.2

A análise dos efeitos principais de cada fator, apresentada na Figura 5.7, mostra que os fatores Tamanho da população e Taxa de mutação possuem forte efeito positivo sobre a resposta final, ou seja, o valor máximo da função. Isso significa que a alteração do nível (-) para o nível (+) melhora o resultado final. Já os fatores Número de gerações e Taxa de cruzamento não possuem efeitos significativos sobre o resultado final.




Figura 5.7 – Gráfico dos efeitos principais

Fonte: MiniTab 14.1®

A análise de variância pode ser vista na Figura 5.8. Nota-se que os efeitos principais e as interações de segunda ordem são consideradas significativas para um *p-value* de 0,05.

Analysis of Variance for Y (coded units)						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	1,01275	1,01275	0,253187	10,45	0,000
2-Way Interactions	6	0,62390	0,62390	0,103983	4,29	0,001
3-Way Interactions	4	0,11249	0,11249	0,028123	1,16	0,337
4-Way Interactions	1	0,00174	0,00174	0,001742	0,07	0,789
Residual Error	64	1,55079	1,55079	0,024231		
Pure Error	64	1,55079	1,55079	0,024231		
Total	79	3,30167				

Figura 5.8 – Análise de variância

Fonte: MiniTab 14.1®

O peso dos efeitos desses fatores pode ser visualizado no gráfico de *Pareto* para os efeitos padronizados, mostrado na Figura 5.9. Neste gráfico, verifica-se que o fator D (Taxa de mutação) e o fator A (Tamanho da população) têm uma importância relativa bem maior que a dos outros fatores principais, para um grau de 95% de confiança ($\alpha - 1$).

Um destaque especial para a interação ente os fatores AD (Tamanho da

população * Taxa de mutação). Esta interação de segunda ordem aparece em terceiro lugar em importância relativa.




Figura 5.9 – Gráfico de Pareto para os efeitos padronizados

Fonte: MiniTab 14.1®

5.3.7.3 Função representada pela Equação 5.3

A análise dos efeitos principais de cada fator, apresentada na Figura 5.10, mostra que o fator Tamanho da população possui forte efeito positivo sobre a resposta final, ou seja, o valor mínimo da função. Isso significa que a alteração do nível (-) para o nível (+) melhora o resultado final. Já os fatores Número de gerações e Taxa de cruzamento e Taxa de mutação não possuem efeitos significativos sobre o resultado final.




Figura 5.10 – Gráfico dos efeitos principais

Fonte: MiniTab 14.1®

A análise de variância pode ser vista na Figura 5.11. Nota-se que os efeitos principais e as interações de segunda ordem são consideradas significativas para um *p-value* de 0,05.

Analysis of Variance for Y (coded units)						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	7,5051	7,50511	1,8763	13,77	0,000
2-Way Interactions	6	3,7688	3,76878	0,6281	4,61	0,001
3-Way Interactions	4	1,6219	1,62193	0,4055	2,97	0,026
4-Way Interactions	1	0,8036	0,80358	0,8036	5,90	0,018
Residual Error	64	8,7236	8,72361	0,1363		
Pure Error	64	8,7236	8,72361	0,1363		
Total	79	22,4230				

Figura 5.11 – Análise de variância

Fonte: MiniTab 14.1®

O peso dos efeitos desses fatores pode ser visualizado no gráfico de *Pareto* para os efeitos padronizados, mostrado na Figura 5.12. Neste gráfico, verifica-se que o fator A (Tamanho da população) tem uma importância relativa bem maior que a dos outros fatores principais, para um grau de 95% de confiança ($\alpha - 1$).

Um destaque especial para a interação ente os fatores CD (Taxa de cruzamento * Taxa de mutação). Esta interação de segunda ordem aparece em segundo lugar em importância relativa.




Figura 5.12 – Gráfico de Pareto para os efeitos padronizados

Fonte: MiniTab 14.1®

5.3.7.4 Função representada pela Equação 5.4

A análise dos efeitos principais de cada fator, apresentada na Figura 5.13, mostra que o fator Tamanho da população possui forte efeito positivo sobre a resposta final, ou seja, o valor mínimo da função. Isso significa que a alteração do nível (-) para o nível (+) melhora o resultado final. Já os fatores Número de gerações e Taxa de cruzamento, Taxa de mutação não possuem efeitos significativos sobre o resultado final.




Figura 5.13 – Gráfico dos efeitos principais

Fonte: MiniTab 14.1®

A análise de variância pode ser vista na Figura 5.14. Nota-se que somente os efeitos principais são consideradas significativas para um *p-value* de 0,05.

Analysis of Variance for Y (coded units)						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	86436095	86436095	21609024	11,58	0,000
2-Way Interactions	6	24051575	24051575	4008596	2,15	0,060
3-Way Interactions	4	8842317	8842317	2210579	1,18	0,326
4-Way Interactions	1	3632929	3632929	3632929	1,95	0,168
Residual Error	64	119418168	119418168	1865909		
Pure Error	64	119418168	119418168	1865909		
Total	79	242381083				

Figura 5.14 – Análise de variância

Fonte: MiniTab 14.1®

O peso dos efeitos desses fatores pode ser visualizado no gráfico de *Pareto* para os efeitos padronizados, mostrado na Figura 5.15. Neste gráfico, verifica-se que o fator A (Tamanho da população) tem uma importância relativa bem maior que a dos outros fatores principais, para um grau de 95% de confiança ($\alpha - 1$).

Um destaque especial para a interação ente os fatores AD (Tamanho da população * Taxa de mutação). Esta interação de segunda ordem aparece em segundo lugar em importância relativa.




Figura 5.15 – Gráfico de Pareto para os efeitos padronizados

Fonte: MiniTab 14.1®

5.3.7.5 Função representada pela Equação 5.5

A análise dos efeitos principais de cada fator, apresentada na Figura 5.16, mostra que os fatores Tamanho da população e Taxa de mutação possuem forte efeito positivo sobre a resposta final, ou seja, o valor máximo da função. Isso significa que a alteração do nível (-) para o nível (+) melhora o resultado final. Já os fatores Número de gerações e Taxa de cruzamento não possuem efeitos significativos sobre o resultado final.




Figura 5.16 – Gráfico dos efeitos principais

Fonte: MiniTab 14.1®

A análise de variância pode ser vista na Figura 5.17. Nota-se que somente os efeitos principais são consideradas significativas para um *p-value* de 0,05.

Analysis of Variance for Y (coded units)						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	0,043793	0,0437933	0,0109483	8,66	0,000
2-Way Interactions	6	0,021451	0,0214508	0,0035751	2,83	0,017
3-Way Interactions	4	0,008685	0,0086851	0,0021713	1,72	0,157
4-Way Interactions	1	0,000101	0,0001014	0,0001014	0,08	0,778
Residual Error	64	0,080956	0,0809564	0,0012649		
Pure Error	64	0,080956	0,0809564	0,0012649		
Total	79	0,154987				

Figura 5.17 – Análise de variância

Fonte: MiniTab 14.1®

O peso dos efeitos desses fatores pode ser visualizado no gráfico de *Pareto* para os efeitos padronizados, mostrado na Figura 5.18. Neste gráfico, verifica-se que os fatores A (Tamanho da população), juntamente com o fator D (Taxa de mutação) têm uma importância relativa bem maior que a dos outros fatores principais, para um grau de 95% de confiança ($\alpha - 1$).

Um destaque especial para a interação ente os fatores AD (Tamanho da população * Taxa de mutação). Esta interação de segunda ordem aparece em terceiro lugar em importância relativa.




Figura 5.18 – Gráfico de Pareto para os efeitos padronizados

Fonte: MiniTab 14.1®

5.3.8 Conclusões e recomendações

Pôde-se observar algumas características sobre o comportamento dos parâmetros do algoritmo genético nos cinco projetos de experimentos executados. Essas características são listadas a seguir:

1. O parâmetro Tamanho da população foi significativo em todos os projetos. Além disso, pelo gráfico de *Pareto*, este parâmetro mostrou quase sempre uma maior importância relativa;
2. Ao contrário, o parâmetro Número de gerações não foi significativo em nenhum dos projetos analisados. Uma pergunta pode ser feita: *será que 50 gerações é suficiente para bons resultados?*;
3. Da mesma forma, o parâmetro Taxa de cruzamento não foi significativo em nenhum dos projetos analisados. Muito de publica sobre melhorias na taxa de cruzamento em operadores genéticos. Outra pergunta pode ser feita: *será que a preocupação com esse parâmetro é necessária?*;
4. Ao contrário da taxa de cruzamento, a Taxa de mutação foi significativa em alguns

projetos;

5. O efeito das interações de segunda ordem mostrou-se significativo em quatro dos cinco projetos analisados. Isto reforça a importância de se compreender os efeitos causados por essas interações;
6. Ocorreu um efeito significativo de quarta ordem. Isto reforça a importância no cuidado na escolha dos parâmetros do algoritmo genético.

5.4 CONSIDERAÇÕES FINAIS

Este capítulo apresentou uma análise do comportamento dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade da resposta destes algoritmos.

A análise no tempo de convergência se deu através de um levantamento bibliográfico, enquanto que a análise na qualidade da resposta dos algoritmos genéticos se desenvolveu através de projeto de experimentos, aplicado através de uma metodologia proposta por Montgomery (2005). Cabe ressaltar que esta aplicação só foi possível graças a utilização de uma ferramenta computacional desenvolvida.

Destaca-se, neste capítulo, a ocorrência de uma proporção de importância maior do parâmetro tamanho da população tanto no tempo de convergência como na qualidade da resposta dos algoritmos genéticos.

Com isso, é possível finalizar a fase de conceitualização de Mitroff *et al.* (1974), destacada na Figura 5.1. Nesta fase, definiu-se as variáveis relevantes para o problema de otimização de modelos simulação a eventos discretos, ou seja, qual parâmetro do algoritmo genético mais influencia o tempo de convergência e a qualidade da resposta destes algoritmos.

CAPÍTULO 6 – DESENVOLVIMENTO DO MÉTODO DE OTIMIZAÇÃO

6.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é apresentar o método de otimização proposto para modelos de simulação a eventos discretos. Para tal, inicialmente serão mostradas as adaptações na estrutura dos algoritmos genéticos em relação aos parâmetros destes algoritmos. Na sequência, será mostrado o método proposto para a otimização de modelos de simulação a eventos discretos através dos algoritmos genéticos. Finalmente, será apresentado a ferramenta computacional desenvolvida capaz de executar o método de otimização proposto.

Cabe ressaltar que este capítulo refere-se, em relação ao modelo de Mitroff *et al.* (1974), a fase de modelagem, pois segundo Bertrand e Fransoo (2002) nesta fase constrói-se um modelo quantitativo que define as relações causais entre as variáveis selecionadas na fase de conceitualização. A Figura 6.1 destaca a fase do modelo de Mitroff *et al.* (1974) pertinente a este capítulo.

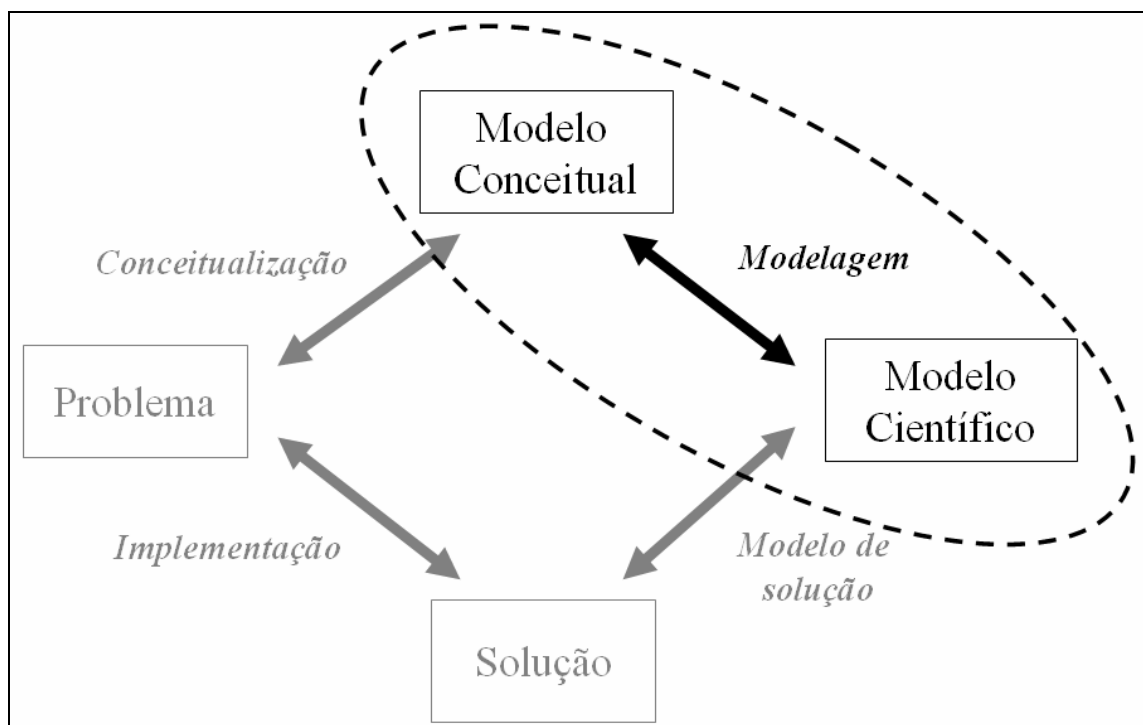


Figura 6.1 – Fase de modelagem

Fonte: Adaptado de Mitroff *et al.* (1974)

6.2 ADAPTAÇÕES NA ESTRUTURA DO ALGORITMO GENÉTICO

Mostrou-se, no capítulo anterior, que dos quatro parâmetros existentes para os algoritmos genéticos, o parâmetro tamanho da população é o maior responsável pela velocidade de convergência desses algoritmos. Também se mostrou, através do projeto de experimentos, realizado no capítulo anterior, que o parâmetro tamanho da população foi significativo, em relação a qualidade da resposta, em todos os projetos analisados, além de quase sempre possuir uma maior importância relativa.

Paralelamente, o escopo desta tese restringe-se a modelos de simulação computacional a eventos discretos, cujas variáveis de entrada são do tipo discretas, determinísticas e inteiras.

Desta forma, serão realizadas adaptações na estrutura do algoritmo genético, considerando as análises comentadas anteriormente, com o intuito de melhorar a eficiência na otimização de modelos de simulação a eventos discretos, além de manter sua eficácia, quando comparado a uma ferramenta de otimização comercial.

A Figura 6.2 mostra como foram direcionadas as adaptações na estrutura do Algoritmo Genético.

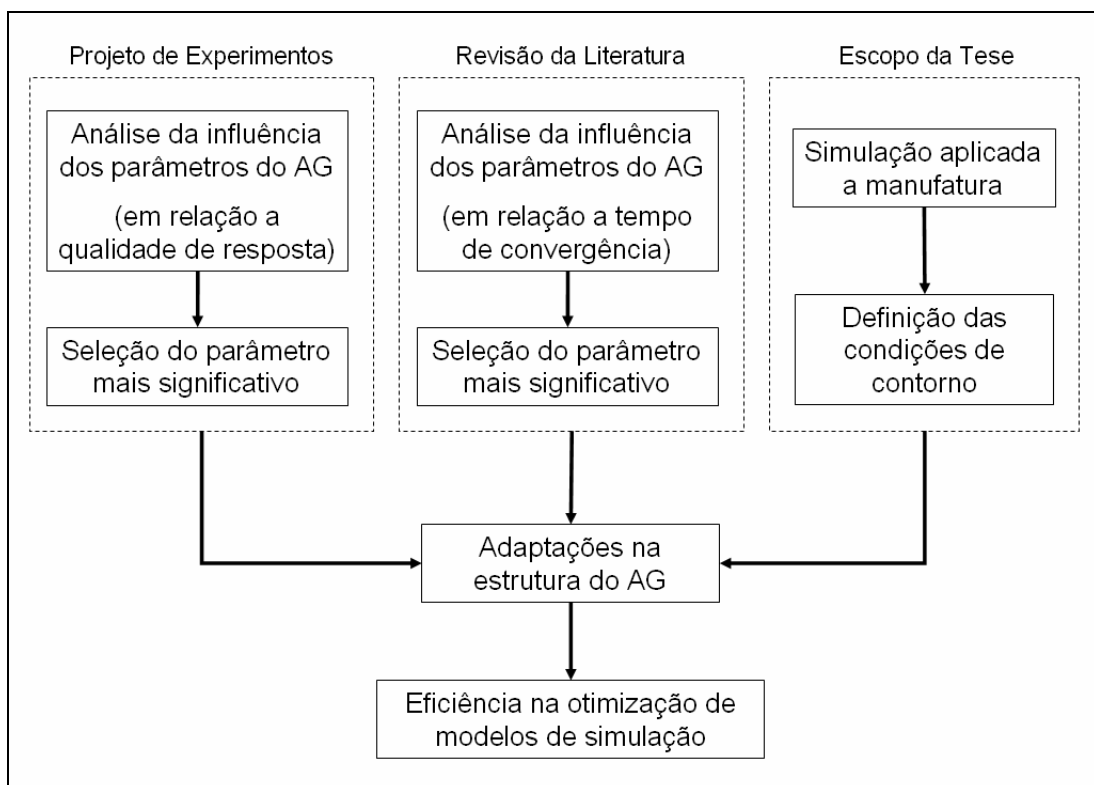


Figura 6.2 – Adaptações na estrutura do Algoritmo Genético

Para a realização das adaptações na estrutura do algoritmo genético, proposto nesta tese de doutorado, levou-se em consideração, principalmente, a influência que o tamanho da população exerce na qualidade da resposta e no tempo de convergências destes algoritmos, aliado ao escopo desta tese. Utilizou-se apenas do parâmetro tamanho da população, pois os parâmetros número de gerações e taxa de cruzamento não foram significativos em nenhum dos projetos de experimentos analisados no capítulo anterior, enquanto que a taxa de mutação foi significativa somente em alguns projetos.

Estas adaptações têm a intenção de melhorar a velocidade de convergência do algoritmo genético e, simultaneamente manter a qualidade de resposta destes algoritmos.

Cabe ressaltar que, conforme visto na revisão bibliográfica sobre algoritmos genéticos, as técnicas de adaptação nos parâmetros destes algoritmos têm sido utilizadas por diversos autores na intenção de melhorar seu desempenho (LINDEN, 2006).

6.3 ADAPTAÇÕES NO PARÂMETRO TAMANHO DA POPULAÇÃO

O tamanho da população é representado por um conjunto de indivíduos. Por sua vez, um indivíduo da população é a representação, no caso desta tese de doutorado, de uma possível solução na forma binária $\{0,1\}$.

Considerando-se uma variável discreta, determinística e inteira, com uma variação entre $[1, 10]$ e uma precisão de 1, é possível calcular a quantidade de *bits* necessários para o indivíduo, ou seja, o tamanho do indivíduo, utilizando-se a Equação 6.1 (MITCHELL, 1996), apresentada na revisão bibliográfica sobre algoritmos genéticos.

$$\text{Precisão} = \frac{\text{sup}_i - \text{inf}_i}{2^k - 1} \quad (6.1)$$

Sendo:

k – número de *bits* do cromossomo (tamanho do indivíduo);

$[inf_i, sup_i]$ – limites inferior e superior da faixa de operação (variação).

Substituindo-se os valores, tem-se:

$$1 = \frac{10-1}{2^k - 1} \Rightarrow k = 3,32 \Rightarrow k = 4 \quad (6.2)$$

Desta forma, para as condições estabelecidas, serão necessários 4 *bits* para o tamanho do indivíduo. Percebe-se, então, que o tamanho do indivíduo para atender as condições de contorno propostas por esta tese de doutorado será sempre menor do que se fosse um valor não inteiro. A Tabela 6.1 comprova tal afirmação. Nota-se que mesmo com uma maior variação entre os limites inferior e superior o tamanho do indivíduo, considerando-se variáveis inteiras, ainda será pequeno.

Tabela 6.1 – Tamanho do indivíduo em relação a variação entre os limites inferior e superior

Variação entre os limites inferior e superior	Quantidade de <i>bits</i> necessários (tamanho do indivíduo)
5	3
10	3
20	5
30	5
40	6
50	6

Cabe ressaltar que o número de *bits* necessários para o tamanho do indivíduo também será pequeno para aos problemas de otimização de modelos de simulação a eventos discretos com mais de uma variável de entrada. Mesmo este número de *bits* tendo que contemplar, para cada uma destas variáveis, as necessidades relacionadas a variação entre seus limites inferiores e superiores e a precisão desejada.

Desta forma, uma vez que se tem uma redução no tamanho do indivíduo, espera-se que o tamanho da população necessário para garantir a robusteza dos algoritmos genéticos também seja menor. Entretanto, tem-se a seguinte questão: *qual o tamanho da população ideal para manipular estes indivíduos?*

Uma possível resposta a esta questão está em Goldberg (1989), que estabelece uma relação entre tamanho da população e tamanho do indivíduo. Esta relação, apresentada na revisão bibliográfica sobre algoritmos genéticos, é mostrada na Equação 6.3.

$$\text{Tamanho da população} = 1,65 \cdot 2^{0,21 \cdot k} \quad (6.3)$$

Sendo:

k – número de *bits* do cromossomo (tamanho do indivíduo);

Através da Equação 6.3 verifica-se que o tamanho da população cresce exponencialmente em relação ao crescimento do tamanho do indivíduo. A Tabela 6.2 mostra este crescimento.

Tabela 6.2 – Relação entre tamanho do indivíduo e tamanho da população

Tamanho do indivíduo	Tamanho da população
5	4
10	8
15	15
20	31
30	130
40	558
50	2390
60	10244

Nota-se que para um tamanho de indivíduo pequeno o tamanho da população, necessário para a manipulação do algoritmo genético proposto, também será relativamente pequeno.

Mesmo utilizando-se a expressão de Goldberg (1989), mostrada anteriormente na Equação 6.3, para a manipulação do parâmetro tamanho da população, optou-se, também, em inserir uma taxa de crescimento neste parâmetro. Cabe ressaltar que, de fato, este incremento no tamanho da população, a cada geração, é que torna o proposto algoritmo genético adaptativo. Pode-se justificar esta adaptação através do levantamento bibliográfico apresentado a seguir.

Gong *et al.* (2007) utilizam técnicas adaptativas para o tamanho de população. Segundo os autores, a cada geração do algoritmo genético, um tamanho de população diferente é utilizado. A intenção é reduzir o tempo processamento em busca da solução ótima e ao mesmo tempo evitar a convergência prematura do algoritmo.

Já Ma e Zhang (2008) apresentam uma técnica adaptativa para o tamanho da população que não descarta alguns dos cromossomos utilizados na operação de cruzamento. Como consequência desta adaptação, a cada geração tem-se um número maior para o tamanho da população, que pode aumentar de 1 a 100% do seu tamanho original.

De forma semelhante, Kaveh e Shahrouzi (2007) propõem um método para ajustar o tamanho da população. Inicia-se o algoritmo genético com um tamanho de população pré-definido e a cada geração este valor é aumentado com base em uma taxa. Os autores definem que o valor máximo desta taxa deverá ser de 50%. O resultado encontrado pelos autores mostrou uma melhora significativa no tempo de convergência do algoritmo genético.

Nesta tese, optou-se em utilizar uma taxa de crescimento no parâmetro tamanho da população igual a 50%. Justifica-se a escolha deste valor, uma vez que o método proposto sempre iniciará com um valor para o tamanho da população pequeno, quando comparado aos valores encontrados na revisão bibliográfica. O aumento de 50% no tamanho da população a cada geração permitirá ao método proposto buscar o tamanho da população ideal de Lobo e Goldberg (2004), apresentado na Figura 5.2 do capítulo anterior. Desta forma, garante-se a redução no tempo de convergência do algoritmo genético, além de garantir a qualidade na resposta deste algoritmo.

O fluxograma apresentado na Figura 6.3, mostra os procedimentos adotados na adaptação do parâmetro tamanho da população para o proposto método de otimização de modelos de simulação a eventos discretos.

Inicialmente, calcula-se a quantidade de *bits* necessários para cada indivíduo da população através da Equação 6.1 (MITCHELL, 1996). Na seqüência, estima-se o tamanho da população inicial através da Equação 6.3 (GOLDBERG, 1989). O algoritmo genético é então executado e os resultados desta primeira geração são avaliados.

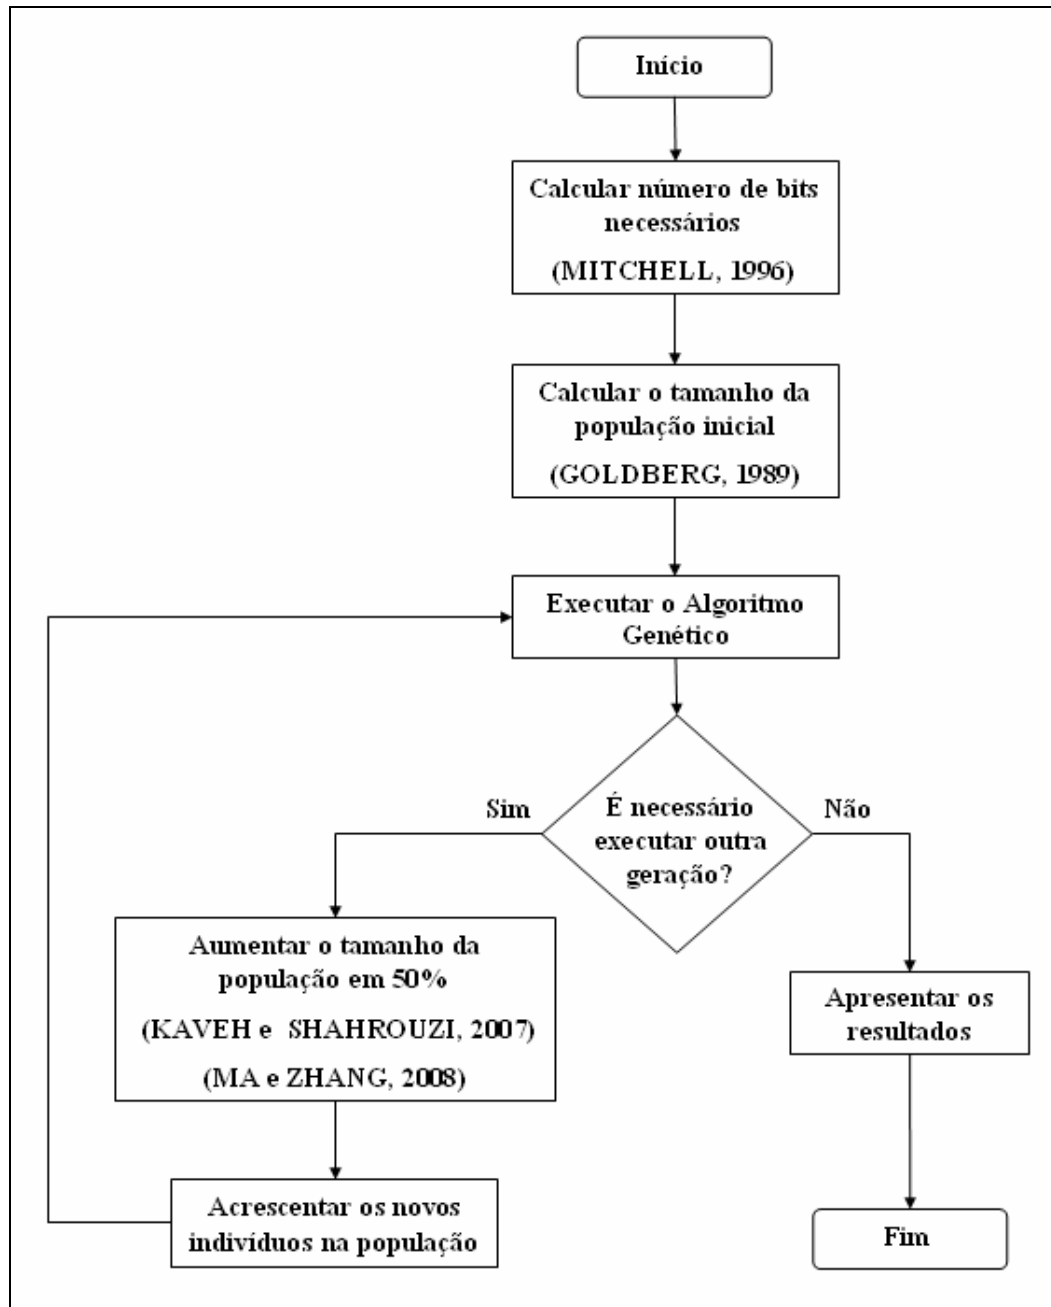


Figura 6.3 – Adaptação proposta para o parâmetro tamanho da população

Caso não seja necessário executar uma nova geração para o algoritmo genético, os resultados são apresentados e encerra-se a adaptação. Caso contrário, ou seja, se for necessário executar uma nova geração, aumenta-se o tamanho da população em 50% (KAVEH e SHAHROUZI, 2007; MA e ZHANG, 2008). Estes novos indivíduos serão gerados aleatoriamente e inseridos na população atual do problema. O algoritmo genético será executado até não ser mais necessário avaliar outra geração.

6.4 CONSIDERAÇÕES SOBRE O PARÂMETRO NÚMERO DE GERAÇÕES

Segundo Mitchell (1996), o número de gerações está associado com o critério de parada do algoritmo genético. Em outras palavras, algum critério deve ser adotado para o término do processamento do algoritmo. Existem diferentes tipos de critério de parada, por exemplo, têm-se o critério do número máximo de gerações ou tempo limite de processamento para encerramento do processo.

Diferentemente do algoritmo genético utilizado no capítulo 5, onde o total de número de gerações era fornecido no início do processo, será adotado para o algoritmo proposto neste capítulo, que este encerre no momento que se percebe que não há mais melhorias de uma geração para outra. Isto faz com que o número de gerações seja conhecido somente quando o critério de parada for satisfeito. De fato, este critério de parada para o número de gerações é citado por diversos autores (GOLDBERG, 1989; TANOMARU, 1995; BARBOSA, 2005; AL-AOMAR e AL-OKAILY, 2006; LINDEN, 2006).

Cabe ressaltar que esta modificação no critério de parada para o algoritmo proposto, não pode ser considerada como uma adaptação, uma vez que este critério não é mutável ao longo das gerações.

Optou-se por este critério uma vez que o parâmetro número de gerações não foi significativo no estudo realizado no capítulo 5. Desta forma, mesmo não considerando esta mudança como uma adaptação, espera-se que esta contribua para melhorar o desempenho do algoritmo proposto.

6.5 CONSIDERAÇÕES SOBRE OS PARÂMETROS TAXA DE CRUZAMENTO E TAXA DE MUTAÇÃO

Segundo Mitchell (1996), a taxa de cruzamento é a probabilidade de se efetuar o cruzamento entre dois indivíduos da população. De forma semelhante, a taxa de mutação determina se os genes dos indivíduos sofrerão mutação ou não.

Optou-se em não realizar nenhuma adaptação nesses parâmetros, principalmente pelas seguintes razões:

Primeiro, tem-se o fato do parâmetro taxa de cruzamento não ter se mostrado significativo em nenhum dos projetos estudados no capítulo 5.

Segundo, apesar do parâmetro taxa de mutação ter sido significativo em alguns dos projetos estudados no capítulo 5, também se optou em não efetuar adaptações neste parâmetro. Uma vez que o tamanho da população foi reduzido, espera-se que a convergência do algoritmo genético seja feita de forma mais rápida. Desta forma, acredita-se que as mudanças que poderiam ser feitas neste parâmetro não contribuiriam com a redução do tempo de convergência do método de otimização.

O operador de cruzamento utilizado no desenvolvimento do método de otimização proposto foi o de Cruzamento de um Ponto. Já o operador de mutação utilizado foi o de Mutação Binária Simples. Os valores definidos para as taxas de cruzamento e a taxa de mutação que serão utilizados na otimização dos modelos de simulação no próximo capítulo são respectivamente 80% e 10%. Estas escolhas foram feitas com base no projeto de experimentos realizado no capítulo 5, sendo esses valores atribuídos ao nível (+) do projeto fatorial completo.

6.6 MÉTODO PARA OTIMIZAÇÃO DE MODELOS DE SIMULAÇÃO

O método proposto para a otimização de modelos de simulação a eventos discretos, que atende às condições de contorno estabelecidas, pode ser dividido em duas fases.

A primeira fase, mostrada na Figura 6.4, consiste na verificação da possibilidade de aplicação do método para o problema proposto.

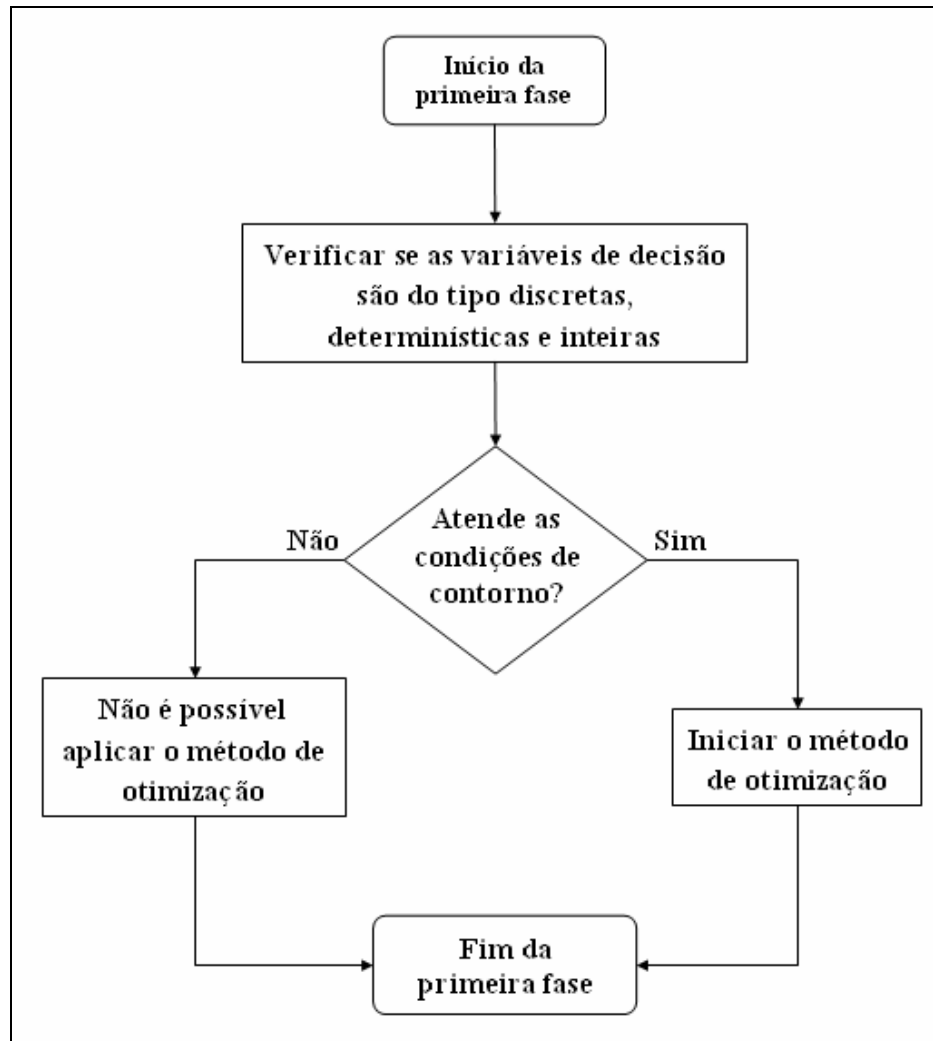


Figura 6.4 – Fluxograma da primeira fase do método de otimização proposto

Inicialmente, tem-se a verificação das variáveis de decisão para o modelo de simulação que se pretende otimizar. Cabe ressaltar que este método só foi validado para as condições de contorno estabelecidas no capítulo 1 desta tese de doutorado, ou seja, as variáveis de decisão precisam ser do tipo discretas, determinísticas e inteiras. Se estas condições forem atendidas, o método está apto a iniciar a fase de otimização do modelo de simulação. Caso contrário, não é possível iniciar a fase de otimização.

A segunda fase do método proposto consiste no processo de otimização, propriamente dito, de modelos de simulação a eventos discretos. O fluxograma apresentado na Figura 6.5 mostra este processo de otimização, além das adaptações feitas no algoritmo genético.

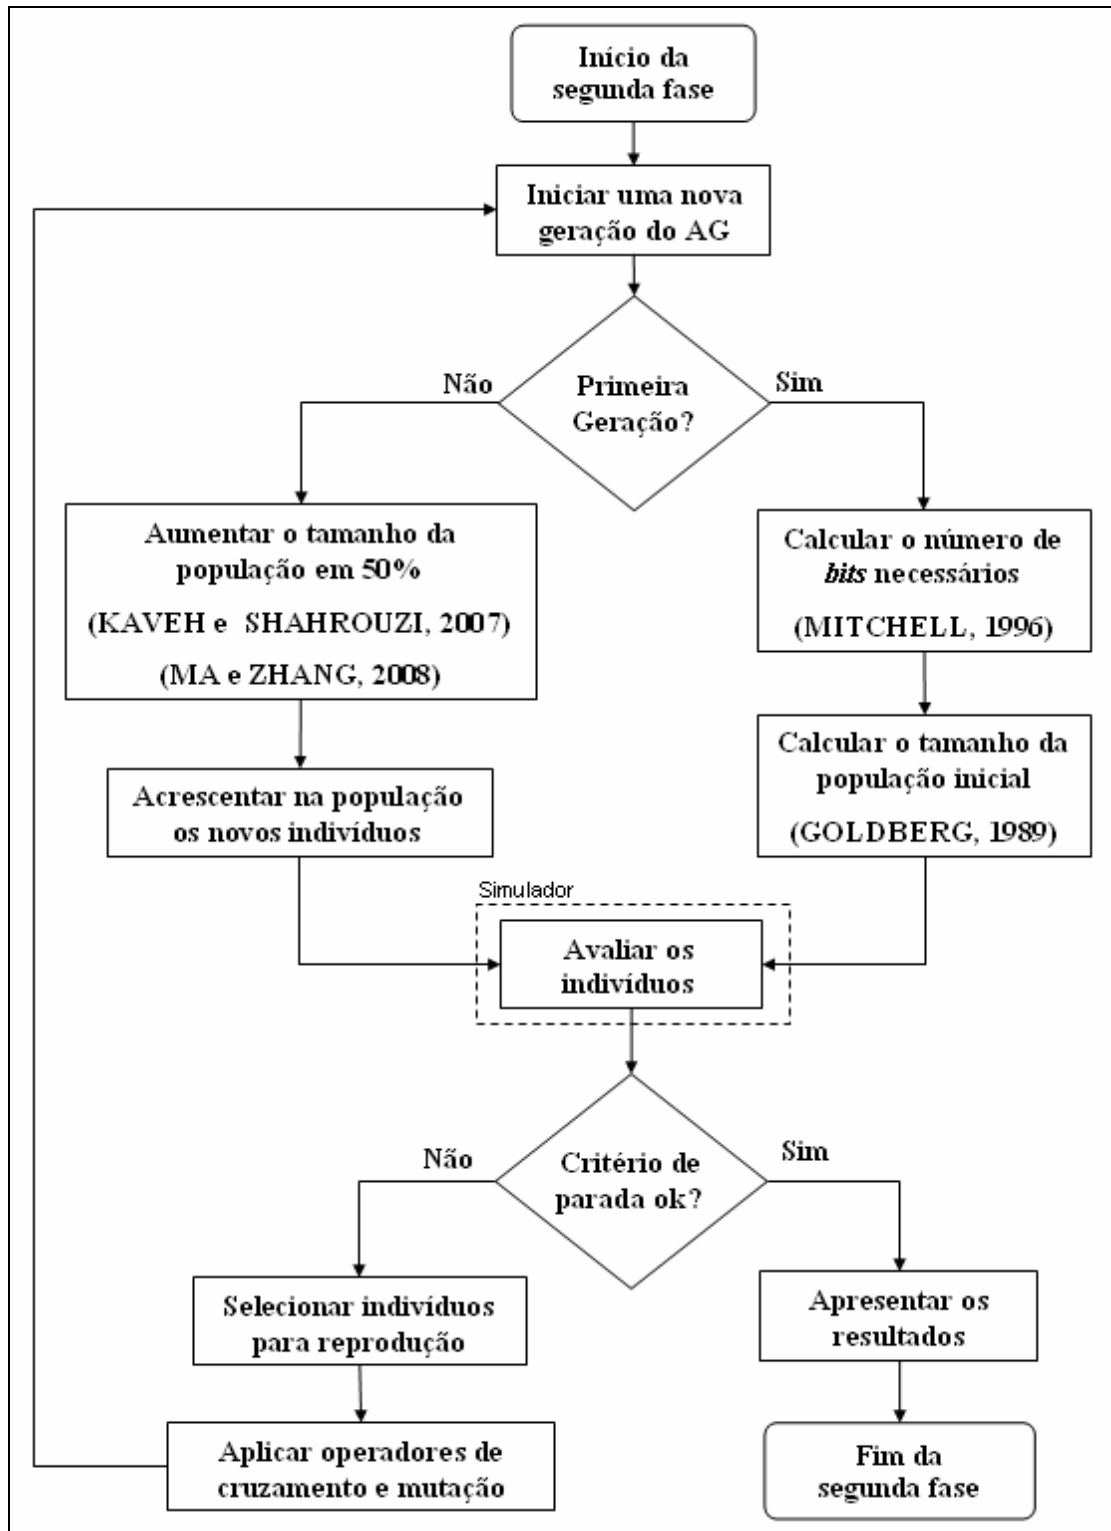


Figura 6.5 – Fluxograma da segunda fase do método de otimização proposto

Ao iniciar-se uma nova geração, verifica-se se esta é a primeira geração. Se a resposta a esta questão for afirmativa, faz-se o cálculo do número de *bits* necessários para cada indivíduo da população do algoritmo genético, através da Equação 6.1 (MITCHELL, 1996). Na seqüência, calcula-se o tamanho da população inicial,

considerando-se a Equação 6.3 (GOLDBERG, 1989). Gera-se então a população inicial do algoritmo genético. Cabe ressaltar que estes dois passos só acontecerão na primeira vez que se executar a fase 2.

Se já existir uma população, ou seja, se não for a primeira geração, aumenta-se o parâmetro tamanho da população em 50% (KAVEH e SHAHROUZI, 2007; MA e ZHANG, 2008). Estes novos indivíduos serão gerados aleatoriamente e inseridos na população atual do problema.

A avaliação de cada indivíduo é realizada através do simulador a eventos discretos. Para tal, o método envia, separadamente, cada indivíduo da população para o simulador, e este retorna a resposta do modelo de simulação para tais indivíduos com base na função objetivo definida. O item 6.7, a seguir, mostra com mais detalhes o funcionamento desta avaliação através da ferramenta computacional desenvolvida.

Após a avaliação de todos os indivíduos da população, verifica-se se há melhorias na resposta da geração atual em relação a geração anterior. Se não ocorrer melhorias significativas, ou seja, inferior a precisão da função objetivo, considera-se que a condição de parada do método foi satisfeita. Apresenta-se, então os resultados da otimização do modelo de simulação e encerra-se o método.

Caso a condição de parada não seja satisfatória, selecionam-se os indivíduos para reprodução, através do método da roleta, apresentado no capítulo 3. Na seqüência, aplicam-se os operadores de cruzamento e mutação nos indivíduos selecionados anteriormente. Utilizaram-se as taxas de 80% e 10% para as taxas de cruzamento e mutação respectivamente.

Após a aplicação destes operadores nos indivíduos selecionados, uma nova geração pode ser formada, iniciando-se todo o processo novamente.

6.7 FERRAMENTA COMPUTACIONAL DESENVOLVIDA

Para o desenvolvimento do método proposto, preocupou-se em elaborar uma ferramenta computacional, com base nos algoritmos genéticos, capaz de permitir a manipulação de seus parâmetros, além de permitir a comunicação entre esta

ferramenta computacional e o simulador a eventos discretos. Esta comunicação se dá através de um objeto chamado *ProActiveX*, fornecido pelo fabricante do simulador, conforme mostra a Figura 6.7.

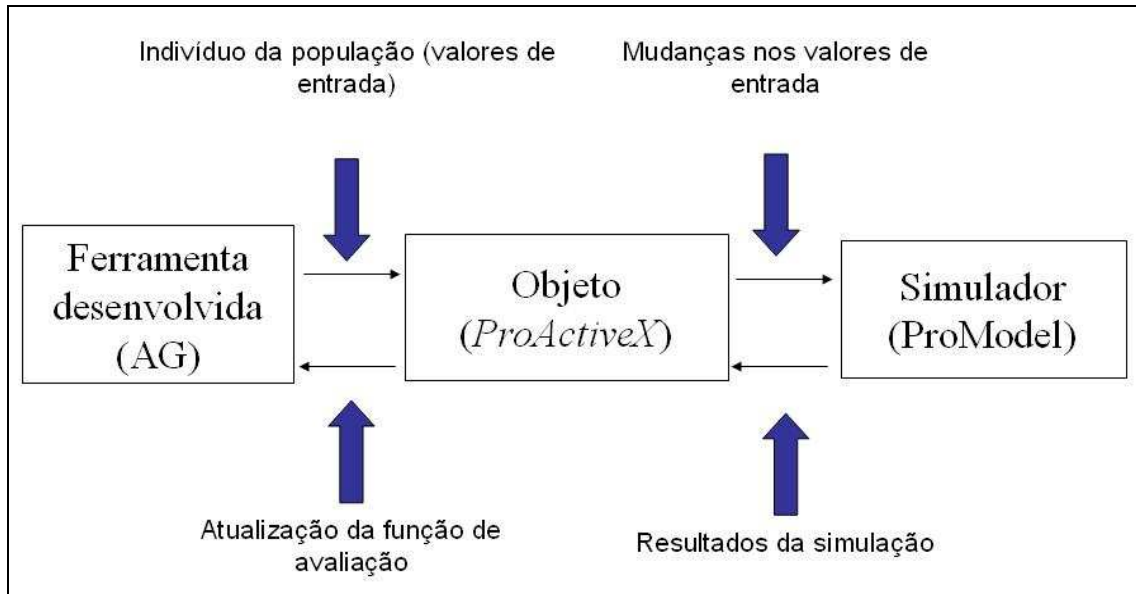


Figura 6.7 - Comunicação entre a ferramenta desenvolvida e o simulador

Para executar a otimização, a ferramenta computacional envia para o objeto *ProActiveX*, os indivíduos da população. Esses indivíduos representam as variáveis de entrada do modelo de simulação, tais como: quantidade de operadores, quantidade de máquinas, etc. O objeto então insere esses valores no simulador, aguarda a execução da simulação e recupera os resultados do modelo simulado. Esses resultados podem ser: a produtividade, a taxa de produção, a eficiência do sistema produtivo, ou qualquer indicador de desempenho desejado. Esses resultados serão utilizados na avaliação de cada indivíduo existente do algoritmo genético.

6.8 CONSIDERAÇÕES FINAIS

Este capítulo apresentou o método de otimização desenvolvido para modelos de simulação a eventos discretos. O método consiste na estimativa do tamanho da população inicial e na adaptação no parâmetro tamanho da população no funcionamento do algoritmo genético.

Cabe ressaltar que o método proposto é válido para as condições de contorno estabelecidas por esta tese de doutorado, que consiste na manipulação de variáveis de decisão do tipo discretas, determinísticas e inteiras.

Foi apresentada, também, a ferramenta computacional desenvolvida capaz de permitir a aplicação do método proposto em modelos de simulação, além de permitir a manipulação dos parâmetros do algoritmo genético e a comunicação com o simulador a eventos discretos.

Com isso, é possível finalizar a fase de modelagem de Mitroff *et al.* (1974), destacada na Figura 6.1. Nesta fase, construiu-se um modelo quantitativo para otimização de modelos simulação a eventos discretos.

CAPÍTULO 7 – APLICAÇÃO DO MÉTODO DE OTIMIZAÇÃO PROPOSTO

7.1 CONSIDERAÇÕES INICIAIS

O objetivo deste capítulo é efetuar a comparação do método de otimização desenvolvido com uma ferramenta disponível comercialmente. Para tal, inicialmente, se fará as justificativas da escolha da ferramenta comercial, seguida da metodologia utilizada para a comparação entre estes métodos de otimização.

Na seqüência, serão apresentados os quatro objetos de estudo utilizados. Finalmente, será efetuada a otimização destes objetos de estudo, através dos dois métodos de otimização, sendo apresentada uma comparação entre esses resultados.

Cabe ressaltar que este capítulo refere-se, em relação ao modelo de Mitroff *et al.* (1974), a fase de modelo de solução. Bertrand e Fransoo (2002) afirmam que nesta fase, utiliza-se um modelo de resolução através de regras matemáticas, ou seja, aplicar-se-á o método de otimização proposto na fase de modelagem com a intenção de avaliar as soluções encontradas. A Figura 7.1 destaca a fase do modelo de Mitroff *et al.* (1974) pertinente a este capítulo.

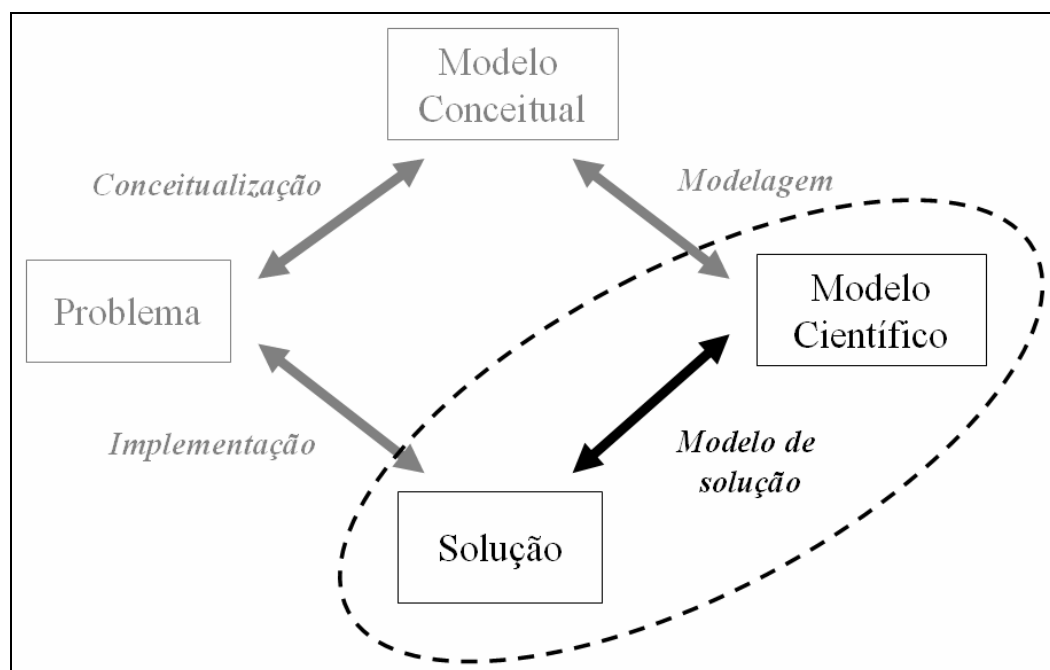


Figura 7.1 – Fase de modelo de solução

Fonte: Adaptado de Mitroff *et al.* (1974)

7.2 JUSTIFICATIVA DO USO DO PROMODEL® / SIMRUNNER®

Para Delinchant *et al.* (2007), os softwares para otimização de modelos de simulação compreendem um novo paradigma de implementação no estudo de simulação. Oferecem uma nova oportunidade de rapidamente conectar o modelo computacional desenvolvido a um algoritmo de otimização através de uma interface padronizada.

Segundo Appelqvist e Lehtonen (2005), muitos pacotes de simulação, tais como AtoMod®, eMPower®, ProModel® e Quest®, oferecem ferramentas de otimização, que segundo os autores, tem o objetivo de encontrar a combinação dos valores das variáveis de entrada que possibilitam o melhor resultado na variável de saída.

Para a realização dos modelos computacionais apresentados nesta tese, foi utilizado o software Promodel® da Promodel Corporation, um dos softwares de simulação mais utilizados no mercado (DOLOI e JAFARI, 2003).

Este pacote de simulação incorpora três programas principais: Promodel® (para simulação a eventos discretos), SimRunner® (para otimização de modelos de simulação) e Stat::Fit® (para estudo de distribuições de probabilidade).

Segundo Harrel, Ghosh e Bowden (2000), o SimRunner® é relativamente simples de se usar. Segundo estes autores é possível utilizar o SimRunner® apenas com um conhecimento básico sobre heurísticas de busca de problemas de otimização.

Verma, Gibbs e Gilgan (2000) afirmam que o SimRunner® pode facilmente ser incorporado como uma ferramenta de tomada de decisão e fazer parte do dia a dia das decisões dos gestores. Isto é possível graças sua facilidade de uso.

Adicionalmente, conforme mostrado na revisão bibliográfica sobre simulação, o SimRunner® se utiliza dos algoritmos genéticos para a otimização dos modelos de simulação.

Desta forma, o método de otimização de modelos de simulação a eventos discreto, proposto por esta tese, será comparado ao otimizador do Promodel®, ou seja, ao SimRunner®. Utilizou-se nesta tese a versão 4.22 do Promodel®, que incorpora a versão 2.8d do SimRunner®.

7.3 METODOLOGIA UTILIZADA NESTE CAPÍTULO

Conforme já apresentado na revisão bibliográfica, geralmente as metodologias de otimização em simulação partem de um modelo já existente e validado. A metodologia para otimização de modelos de simulação utilizada neste capítulo será a proposta por Harrel, Ghosh e Bowden (2000). Esta metodologia já foi descrita na revisão bibliográfica sobre simulação. A Figura 7.2 apresenta um fluxograma com esta metodologia sintetizada.

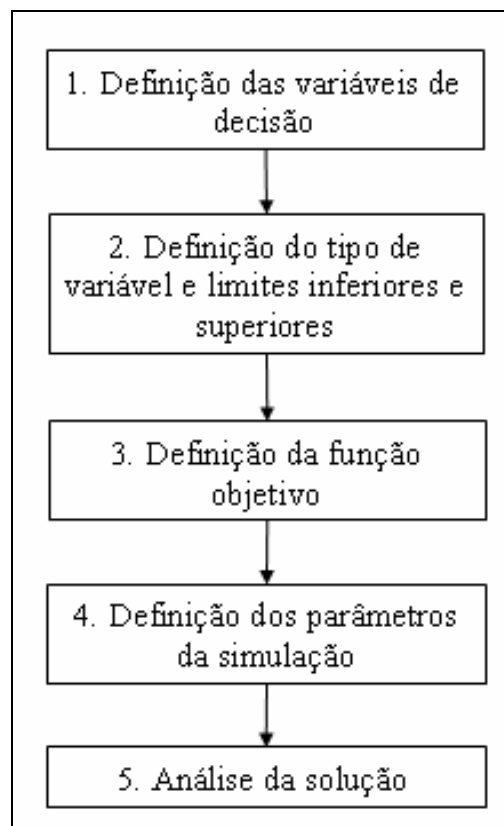


Figura 7.2 – metodologia para otimização de modelos de simulação

Fonte: Harrel, Ghosh e Bowden (2000)

Cabe ressaltar que mesmo seguindo uma metodologia para a execução da otimização em simulação, alguns fatores afetam diretamente o desempenho de busca, entre eles: precisão do modelo, número de variáveis, complexidade da função objetivo, valores iniciais das variáveis e seus limites.

Desta forma, a comparação entre o método de otimização proposto e o *SimRunner*® será realizada mantendo-se os mesmos valores para estes atributos e através da mesma metodologia proposta por Harrel, Ghosh e Bowden (2000).

Vale a pena destacar que o método de otimização, desenvolvido nesta tese, atua entre o quarto e quinto passos da metodologia de otimização proposta por esses autores, assim como o *SimRunner*®.

7.4 OBJETOS DE ESTUDO

Quatro objetos de estudo foram selecionados. O primeiro e o segundo objetos de estudo referem-se a empresas do setor automobilístico. Já o terceiro e o quarto objeto de estudo referem-se a uma empresa de alta tecnologia. A seguir apresenta-se uma descrição de cada objeto de estudo, juntamente com o modelo computacional desenvolvido para cada um destes objetos.

Cabe ressaltar que os modelos conceituais e computacionais de cada um dos objetos de estudo, utilizados nesta tese, foram verificados e validados em trabalhos anteriores ao qual o pesquisador foi co-autor. Estas etapas de validação e verificação foram apresentadas em artigos de congressos e serão referenciadas, a seguir, para cada um destes objetos de estudo.

7.4.1 Primeiro objeto de estudo

O primeiro objeto de estudo refere-se a uma linha de produção de uma empresa do setor automobilístico produtora de componentes eletrônicos. Tal linha de produção é responsável pela fabricação de 900 peças diárias divididas em quatro famílias.

A verificação e a validação do modelo conceitual e computacional encontram-se em Montevechi *et al.* (2007). A Figura 7.3 ilustra o ambiente de construção do modelo computacional no ProModel®.

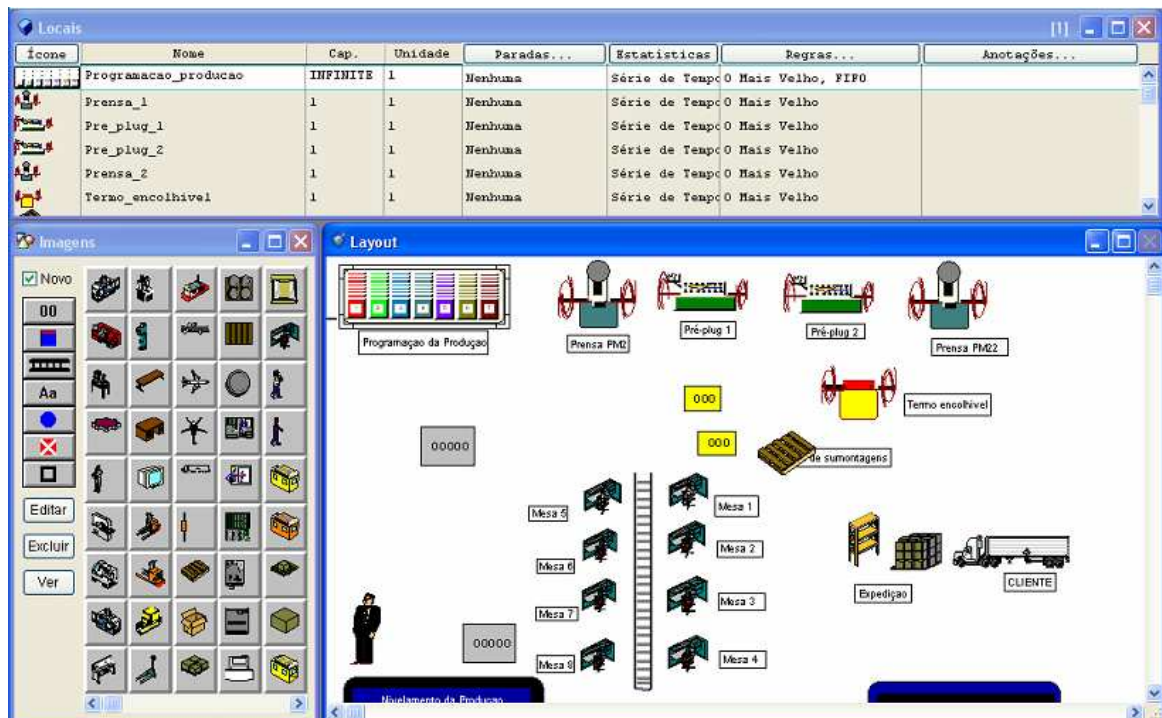


Figura 7.3 – Ambiente de construção do modelo computacional no ProModel® para o primeiro objeto de estudo

7.4.2 Segundo objeto de estudo

O segundo objeto de estudo refere-se a uma célula de manufatura de uma empresa do setor de autopeças. O produto final desta célula é o anel para pistão, utilizado em motores de automóveis.

A verificação e a validação do modelo conceitual e computacional encontram-se em Montevechi *et al.* (2008a). A Figura 7.4 ilustra o ambiente de construção do modelo computacional no *ProModel*®.

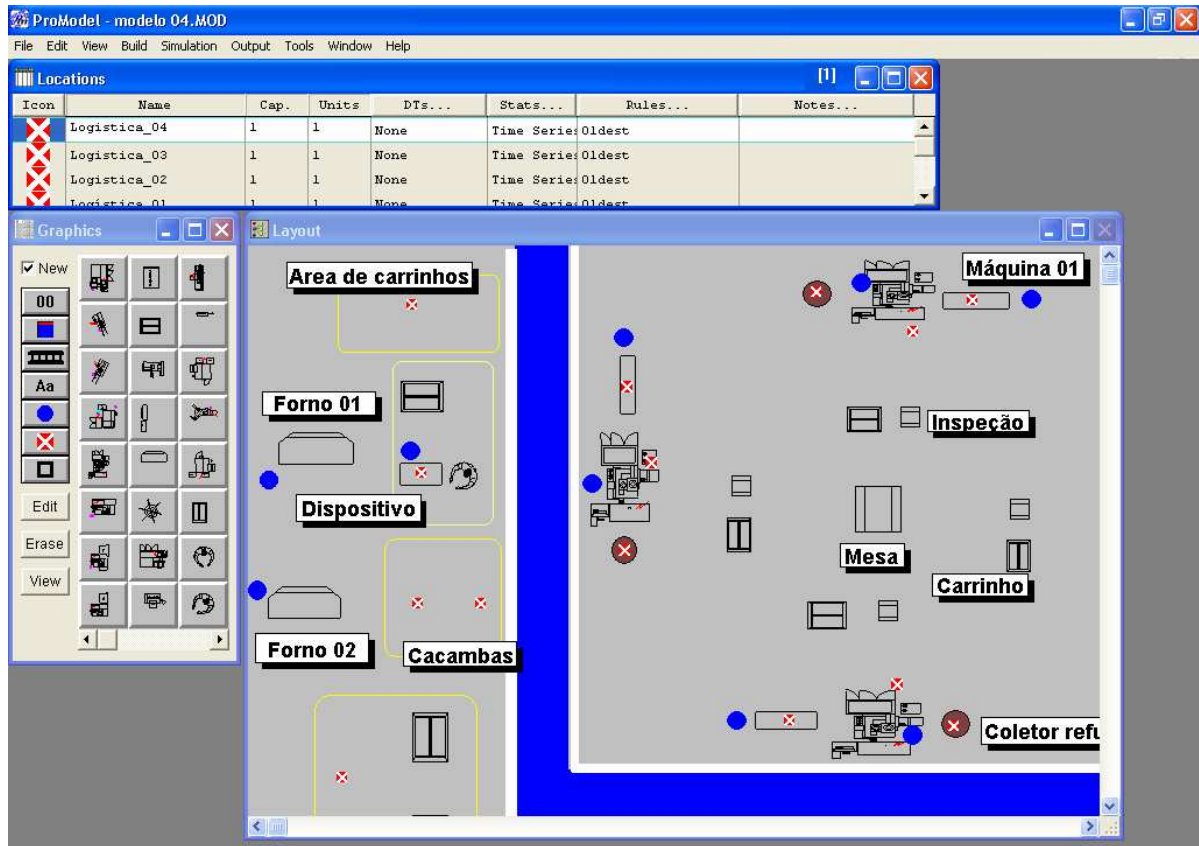


Figura 7.4 – Ambiente de construção do modelo computacional no ProModel® para o segundo objeto de estudo

7.4.3 Terceiro objeto de estudo

O terceiro objeto de estudo refere-se a uma empresa brasileira de alta tecnologia, focada na fabricação e desenvolvimento de equipamentos para a comunicação óptica. A área de manufatura da empresa é composta por seis células de produção, sendo cada célula responsável por montar um grupo de equipamentos. A modelagem foi desenvolvida na célula de *transponders*. O produto analisado neste objeto de estudo é o *transponder* de 2,5 Gb.

A verificação e a validação do modelo conceitual e computacional encontram-se em Montevechi *et al.* (2008b). A Figura 7.5 ilustra o ambiente de construção do modelo computacional no *ProModel*®.

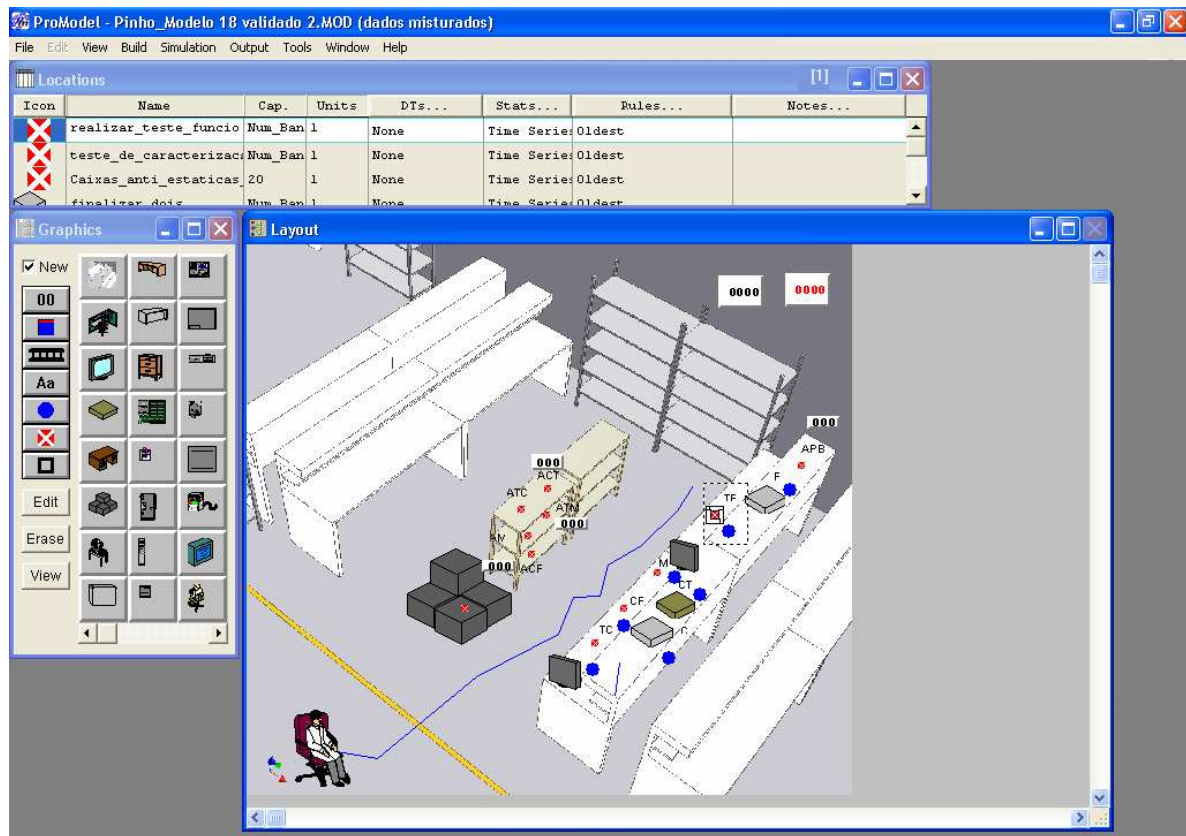


Figura 7.5 – Ambiente de construção do modelo computacional do ProModel® para o terceiro objeto de estudo

7.4.4 Quarto objeto de estudo

O quarto objeto de estudo refere-se a mesma célula de manufatura do objeto de estudo anterior. Entretanto o produto aqui analisado é o *transponder* de 10Gb.

A verificação e a validação do modelo conceitual e computacional encontram-se em Montevechi *et al.* (2008b). A Figura 7.6 ilustra o ambiente de construção do modelo computacional no *ProModel*®.

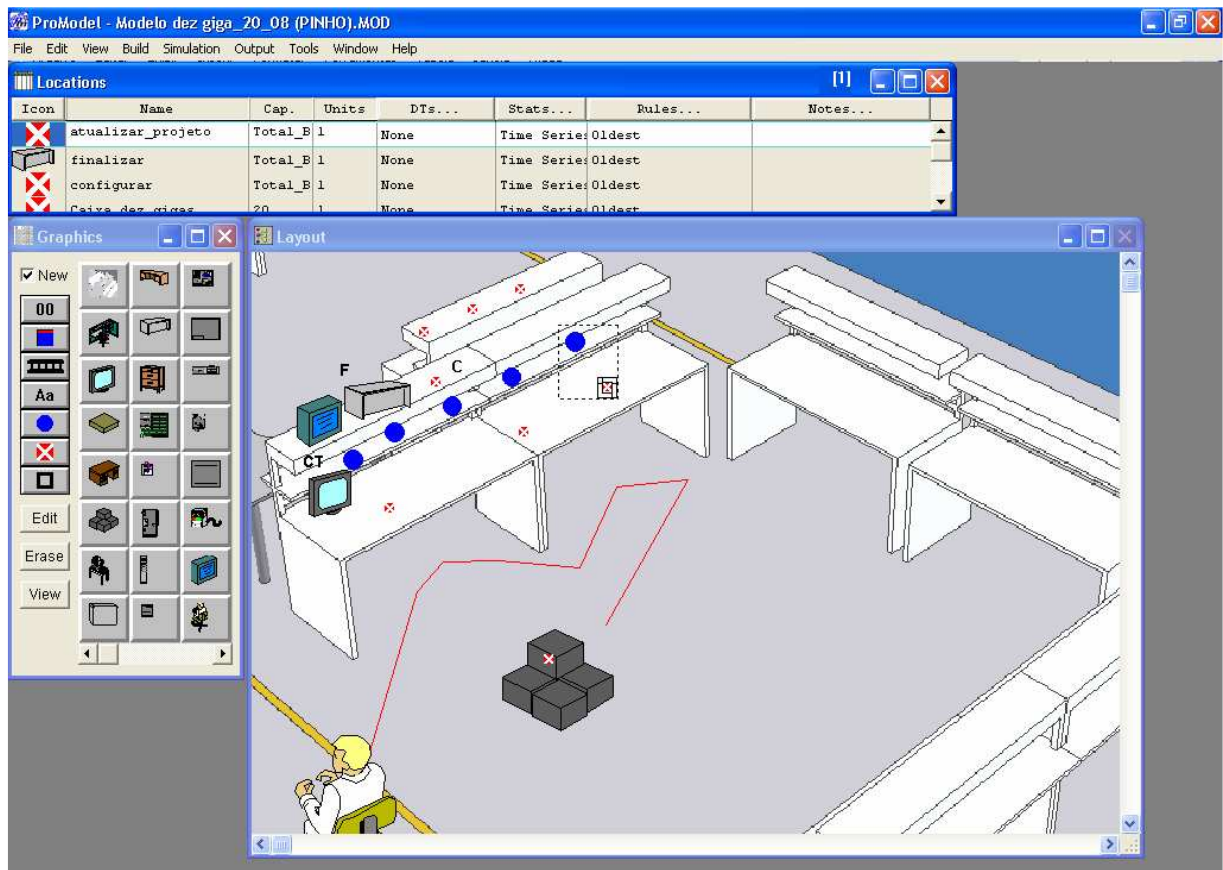


Figura 7.6 – Ambiente de construção do modelo computacional do ProModel® para o quarto objeto de estudo

7.5 OTIMIZAÇÃO DOS OBJETOS DE ESTUDO

Apresenta-se, a seguir, a otimização dos quatro objetos de estudo citados anteriormente. Serão comparados os resultados obtidos através do *SimRunner*® e do método de otimização proposto.

O computador utilizado para a comparação entre os métodos de otimização possui as seguintes especificações técnicas:

- Processador: AMD ATHLON XP 2000+ de 1,67 GHz;
- Memória RAM: 1 Gb;
- Placa de vídeo: ATI RADEON 256 Mb;
- Placa Mãe: PC CHIPS 300 GHz;
- Sistema operacional: Windows XP (Service Pack 2).

7.5.1 Primeiro objeto de estudo

A seguir apresenta-se os 5 passos necessários para a execução da metodologia de otimização proposta por Harrel, Ghosh e Bowden (2000) para modelos de simulação computacional.

7.5.1.1 Definição das variáveis de decisão (passo 1)

As variáveis de decisão deste problema de otimização foram definidas como sendo as quantidades de *kanbans* necessários para as peças aqui denominadas de P1 e P2.

7.5.1.2 Definição do tipo de variável e limites superiores e inferiores (passo 2)

No presente problema, as variáveis representam as quantidades de *kanbans*, assim elas devem ser do tipo determinísticas, discretas e inteiras. Na definição dos limites das variáveis, foi tomada a quantidade atual de cartões como limite máximo (12 cartões), uma vez que não se deseja utilizar quantidades maiores que estas, e uma única unidade como limite mínimo.

7.5.1.3 Definição da função objetivo (passo 3)

O objetivo desta otimização será encontrar a quantidade mínima de *kanbans*, para cada uma das peças analisadas, necessários para garantir a demanda semanal da empresa e manter o mínimo de estoque intermediário entre os estágios produtivos. Para tal, elaborou-se uma função objetivo considerando-se a produção semanal, número de cartões utilizados e o estoque em processamento. Cabe ressaltar que a função objetivo utilizada neste objeto de estudo é linear.

7.5.1.4 Definição dos parâmetros da simulação (passo 4)

O *SimRunner*®, apresenta três perfis de otimização: cauteloso, moderado e agressivo. Desta forma, serão analisados os tempos de processamento para cada um destes perfis, juntamente com a qualidade da solução encontrada pelo simulador. Para cada um dos experimentos realizados serão adotadas três replicações.

Adicionalmente, o *SimRunner*® não permite, em suas configurações, definições sobre os parâmetros dos algoritmo genético utilizado por este. Em contra partida, o método de otimização proposto por esta tese permite a configurações destes parâmetros. Selecionaram-se, então, as seguintes opções: taxa de cruzamento: 80%; taxa de mutação: 20%; número de replicações: 3.

Nota-se que as definições para o número de replicações foram as mesmas que adotadas para o *SimRunner*®, uma vez que a intenção deste capítulo é comparar os dois procedimentos de otimização. As definições dos valores para a taxa de cruzamento e para a taxa de mutação já foram discutidas no capítulo anterior, assim como o número de gerações e as adaptações desenvolvidas no tamanho da população.

7.5.1.5 Análise da solução (passo 5)

Nas tabelas apresentadas a seguir têm-se os resultados da função objetivo e dos tempos de processamento necessários para atingir os resultados da otimização, considerando uma e duas variáveis de decisão respectivamente.

A Tabela 7.1 apresenta os resultados encontrados para o perfil agressivo do *SimRunner*®.

Tabela 7.1 – Resultados da otimização do primeiro objeto de estudo no perfil agressivo do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	9511	99
1 - Quantidade kanbans P1		
<i>Duas variáveis de decisão</i>	9513	237
1 - Quantidade kanbans P1		
2 - Quantidade kanbans P2		

A Tabela 7.2 apresenta os resultados encontrados para o perfil moderado do *SimRunner*®.

Tabela 7.2 – Resultados da otimização do primeiro objeto de estudo no perfil moderado do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	9514	132
1 - Quantidade kanbans P1		
<i>Duas variáveis de decisão</i>	9517	696
1 - Quantidade kanbans P1		
2 - Quantidade kanbans P2		

A Tabela 7.3 apresenta os resultados encontrados para o perfil cauteloso do *SimRunner*®.

Tabela 7.3 – Resultados da otimização do primeiro objeto de estudo no perfil cauteloso do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	9514	177
1 - Quantidade kanbans P1		
<i>Duas variáveis de decisão</i>	9517	738
1 - Quantidade kanbans P1		
2 - Quantidade kanbans P2		

A Tabela 7.4 apresenta os resultados encontrados para o método de otimização proposto.

Tabela 7.4 – Resultados da otimização do primeiro objeto de estudo pelo método de otimização proposto

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	9514	288
1 - Quantidade <i>kanbans</i> P1		
<i>Duas variáveis de decisão</i>	9517	429
1 - Quantidade <i>kanbans</i> P1		
2 - Quantidade <i>kanbans</i> P2		

A Figura 7.7 sintetiza graficamente a comparação entre a média de três replicações para os resultados encontrados da função objetivo, ou seja, a qualidade da

resposta. Estes resultados são apresentados para cada um dos perfis existentes no *SimRunner*® e para o método de otimização proposto, considerando uma e duas variáveis de decisão respectivamente.




Figura 7.7 – Gráfico com a comparação da qualidade da resposta encontrada na otimização

Em relação ao *SimRunner*®, nota-se pelo gráfico da Figura 7.7, que para uma variável de decisão, a qualidade na resposta foi melhorada com a alteração do perfil agressivo para o perfil moderado, e não ocorreram alterações na qualidade da resposta no perfil cauteloso. A mesma análise pode ser feita para duas variáveis de decisão.

Já em relação ao método de otimização proposto, a qualidade na resposta foi a mesma que a encontrada no perfil moderado e cauteloso do *SimRunner*®, tanto para uma como duas variáveis de decisão.

Entretanto, os valores mostrados no gráfico da Figura 7.7 são valores médios da função objetivo calculados pelo *SimRunner*® e pelo método de otimização proposto. Portanto, a correta afirmação que a qualidade da resposta do método de otimização proposto foi mantida em relação ao *SimRunner*® só é possível mediante a análise estatística, mostrada a seguir.

Cabe ressaltar que o *SimRunner*® não apresenta os valores das amostras e também não apresenta o desvio padrão para a solução encontrada. Em contra partida, é possível obter estes resultados pelo método de otimização proposto. Desta forma, será

utilizado, para verificar a qualidade da resposta, um teste de hipótese sobre uma média populacional com desvio padrão desconhecido (TRIOLA, 2005).

O valor médio da função objetivo e seu respectivo desvio padrão obtidos pelo método de otimização proposto, para uma e duas variáveis de decisão, são apresentados na Tabela 7.5.

Tabela 7.5 – Média e desvio padrão da função objetivo encontrada pelo método de otimização proposto

Quantidade de variáveis de decisão	Média	Desvio padrão
1	9514,67	5,03
2	9517,67	3,05

A hipótese H_0 será que as médias encontrada pelo método de otimização proposto para uma e duas variáveis de decisão, respectivamente, são iguais as médias encontradas pelo *SimRunner*® para o perfil cauteloso. Cabe ressaltar que optou-se em testar a qualidade da resposta apenas para o perfil cauteloso do *SimRunner*® uma vez que, segundo Harrel, Ghosh e Bowden (2000), este é o perfil que apresenta a melhor qualidade de resposta.

Já a hipótese alternativa H_1 será que a média da qualidade encontrada pelo método de otimização proposto seja inferior a média da qualidade encontrada pelo perfil cauteloso do *SimRunner*®.

Para a realização deste teste de hipótese selecionou-se a distribuição t , uma vez que não se conhece o desvio padrão da amostra que se quer avaliar e os dados amostrais provêm de uma população que é normalmente distribuída. A estatística de teste utilizada para avaliar H_0 é apresentada na Equação 7.1 (TRIOLA, 2005).

$$t = \frac{\bar{x} - \mu_{\bar{x}}}{\frac{s}{\sqrt{n}}} \quad (7.1)$$

Sendo:

- \bar{x} : média da qualidade da resposta obtida pelo método de otimização proposto;
- $\mu_{\bar{x}}$: média da qualidade da resposta obtida pelo *SimRunner*®;
- s : desvio padrão da qualidade da resposta obtida pelo método de otimização proposto;

- n: tamanho da amostra (número de replicações).

Para uma variável de decisão, a estatística de teste será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\sqrt{n}} = \frac{9514,67 - 9514,00}{\frac{5,03}{\sqrt{3}}} = 0,23 \quad (7.2)$$

Utilizando-se a tabela estatística para distribuição t (TRIOLA, 2005), considerando-se um nível de significância igual a 0,05 e um grau de liberdade igual a $n-1=2$, tem-se o valor crítico de t igual a 2,920 ($t_{\text{crítico}} = 2,920$). Como a estatística de teste $t = 0,23$ não se encontra na região crítica, não é possível rejeitar H_0 . Desta forma, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para uma variável de decisão no perfil cauteloso.

Para duas variáveis de decisão, a estatística de teste será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\sqrt{n}} = \frac{9517,67 - 9517,00}{\frac{3,05}{\sqrt{3}}} = 0,38 \quad (7.3)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,38$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Portanto, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para duas variáveis de decisão no perfil cauteloso.

A Figura 7.8 sintetiza graficamente a comparação entre os tempos de processamento necessário para se atingir os resultados da otimização para cada um dos perfis existentes no *SimRunner*® e o método de otimização proposto, considerando uma e duas variáveis de decisão respectivamente.

Nota-se, em relação ao tempo de processamento, que o método de otimização proposto para uma variável de decisão mostrou-se inferior, ou seja, mais lento, quando comparado a todos os perfis do *SimRunner*®.




Figura 7.8 – Gráfico com a comparação entre os tempos de processamento da otimização

Já para duas variáveis de decisão, o método de otimização proposto mostrou-se superior, ou seja, mais rápido, quando comparado aos perfis moderado e cauteloso do *SimRunner*®. A exceção ocorre para o perfil agressivo. Entretanto, mesmo sendo mais lento que o perfil agressivo, a média dos resultados da função objetivo, ou seja, a qualidade da resposta, foi melhor, conforme mostrado na Figura 7.7.

7.5.2 Segundo objeto de estudo

A seguir apresenta-se os 5 passos necessários para a execução da metodologia de otimização proposta por Harrel, Ghosh e Bowden (2000) para modelos de simulação computacional.

7.5.2.1 Definição das variáveis de decisão (passo 1)

As variáveis de decisão para este objeto de estudo são as quantidades de colaboradores para uma das operações existentes na célula: operação A, operação B e operação C. A quantidade de colaboradores para cada operação afeta diretamente a variável de resposta: total de peças produzidas.

7.5.2.2 Definição do tipo de variável e limites superiores e inferiores (passo 2)

No presente objeto de estudo, as variáveis de decisão representam as quantidades de colaboradores, desta forma, estas variáveis devem ser do tipo inteiro, com limite inferior igual a 1 e limite superior igual a 10.

7.5.2.3 Definição da função objetivo (passo 3)

O objetivo desta otimização será encontrar a quantidade mínima de colaboradores para cada uma das operações A, B e C, que maximizam o total de peças produzidas em uma semana de produção. Para tal, elaborou-se uma função objetivo para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um dos colaboradores utilizados. Cabe ressaltar que a função objetivo utilizada neste objeto de estudo é linear.

7.5.2.4 Definição dos parâmetros da simulação (passo 4)

A definição dos parâmetros da simulação, para este objeto de estudo, tanto para o *SimRunner*® quanto para o método de otimização proposto, são as mesmas que apresentadas para o primeiro objeto de estudo, no item 7.5.1.4.

7.5.2.5 Análise da solução (passo 5)

Nas tabelas apresentadas a seguir têm-se os resultados da função objetivo e dos tempos de processamento necessários para atingir os resultados da otimização, considerando uma, duas e três variáveis de decisão respectivamente.

A Tabela 7.6 apresenta os resultados encontrados para o perfil agressivo do *SimRunner*®.

Tabela 7.6 – Resultados da otimização do segundo objeto de estudo no perfil agressivo do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	421	45
1 - Quant. Colaboradores Operação A		
<i>Dois variáveis de decisão</i>	433	159
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B	421	372
<i>Três variáveis de decisão</i>		
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B		
3 - Quant. Colaboradores Operação C		

A Tabela 7.7 apresenta os resultados encontrados para o perfil moderado do *SimRunner*®.

Tabela 7.7 – Resultados da otimização do segundo objeto de estudo no perfil moderado do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	421	48
1 - Quant. Colaboradores Operação A		
<i>Dois variáveis de decisão</i>	433	378
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B	442	552
<i>Três variáveis de decisão</i>		
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B		
3 - Quant. Colaboradores Operação C		

A Tabela 7.8 apresenta os resultados encontrados para o perfil cauteloso do *SimRunner*®.

Tabela 7.8 – Resultados da otimização do segundo objeto de estudo no perfil cauteloso do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	421	57
1 - Quant. Colaboradores Operação A		
<i>Dois variáveis de decisão</i>	433	399
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B	453	864
<i>Três variáveis de decisão</i>		
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B		
3 - Quant. Colaboradores Operação C		

A Tabela 7.9 apresenta os resultados encontrados para o método de otimização proposto.

Tabela 7.9 – Resultados da otimização do segundo objeto de estudo pelo método de otimização proposto

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	421	336
1 - Quant. Colaboradores Operação A		
<i>Dois variáveis de decisão</i>	433	375
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B	453	420
<i>Três variáveis de decisão</i>		
1 - Quant. Colaboradores Operação A		
2 - Quant. Colaboradores Operação B		
3 - Quant. Colaboradores Operação C		

A Figura 7.9 sintetiza graficamente a comparação entre a média de três replicações para os resultados encontrados da função objetivo, ou seja, a qualidade da resposta. Estes resultados são apresentados para cada um dos perfis existentes no *SimRunner*® e para o método de otimização proposto, considerando uma, duas e três variáveis de decisão respectivamente.

Em relação ao *SimRunner*®, nota-se pelo gráfico da Figura 7.9, que para uma e duas variáveis de decisão, a qualidade da resposta permaneceu sempre a mesma com as alterações entre os perfis agressivo, moderado e cauteloso. Entretanto, para três

variáveis de decisão, a qualidade da resposta foi melhorada com as alterações entre os perfis agressivo, moderado e cauteloso.




Figura 7.9 – Gráfico com a comparação da qualidade da resposta encontrada na otimização

Já em relação ao método de otimização proposto, tanto para uma como para duas variáveis de decisão a qualidade na resposta foi a mesma que a encontrada nos perfis agressivo, moderado e cauteloso do *SimRunner*®. Entretanto, para três variáveis de decisão, a qualidade da resposta foi a mesma que a do perfil cauteloso e superior aos perfis agressivo e moderado.

Assim como no primeiro objeto de estudo, os valores mostrados no gráfico da Figura 7.9 são valores médios da função objetivo calculados pelo *SimRunner*® e pelo método de otimização proposto. Portanto, a correta afirmação que a qualidade da resposta do método de otimização proposto foi mantida em relação ao *SimRunner*® só é possível mediante a uma análise estatística. Desta forma, serão adotados os mesmos procedimentos do primeiro objeto de estudo para a comparação entre as qualidades de resposta.

O valor médio da função objetivo e seu respectivo desvio padrão obtidos pelo método de otimização proposto, para uma, duas e três variáveis de decisão, são apresentados na Tabela 7.10.

Tabela 7.10 – Média e desvio padrão da função objetivo encontrada pelo método de otimização proposto

Quant. de variáveis de decisão	Média	Desvio padrão
1	419,67	3,51
2	432,67	7,50
3	452,67	2,52

A hipótese H_0 será que as médias encontrada pelo método de otimização proposto para uma, duas e três variáveis de decisão, respectivamente, são iguais as médias encontradas pelo *SimRunner*® para o perfil cauteloso. Já a hipótese alternativa H_1 será que a média da qualidade encontrada pelo método de otimização proposto seja inferior a média da qualidade encontrada pelo perfil cauteloso do *SimRunner*®.

Para uma variável de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\bar{x} - \mu_x}{\frac{s}{\sqrt{n}}} = \frac{419,67 - 421,00}{\frac{3,51}{\sqrt{3}}} = -0,66 \quad (7.4)$$

Utilizando-se a tabela estatística para distribuição t (TRIOLA, 2005), considerando-se um nível de significância igual a 0,05 e um grau de liberdade igual a $n-1=2$, tem-se o valor crítico de t igual a -2,920 ($t_{\text{crítico}} = -2,920$). Como a estatística de teste $t = -0,66$ não se encontra na região crítica, não é possível rejeitar H_0 . Desta forma, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para uma variável de decisão no perfil cauteloso.

Para duas variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\bar{x} - \mu_x}{\frac{s}{\sqrt{n}}} = \frac{432,67 - 433,00}{\frac{7,50}{\sqrt{3}}} = -0,076 \quad (7.5)$$

Da mesma forma que anteriormente a estatística de teste $t = -0,076$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para duas variáveis de decisão no perfil cauteloso.

Para três variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\bar{x} - \mu_{\bar{x}}}{\frac{s}{\sqrt{n}}} = \frac{452,67 - 453,00}{\frac{2,52}{\sqrt{3}}} = -0,227 \quad (7.6)$$

Da mesma forma que anteriormente a estatística de teste $t = -0,227$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para três variáveis de decisão no perfil cauteloso.

A Figura 7.10 sintetiza graficamente a comparação entre os tempos de processamento necessário para se atingir os resultados da otimização para cada um dos perfis existentes no *SimRunner*® e o método de otimização proposto, considerando uma, duas e três variáveis de decisão respectivamente.




Figura 7.10 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se, em relação ao tempo de processamento, que o método de otimização proposto para uma variável de decisão mostrou-se inferior, ou seja, mais lento, quando comparado a todos os perfis do *SimRunner*®.

Para duas variáveis de decisão, o método de otimização proposto apresentou um tempo de otimização semelhante quando comparado aos perfis moderado e cauteloso do *SimRunner*® e mais lento quando comparado ao perfil agressivo.

Já para três variáveis de decisão, o método de otimização proposto mostrou-se superior, ou seja, mais rápido, quando comparado aos perfis moderado e cauteloso do *SimRunner*®. A exceção ocorre para o perfil agressivo. Entretanto, mesmo sendo mais lento que o perfil agressivo, a qualidade da resposta foi melhor, conforme mostrado na Figura 7.9.

7.5.3 Terceiro objeto de estudo

A seguir apresenta-se os 5 passos necessários para a execução da metodologia de otimização proposta por Harrel, Ghosh e Bowden (2000) para modelos de simulação computacional.

7.5.3.1 Definição das variáveis de decisão (passo 1)

As variáveis de decisão (variáveis de entrada) para o modelo analisado são: quantidade de operadores na célula, número de bancadas com *setup*, número de bancadas sem *setup* e se há ou não organização de material feita pela produção. O resultado de cada uma dessas variáveis afeta diretamente a variável de resposta: total de peças produzidas.

7.5.3.2 Definição do tipo de variável e limites superiores e inferiores (passo 2)

As três primeiras variáveis de decisão selecionadas são do tipo discretas e inteiras, com limite inferior igual a 1 e limite superior igual a 10. A quarta variável de decisão (se há ou não organização de material) é do tipo discreta e binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

7.5.3.3 Definição da função objetivo (passo 3)

O objetivo desta otimização será encontrar a quantidade mínima de operadores e de bancadas com e sem *setups*, além é claro de verificar se vale ou não a pena

organizar os materiais na produção. Para tal, elaborou-se uma função para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um das decisões obtidas pelas variáveis de entrada.

7.5.3.4 Definição dos parâmetros da simulação (passo 4)

A definição dos parâmetros da simulação, para este objeto de estudo, tanto para o *SimRunner*® quanto para o método de otimização proposto, são as mesmas que apresentadas para o primeiro objeto de estudo, no item 7.5.1.4.

7.5.3.5 Análise da solução (passo 5)

Nas tabelas apresentadas a seguir têm-se os resultados da função objetivo e dos tempos de processamento necessários para atingir os resultados da otimização, considerando uma, duas, três e quatro variáveis de decisão respectivamente.

A Tabela 7.11 apresenta os resultados encontrados para o perfil agressivo do *SimRunner*®.

Tabela 7.11 – Resultados da otimização do terceiro objeto de estudo no perfil agressivo do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>		
1 - Quantidade de operadores na célula	43,6	72
<i>Duas variáveis de decisão</i>		
1 - Quantidade de operadores na célula	60,3	126
2 - Número de bancadas com setup		
<i>Três variáveis de decisão</i>		
1 - Quantidade de operadores na célula	52,6	246
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
<i>Quatro variáveis de decisão</i>		
1 - Quantidade de operadores na célula	290	414
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
4 - Há ou não organização de material		

A Tabela 7.12 apresenta os resultados encontrados para o perfil moderado do *SimRunner*®.

Tabela 7.12 – Resultados da otimização do terceiro objeto de estudo no perfil moderado do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>		
1 - Quantidade de operadores na célula	50,5	93
<i>Duas variáveis de decisão</i>		
1 - Quantidade de operadores na célula	80,2	411
2 - Número de bancadas com setup		
<i>Três variáveis de decisão</i>		
1 - Quantidade de operadores na célula	268,7	519
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
<i>Quatro variáveis de decisão</i>		
1 - Quantidade de operadores na célula	290,1	711
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
4 - Há ou não organização de material		

A Tabela 7.13 apresenta os resultados encontrados para o perfil cauteloso do *SimRunner*®.

Tabela 7.13 – Resultados da otimização do terceiro objeto de estudo no perfil cauteloso do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>		
1 - Quantidade de operadores na célula	50,5	105
<i>Duas variáveis de decisão</i>		
1 - Quantidade de operadores na célula	82,5	504
2 - Número de bancadas com setup		
<i>Três variáveis de decisão</i>		
1 - Quantidade de operadores na célula	290,1	867
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
<i>Quatro variáveis de decisão</i>		
1 - Quantidade de operadores na célula	290,1	1317
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
4 - Há ou não organização de material		

A Tabela 7.14 apresenta os resultados encontrados para o método de otimização proposto.

Tabela 7.14 – Resultados da otimização do terceiro objeto de estudo pelo método de otimização proposto

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	50,5	450
1 - Quantidade de operadores na célula		
<i>Duas variáveis de decisão</i>	82,5	485
1 - Quantidade de operadores na célula		
2 - Número de bancadas com setup		
<i>Três variáveis de decisão</i>	290,1	521
1 - Quantidade de operadores na célula		
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
<i>Quatro variáveis de decisão</i>	290,1	544
1 - Quantidade de operadores na célula		
2 - Número de bancadas com setup		
3 - Número de bancadas sem setup		
4 - Há ou não organização de material		

A Figura 7.11 sintetiza graficamente a comparação entre a média de três replicações para os resultados encontrados da função objetivo, ou seja, a qualidade da resposta. Estes resultados são apresentados para cada um dos perfis existentes no *SimRunner*® e para o método de otimização proposto, considerando uma, duas, três e quatro variáveis de decisão respectivamente.

Em relação ao *SimRunner*®, nota-se pelo gráfico da Figura 7.11, que para uma variável de decisão, a qualidade da resposta permaneceu a mesma com as alterações entre os perfis agressivo, moderado e cauteloso. Entretanto, para duas, três e quatro variáveis de decisão, a qualidade da resposta foi melhorada com a alteração entre o perfil agressivo e moderado, permanecendo a mesma qualidade na alteração para o perfil cauteloso.

Já em relação ao método de otimização proposto, para uma, duas, três e quatro variáveis de decisão a qualidade da resposta foi a mesma que a do perfil cauteloso e superior aos perfis agressivo e moderado.




Figura 7.11 – Gráfico com a comparação da qualidade da resposta encontrada na otimização

Assim como no primeiro objeto de estudo, os valores mostrados no gráfico da Figura 7.11 são valores médios da função objetivo calculados pelo *SimRunner*® e pelo método de otimização proposto. Portanto, a correta afirmação que a qualidade da resposta do método de otimização proposto foi mantida em relação ao *SimRunner*® só é possível mediante a uma análise estatística. Desta forma, serão adotados os mesmos procedimentos do primeiro e do segundo objeto de estudo para a comparação entre as qualidades de resposta.

O valor médio da função objetivo e seu respectivo desvio padrão obtidos pelo método de otimização proposto, para uma, duas, três e quatro variáveis de decisão, são apresentados na Tabela 7.15.

Tabela 7.15 – Média e desvio padrão da função objetivo encontrada pelo método de otimização proposto

Quant. de variáveis de decisão	Média	Desvio padrão
1	50,33	2,51
2	82,33	4,04
3	289,67	4,50
4	290,67	3,05

A hipótese H_0 será que as médias encontrada pelo método de otimização proposto para uma, duas, três e quatro variáveis de decisão, respectivamente, são

iguais as médias encontradas pelo *SimRunner*® para o perfil cauteloso. Já a hipótese alternativa H_1 será que a média da qualidade encontrada pelo método de otimização proposto seja inferior a média da qualidade encontrada pelo perfil cauteloso do *SimRunner*®.

Para uma variável de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\sqrt{n}} = \frac{50,33 - 50,50}{\frac{2,51}{\sqrt{3}}} = -0,117 \quad (7.7)$$

Utilizando-se a tabela estatística para distribuição t (TRIOLA, 2005), considerando-se um nível de significância igual a 0,05 e um grau de liberdade igual a $n-1=2$, tem-se o valor crítico de t igual a -2,920 ($t_{\text{crítico}} = -2,920$). Como a estatística de teste $t = -0,117$ não se encontra na região crítica, não é possível rejeitar H_0 . Desta forma, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para uma variável de decisão no perfil cauteloso.

Para duas variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\sqrt{n}} = \frac{82,33 - 82,50}{\frac{4,04}{\sqrt{3}}} = -0,073 \quad (7.8)$$

Da mesma forma que anteriormente a estatística de teste $t = -0,073$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para duas variáveis de decisão no perfil cauteloso.

Para três variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\sqrt{n}} = \frac{289,67 - 290,10}{\frac{4,50}{\sqrt{3}}} = -0,165 \quad (7.9)$$

Da mesma forma que anteriormente a estatística de teste $t = -0,165$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para três variáveis de decisão no perfil cauteloso.

Para quatro variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s} = \frac{290,67 - 290,10}{\frac{3,05}{\sqrt{3}}} = 0,324 \quad (7.10)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,324$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para quatro variáveis de decisão no perfil cauteloso.

A Figura 7.12 sintetiza graficamente a comparação entre os tempos de processamento necessário para se atingir os resultados da otimização para cada um dos perfis existentes no *SimRunner*® e o método de otimização proposto, considerando uma, duas, três e quatro variáveis de decisão respectivamente.




Figura 7.12 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se, em relação ao tempo de processamento, que o método de otimização proposto para uma variável de decisão mostrou-se inferior, ou seja, mais lento, quando comparado a todos os perfis do *SimRunner*®.

Para duas variáveis de decisão, o método de otimização proposto apresentou um tempo de otimização semelhante quando comparado aos perfis moderado e cauteloso do *SimRunner*® e mais lento quando comparado ao perfil agressivo.

Já para três e quatro variáveis de decisão, o método de otimização proposto mostrou-se superior, ou seja, mais rápido, quando comparado aos perfis moderado e cauteloso do *SimRunner*®. A exceção ocorre para o perfil agressivo. Entretanto, mesmo sendo mais lento que o perfil agressivo, a qualidade da resposta foi melhor, conforme mostrado na Figura 7.11.

7.5.4 Quarto objeto de estudo

A seguir apresenta-se os 5 passos necessários para a execução da metodologia de otimização proposta por Harrel, Ghosh e Bowden (2000) para modelos de simulação computacional.

7.5.4.1 Definição das variáveis de decisão (passo 1)

As variáveis de decisão (variáveis de entrada) para o modelo analisado são: número de bancadas com equipamentos, número de bancadas sem equipamentos, quantidade de operadores na célula, se há ou não organização de material feita pela produção e se há ou não a atividade atualizar projeto. O resultado de cada uma dessas variáveis afeta diretamente a variável de resposta: total de peças produzidas.

7.5.4.2 Definição do tipo de variável e limites superiores e inferiores (passo 2)

As três primeiras variáveis de decisão selecionadas são do tipo discretas e inteiras, com limite inferior igual a 1 e limite superior igual a 10. A quarta variável de decisão (se há ou não organização de material) é do tipo discreta e binária, com limite

inferior igual a 0 (não há) e limite superior igual a 1 (há). A quinta variável de decisão (se há ou não a atividade atualizar projeto) também é do tipo discreta e binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

7.5.4.3 Definição da função objetivo (passo 3)

O objetivo desta otimização será encontrar a quantidade mínima de operadores e de bancadas com e sem equipamentos, além é claro de verificar se vale ou não a pena organizar os materiais na produção e efetuar a atualização de projetos. Para tal, elaborou-se uma função para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um das decisões obtidas pelas variáveis de entrada.

7.5.4.4 Definição dos parâmetros da simulação (passo 4)

A definição dos parâmetros da simulação, para este objeto de estudo, tanto para o *SimRunner*® quanto para o método de otimização proposto, são as mesmas que apresentadas para o primeiro objeto de estudo, no item 7.4.1.4.

7.5.4.5 Análise da solução (passo 5)

Nas tabelas apresentadas a seguir têm-se os resultados da função objetivo e dos tempos de processamento necessários para atingir os resultados da otimização, considerando uma, duas, três, quatro e cinco variáveis de decisão respectivamente.

A Tabela 7.16 apresenta os resultados encontrados para o perfil agressivo do *SimRunner*®.

Tabela 7.16 – Resultados da otimização do quarto objeto de estudo no perfil agressivo do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	169	39
1 - Número de bancadas com equipamentos		
<i>Duas variáveis de decisão</i>	170	159
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
<i>Três variáveis de decisão</i>	720	246
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
<i>Quatro variáveis de decisão</i>	730	417
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
<i>Cinco variáveis de decisão</i>	730	501
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
5 - Há ou não a atividade atualizar projeto		

A Tabela 7.17 apresenta os resultados encontrados para o perfil moderado do *SimRunner*®.

Tabela 7.17 – Resultados da otimização do quarto objeto de estudo no perfil moderado do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	169	54
1 - Número de bancadas com equipamentos		
<i>Duas variáveis de decisão</i>	172	423
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
<i>Três variáveis de decisão</i>	730	495
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
<i>Quatro variáveis de decisão</i>	740	677
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
<i>Cinco variáveis de decisão</i>	740	1386
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
5 - Há ou não a atividade atualizar projeto		

A Tabela 7.18 apresenta os resultados encontrados para o perfil cauteloso do *SimRunner*®.

Tabela 7.18 – Resultados da otimização do quarto objeto de estudo no perfil cauteloso do *SimRunner*®

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	169	72
1 - Número de bancadas com equipamentos		
<i>Dois variáveis de decisão</i>	172	462
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
<i>Três variáveis de decisão</i>	740	897
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
<i>Quatro variáveis de decisão</i>	740	1344
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
<i>Cinco variáveis de decisão</i>	740	3615
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
5 - Há ou não a atividade atualizar projeto		

A Tabela 7.19 apresenta os resultados encontrados para o método de otimização proposto.

Tabela 7.19 – Resultados da otimização do quarto objeto de estudo pelo método de otimização proposto

Número de variáveis de decisão	Valor da Função objetivo	Tempo (segundos)
<i>Uma variável de decisão</i>	169	303
1 - Número de bancadas com equipamentos		
<i>Dois variáveis de decisão</i>	172	453
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
<i>Três variáveis de decisão</i>	740	507
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
<i>Quatro variáveis de decisão</i>	740	576
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
<i>Cinco variáveis de decisão</i>	740	696
1 - Número de bancadas com equipamentos		
2 - Número de bancadas sem equipamentos		
3 - Quantidade de operadores na célula		
4 - Há ou não organização de material		
5 - Há ou não a atividade atualizar projeto		

A Figura 7.13 sintetiza graficamente a comparação entre a média de três replicações para os resultados encontrados da função objetivo, ou seja, a qualidade da resposta. Estes resultados são apresentados para cada um dos perfis existentes no *SimRunner*® e para o método de otimização proposto, considerando uma, duas, três, quatro e cinco variáveis de decisão respectivamente.

Em relação ao *SimRunner*®, nota-se pelo gráfico da Figura 7.13, que para uma e duas variáveis de decisão, a qualidade da resposta permaneceu a mesma com as alterações entre os perfis agressivo, moderado e cauteloso. Entretanto, para três, quatro e cinco variáveis de decisão, a qualidade da resposta foi melhorada com a alteração entre o perfil agressivo e moderado. E melhorada ainda mais com a alteração para o perfil cauteloso.

Já em relação ao método de otimização proposto, para uma, duas, três, quatro e cinco variáveis de decisão a qualidade da resposta foi a mesma que a do perfil cauteloso e superior aos perfis agressivo e moderado.




Figura 7.13 – Gráfico com a comparação da qualidade da resposta encontrada na otimização

Assim como no primeiro objeto de estudo, os valores mostrados no gráfico da Figura 7.13 são valores médios da função objetivo calculados pelo *SimRunner*® e pelo método de otimização proposto. Portanto, a correta afirmação que a qualidade da resposta do método de otimização proposto foi mantida em relação ao *SimRunner*® só é possível mediante a uma análise estatística. Desta forma, serão adotados os mesmos procedimentos do primeiro, segundo e terceiro objeto de estudo para a comparação entre as qualidades da resposta.

O valor médio da função objetivo e seu respectivo desvio padrão obtidos pelo método de otimização proposto, para uma, duas, três, quatro e cinco variáveis de decisão, são apresentados na Tabela 7.20 seguir.

Tabela 7.20 – Média e desvio padrão da função objetivo encontrada pelo método de otimização proposto

Quant. de variáveis de decisão	Média	Desvio padrão
1	169,33	7,02
2	172,66	6,51
3	740,33	4,04
4	740,67	2,51
5	740,33	7,50

A hipótese H_0 será que as médias encontrada pelo método de otimização proposto para uma, duas, três, quatro e cinco variáveis de decisão, respectivamente, são iguais as médias encontradas pelo *SimRunner*® para o perfil cauteloso. Já a hipótese alternativa H_1 será que a média da qualidade encontrada pelo método de otimização proposto seja inferior a média da qualidade encontrada pelo perfil cauteloso do *SimRunner*®.

Para uma variável de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\frac{1}{\sqrt{n}}} = \frac{169,33 - 169,00}{\frac{7,02}{\sqrt{3}}} = 0,081 \quad (7.11)$$

Utilizando-se a tabela estatística para distribuição t (TRIOLA, 2005), considerando-se um nível de significância igual a 0,05 e um grau de liberdade igual a $n-1=2$, tem-se o valor crítico de t igual a 2,920 ($t_{\text{crítico}} = 2,920$). Como a estatística de teste $t = 0,081$ não se encontra na região crítica, não é possível rejeitar H_0 . Desta forma, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para uma variável de decisão no perfil cauteloso.

Para duas variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_x}{s}}{\frac{1}{\sqrt{n}}} = \frac{172,66 - 172,00}{\frac{6,51}{\sqrt{3}}} = 0,176 \quad (7.12)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,176$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para duas variáveis de decisão no perfil cauteloso.

Para três variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_{\bar{x}}}{s}}{\sqrt{n}} = \frac{740,33 - 740,00}{\frac{4,04}{\sqrt{3}}} = 0,142 \quad (7.13)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,142$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para três variáveis de decisão no perfil cauteloso.

Para quatro variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_{\bar{x}}}{s}}{\sqrt{n}} = \frac{740,67 - 740,00}{\frac{2,51}{\sqrt{3}}} = 0,462 \quad (7.14)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,462$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para quatro variáveis de decisão no perfil cauteloso.

Para cinco variáveis de decisão, a estatística de teste utilizada para avaliar H_0 será:

$$t = \frac{\frac{\bar{x} - \mu_{\bar{x}}}{s}}{\sqrt{n}} = \frac{740,33 - 740,00}{\frac{7,50}{\sqrt{3}}} = 0,076 \quad (7.15)$$

Da mesma forma que anteriormente a estatística de teste $t = 0,076$ não se encontra na região crítica, portanto não é possível rejeitar H_0 . Então, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® para cinco variáveis de decisão no perfil cauteloso.

A Figura 7.14 sintetiza graficamente a comparação entre os tempos de processamento necessário para se atingir os resultados da otimização para cada um dos perfis existentes no *SimRunner*® e o método de otimização proposto, considerando uma, duas, três, quatro e cinco variáveis de decisão respectivamente.




Figura 7.14 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se, em relação ao tempo de processamento, que o método de otimização proposto para uma variável de decisão mostrou-se inferior, ou seja, mais lento, quando comparado a todos os perfis do *SimRunner*®.

Para duas variáveis de decisão, o método de otimização proposto apresentou um tempo de otimização semelhante quando comparado aos perfis moderado e cauteloso do *SimRunner*® e mais lento quando comparado ao perfil agressivo.

Já para três, quatro e cinco variáveis de decisão, o método de otimização proposto mostrou-se superior, ou seja, mais rápido, quando comparado aos perfis moderado e cauteloso do *SimRunner*®. A exceção ocorre para o perfil agressivo. Entretanto, mesmo sendo mais lento que o perfil agressivo, a qualidade da resposta foi melhor, conforme mostrado na Figura 7.13.

7.6 ANÁLISE DOS RESULTADOS

A Figura 7.15 mostra uma comparação entre os tempos de processamento necessários, considerando uma variável de decisão, para a otimização de cada um dos objetos de estudo analisados.




Figura 7.15 – Gráfico com os tempos de processamento da otimização para uma variável de decisão

Nota-se que, para uma variável de decisão, o método de otimização proposto foi sempre o mais lento, quando comparado aos perfis de otimização do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto não é adequado para a manipulação de apenas uma variável de decisão.

A Figura 7.16 mostra uma comparação entre os tempos de processamento necessários, considerando duas variáveis de decisão, para a otimização de cada um dos objetos de estudo analisados.

Nota-se que, para duas variáveis de decisão, o método de otimização proposto foi mais rápido ou semelhante aos tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto já se mostra adequado para a manipulação de duas variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.




Figura 7.16 – Gráfico com a comparação entre os tempos de processamento da otimização

A Figura 7.17 mostra uma comparação entre os tempos de processamento necessários, considerando três variáveis de decisão, para a otimização do segundo, terceiro e quarto objetos de estudo analisados.




Figura 7.17 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se que, para três variáveis de decisão, o método de otimização proposto foi mais rápido ou semelhante aos tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto é adequado para a manipulação de três variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.

A Figura 7.18 mostra uma comparação entre os tempos de processamento necessários, considerando quatro variáveis de decisão, para a otimização do terceiro e quarto objetos de estudo analisados.




Figura 7.18 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se que, para quatro variáveis de decisão, o método de otimização proposto foi mais rápido que os tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto é adequado para a manipulação de quatro variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto

conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.

A Figura 7.19 mostra uma comparação entre os tempos de processamento necessários, considerando cinco variáveis de decisão, para a otimização do quarto objeto de estudo analisado.




Figura 7.19 – Gráfico com a comparação entre os tempos de processamento da otimização

Nota-se que, para cinco variáveis de decisão, o método de otimização proposto foi mais rápido que os tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto é adequado para a manipulação de cinco variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.

7.7 CONSIDERAÇÕES FINAIS

Este capítulo mostrou a comparação do método de otimização desenvolvido com uma ferramenta disponível comercialmente, conhecida como *SimRunner*®, através da metodologia de otimização para modelos de simulação a eventos discretos proposta por Harrel, Ghosh e Bowden (2000). Esta metodologia foi aplicada em quatro objetos de estudo distintos.

Nota-se que o método de otimização proposto não oferece ganho no tempo de processamento ao considerar uma variável de decisão. Já ao manipular duas variáveis de decisão, o método mostrou-se mais rápido em alguns objetos de estudo e com tempo de processamento semelhante em outros objetos de estudo, quando comparado aos perfis moderado e cauteloso do *SimRunner*®. De fato, o método de otimização proposto é sempre mais eficiente a partir de três variáveis de decisão analisadas simultaneamente.

Em relação a qualidade dos resultados, o método de otimização proposto mostrou-se tão eficaz quanto o *SimRunner*®.

Com isso, é possível finalizar a fase de modelo de solução de Mitroff *et al.* (1974), destacada na Figura 7.1. Nesta fase, aplicou-se o método de otimização proposto em quatro objetos de estudo com a intenção de avaliar as soluções encontradas.

CAPÍTULO 8 – CONCLUSÕES

8.1 CONSIDERAÇÕES INICIAIS

Inicialmente, neste capítulo, serão apresentadas as conclusões e contribuições geradas por esta pesquisa. Na seqüência, apresentam-se as considerações finais desta tese de doutorado seguida das sugestões para trabalhos futuros.

Cabe ressaltar que este capítulo refere-se, em relação ao modelo de Mitroff *et al.* (1974), a fase de implementação. Bertrand e Fransoo (2002) afirmam que nesta fase, os resultados do modelo são implementados, ou seja, o novo método de otimização passa a ser utilizado. A Figura 8.1 destaca a fase do modelo de Mitroff *et al.* (1974) pertinente a este capítulo.

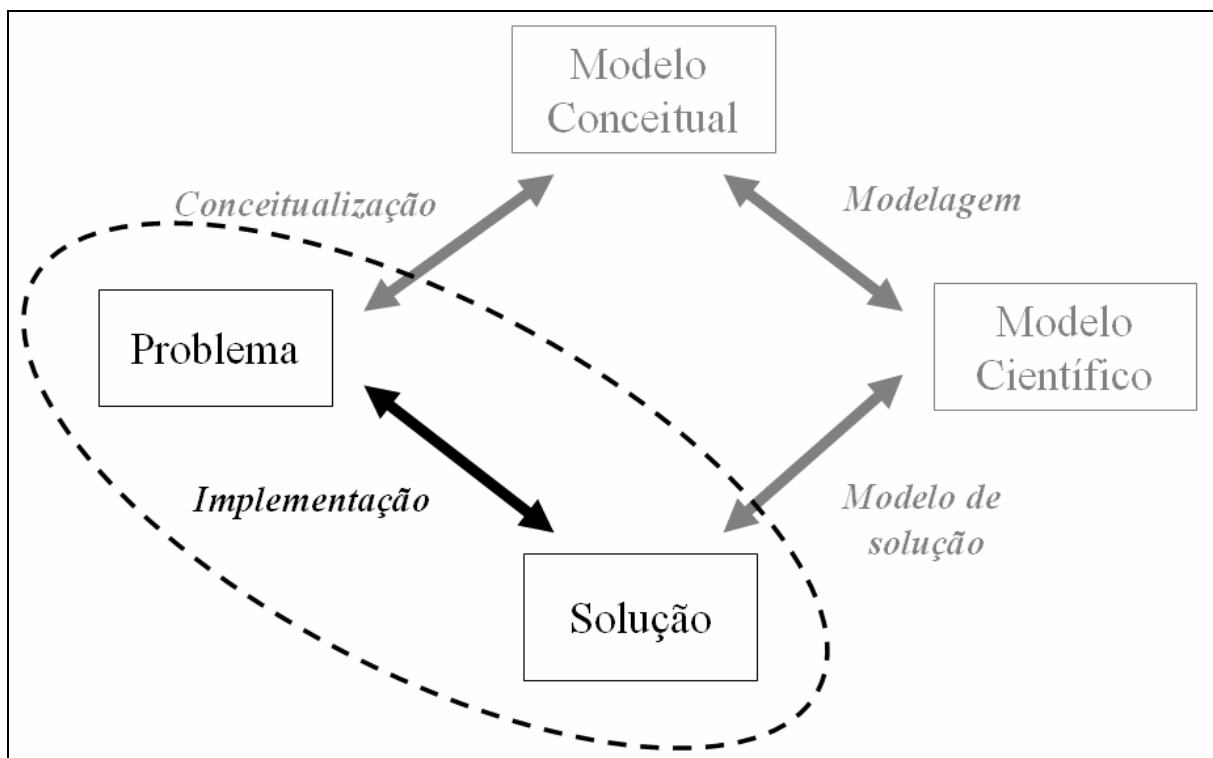


Figura 8.1 – Fase de implementação

Fonte: Adaptado de Mitroff *et al.* (1974)

8.2 CONCLUSÕES E CONTRIBUIÇÕES DA PESQUISA

A contribuição desta pesquisa foi desenvolver um método de otimização para modelos de simulação a eventos discretos aplicados a sistemas de manufatura, capaz de atingir os resultados de forma mais rápida e com a mesma qualidade, quando comparado a um software de otimização comercial.

O método de otimização proposto consiste, primeiramente, na estimativa do tamanho da população inicial, com base no tamanho do indivíduo necessário para a manipulação das variáveis de decisão do modelo de simulação. Na seqüência, realiza-se a adaptação no parâmetro tamanho da população, aumentando-o em 50% a cada nova geração. A intenção é buscar um tamanho de população ideal capaz de garantir a qualidade dos resultados com um menor tempo de convergência.

Quatro objetos de estudo foram utilizados na aplicação do método de otimização proposto. Os resultados encontrados foram comparados com uma ferramenta de otimização disponível comercialmente, conhecida como *SimRunner*®, através da metodologia de otimização para modelos de simulação a eventos discretos proposta por Harrel, Ghosh e Bowden (2000). Em relação a qualidade dos resultados, o método de otimização proposto mostrou-se tão eficaz quanto o *SimRunner*®.

Para uma variável de decisão, o método de otimização proposto mostrou-se menos eficiente. Já para duas variáveis de decisão analisadas simultaneamente, o método apresentou melhor ou igual eficiência. Entretanto, para três ou mais variáveis de decisão analisadas simultaneamente, o método de otimização proposto é sempre mais eficiente.

Quando comparado ao perfil cauteloso do *SimRunner*®, o método de otimização proposto para o primeiro objeto de estudo, considerando-se duas variáveis de decisão, foi cerca de 46% mais rápido. Em relação ao segundo objeto de estudo, considerando-se três variáveis de decisão, o método foi cerca de 51% mais rápido. Já para o terceiro objeto de estudo, considerando-se quatro variáveis de decisão, o método foi cerca de 59% mais rápido. Finalmente, para o quarto objeto de estudo, considerando-se cinco variáveis de decisão, o método foi cerca de 80% mais rápido.

De mesma forma que anteriormente, quando comparado ao perfil moderado do *SimRunner*®, o método de otimização proposto para o primeiro objeto de estudo, considerando-se duas variáveis de decisão, foi cerca de 38% mais rápido. Em relação ao segundo objeto de estudo, considerando-se três variáveis de decisão, o método foi cerca de 24% mais rápido. Já para o terceiro objeto de estudo, considerando-se quatro variáveis de decisão, o método foi cerca de 23% mais rápido. Finalmente, para o quarto objeto de estudo, considerando-se cinco variáveis de decisão, o método foi cerca de 50% mais rápido.

Cabe ressaltar que o método proposto é válido para as condições de contorno estabelecidas por esta tese, que consiste na manipulação de variáveis de decisão do tipo discretas, determinísticas e inteiras.

Os objetivos específicos desta pesquisa foram:

1. Analisar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência desses algoritmos;

Através do levantamento bibliográfico realizado, constatou-se que o parâmetro tamanho da população exerce forte influência na velocidade de convergência dos algoritmos genéticos. Além disso, este parâmetro afeta diretamente o desempenho global e a eficiência do algoritmo genético.

2. Analisar a influência dos parâmetros dos algoritmos genéticos na qualidade da variável de reposta desses algoritmos;

A influência dos parâmetros dos algoritmos genético na qualidade da variável de reposta desses algoritmos foi analisada através da aplicação da técnica de projeto de experimentos nesses parâmetros. Esta análise ocorreu na otimização de cinco funções matemáticas conhecidas.

Chegou-se a algumas constatações interessantes tais como a importância do parâmetro tamanho da população e a não expressividade dos parâmetros número de

gerações e taxa de cruzamento. Outra constatação interessante é que os efeitos das interações quase sempre estão presentes na obtenção das variáveis de resposta, além do fato de ter ocorrido um efeito significativo de quarta ordem, reforçando a importância no cuidado na escolha dos parâmetros do algoritmo genético.

3. Desenvolver uma ferramenta computacional capaz de operacionalizar o método de otimização proposto no objetivo principal desta tese de doutorado;

Foi apresentada uma ferramenta computacional capaz de permitir a aplicação do método de otimização proposto em modelos de simulação computacional, além de permitir a manipulação dos parâmetros do algoritmo genético e a comunicação com o simulador a eventos discretos.

8.3 CONSIDERAÇÕES FINAIS

Constatou-se que o método de otimização proposto, ao manipular mais de duas variáveis de decisão simultaneamente, é mais eficiente, ou seja, mais rápido, quando comparado a uma ferramenta de otimização disponível comercialmente. Cabe destacar que o método também apresentou a mesma eficácia, ou seja, a mesma qualidade nas respostas da otimização.

Sugere-se, então, que o método de otimização proposto passe a ser adotado, desde que as condições de contorno desta pesquisa sejam atendidas. Com isso, é possível finalizar a fase de implementação de Mitroff *et al.* (1974), destacada na Figura 8.1.

Conforme citado no capítulo 1 desta tese de doutorado, a metodologia de pesquisa utilizada foi a *Empírica Normativa*, onde preocupou-se em melhorar uma situação atual, ou seja, o desempenho do processo de otimização em modelos de simulação a eventos discretos, e todo o ciclo de Mitroff *et al.* (1974) foi considerado.

8.4 SUGESTÕES PARA TRABALHOS FUTUROS

A pesquisa abordada nesta tese de doutorado ainda permite novos avanços. Alguns desdobramentos podem ser citados:

- Efetuar uma comparação do método de otimização proposto com outras ferramentas de otimização comerciais;
- Avaliar o desempenho do método de otimização proposto com modelos de simulação a eventos discretos que possuem funções objetivas não lineares;
- Desenvolver um método de otimização que trabalhe com variáveis não inteiras.

Além disso, o item relativo a conclusões e recomendações do capítulo 5, Análise dos parâmetros dos algoritmos genéticos, em relação à qualidade da resposta, levantou algumas questões sobre tais parâmetros. Responder a tais questões também pode ser considerado uma sugestão para trabalhos futuros.

REFERÊNCIAS BIBLIOGRÁFICAS

AKHTAR , S.; LIN-SHU, H. Optimization and Sizing for Propulsion System of Liquid Rocket Using Genetic Algorithm. **Chinese Journal of Aeronautics**, v.20, p. 40-46, 2007.

AL-AOMAR, R.; AL-OKAILY, A. A GA-based parameter design for single machine turning process with high-volume production. **Computers & Industrial Engineering**, v.50, p.317–337, 2006.

ANTONY, J.; KATE, M.; FRANGOU, A. A strategic methodology to the use of advanced statistical quality improvements techniques. **The TQM Magazine**, v.10, n.3, p.169-176, 1998.

APPELQVIST, P.; LEHTONEN, J.M. Combining optimisation and simulation for steel production scheduling. **Journal of Manufacturing Technology Management**, v.16, n. 2, p.197-210, 2005.

APRIL, J.; GLOVER, F.; KELLY, J. P.; LAGUNA, M. Practical Introduction to Simulation Optimization. In: **Proceedings of the Winter Simulation Conference**, Boulder, CO, USA, 2003.

AZADEH, A.; TARVERDIAN, S. Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption. **Energy Policy**, v.35, p.5229–5241, 2007.

BACHELET, B.; YON, L. Model enhancement: Improving theoretical optimization with simulation. **Simulation Modelling Practice and Theory**, v.15, p.703–715, 2007.

BÄCK, T; HAMMEL, U; SCHWEFEL, H. Evolutionary computation: comments on the history and current state. **Evolutionary Computation**, April, v.1, 1997.

BÄCK, T; FOGEL, D. B.; MICHALEWICS, Z. **Evolutionary Computation 2: Advanced Algorithms and Operators**. Bristol, UK, Institute of Physics, 2000.

BALCI, O. Verification, validation, and certification of modeling and simulation applications. In: **Proceedings of the Winter Simulation Conference**, New Orleans, Louisiana, USA, 2003.

BANKS, J. **Handbook of simulation: Principles, Methodology, Advances, Applications, and Practice**. Ed. John Wiley & Sons, Inc., 1998.

BANKS, J. Introduction to Simulation. **Proceedings of the Winter Simulation Conference**, Atlanta, USA, 2000.

BANKS, J. Panel Session: The Future of Simulation. **Proceedings of the Winter Simulation Conference**, Atlanta, GA, USA, 2001.

BANKS, J.; CARSON, J. S.; NELSON, B. L.; NICOL, D. M. **Discrete-event Simulation**. 4.ed. Upper Saddle River, NJ: Prentice-Hall, 2005.

BARBOSA, H. J. C.; LEMONGE, A. C. C. A new adaptive penalty scheme for genetic algorithms. **Information Sciences**, v.156, p.215-251, 2003.

BARBOZA, A. O. **Simulação e Técnica da Computação Evolucionária Aplicadas a Problemas de Programação Linear Inteira Mista**. 2005. Tese (Engenharia Elétrica e Informática Industrial) – Universidade Tecnológica Federal do Paraná, PR, 2005.

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

BIESBROEK, R.G.J.; ANCAROLA, B.P. Study of genetic algorithm settings for trajectory optimization. **Proceedings of 54th International Astronautical Congress**, Bremen, Germany, 2003.

BRIGHENTI, J.R.N. **Simulação e Otimização de uma Linha de Manufatura em Fase de Projeto**. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2006.

CARVALHO, A. C. P. L. F.; BRAGA, A. P.; LUDEMIR, T. B. Computação Evolutiva, In: REZENDE, S. O. (Coord.), **Sistemas Inteligentes – Fundamentos e Aplicações**, Ed. Manole, 1^a.ed, Capítulo 9, São Paulo, 2003.

CASTRO, H. P. **Utilização de algoritmos genéticos para solução de problemas de produção de uma refinaria de petróleo**. 2001. Dissertação de Mestrado – Universidade Federal de Santa Catarina, SC, 2001.

CHEN, Y. M.; LIN, C. T. Dynamic parameter optimization of evolutionary computation for on-line prediction of time series with changing dynamics. **Applied Soft Computing**, v.7, p.1170–1176, 2007

CHENG, B. W.; CHANG, C. L. A study on flowshop scheduling problem combining Taguchi experimental design and genetic algorithm. **Expert Systems with Applications**, v.32, p.415–421, 2007.

CHENG, T.; FENG, C.; HSU, M. An integrated modeling mechanism for optimizing the simulation model of the construction operation. **Automation in Construction**, v.15, p.327–340, 2006.

CHUNG, C.A. **Simulation Modeling Handbook: a practical approach**. Washington D.C: CRC press, 2004.

CHWIF, L. **Redução de modelos de simulação de eventos discretos na sua concepção: uma abordagem causal**. 1999. Tese (Doutorado em Engenharia Mecânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 1999.

CHWIF, L.; MEDINA, A.C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações**. São Paulo: Ed. dos Autores, 2006. 254p.

COELLO, C. A. C. Use of a self-adaptive penalty approach for engineering optimization problems. **Computers in Industry**, v.41, p.113-127, 2000.

COLEMAN, D. E.; MONTEGOMERY, D. C. A systematic approach to planning for a designed industrial experiment. **Technometrics**, v.35, n.1, 1993.

COSTA, C. B. B.; RIVERA, E. A. C.; REZENDE, M. C. A. F.; MACIEL, M. R. W.; MACIEL FILHO, R. Prior detection of genetic algorithm significant parameters: Coupling factorial design technique to genetic algorithm. **Chemical Engineering Science**, v.62, p.4780 – 4801, 2007.

COX, D.R.; REID, N. **The Theory of the Design of Experiments**. Chapman & Hall, CRC, 2000.

CUNHA, A. S.; PINTO, R. L. U. S. Uma técnica para ajuste dos parâmetros de um Algoritmo Genético. **Anais do XXXIII Simpósio Brasileiro de Pesquisa Operacional**, Campos do Jordão, SP, 2001.

DARWIN, C. **The Origin of Species: By Means of Natural Selection or the Preservation of Favored Races in the Struggle for Life**, Oxford University Press, London, UK, 1859 Disponível em: <<http://www.literature.org/authors/darwin-charles/the-origin-of-species/>>. Acesso em: 18 de agosto de 2008.

DAVIS, L. **Handbook of genetic algorithms**. Van Reinhold Nostrand, USA, 1991.
DEDIEU, S.; PIBOULEAU, L.; AZZARO-PANTEL, C.; DOMENECH, S. Design and retrofit of multiobjective batch plants via a multicriteria genetic algorithm. **Computers and Chemical Engineering**, v.27, p.1723-1740, 2003.

DELINCHANT, B.; DURET, D.; ESTRABAUT, L.; GERBAUD, L.; HUU, H.; PELOUX, B.; RAKOTOARISON, H.L.; VERDIERE, F.; WURTZ, F. An optimizer using the software component paradigm for the optimization of engineering systems. **International Journal for Computation and Mathematics in Electrical and Electronic Engineering**, v.26, n.2, p.368-379, 2007.

DOLOI, H.; JAAFARI, A. Conceptual simulation model for strategic decision evaluation in project management. **Logistics Information Management**, v.15, 2003.

DUARTE, R. N. **Simulação computacional: Análise de uma célula de manufatura em lotes do setor de auto-peças**. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2003.

DRSTVENSEK, I.; FICKO, M.; PAHOLE, I.; BALIC, J. A model of simulation environment for prediction and optimization of production processes. **Journal of Materials Processing Technology**, v.155–156, p.1641–1646, 2004.

FALCÃO, A. O.; BORGES, J. G. Designing an Evolution Program for Solving Integer Forest Management Scheduling Models: an Application in Portugal. **Forest Science**, v.47, n.2, p.158-168, 2001.

FOGEL, D. An Introduction to Simulated Evolutionary Optimization. **IEEE - Transactions on Neural Networks**, New York, v.5, n.1, p.3-14, Jan., 1994.

FRAILE-ARDANUY, J.; ZUFIRIA, P.J. Design and comparison of adaptive power system stabilizers based on neural fuzzy networks and genetic algorithms. **Neurocomputing**, v.70, p.2902–2912, 2007.

FÜHNER, T., JUNG, T. Use of genetic algorithms for the development and optimization of crystal growth processes. **Journal of Crystal Growth**, v.266, p.229–238, 2004.

FU, M. C. Optimization for Simulation: Theory vs. Practice. **Journal on Computing**, v.14, n 3, 2002.

GALDÁMEZ, E. V. C. **Aplicação das técnicas de planejamento e análise de experimentos na melhoria da qualidade de um processo de fabricação de produtos plásticos**. 2002. Dissertação de Mestrado – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2002.

GAVIRA, M. O. **Simulação computacional como uma ferramenta de aquisição de conhecimento**. Dissertação (Mestrado em Engenharia de Produção) – Universidade de São Paulo, São Carlos, SP, 2003.

GEORGY, M.; BASILY, S. Y. Using genetic algorithms in optimizing construction material delivery schedules. **Construction Innovation**, v.8, n.1, p.23-45, 2008.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 5. ed. São Paulo: Atlas, 1999.

GOLDBERG, D. E. **Genetic Algorithm in Search, Optimization and Machine Learning**. Addison-Wesley Publishing Company, INC. United States of America, 1989.

GOLDBARG, M. C.; GOLDBARG, E. F. G.; MEDEIROS NETO, F. D. An Evolutionary Approach for the Piston Pump Mobile Unit Problem. **Proceeding of MCO'04 Fifth International Conference on Computer Sciences**. v.1, p.281-290, 2004.

GOLDBARG, M. C.; LUNA, H. P. L. **Otimização Combinatória e Programação Linear: Modelos e Algoritmos**. Editora Campos, Rio de Janeiro, 2000.

GONG, D-W; HAO, G-S; ZHOU, Y; SUN, X-Y. Interactive genetic algorithms with multi-population adaptive hierarchy and their application in fashion design. **Applied Mathematics and Computation**, v.185, p.1098–1108, 2007.

GREFENSTETTE, J. J. Optimization of control parameters for genetic algorithms. **IEEE Transaction on Systems, Man, and Cybernetics, SMC**, v.16, p.122–128, 1986

HABCHI G., BERCHET, C. A model for manufacturing systems simulation with a control dimension. **Simulation Modeling Practice and Theory**, v.11, p.21–44, 2003.

HAO, Q.; SHEN, W. Implementing a hybrid simulation model for a Kanban-based material handling system. **Robotics and Computer-Integrated Manufacturing**, v.24, p.635–646, 2008.

HARREL, C. R.; GHOSH, B. K.; BOWDEN, R. **Simulation Using Promodel**. McGraw-Hill, 2000.

HERRERA, F.; LOZANO, M. Gradual distributed real-coded genetic algorithms. **IEEE Transactions on Evolutionary Computation**, v.4, n.1, p.43–63, 2000.

HERRERA, F.; LOZANO, M.; VERDEGAY, J. L. Tackling Real-Coded Genetic Algorithms – Operators and Tools for Behavioural Analysis. **Artificial Intelligence Review**, v.12, p.265-319, 1998.

HINTERDING, R.; MICHALEWICZ, Z.; EIBEN, A. E. Adaptation in evolutionary computation: a survey. **IEEE Transactions on Evolutionary Computation**, v.3, n.2, p.124-141, IEEE Press, USA, 1997.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. University of Michigan Press, Ann Arbor, 1975.

HWANG, S. F.; HE, R. S. Improving real-parameter genetic algorithm with simulated annealing for engineering problems. **Advances in Engineering Software**, v.37, p.406–418, 2006.

JAMES, T. L.; BARKHI, R.; JOHNSON, J. D. Platform impact on performance of parallel genetic algorithms: Design and implementation considerations. **Engineering Applications of Artificial Intelligence**, v.19, p.843–856, 2006.

JOHANSSON B. **Discrete Event Simulation – present situation and future potential**. Department of Product and Production Development, Chalmers University of Technology, Göteborg, Sweden, 2002.

JUNG, C. F. **Metodologia Científica: Ênfase em Pesquisa Tecnológica**, Terceira edição. Revisada e Ampliada. FACCAT, 2003.

KAMEI, K.; ISHIKAWA, M. Determination of the optimal values of parameters in reinforcement learning for mobile robot navigation by a genetic algorithm. **International Congress Series**, v.1269, p.193–196, 2004.

KAMEI, K.; ISHIKAWA, M. Prediction of the optimal parameter values in reinforcement learning as a function of the environment. **International Congress Series**, v.1301, p.210–213, 2007.

KAR, B.; BANERJEE, R.; BHATTACHARYYA, B. C. Optimization of physicochemical parameters for gallic acid production by evolutionary operation-factorial design technique. **Process Biochemistry**, v.37, p.1395–1401, 2002.

KAVEH, A.; SHAHROUZI, M. A hybrid ant strategy and genetic algorithm to tune the population size for efficient structural optimization. **International Journal for Computer-Aided Engineering and Software**, v.24, n.3, p.237–254, 2007.

KHALIK, M. A.; SHERIF, M.; SARAYA, S.; AREED, F. Parameter identification problem: Real-coded GA approach. **Applied Mathematics and Computation**, v.187, p.1495–1501, 2007.

KELTON, W.D. Designing simulation experiments. In: **Proceedings of the Winter Simulation Conference**, Phoenix, AZ, USA, 1999.

KLEIJNEN, J.P.C.; SANCHEZ, S.M.; LUCAS, T.W.; CIOPPA, T.M. State-of-the-Art Review: A User's Guide to the Brave New World of Designing Simulation Experiments. **Journal on Computing**, v.17, n.3, p.263–289, 2005.

KOZA, J.; KEANE, M. A.; STREETER, M. J. **Genetic Programming IV: Routine Human-Competitive Machine Intelligence**, Kluwer Academic Publishers, Hingham, USA, 2003.

LACKSONEN, T. Empirical comparison of search algorithms for discrete event simulation. **Computers & Industrial Engineering**, v.40, p.133-148, 2001.

LANDSHEER, J. A.; VAN DEN WITTENBOER; MAASSEN, G. H. Additive and multiplicative effects in a fixed 2 x 2 design using ANOVA can be difficult to differentiate: Demonstration and mathematical reason. **Social Science Research**, v.35, p.279–294, 2006.

LAW, A. M.; KELTON, W. D. **Simulation modeling and analysis**. 3.ed. New York: McGraw-Hill, 2000.

LAW A. M.; MCCOMAS, M. G. Simulation of manufacturing systems. **Proceedings of the Winter Simulation Conference**, Tucson, USA, 1999.

LEAL, F.; MONTEVECHI, J. A. B; ALMEIDA, D. A. de; PINHO, A. F. de; MARINS, F. A. S.; OLIVEIRA, J. B. Análise da Capacidade de Produção e Dimensionamento de Estoques no Estudo de um Novo Processo de Manufatura Através da Simulação de Eventos Discretos. In: **SOBRAPO – Simpósio Brasileiro de Pesquisa Operacional**, 2006.

LEBOREIRO, J., ACEVEDO, J. Mejorando la eficiencia de un algoritmo genético para la optimización de procesos usando simuladores comerciales. **Información Tecnológica**, v.13, p.125–135, 2002.

LEBOREIRO, J., ACEVEDO, J. Processes synthesis and design of distillation sequences using modular simulators: a genetic algorithm framework. **Computers and Chemical Engineering**, v.28, p.1223–1236, 2004.

LINDEN, R. **Algoritmos Genéticos: Uma Importante Ferramenta da Inteligência Computacional**. Editora Brasport, Rio de Janeiro, 2006.

LOBO, F. G.; GOLDBERG, D. E. The parameter-less genetic algorithm in practice. **Information Sciences**, v.167, p.217–232, 2004.

MA, Y.; ZHANG, C. Quick convergence of genetic algorithm for QoS-driven web service selection. **Computer Networks**, v.52, p.1093–1104, 2008.

MASOOD, S. Line balancing and simulation of an automated production transfer line. **Assembly Automation**. v.26, n.1, p.69–74, 2006.

MENDES, A. R.; RAMOS, A. L.; SIMARIA, A. S.; VILARINHO, P. M. Combining heuristic procedures and simulation models for balancing a PC camera assembly line. In: **Computers & Industrial Engineering**, v.49, p.413–431, 2005.

MIRANDA, M. N. **Algoritmos Genéticos: Fundamentos e Aplicações**. [On-line], [<http://www.gta.ufrj.br/~marcio/genetic.html>], 2005.

MITCHELL, M. **An Introduction a Genetic Algorithm**. MIT Press, Massachusetts, London, England, 1996.

MITROFF, I. I.; BETZ, F.; PONDY, L. R.; SAGASTI, F. On managing science in the system age: two schemas for the study of science as a whole system phenomenon. **Interfaces**. v.4, n.3, p.46-58, 1974.

MONTEVECHI, J.A.B.; PINHO, A.F. de; LEAL, F.; MARINS, F.A.S. Application of design of experiments on the simulation of a process in an automotive industry. In: **Proceedings of the Winter Simulation Conference**, Washington, DC, USA, 2007.

MONTEVECHI, J.A.B.; PINHO, A.F. DE; LEAL, F.; MARINS, F.A.S.; COSTA, R. F. DA S. Improving a process in a brazilian automotive plant applying process mapping, design of experiments and discrete events simulation. In: **Proceedings of the 20 Symposium Europeo de Modelado y Simulacion (SCS)**, Briatico, Itália, 2008.

MONTEVECHI, J.A.B.; LEAL, F.; PINHO, A.F. DE; COSTA, R.F. DA S.; MARINS, F.A.S.; MARINS, F.F.; JESUS, J.T. Combined use of modeling techniques for the development of the conceptual model in simulation projects. In: **Proceedings of the 2008 Winter Simulation Conference**, Miami, USA, 2008.

MONTGOMERY, D.C. **Design and Analysis of Experiments**. 6th ed., Wiley, 2005.

MONTGOMERY, D.C.; RUNGER, G.C. **Estatística Aplicada e Probabilidade para Engenheiros**. 2.ed. Editora LTC, 2003.

MORI, B. D.; CASTRO, H. F. DE; CAVALCA, K. L. Development of hybrid algorithm based on simulated annealing and genetic algorithm to reliability redundancy optimization. **International Journal of Quality & Reliability Management**, v.24, n.9, p.972-987, 2007.

MYERS, R.; HANCOCK, E. R. Genetic algorithm parameter sets for line labeling. **Pattern Recognition Letters**, v.18, p.1363–1371, 1997.

NANAKORN, P; MEESOMKLIN, K. An adaptive penalty function in genetic algorithms for structural design optimization. **Computers and Structures**, v.79, p.2527-2539, 2001.

NOORDIN, M. Y.; VENKATESH, V. C.; SHARIF, S.; ELTING, S. & ABDULLAH, A. Application of response surface methodology in describing the performance of coated carbide tools when turning AISI 1045 steel. **Journal of Materials Processing Technology**, v.145, 2004.

NÚÑEZ-LETAMENDIA, L. Fitting the control parameters of a genetic algorithm: An application to technical trading systems design. **European Journal of Operational Research**, v.179, p.847–868, 2007.

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

OLIVEIRA, J. B. de. **Simulação Computacional: Análise de um Sistema de Manufatura em Fase de Desenvolvimento**. 2007. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2007.

OPTQUEST FOR ARENA USER'S GUIDE, Rockwell Software Inc., 2002.

OZCELIKT, B.; ERZURUMLU, T. Determination of effecting dimensional parameters on warpage of thin shell plastic parts using integrated response surface method and genetic algorithm. **International Communications in Heat and Mass Transfer**, v.32, p.1085–1094, 2005.

PAIVA, A. P. **Metodologia de Superfície de Resposta Multivariada – Uma proposta de otimização para processos de manufatura com múltiplas respostas correlacionadas**. 2006. 279p. Tese (Doutorado em Engenharia Mecânica) – UNIFEI – Universidade Federal de Itajubá, MG, 2006.

PENDHARKAR, P C. The theory and experiments of designing cooperative intelligent systems. **Decision Support Systems**, v.43, p.1014–1030, 2007.

PEREIRA, I. C. **Proposta de sistematização da simulação para fabricação em lotes**. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2000.

PINHO, A. F. de; LEAL, F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; MAPA, S. M. S.; RIBEIRO, M. J. C. Aumento de Produtividade em uma Linha de Montagem de Chassis Automotivos Através da Simulação Computacional. In: **Anais do XXVI Encontro Nacional de Engenharia de Produção**, Fortaleza, CE, 2006.

PONTES, F. J.; FERREIRA, J. R.; PAIVA, A. P.; BALESTRASSI, P. P. Aplicação de um arranjo fatorial completo ao projeto dos parâmetros de uma rede neural artificial RBF para predição da rugosidade em processo de torneamento. **Anais do XXVII Encontro Nacional de Engenharia de Produção**, Foz do Iguaçu, PR, 2007.

POOJARI, C. A.; VARGHESE, B. Genetic Algorithm based technique for solving Chance Constrained Problems. **European Journal of Operational Research**, v.185, p.1128–1154, 2008.

PROTIL, R. M. Otimização do Processo Decisório Utilizando Simulação Computacional. **XXXIII Simpósio Brasileiro de Pesquisa Operacional**, Campos do Jordão, SP, p.1535-1546, 2001.

RABELO, L.; ESKANDARI, H.; SHAALAN, T.; HELAL, M. Value chain analysis using hybrid simulation and AHP. **International Journal of Production Economics**, v.105, p.536–547, 2007.

RAHAMI, H.; KAVEH, A.; GHOLIPOUR, Y. Sizing, geometry and topology optimization of trusses via force method and genetic algorithm. **Engineering Structures**, v.30, p.2360–2369, 2008.

REES, J.; KOEHLER; G. J. Learning genetic algorithm parameters using hidden Markov models. **European Journal of Operational Research**, v.175, p.806–820, 2006.

REEVES, C. R. **Modern Heuristic Techniques for Combinatorial Problems**. McGraw-Hill Book Company, London, 1995.

RIVERA, E. C.; COSTA, A. C.; ATALA, D. I. P.; MAUGERI, F.; MACIEL, M. R. W, MACIEL FILHO, R. Evaluation of optimization techniques for parameter estimation: Application to ethanol fermentation considering the effect of temperature. **Process Biochemistry**, v.41, p.1682–1687, 2006.

RODRIGUES, J.A.D., TOLEDO, E.C.V., MACIEL FILHO, R. A tuned approach of the predictive-adaptative GPC controller applied to a fed-batch bioreactor using complete factorial design. **Computers and Chemical Engineering**, v.26, p.1493–1500, 2002.

ROY, S. S. Design of genetic-fuzzy expert system for predicting surface finish in ultra-precision diamond turning of metal matrix composite. **Journal of Materials Processing Technology**, v.173, p.337–344, 2006.

RYAN, J.; HEAVEY, C. Process modeling for simulation. **Computers in Industry**, v.57, p.437–450, 2006.

SANCHEZ, S. M. Work smarter, not harder: guidelines for designing simulation experiments. In: **Proceedings of the Winter Simulation Conference**, Monterey, CA, USA, 2006.

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

SHANNON R. E., Introduction to the art and science of simulation. **Proceedings of the Winter Simulation Conference**, Washington, DC, USA, 1998.

SIEMIATKOWSKI, M.; PRZYBYLSKI, W. Simulation studies of process flow with in-line part inspection in machining cells. **Journal of Materials Processing Technology**, v. 171, p. 27–34, 2006.

SILVA, C. M., BISCAIA JR., E. C. Genetic algorithm development for multi-objective optimization of batch free-radical polymerization reactors. **Computers and Chemical Engineering**, v.27, p.1329–1344, 2003.

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

SOUZA, D. O. **Algoritmos Genéticos Aplicados ao Planejamento do Transporte Principal de Madeira**. 2004. Dissertação de Mestrado – Universidade Federal do Paraná, Curitiba, PR, 2004.

STEINBERG, M. D.; HUNTER, W. G. Experimental design: review and comment. **Technometrics**, v.26, n.2, p.71-130, 1984.

STRACK, J. **GPSS: modelagem e simulação de sistemas**. Rio de Janeiro: LTC, 1984.

SUMMANWAR, V. S., JAYARAMAN, V. K., KULKARNI, B. D., KUSUMAKAR, H. S., GUPTA, K., RAJESH, J. Solution of constrained optimization problems by multi-objective genetic algorithm. **Computers and Chemical Engineering**, v.26, p.1481–1492, 2002.

TANOMARU, J. Motivação, fundamentos e Aplicações de Algoritmos Genéticos. **II Congresso Brasileiro de Redes Neurais**, p.373-403, Curitiba, PR, 1995.

TODOROKI, A.; ISHIKAWA, T. Design of experiments for stacking sequence optimizations with genetic algorithm using response surface approximation. **Composite Structures**, v.64, p.349–357, 2004.

TOGAN, V.; DALOGLU, A. T. Optimization of 3d trusses with adaptive approach in genetic algorithms. **Engineering Structures**, v.28, p.1019-1027, 2006.

TOGAN, V.; DALOGLU, A. T. An improved genetic algorithm with initial population strategy and self-adaptive member grouping, **Computers and Structures**, v.86, p.1204–1218, 2008.

TONGCHIM, S.; CHONGSTITVATANA, P. Parallel genetic algorithm with parameter adaptation. **Information Processing Letters**, v. 82, p.47–54, 2002.

TORGA, B. L. M. **Modelagem, Simulação e Otimização em Sistemas Puxados de Manufatura**. 2007. 126 f. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2007.

TREADWELL, M. A.; HERRMANN, J. W. A Kanban Module for Simulation Pull Production in Arena. **Proceedings of the Winter Simulation Conference**, USA, 2005.

TRIOLA, M.F. **Introdução à Estatística**. 9^a.ed. Rio de Janeiro: Editora LTC, 2005.

VERMA, R.; GIBBS, G. D.; GILGAN, R. J. Redesigning check-processing operations using animated computer simulation. **Business Process Management**, v.6, n.1, p.54-64, 2000.

VOLSEM, S. V.; DULLAERT, W.; VAN LANDEGHEM, H. An Evolutionary Algorithm and discrete event simulation for optimizing inspection strategies for multi-stage processes. **European Journal of Operational Research**, v.179, p.621–633, 2007.

TYNI, T.; YLINEN, J. Evolutionary bi-objective optimization in the elevator car routing problem. **European Journal of Operational Research**, v.169, p.960–977, 2006.

YANG, T.; FU, H. P.; YANG, K. Y. An evolutionary-simulation approach for the optimization of multi-constant work-in-process strategy: A case study. **International Journal Production Economics**, v.107, p.104–114, 2007.

YU, S.; ZHU, K.; DIAO, F. A dynamic all parameters adaptive BP neural networks model and its application on oil reservoir prediction. **Applied Mathematics and Computation**, v.195, p.66–75, 2008.

YUN, Y., GEN, M. Performance analysis of adaptive genetic algorithms with fuzzy logic and heuristics. **Fuzzy Optimization and Decision Making**, v.2, n.2, p.161–175, 2003.

ZHANG, H.; ISHIKAWA, M. A solution to combinatorial optimization with time-varying parameters by a hybrid genetic algorithm. **International Congress Series**, v.1269, p.149–152, 2004

ZHANG, H.; LI, H. Simulation-based optimization for dynamic resource allocation. **Automation in Construction**, v.13, p.409–420, 2004.

APÊNDICE A – PUBLICAÇÕES ORIGINADAS

Artigos originados desta tese publicados em periódicos:

PINHO, A.F.de; MONTEVECHI, J.A.B.; MARINS, F.A.S. Análise da Aplicação de Projeto de Experimentos nos Parâmetros dos Algoritmos Genéticos. **Sistemas & Gestão**, revista eletrônica, v.2, p.319-331, 2007.

Artigos originados desta tese publicados em anais de congresso:

PINHO, A.F.de; MONTEVECHI, J.A.B.; MARINS, F.A.S. Desenvolvimento de uma ferramenta computacional para a otimização de modelos de simulação a eventos discretos. In: **XL Simpósio Brasileiro de Pesquisa Operacional**, João Pessoa, 2008.

PINHO, A.F.de; MONTEVECHI, J.A.B.; MARINS, F.A.S.; Ferramenta Computacional para a Otimização de Modelos de Simulação a Eventos Discretos In: **XXVIII Encontro nacional de Engenharia de Produção**, Rio de Janeiro, 2008.

MONTEVECHI, J.A.B.; PINHO, A.F.de; LEAL, F.; MARINS, F.A.S.; COSTA, R.F.S. Improving a process in a Brazilian automotive plant applying process mapping, design of experiments and discrete events simulation. In: **20th European Modeling and Simulation Symposium**, Amantea - Italy, 2008.

MONTEVECHI, J.A.B., COSTA, R.F.S., LEAL, F., PINHO, A.F.de, MARINS, F.A.S., MARINS, F.F., JESUS, J.T. Combined use of modeling techniques for the development of the conceptual model in simulation projects In: **Proceedings of the 2008 Winter Simulation Conference**, Miami, 2008.

PINHO, A.F.de; MONTEVECHI, J.A.B.; MARINS, F.A.S. Análise da aplicação de projeto de experimentos nos parâmetros dos algoritmos genéticos. In: **XII Simpósio Brasileiro de Pesquisa Operacional**, Fortaleza, 2007.

MONTEVECHI, J.A.B.; PINHO, A.F.de; LEAL, F.; MARINS, F.A.S. Application of design of experiments on the simulation of a process in an automotive industry. In: **Proceedings of the 2007 Winter Simulation Conference**, Washington, DC, 2007.

PINHO, A.F.de; LEAL, F.; MONTEVECHI, J.A.B.; MARINS, F.A.S.; MAPA, S.M.S.; RIBEIRO, M.J.C. Aumento da Produtividade em uma Linha de Montagem de Chassis Automotivos através da Simulação Computacional. In: **XXVI Encontro Nacional de Engenharia de Produção**, Fortaleza, 2006.

Artigo submetido à revista e em fase de avaliação:

PINHO, A.F.de; MONTEVECHI, J.A.B.; MARINS, F.A.S.; COSTA, R.F.S. Proposal of an efficient Method for Discrete Event Simulation Model Optimization based on Genetic Algorithms. Artigo submetido à revista **European Journal of Operational Research**, 2008.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)