

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

Rafael de Carvalho Miranda

**ALGORITMO GENÉTICO ADAPTATIVO PARA
OTIMIZAÇÃO DE MODELOS DE SIMULAÇÃO A
EVENTOS DISCRETOS**

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

Área de Concentração: Engenharia de Produção

Orientador: Prof. Dr. José Arnaldo Barra Montevechi

Co-orientador: Prof. Dr. Alexandre Ferreira de Pinho

Março de 2012

Itajubá - MG

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

Rafael de Carvalho Miranda

**ALGORITMO GENÉTICO ADAPTATIVO PARA
OTIMIZAÇÃO DE MODELOS DE SIMULAÇÃO A
EVENTOS DISCRETOS**

Dissertação aprovada por banca examinadora em 12 de março de 2012, conferindo ao autor o título de Mestre em Ciências em Engenharia de Produção.

Banca examinadora:

Prof. Dr. João José de Assis Rangel (UCAM-Campos)

Prof. Dr. José Antonio de Queiroz (UNIFEI)

Prof. Dr. José Arnaldo Barra Montevechi (Orientador)

Prof. Dr. Alexandre Ferreira de Pinho (Co-Orientador)

Março de 2012

Itajubá - MG

DEDICATÓRIA

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

AGRADECIMENTOS

Ao professor José Arnaldo Montevechi pela orientação desse trabalho e por toda amizade, auxílio e empenho ao longo dessa pesquisa. Nunca medindo esforços para me auxiliar no que fosse preciso.

Ao professor Alexandre Pinho, por todo auxílio na programação do *software* desenvolvido e pelas inúmeras discussões sobre algoritmos genéticos e otimização. Sem seu esforço e auxílio esse trabalho não existiria.

Aos professores Fabiano Leal e Fábio Favaretto pela amizade e contribuições realizadas ao longo deste trabalho e do mestrado.

Aos professores do Núcleo de Estudos Avançados para Auxílio à Decisão (NEAAD), André Medeiros, José Hamilton, José Antonio de Queiroz e Josiane Lima.

Aos professores Carlos Mello e João Batista Turrioni pelas inúmeras discussões para a determinação do método de pesquisa deste trabalho.

Ao coordenador do programa de mestrado em engenharia de produção, professor Carlos Sanches, e ao coordenador do programa Pró-Engenharias da CAPES, professor João Roberto Ferreira, por todo auxílio prestado ao longo desses dois anos de mestrado.

Aos professores Luiz Gonzaga Mariano e Alaor Campos por toda amizade, apoio e incentivo nessa etapa de minha vida.

Aos amigos Rafael Florêncio, Mona Liza, Daniel Friend, Paulo Campos, Tábata, Paulo Rotela, Rogério e Luiz Gustavo por sempre me apoiarem e me auxiliarem no que fosse preciso.

A todos os funcionários do Instituto de Engenharia de Produção e Gestão (IEPG) da UNIFEI, em especial, Luiza, Ademar, Bia, Cristina e Luzia, que direta ou indiretamente ajudaram nesse trabalho.

Ao Programa de Pró-Engenharias da CAPES, CNPq e à FAPEMIG pelo apoio e incentivo à pesquisa brasileira, em especial a essa.

A todos vocês, meu muito obrigado!

EPÍGRAFE

“O homem não é nada além daquilo que a educação faz dele.”

Immanuel Kant

RESUMO

Métodos de otimização combinados à simulação a eventos discretos têm sido utilizados nas mais diversas aplicações. Entretanto, estes métodos possuem baixo desempenho em relação ao tempo computacional, ao manipularem mais de uma variável de decisão. Dessa forma, o objetivo deste trabalho é desenvolver um algoritmo genético adaptativo para otimização não linear de modelos de simulação, capaz de atingir bons resultados em termos de eficiência e qualidade de resposta, quando comparado a uma ferramenta de otimização comercial. Para tal, foi utilizado o delineamento de experimentos para definir os parâmetros mais significativos do algoritmo genético, e, para estes parâmetros, foram propostas adaptações. Pôde-se verificar que os parâmetros tamanho de população e número de gerações foram os mais significativos. Desta forma, estratégias adaptativas foram propostas a estes parâmetros, focando principalmente a definição do tamanho da população inicial e seu incremento ao longo das iterações realizadas pelo algoritmo de otimização. Foi implementado também um critério de parada para o algoritmo, baseado na melhoria da qualidade das soluções ao longo das gerações, e dois conjuntos de parâmetros foram definidos para os operadores genéticos de *crossover* e mutação. As alterações introduzidas no algoritmo fizeram com que este conseguisse apresentar bons resultados, tanto em termos de qualidade de resposta, quanto em termos de tempo necessário para sua convergência, quando comparado aos resultados alcançados por um *software* comercial na otimização de oito objetos de estudo.

Palavras Chaves: Simulação a eventos discretos, otimização via simulação, algoritmo genético, algoritmo genético adaptativo.

ABSTRACT

Optimization methods in discrete event simulation are widely used. However, the performance of these methods drops off dramatically in terms of computational time when manipulating more than one decision variable. The objective of this research is to develop an adaptive genetic algorithm for optimization of non-linear simulation models which is capable of reaching good results in terms of efficiency and response quality when compared to a commercial optimization tool. In order to do so, design of experiments was utilized to define the algorithm's most significant parameters and propose adaptations for them. It was verified that the parameters of population size and number of generations were the most significant. Thus, adaptive strategies have been proposed for these parameters, focusing primarily on defining the size of the initial population of the algorithm and its increase over the iterations performed by the optimization algorithm. A stopping criterion for the algorithm based on improving the quality of the solutions over the generations was implemented, and two sets of parameters were defined for the genetic operators of crossover and mutation. The changes led the algorithm to produce good results in terms of quality and response time needed for convergence when compared to a commercial software package in optimization of eight objects of study.

Key-words: Discrete Events Simulation, Simulation Optimization, Genetic Algorithms, Adaptive Genetic Algorithms.

LISTA DE FIGURAS

Figura 2.1 - Estrutura de pesquisa em simulação	22
Figura 3.1 - Estrutura de pesquisa em simulação	29
Figura 3.2 - Sequência de passos para um projeto de simulação	30
Figura 3.3 - Modelo de simulação	32
Figura 3.4 - Representação modelagem, simulação e otimização	34
Figura 3.5 - Princípio de funcionamento de um modulo de otimização integrado a um <i>software</i> de simulação	35
Figura 3.6 - Esquema básico de um algoritmo genético.....	42
Figura 3.7 - Modelo geral de um processo	54
Figura 4.1 - Estrutura clássica de um AG e parâmetros analisados	59
Figura 4.2 - Modelo implementado no <i>ProModel</i> ® para o primeiro objeto de estudo.....	60
Figura 4.3 - Modelo conceitual para o primeiro objeto de estudo.....	61
Figura 4.4 - Modelo implementado no <i>ProModel</i> ® para o segundo objeto de estudo	62
Figura 4.5 - Modelo conceitual para o segundo objeto de estudo	63
Figura 4.6 - Modelo implementado no <i>ProModel</i> ® para o terceiro objeto de estudo	64
Figura 4.7 - Modelo conceitual para o terceiro objeto de estudo	65
Figura 4.8 - Gráfico dos efeitos principais para Solução	72
Figura 4.9 - Gráfico de Pareto dos efeitos padronizados para Solução.....	73
Figura 4.10 - Gráfico dos efeitos principais para Tempo	74
Figura 4.11 - Gráfico de Pareto dos efeitos padronizados para Tempo	75
Figura 4.12 - Gráfico dos efeitos principais para Solução	77
Figura 4.13 - Gráfico de Pareto dos efeitos padronizados para Solução.....	78
Figura 4.14 - Gráfico dos efeitos principais para Tempo	79
Figura 4.15 - Gráfico de Pareto dos efeitos padronizados para Tempo	80
Figura 4.16 - Gráfico dos efeitos principais para Solução	82
Figura 4.17 - Gráfico de Pareto dos efeitos padronizados para Solução.....	83
Figura 4.18 - Gráfico dos efeitos principais para Tempo	84
Figura 4.19 - Gráfico de Pareto dos efeitos padronizados para Tempo	85
Figura 5.1 - Estrutura do AGA proposto	97
Figura 5.2 - Relacionamento entre o método de otimização e o simulador via objeto	99
Figura 6.1 - Interface gráfica do <i>software SimRunner</i> ®.....	102

Figura 6.2 - Modelo implementado no <i>ProModel</i> ® para o primeiro objeto de estudo.....	104
Figura 6.3 - Modelo conceitual para o primeiro objeto de estudo.....	105
Figura 6.4 - Modelo implementado no <i>ProModel</i> ® para o segundo objeto de estudo	106
Figura 6.5 - Modelo conceitual para o segundo objeto de estudo	107
Figura 6.6 - Modelo implementado no <i>ProModel</i> ® para o terceiro objeto de estudo	108
Figura 6.7 - Modelo conceitual para o terceiro objeto de estudo	109
Figura 6.8 - Modelo implementado no <i>ProModel</i> ® para o quarto objeto de estudo	110
Figura 6.9 - Modelo conceitual para o quarto objeto de estudo	111
Figura 6.10 - Modelo implementado no <i>ProModel</i> ® para o quinto objeto de estudo	112
Figura 6.11 - Modelo conceitual para o quinto e sexto objetos de estudo	113
Figura 6.12 - Modelo implementado no <i>ProModel</i> ® para o sexto objeto de estudo	114
Figura 6.13 - Modelo implementado no <i>ProModel</i> ® para o sétimo objeto de estudo	115
Figura 6.14 - Modelo conceitual para o sétimo objeto de estudo.....	116
Figura 6.15 - Modelo implementado no <i>ProModel</i> ® para o oitavo objeto de estudo.....	117
Figura 6.16 - Modelo conceitual para o oitavo objeto de estudo	118

LISTA DE TABELAS

Tabela 3.1 - <i>Softwares</i> de otimização	37
Tabela 3.2 - Características das principais técnicas de Projeto e Análise de Experimentos	56
Tabela 4.1 - Fatores, níveis e variações do projeto de experimentos	66
Tabela 4.2 - Matriz experimental	67
Tabela 4.3 - Resultados da otimização do primeiro modelo de simulação	68
Tabela 4.4 - Tempo necessário para convergência do primeiro modelo de simulação	68
Tabela 4.5 - Resultados da otimização do segundo modelo de simulação	69
Tabela 4.6 - Tempo necessário para convergência do segundo modelo de simulação	69
Tabela 4.7 - Resultados da otimização do terceiro modelo de simulação	70
Tabela 4.8 - Tempo necessário para convergência do terceiro modelo de simulação.....	70
Tabela 4.9 - Análise de variâncias para a resposta Solução	71
Tabela 4.10 - Efeitos estimados e coeficientes para Solução	73
Tabela 4.11 - Análise de Variâncias para a resposta Tempo	74
Tabela 4.12 - Efeitos estimados e coeficientes para Tempo	76
Tabela 4.13 - Análise de Variâncias para a resposta Solução	76
Tabela 4.14 - Efeitos estimados e coeficientes para Solução	78
Tabela 4.15 - Análise de Variâncias para a resposta Tempo.....	79
Tabela 4.16 - Efeitos estimados e coeficientes para Tempo	81
Tabela 4.17 - Análise de Variâncias para a resposta Solução	81
Tabela 4.18 - Efeitos estimados e coeficientes para Solução	83
Tabela 4.19 - Análise de Variâncias para a resposta Tempo.....	84
Tabela 4.20 - Efeitos estimados e coeficientes para Tempo	86
Tabela 5.1 - Relação entre tamanho do indivíduo e tamanho da população segundo Goldberg (1989)	91
Tabela 5.2 - Relação entre tamanho do indivíduo e tamanho da população segundo Reeves (1993)	92
Tabela 6.1 - Apresentação dos objetos de estudos	103
Tabela 6.2 - Variáveis de decisão, tipo e limites para o primeiro objeto de estudo	104
Tabela 6.3 - Variáveis de decisão, tipo e limites para o segundo objeto de estudo.....	106
Tabela 6.4 - Variáveis de decisão, tipo e limites para o terceiro objeto de estudo.....	108
Tabela 6.5 - Variáveis de decisão, tipo e limites para o quarto objeto de estudo.....	110

Tabela 6.6 - Variáveis de decisão, tipo e limites para o quinto objeto de estudo.....	112
Tabela 6.7 - Variáveis de decisão, tipo e limites para o sexto objeto de estudo	114
Tabela 6.8 - Variáveis de decisão, tipo e limites para o sétimo objeto de estudo	115
Tabela 6.9 - Variáveis de decisão, tipo e limites para o oitavo objeto de estudo	117
Tabela 6.10 - Características dos <i>softwares</i> utilizados	119
Tabela 6.11 - Resultados Otimização primeiro objeto de estudo	120
Tabela 6.12 - Resultados Otimização segundo objeto de estudo	121
Tabela 6.13 - Resultados Otimização terceiro objeto de estudo.....	123
Tabela 6.14 - Resultados Otimização quarto objeto de estudo.....	124
Tabela 6.15 - Resultados Otimização quinto objeto de estudo.....	125
Tabela 6.16 - Resultados Otimização sexto objeto de estudo	126
Tabela 6.17 - Resultados Otimização sétimo objeto de estudo	127
Tabela 6.18 - Resultados Otimização oitavo objeto de estudo.....	128

LISTA DE ABREVIATURAS

AG	<i>Algoritmo Genético</i>
AGA	<i>Algoritmo Genético Adaptativo</i>
ANOVA	<i>Analysis of Variance</i>
DOE	<i>Design of Experiments</i>

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Relevância da pesquisa.....	15
1.2 Objetivo	16
1.3 Condições de contorno da pesquisa.....	17
1.4 Estrutura da dissertação	17
2. MÉTODO DE PESQUISA	19
2.1 Considerações iniciais	19
2.2 Metodologia de pesquisa quantitativa: modelagem e simulação.....	19
2.3 Classificação da pesquisa	20
2.4 Etapas de uma pesquisa em modelagem e simulação.....	21
2.5 Etapas do método a serem desenvolvidas.....	23
2.6 Considerações finais	23
3. FUNDAMENTAÇÃO TEÓRICA.....	24
3.1 Considerações iniciais	24
3.2 Simulação a eventos discretos	24
3.2.1 Histórico da simulação	24
3.2.2 Introdução à simulação	26
3.2.3 Vantagens e desvantagens da simulação	27
3.2.4 Metodologias para estudos de simulação	28
3.3 Otimização via simulação.....	32
3.3.1 Simulação combinada à otimização	32
3.3.2 Princípios de funcionamento	34
3.3.3 <i>Softwares</i> de otimização via simulação	35
3.3.4 Metodologia para otimização via simulação	37
3.3.5 Casos na literatura	38
3.4 Algoritmos Genéticos	40
3.4.1 AG: Definições básicas	40
3.4.2 Componentes básicos dos AG	41
3.4.3 Representação Genética.....	43
3.4.4 População inicial	43
3.4.5 Função avaliação	44

3.4.6 Métodos de seleção de reprodução	45
3.4.7 Operadores de seleção de gerações	45
3.4.7.1 Roleta simples ou seleção proporcional	45
3.4.7.2 Roleta ponderada ou seleção por ordenação.....	46
3.4.7.3 Seleção por torneio	46
3.4.7.4 Seleção elitista	46
3.4.8 Operadores genéticos.....	47
3.4.8.1 Operador de <i>Crossover</i>	47
3.4.8.2 Operador de Mutação	48
3.4.9 Critérios de parada.....	49
3.4.10 Parâmetros de configuração	49
3.4.11 Técnicas de adaptação de parâmetros em AG	51
3.5 Projeto e análise de experimentos	53
3.5.1 Planejamento fatorial completo	57
3.6 Considerações finais	57
4. ANÁLISE DOS PARÂMETROS DO ALGORITMO GENÉTICO	58
4.1 Considerações iniciais	58
4.2 Análise dos parâmetros do AG no tempo de convergência e na qualidade de resposta	58
4.2.1 Reconhecimento e definição do problema.....	60
4.2.2 Escolha dos fatores e dos níveis de trabalho	66
4.2.3 Seleção das variáveis de resposta	66
4.2.4 Escolha do projeto experimental	66
4.2.5 Realização dos experimentos.....	67
4.2.6 Análise estatística dos dados	70
4.2.6.1 Análise estatística do primeiro modelo	71
4.2.6.2 Análise estatística do segundo modelo	76
4.2.6.3 Análise estatística do terceiro modelo	81
4.2.7 Conclusões e Recomendações	86
4.3 Considerações finais	87
5. MÉTODO DE OTIMIZAÇÃO PROPOSTO	88
5.1 Considerações iniciais	88

5.2 Adaptações necessárias para os parâmetros do algoritmo de otimização	88
5.2.1 Adaptações para o parâmetro tamanho de população	89
5.2.2 Alteração do parâmetro número de gerações	93
5.2.3 Parâmetros taxa de <i>crossover</i> , taxa de mutação e taxa de elitismo	94
5.3 Estrutura do AGA proposto	96
5.4 Software desenvolvido	98
5.5 Considerações finais	99
6. APLICAÇÃO DO MÉTODO DE OTIMIZAÇÃO PROPOSTO	100
6.1 Considerações iniciais	100
6.2 Software de simulação e otimização utilizados	100
6.2.1 <i>Promodel</i> ® e <i>SimRunner</i> ®	100
6.3 Metodologia para condução do estudo comparativo	102
6.4 Objetos de estudo	103
6.4.1 Primeiro objeto de estudo	104
6.4.2 Segundo objeto de estudo	106
6.4.3 Terceiro objeto de estudo	108
6.4.4 Quarto objeto de estudo	110
6.4.5 Quinto objeto de estudo	112
6.4.6 Sexto objeto de estudo	114
6.4.7 Sétimo objeto de estudo	115
6.4.8 Oitavo objeto de estudo	117
6.5 Otimização dos objetos de estudo	119
6.5.1 Otimização do primeiro objeto de estudo	120
6.5.1.1 Formulação matemática	120
6.5.1.2 Análise dos resultados	120
6.5.2 Otimização do segundo objeto de estudo	121
6.5.2.1 Formulação matemática	121
6.5.2.2 Análise dos resultados	121
6.5.3 Otimização do terceiro objeto de estudo	122
6.5.3.1 Formulação matemática	122
6.5.3.2 Análise dos resultados	122
6.5.4 Otimização do quarto objeto de estudo	123

6.5.4.1	Formulação matemática.....	123
6.5.4.2	Análise dos resultados	124
6.5.5	Otimização do quinto objeto de estudo	124
6.5.5.1	Formulação matemática.....	124
6.5.5.2	Análise dos resultados	125
6.5.6	Otimização do sexto objeto de estudo	125
6.5.6.1	Formulação matemática.....	125
6.5.6.2	Análise dos resultados	126
6.5.7	Otimização do sétimo objeto de estudo	126
6.5.7.1	Formulação matemática.....	126
6.5.7.2	Análise dos resultados	127
6.5.8	Otimização do oitavo objeto de estudo.....	128
6.5.8.1	Formulação matemática.....	128
6.5.8.2	Análise dos resultados	128
6.6	Considerações finais	129
7.	CONCLUSÃO.....	130
7.1	Considerações iniciais	130
7.2	Conclusões gerais	130
7.3	Verificação dos objetivos específicos.....	132
7.4	Sugestões para trabalhos futuros	133
	REFERÊNCIAS BIBLIOGRÁFICAS	134
	ANEXO - Símbolos IDEF-SIM	145
	APÊNDICE - Artigos publicados em congressos e periódicos	146

1. INTRODUÇÃO

1.1 Relevância da pesquisa

A simulação computacional com o passar do tempo tem sido utilizada de forma crescente para auxílio à tomada de decisões (BANKS *et al.*, 2005; BRUZZONE *et al.*, 2007; SARGENT, 2009; LAW, 2007; LAW e KELTON, 2000). Esta já é apontada como uma das técnicas de pesquisa mais utilizadas em vários setores, devido, principalmente, à sua versatilidade, flexibilidade e poder de análise (JAHANGIRIAN *et al.*, 2010; RYAN e HEAVEY, 2006).

No entanto, para Law e McComas (2002), uma das desvantagens da simulação é que esta por si só não é uma técnica de otimização. Fazendo com que um analista tenha que simular várias configurações do sistema real e escolher, dentre todos os resultados alcançados, aquele que apresente o maior desempenho. Esse cenário vem sendo alterado, devido, sobretudo, à disponibilidade de computadores mais rápidos e à melhoria nas técnicas de busca e nas heurísticas de otimização.

Corroborando com esta afirmação, Fu (2002), Fu *et al.* (2000), Banks *et al.* (2005) e Harrel *et al.* (2002), afirmam que o uso da otimização em conjunto com a simulação vem crescendo de forma contínua, devido a pacotes de simulação que possuem rotinas de otimização integradas.

Segundo Hillier e Lieberman (2010), a metodologia para emprego de simulação na tentativa de identificar a melhor configuração para um sistema é conhecida como otimização via simulação. E ressaltam que este campo apresenta um interesse crescente na pesquisa operacional. Já, Ólafsson e Kim (2002), definem otimização baseada em simulação como o processo para encontrar o melhor valor para alguma variável de decisão em um sistema, onde o desempenho é avaliado através dos resultados de um modelo de simulação deste sistema.

Para Azadeh, Tabatabaee e Maghsoudi (2009), a otimização via simulação é uma das tecnologias mais importantes que surgiram nos últimos anos. Estes autores ressaltam que metodologias anteriores à essa integração, exigiam a realização de mudanças em modelos de simulação complexas e difíceis que, em muitos casos, não eram economicamente viáveis para casos reais, especialmente, para problemas com um grande número de variáveis de decisão.

Dentre os vários *softwares* ou módulos de otimização integrados a *softwares* de simulação, destacam-se: o *AutoStat*®, o *OptQuest*®, o *Optimiz*®, o *Optimizer*®, o *WizardGA*® e o *SimRunner*® (FU, 2002; LAW, 2007; LAW e KELTON, 2000; LAW e

MCCOMAS, 2002). Estes *softwares* utilizam diferentes métodos de busca, tais como: Algoritmos Evolucionários (COELLO, LAMONT, VAN VELDHUIZEN, 2007), Algoritmos Genéticos (HOLLAND, 1992), Busca *Scatter* (MARTÍ, LAGUNA e GLOVER, 2006), Busca Tabu (GLOVER, LAGUNA e MARTI, 2005), Redes Neurais (RIPLEY, 1996) e a *Simulated Anneling* (AARTS, KORST e MICHIELS, 2005).

Fu (2002) destaca a utilização de rotinas de otimização baseadas em metaheurísticas com predominância dos Algoritmos Evolutivos, como os Algoritmos Genéticos. Este fato pode ser verificado em alguns pacotes de otimização comerciais como o *SimRunner*® da *ProModel*®, o *WizardGA*® da SIMENS e o *AutoStat*® do *AutoMod*® (LAW e KELTON, 2000).

Os Algoritmos Genéticos (AG) são uma família de técnicas de busca aleatória e foram introduzidos por Holland na década de 1970 (HOLLAND, 1992). Os AG vêm sendo usados com sucesso para encontrar soluções ótimas ou quase ótimas para uma ampla variedade de problemas de otimização (GEN e CHENG, 1997).

Apesar dos avanços ocorridos nos *softwares* de otimização para modelos de simulação, uma crítica comum a estes pacotes comerciais é que, ao manipularem mais de uma variável de entrada, tais *softwares* tornam-se muito lentos (HARREL, GHOSH e BOWDEN, 2004).

Para April *et al.* (2003), Banks (2001), Pinho (2008), Silva (2005) e Torga (2007), a grande limitação para o uso da otimização em simulação é o número de variáveis a serem manipuladas, sendo o desempenho desses *softwares* reduzidos de forma considerável em modelos com um alto número de variáveis.

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

1.2 Objetivo

Os *softwares* de otimização comerciais para modelos de simulação disponíveis hoje no mercado, funcionam como verdadeiras “caixas pretas”. Pouco se sabe sobre sua real estrutura ou sobre seu algoritmo de otimização, tornando praticamente impossível que uma discussão mais ampla sobre esses métodos de otimização possa ser desenvolvida.

Nesse sentido, o trabalho aqui desenvolvido apresenta as etapas que levaram ao desenvolvimento de um algoritmo de otimização, a discussão de seus principais parâmetros de configuração, bem como as adaptações para a estrutura do algoritmo que o tornaram apto à otimização de modelos de simulação.

Em face deste contexto, o objetivo geral deste trabalho é desenvolver um Algoritmo Genético Adaptativo (AGA) para otimização de modelos de simulação a eventos discretos não lineares. O AGA desenvolvido deverá ser capaz de atingir bons resultados em termos de eficiência (rapidez para se alcançar uma solução) e qualidade de resposta, quando comparado à uma ferramenta de otimização comercial.

Como objetivos específicos desta pesquisa, tem-se:

- analisar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade de resposta na otimização de modelos de simulação a eventos discretos não lineares;
- desenvolver a estrutura e propor as adaptações necessárias para o AGA;
- desenvolver uma ferramenta computacional capaz de operacionalizar o AGA proposto;
- comparar o AGA proposto com um *software* comercial de otimização de modelos de simulação.

1.3 Condições de contorno da pesquisa

O método de otimização a ser desenvolvido ao longo dessa dissertação se aplicará a modelos de simulação a eventos discretos, cujas variáveis de decisão (variáveis de entrada) sejam do tipo: discretas, determinísticas e inteiras, além de possuírem uma pequena variação entre seus limites inferior e superior.

A escolha de tais condições se deve ao fato que, segundo Pinho (2008), a maioria dos trabalhos presentes na literatura sobre otimização via simulação utiliza essas condições de contorno.

1.4 Estrutura da dissertação

A presente dissertação encontra-se estruturada em sete capítulos. O primeiro, já apresentado, mostrou o contexto no qual está inserido o trabalho, bem como a relevância do mesmo. Foram apresentados também os objetivos a serem alcançados.

O *Capítulo 2* apresenta o método de pesquisa Modelagem e Simulação, método este que guiou a condução deste trabalho. Ao longo do capítulo, são apresentados os principais conceitos relacionados a este método de pesquisa, as etapas que envolvem a elaboração de um projeto de modelagem e simulação e a classificação deste trabalho segundo Bertrand e Fransoo (2002).

O *Capítulo 3* apresenta a fundamentação teórica que alicerça o trabalho. Buscou-se, neste capítulo, sumarizar o que há de mais recente na literatura sobre simulação a eventos

discretos, otimização via simulação, algoritmos genéticos e planejamento de experimentos (os quatro pilares dessa dissertação). Para tal, uma revisão de literatura foi realizada, contemplando, principalmente, periódicos internacionais e nacionais, artigos de congressos, livros, teses e dissertações.

O **Capítulo 4** faz uma análise da influência dos parâmetros dos AG no tempo de convergência e na qualidade da resposta na otimização de modelos de simulação a eventos discretos. Nesse capítulo, é utilizado o planejamento de experimentos para verificar a significância dos parâmetros do AG.

O **Capítulo 5** discute a proposta de um AGA para otimização de modelos de simulação a eventos discretos não lineares, apresentando as adaptações propostas para o AG e a ferramenta de otimização desenvolvida.

O **Capítulo 6** aplica o AGA desenvolvido na otimização de oito objetos de estudo, e compara os resultados alcançados com o algoritmo desenvolvido com um *software* de otimização comercial, o *SimRunner*®.

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

2. MÉTODO DE PESQUISA

2.1 Considerações iniciais

O presente capítulo apresenta o método de pesquisa quantitativo utilizado nessa dissertação: Modelagem e Simulação. A classificação apresentada para a presente pesquisa foi realizada, segundo a proposta definida por Bertrand e Fransoo (2002). Apresentam-se também as etapas de pesquisa em modelagem e simulação segundo o método de Mitroff *et al.* (1974), a contribuição mais clássica relatada na literatura, que guiará os passos dessa dissertação.

2.2 Metodologia de pesquisa quantitativa: modelagem e simulação

Para Bertrand e Fransoo (2002), a modelagem quantitativa tem sido a base da maioria das pesquisas em Pesquisa Operacional. Inicialmente, a modelagem quantitativa foi orientada para solução de problema reais, ao invés de servir para o desenvolvimento de conhecimento científico. Porém, com o passar do tempo, esse fato se alterou, e a necessidade de desenvolver uma teoria explicativa e preditiva sobre os processos operacionais tornou-se necessária.

Para Martins (2010), existem quatro métodos de pesquisa que são mais apropriados em engenharia de produção para a condução de uma pesquisa quantitativa: a Pesquisa Levantamento (*Survey*), a Modelagem e Simulação, a Experimentação e o Quase-Experimento.

Segundo vários autores (BERTO e NAKANO, 2000; FILIPPINI, 1997; MIGUEL, 2007; NAKANO, 2010), a Modelagem e Simulação é um dos métodos de pesquisa mais utilizados em engenharia de produção, ao lado da Pesquisa Levantamento (*Survey*), do Estudo de Caso e da Pesquisa-Ação.

Chung (2004) define Modelagem e Simulação como o processo de criar e experimentar um sistema físico através de um modelo matemático computadorizado. Para Bertrand e Fransoo (2002), este método deve ser usado quando se deseja prever o efeito de mudanças no sistema ou avaliar seu desempenho ou comportamento, sendo utilizado na resolução de problemas reais.

Na Modelagem e Simulação, o pesquisador manipula as variáveis de entrada e seus níveis, mas não o faz na realidade, utilizando para isso um modelo de pesquisa. Podendo haver ou não a criação de um modelo computacional para manipular as variáveis do modelo (MARTINS, 2010).

Para Hillier e Lieberman (2010), normalmente a simulação é usada quando o sistema real é muito complexo para ser analisado satisfatoriamente por um modelo matemático. Ainda

segundo os autores, se o modelador for capaz de construir um modelo matemático que seja, ao mesmo tempo, uma representação razoável do problema e passível de ser solucionado, essa abordagem deve ser preferida em relação à simulação. Contudo, inúmeros problemas são muito complexos para permitir o uso dessa metodologia, fazendo com que a simulação seja, na maioria das vezes, a única abordagem prática para resolução do problema.

Para Aghaie e Popplewell (1997), a simulação traz mais benefícios em comparação à experimentação direta em sistemas reais. Por meio deste método, o sistema modelado pode ser examinado sob condições controladas e experimentações podem ser realizadas sem riscos ou custos para o sistema real.

2.3 Classificação da pesquisa

Segundo a classificação proposta por Bertrand e Fransoo (2002), pode-se classificar este trabalho como uma pesquisa baseada em modelagem quantitativa. Esta classificação é atribuída às pesquisas onde modelos de relações causais entre variáveis de controle e variáveis de desempenho são desenvolvidas, analisadas ou testadas e se alteram sobre um domínio específico.

Estes autores classificam as metodologias de pesquisa para modelagens quantitativas em duas classes: pesquisas axiomáticas e pesquisas empíricas. Nas pesquisas axiomáticas, a principal preocupação do pesquisador é a obtenção de soluções dentro do modelo definido. A pesquisa axiomática produz conhecimento sobre o comportamento de certas variáveis e também pode produzir conhecimento sobre como manipular algumas variáveis no modelo. Já na pesquisa empírica, a principal preocupação do pesquisador é assegurar que existe uma adequação entre o modelo desenvolvido e as observações e ações no sistema real. Neste tipo de pesquisa, os resultados teóricos são aplicados em processos reais.

Em uma classificação mais ampla, Bertrand e Fransoo (2002) classificam as pesquisas axiomáticas e empíricas em descritivas e normativas.

- **Axiomáticas Normativas:** preocupadas em desenvolver políticas, estratégias e ações para melhorar os resultados disponíveis na literatura existente, para encontrar uma solução ótima para um problema recém-definido ou para comparar as diferentes estratégias para lidar com um problema específico;
- **Axiomáticas Descritivas:** visa compreender o processo que foi modelado; estando primariamente, interessada em analisar o modelo, que conduz ao entendimento e explicação das características do mesmo;

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

Para o caso específico dessa dissertação, como o objetivo se concentra no desenvolvimento de um método de otimização de modelos de simulação a eventos discretos, pode-se afirmar que a metodologia de pesquisa utilizada é a Empírica Normativa. Esta metodologia foi escolhida uma vez que é empregada quando se busca melhorar uma situação atual, como incrementar o desempenho de um método de otimização.

2.4 Etapas de uma pesquisa em modelagem e simulação

O método de pesquisa abordado nessa seção é o método mais antigo já proposto para utilização da simulação como método científico: o método proposto por Mitroff *et al.* (1974), utilizado como base para outros métodos propostos por vários autores.

Para Costa (2010), analisando-se diferentes trabalhos publicados na literatura sobre o assunto (BANKS, 1998; BANKS *et al.*, 2005; CHWIF e MEDINA, 2010; LAW, 2009; MONTEVECHI *et al.*, 2007; PINHO, 2008; SÁNCHEZ, 2007; SARGENT, 2009), verifica-se que muitos dos métodos propostos se aproximam dos conceitos e da estrutura preconizada no trabalho de Mitroff *et al.* (1974). Este modelo é apresentado na **Figura 2.1**.

O modelo proposto é baseado em quatro etapas (MITROFF *et al.*, 1974):

- Conceitualização;
- Modelagem;
- Solução pelo modelo;
- Implementação.

Segundo Bertrand e Fransoo (2002), na primeira etapa, o pesquisador elabora o modelo conceitual do problema que está sob análise, toma decisões sobre as variáveis que precisam ser adicionadas ao modelo e define o alcance do problema e do modelo. Na fase de modelagem, o pesquisador constrói o modelo científico, definindo as relações causais entre as variáveis. Na fase seguinte, solução pelo modelo, a matemática desempenha um papel fundamental e o modelo científico é resolvido utilizando-se algum método matemático. Por

fim, na última etapa, Implementação, a solução encontrada é aplicada ao sistema real, após o qual um novo ciclo pode recomeçar.

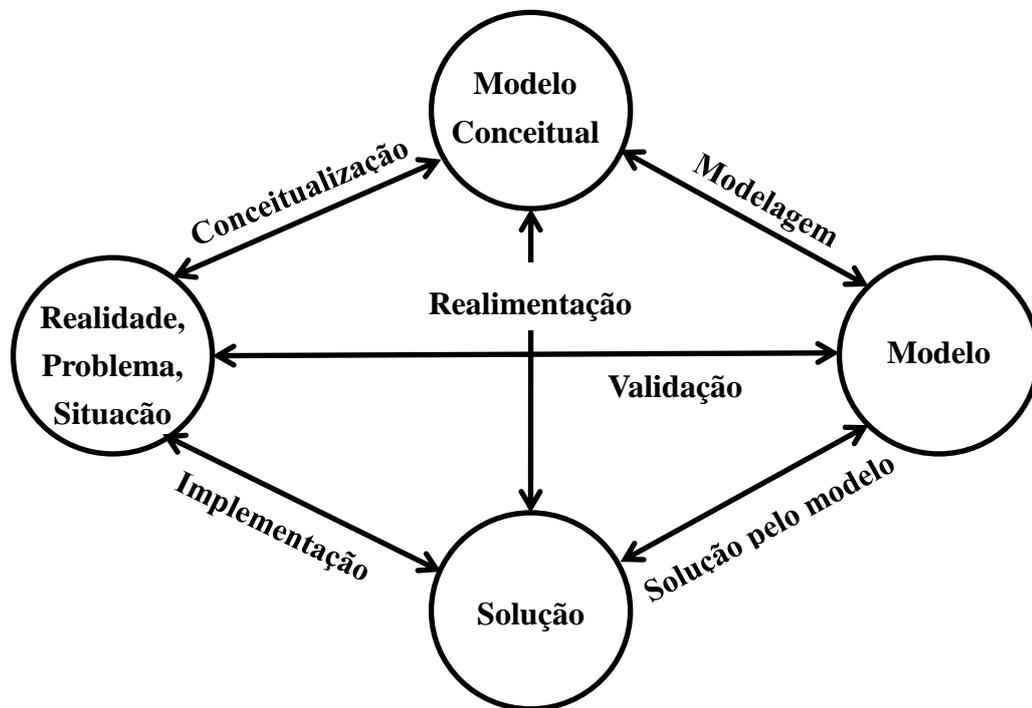


Figura 2.1 - Estrutura de pesquisa em simulação

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

Um ciclo de pesquisa pode começar e terminar em qualquer uma das fases do método, desde que o pesquisador esteja consciente das partes específicas do processo de solução que ele conduz e, conseqüentemente, dos resultados que ele pode trazer (MITROFF *et al.*, 1974). Ainda segundo os autores, os pesquisadores podem seguir um atalho por meio da realimentação no ciclo proposto, encurtando, assim, o caminho e diminuindo as etapas necessárias à condução do método, mas que pode levar a erros de conceitualização ou na obtenção da solução.

Para Bertrand e Fransoo (2002), nas pesquisas axiomáticas descritivas, os pesquisadores elaboram o modelo conceitual e o modelo científico, porém não passam pela fase de resolução de problemas. Nas axiomáticas normativas, os pesquisadores desenvolvem a modelagem e o modelo de solução e os resultados do modelo são repassados diretamente ao modelo conceitual. Nas empíricas descritivas, os pesquisadores desenvolvem a conceitualização, modelagem e a validação, preocupando-se demais, neste tipo de pesquisa, com a validação. Finalmente, nas pesquisas empíricas normativas, todo o ciclo preconizado por Mitroff *et al.* (1974) é desenvolvido, sendo a mais completa das pesquisas.

2.5 Etapas do método a serem desenvolvidas

A primeira etapa do método de pesquisa, conceitualização, corresponderá, nesse trabalho, à análise do comportamento dos parâmetros dos algoritmos genéticos quanto ao tempo de convergência e à qualidade da resposta. Nesta etapa, duas estratégias serão utilizadas: o levantamento bibliográfico e o delineamento de experimentos. O primeiro buscará na literatura aspectos relacionadas aos valores mais comuns utilizados para a definição dos parâmetros do AG (*Capítulo 3*). Já o planejamento de experimentos, relacionará os principais parâmetros do algoritmo e definirá quais são os mais significativos para se alcançar soluções de elevada qualidade e quais são aqueles que mais influenciam o tempo de convergência (*Capítulo 4*).

Na etapa de modelagem, serão definidas as adaptações necessárias à estrutura do AG em relação aos parâmetros, visando a melhoria da qualidade de resposta e do tempo de convergência do algoritmo (*Capítulo 5*). Ao final dessa etapa, o método estará apto para a otimização de modelos de simulação a eventos discretos não lineares.

Na etapa de solução pelo modelo (*Capítulo 6*), o método de otimização será utilizado na otimização de modelos de simulação (oito objetos de estudo) e seus resultados serão confrontados com um *software* de otimização comercial.

Por fim, na última etapa, implementação (*Capítulo 7*), os resultados alcançados com a utilização do método são implementados, ou seja, o método de otimização desenvolvido passa a ser utilizado.

2.6 Considerações finais

O presente capítulo apresentou o método de pesquisa quantitativo utilizado nessa dissertação. Pode-se verificar que, devido às características apresentadas pela modelagem e simulação, este método de pesquisa é o indicado para esse estudo. Apresentou-se, também, a classificação da pesquisa segundo Bertrand e Fransoo (2002). De acordo com os autores, pode-se classificar a presente pesquisa como Empírica Normativa. Por fim, apresentou-se a sequência de passos para a condução de um estudo de simulação segundo Mitroff *et al.* (1974).

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Considerações iniciais

Este capítulo apresenta o referencial teórico que suporta esta dissertação. Tentou-se aqui sumarizar o estado da arte em simulação, otimização via simulação, algoritmos genéticos e delineamento de experimentos. Para tal, uma vasta revisão de literatura foi realizada abrangendo principalmente, periódicos nacionais e internacionais, artigos de congressos, livros, teses e dissertações.

Inicialmente, são apresentados os principais conceitos relacionados à simulação a eventos discretos, seguidos de sua evolução ao longo do tempo e suas principais vantagens e desvantagens. No que diz respeito à otimização via simulação, foi explorado principalmente seu princípio de funcionamento, a metodologia para otimização via simulação, os principais *softwares* de otimização existentes e casos presentes na literatura que exemplificam sua utilização. Com relação aos algoritmos genéticos, buscou-se definir os principais conceitos e componentes dessa importante metaheurísticas. O capítulo é encerrado com os principais conceitos referentes ao delineamento de experimentos.

3.2 Simulação a eventos discretos

3.2.1 Histórico da simulação

A história da simulação pode ser escrita a partir de várias perspectivas, como a utilização da simulação (análise, treinamento, pesquisa), os tipos de simulação (eventos discretos, contínua, combinada), as linguagens de programação ou os ambientes de simulação (GPSS, SIMSCRIPT, SIMULA, SLAM, Arena, AutoMOD, Símio) e os domínios de aplicativo ou as comunidades de interesse (comunicações, fabricação, transporte, militar) (GOLDSMAN, NANCE e WILSON, 2009).

A necessidade de modelagem e simulação, impulsionada pelas exigências de um mundo em guerra, motivou o desenvolvimento da computação na década de 40. Centros de pesquisas militares associados a universidades foram criados para este fim nos Estados Unidos (AKERA, 2002). A partir daí, o avanço da simulação sempre esteve associado ao avanço da computação, e nos mais de 50 anos que se seguiram desde o desenvolvimento da computação, simulação e computação sempre estiveram interligadas, atraindo o interesse de inúmeros pesquisadores (JENKINS e RICE, 2009).

Tomando por base o desenvolvimento da computação, a criação dos *softwares* de simulação e as linguagens de programação, Nance (1995) divide a história da simulação em cinco grandes períodos:

- **O Período de Pesquisa (1955-1960):** nesse período, a simulação foi desenvolvida com linguagens de programação gerais, como, por exemplo o Fortran e o Pascal (GAVIRA, 2003). Muitas pesquisas foram conduzidas buscando-se rotinas de programação que facilitassem a simulação. O *General Simulation Program* (GSP), descrito em 1960, é creditado como o primeiro simulador (JENKINS e RICE, 2009).
- **O Advento (1961-1965):** foram desenvolvidas nesse período as primeiras linguagens de programação voltadas à simulação (GPSS, SIMULA I, SIMSCRIPT, CSL, GASP, OPS, e Dínamo). Linguagens estas que continham rotinas específicas e símbolos de diagramas de fluxo que facilitavam a construção de modelos de simulação a eventos discretos (PIDD, 2004).
- **O Período de Formação (1966-1970):** durante este período, conceitos foram revisados e refinados, promovendo uma maior consistência na representação de cada linguagem de programação. Novas versões de várias linguagens de programação surgiram ou foram reformuladas (GPSS, SIMULA, SIMSCRIPT, GASP, OPS, e CSL) (BANKS *et al.*, 2005).
- **O Período de Expansão (1971-1978):** nesse período, desenvolveu-se a simulação tal como é utilizada hoje, devido, sobretudo, a maior eficiência e redução dos custos dos computadores. Nessa época a simulação passou a ser descoberta pelas indústrias, principalmente, pelas de grande porte (KELTON, SADOWSKI e STURROCK, 2007). Este período viu grandes ampliações das capacidades e possibilidades de linguagens de programação, como o GPSS, SIMSCRIPT e GASP (JENKINS e RICE, 2009).
- **O Período de consolidação e renovação (1979-1986):** nesse período, surgiram as linguagens de simulação mais evoluídas, como a SLAM II e a SIMAN (BANKS *et al.*, 2005).

Banks *et al.* (2009) acrescentam mais dois períodos à história da simulação proposto por Nance (1995). O sexto período proposto estende-se de 1987 a 2008, sendo denominado de Período de Integração de Ambientes. Neste período, surgiram os *softwares* de simulação com interfaces gráficas com o usuário, animação e outras ferramentas de visualização cuja disseminação foi facilitada com a introdução dos computadores pessoais. Nesse período, segundo Kelton, Sadowski e Sturrock (2007), a simulação adquiriu maturidade, visto que

várias empresas de pequeno porte passaram a utilizar essa ferramenta já no início de seus projetos.

O último período foi denominado de o Futuro (2009 - 2011). Nesse período, a computação gráfica, a realidade virtual e os ambientes virtuais são apontados como as novas perspectivas para a simulação. Somados a isso, Nance e Sargent (2002) apontam que modelagens em tempo real e via *web* podem expandir o uso e ampliar o conhecimento sobre a simulação.

3.2.2 Introdução à simulação

Inúmeras são as definições de simulação encontradas na literatura. Esta sessão parte das definições apresentadas por três dos maiores autores na área de simulação a eventos discretos.

Segundo Banks (1998), a simulação é a imitação de um processo ou sistema do mundo real ao longo do tempo. Ela envolve a criação de uma história artificial e a observação desta história para se fazer inferência sobre as características da operação do sistema do qual representa.

Harrel, Ghosh e Bowden (2004) definem simulação como sendo a imitação de um sistema dinâmico usando um modelo computacional para avaliar e melhorar o desempenho deste sistema.

Já para Law e Kelton (2000), a simulação a eventos discretos está preocupada com a modelagem de um sistema através de uma representação na qual as variáveis mudam de estado instantaneamente em pontos distintos no tempo, a partir da ocorrência de eventos.

No passado, a simulação era considerada uma técnica de último recurso, usada somente quando todas as outras técnicas disponíveis falhassem (LAW e KELTON, 2000). Porém, com o passar do tempo e o avanço da computação, ela vem se tornando uma das técnicas mais utilizadas para apoio à tomada de decisões. Ryan e Heavey (2006) apontam a simulação como uma das técnicas de pesquisa mais utilizada devido, principalmente, à sua versatilidade, flexibilidade e poder de análise.

Autores como Banks *et al.* (2005) e O’kane, Spenceley e Taylor (2000) afirmam que a simulação tem se tornado uma das técnicas mais populares para se analisar problemas complexos. Atualmente, com a evolução dos estudos na área, a simulação a eventos discretos vem sendo cada vez mais utilizada e os benefícios com ela obtidos têm gerado impactos nos mais diferentes sistemas (MIRANDA *et al.*, 2010).

Segundo Hillier e Lieberman (2010), a simulação é uma técnica extremamente versátil, podendo ser utilizada para investigar praticamente qualquer tipo de sistema estocástico. Essa

versatilidade fez da simulação a técnica de pesquisa operacional mais utilizada para estudos que lidam com sistemas estocásticos.

Ainda segundo estes autores, devido à enorme diversidade de sua aplicação, é praticamente impossível enumerar todas as áreas nas quais a simulação vem sendo utilizada.

Tomando-se como referência os anais da *Winter Simulation Conference* (WSC), Banks *et al.* (2005) e Hillier e Lieberman (2010) apresentam algumas categorias particularmente importantes de aplicações da simulação.

Entre as principais categorias, destacam-se (BANKS *et al.*, 2005; HILLIER e LIEBERMAN, 2010): projeto e operações em manufatura, gerenciamento de projetos e construção civil, logística, *supply chain* e redes de distribuição, administração do sistema de estoques, modelagem de transporte e tráfego, análise de riscos, aplicações médicas, aplicações militares e aplicações nas mais diversas áreas de serviços, tais como: serviços governamentais, bancos, hotelaria, restaurantes, instituições educacionais, entre outros.

3.2.3 Vantagens e desvantagens da simulação

Segundo Banks *et al.* (2005), inúmeras são as vantagens proporcionadas pela simulação, embora esta também apresente algumas desvantagens. Pinho (2008) e Torga (2007) afirmam que, se comparada a modelos matemáticos, as vantagens proporcionadas pela simulação a eventos discretos são enormes. Principalmente, no que diz respeito à sua conceituação de fácil compreensão e à possibilidade de comparação entre o sistema real e o modelo virtual, trazendo maiores contribuições para o objeto em estudo.

Para Law e Kelton (2000), possivelmente uma das maiores vantagens do uso da simulação seja a de prover aos tomadores de decisão uma visão ampla de todo o sistema. Ainda segundo Law (2009), a simulação é uma alternativa à experimentação direta no sistema real, evitando, assim, os custos devidos à experimentação real e à interrupção do fluxo de atividades do sistema real.

Chwif e Medina (2010) ressaltam que devido à grande complexidade dos modelos de manufatura, devido à sua natureza dinâmica e aleatória, um modelo de simulação permite reproduzir em um computador o mesmo comportamento que o sistema teria se submetido às mesmas condições de contorno.

Além de todas as vantagens citadas, Banks *et al.* (2005) destacam:

- Novos projetos de equipamentos, definições de *layouts* e sistemas de transportes podem ser testados via simulação sem consumo de recursos ou aquisição de equipamentos;

- Fornecer uma maior compreensão sobre interações entre variáveis e a importância de seus efeitos no sistema;
- Análises de gargalo podem ser realizadas para se descobrir onde estoque em processo, informações e materiais estão em excesso;
- O estudo de simulação pode auxiliar no entendimento de como o sistema opera como um todo ao invés de como operam suas partes;
- Questões “*What if*” podem ser respondidas, o que é particularmente útil no *design* de novos sistemas.

Mesmo com tamanhas vantagens, alguns autores destacam algumas desvantagens de seu uso. Law e Kelton (2000) destacam:

- Os modelos de simulação são, em sua maioria, caros e consomem tempo para serem desenvolvidos. Adicionalmente, a construção de um modelo de simulação requer, por parte do modelador, treinamento especial em um *software* ou linguagem de programação;
- Os resultados provenientes do modelo de simulação podem ser difíceis de serem interpretados pelos tomadores de decisões;
- O modelo precisa ser validado, e caso não represente adequadamente o sistema real, as informações que forem provenientes deste não possuirão utilidade;
- Cada rodada de um modelo de simulação produz somente estimativas da verdadeira característica do modelo para um limitado conjunto de parâmetros de entrada. Assim, serão necessárias várias rodadas independentes para cada conjunto de parâmetros a serem estudados.

Ainda segundo Carson (2004), o tempo disponível para a condução de um projeto de simulação pode não ser suficiente para a elaboração de um estudo seguro, levando os tomadores de decisão a conclusões erradas baseadas em evidências insuficientes.

3.2.4 Metodologias para estudos de simulação

Ao contrário das quatro etapas propostas por Mitroff *et al.* (1974), apresentadas no **Capítulo 2**, o modelo proposto por Chwif e Medina (2010) divide seu método em três grandes fases: concepção, implementação e análise dos resultados. A esquematização do método proposto por esses autores pode ser visualizada na **Figura 3.1**.

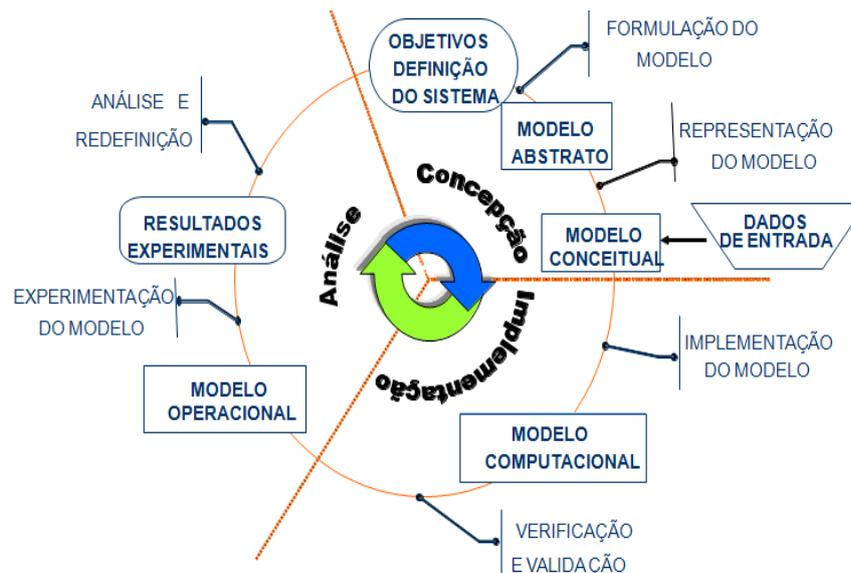


Figura 3.1 - Estrutura de pesquisa em simulação
Fonte: Chwif e Medina (2010)

Apesar da importância histórica do método proposto por Mitroff *et al.* (1974), os modelos de simulação utilizados nesse trabalho foram construídos segundo o método proposto por Chwif e Medina (2010), apresentado sob a ótica de Montevechi *et al.* (2010). A utilização desse método se deve, principalmente, à sua adequação ao trabalho aqui desenvolvido e à sua contemporaneidade, visto ter sido apresentado inicialmente em 2007 e revisado posteriormente em 2010, tendo suportado diversos trabalhos em simulação do grupo de pesquisa do pesquisador.

Segundo Chwif e Medina (2010), a melhor maneira de se imaginar o projeto de simulação é em forma de espiral, em que as etapas do método se repetem em sequência, até que, entre uma interação e outra, não exista mais diferença nos resultados obtidos.

Para Costa (2010), na visão proposta por Montevechi *et al.* (2010), os autores elaboraram um fluxograma, com base na estrutura proposta por Chwif e Medina (2010), para representar a lógica de um projeto de simulação. A **Figura 3.2** apresenta o fluxograma proposto.

Para Chwif e Medina (2010), na fase de concepção os analistas devem compreender bem o sistema que desejam simular, bem como definir com clareza quais os objetivos deverão ser alcançados com o estudo.

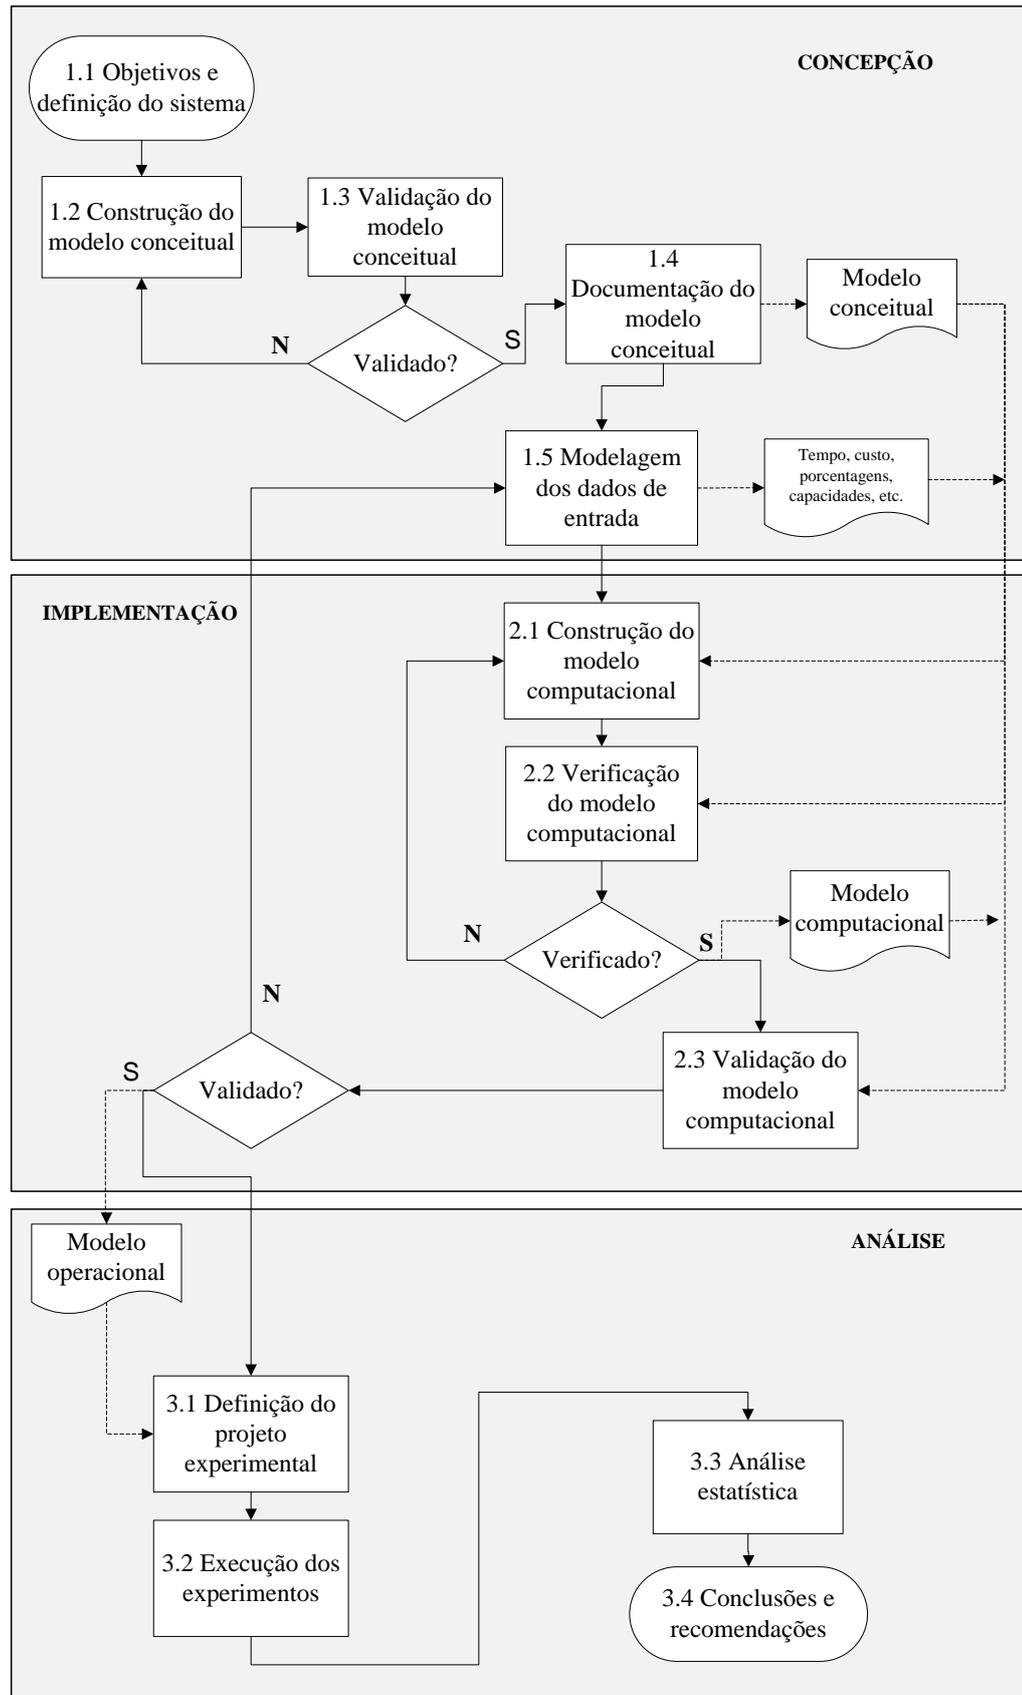


Figura 3.2 - Sequência de passos para um projeto de simulação
 Fonte: Montevechi *et al.* (2010)

No passo que se segue, Banks *et al.* (2005) afirmam que a construção do modelo conceitual é mais uma arte do que uma ciência. Robinson (2008) define modelo conceitual como uma descrição independente do modelo de simulação que será desenvolvido, descrevendo os objetivos, entradas, saídas, conteúdo, pressupostos e simplificações do sistema real. Para Perera e Liyanage (2000), o modelo conceitual pode incrementar a qualidade do modelo computacional bem como reduzir o tempo necessário na sua construção.

Ao final da elaboração do modelo conceitual, o mesmo necessita ser validado. Sargent (2009) destaca a utilização da técnica de validação face a face. Técnica segundo a qual os especialistas no sistema compreendem o modelo como uma representação correta da realidade.

Como última etapa da fase de concepção, tem-se a modelagem dos dados de entrada. Chwif e Medina (2010) destacam a importância dessa etapa, uma vez que os dados coletados no sistema real irão alimentar o modelo computacional. Para Costa (2010), os dados de entrada devem ser coletados e ajustados a uma distribuição de probabilidade antes de serem implementados no modelo computacional.

A fase de implementação se inicia com a construção do modelo computacional. Para Chwif e Medina (2010) e Montevechi *et al.* (2008b), o modelo computacional é obtido através da conversão do modelo conceitual, utilizando-se para tal, de alguma linguagem de simulação ou um simulador comercial.

Uma vez construído o modelo computacional, esse deve passar por duas etapas de extrema importância: a verificação e a validação. Segundo Sargent (2009), a verificação de um modelo é definida ao assegurar-se que o modelo computacional e sua implementação estão corretos. Para Montevechi *et al.* (2008b), a verificação também consiste em eliminar os erros do modelo computacional.

Já, a validação do modelo computacional é definida como a determinação de que o comportamento do modelo simulado detém precisão suficiente para representar o modelo real para a aplicabilidade a qual se destina. Desta forma, se o modelo não é uma aproximação bastante fiel do sistema real, todas as conclusões derivadas deste estarão susceptíveis a erros e poderão resultar em decisões incorretas (SARGENT, 2009). Para Banks *et al.* (2005), a etapa de validação deve ser executada até que o modelo possua a precisão desejada pelos analistas de simulação.

Segundo Chwif e Medina (2010), na última fase do método, Análise, o modelo computacional está preparado para a execução de experimentos, dando origem ao modelo experimental ou modelo operacional.

Nesta fase ocorrem a definição do projeto experimental, a realização de experimentos e a análise dos dados obtidos. Para Banks *et al.* (2005), a realização de réplicas no modelo e a subsequente análise dos dados provenientes da simulação são usados para estimar as medidas de desempenho do sistema que está sendo estudado.

De posse dos resultados do modelo, conclusões e recomendações para o sistema real podem ser elaboradas e aplicadas. Caso necessário, o modelo pode ser alterado e o ciclo reiniciado (CHWIF e MEDINA, 2010).

3.3 Otimização via simulação

3.3.1 Simulação combinada à otimização

Harrel, Ghosh e Bowden (2004) definem otimização via simulação como o processo de testar diferentes combinações de valores para variáveis que podem ser controladas, objetivando encontrar a combinação de valores que forneça o resultado mais desejável para os resultados de saída em um modelo de simulação.

Um modelo de simulação geralmente inclui n variáveis de entrada (x_1, x_2, \dots, x_n) e m variáveis de saída ($f_1(x), f_2(x), \dots, f_m(x)$) ou (y_1, y_2, \dots, y_m) (**Figura 3.3**). A otimização desse modelo de simulação implica encontrar a configuração ótima das variáveis de entrada, ou seja, os valores de x_1, x_2, \dots, x_n que otimizem a(s) variável(eis) de saída(s) (CARSON e MARIA, 1997).

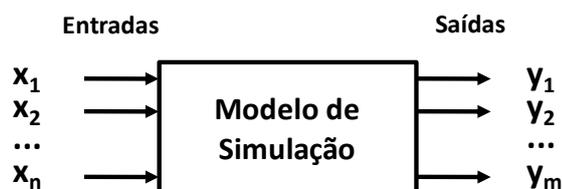


Figura 3.3 - Modelo de simulação
Fonte: Adaptado de Carson e Maria (1997)

Um problema tradicional de otimização via simulação (minimização com um único objetivo) pode ser representado como visto na Eq. 1 (FU, 1994):

$$\begin{aligned} \min f \theta & \\ \text{s. t } \theta & \in \Theta \end{aligned} \quad (1)$$

Onde $f \theta = E[\psi \theta, \omega]$ é o valor esperado da performance do sistema estimado por $f(\theta)$, que é obtido a partir de amostras do modelo de simulação $\psi_j \theta, \omega$ observados segundo

parâmetros de entrada discretos ou contínuos restringidos por θ dentro de um conjunto de viabilidade $\theta \subset \mathbb{R}^d$.

Para Rosen, Harmonosky e Traband (2007), o método de otimização aplicável para a resolução do problema apresentado na Eq. (1) depende se o sistema simulado consiste de variáveis contínuas ou discretas.

Há na literatura muitos métodos disponíveis para resolução de problemas como o apresentado na Eq. (1), mas, infelizmente, alguns desses métodos não garantem que a solução encontrada seja uma solução ótima (BETTONVIL, CASTILLO e KLEIJNEN, 2009)

Para Harrel *et al.*(2002), o uso da otimização visa responder perguntas do tipo: Quais os ajustes ótimos das variáveis de entrada (x) que maximizam (ou minimizam) uma saída no modelo de simulação? Nesse sentido, o objetivo é encontrar um valor ótimo que maximize ou minimize um determinado indicador de desempenho.

Stuckman, Evans e Mollaghasemi (1991) classificam em três grupos os analistas que utilizam a simulação na tentativa de otimizar um sistema real. O primeiro grupo recorrerá à tentativa e erro, alterando desordenadamente as variáveis de entrada na esperança de encontrar uma solução que otimize o sistema. O segundo grupo promoverá uma alteração sistemática das variáveis de entrada, como em uma análise de sensibilidade (CHWIF e MEDINA, 2010) e observará os resultados alcançados. Já, o terceiro grupo utilizará um procedimento de otimização via simulação, aplicando uma técnica de otimização para o problema.

Para Chwif e Medina (2010), inúmeras são as vantagens desta última abordagem. Para estes autores, a principal vantagem se encontra em se ter um procedimento sistemático para a otimização das variáveis, evitando o método de tentativa e erro. Adicionalmente, com a utilização integrada da otimização, a simulação se torna uma geradora de soluções e não só uma avaliadora de soluções.

Kleijnen, Beers e Nieuwenhuyse (2010) reconhecem os problemas de otimização via simulação como problemas de difícil solução. E apresentam como desvantagens de sua utilização o fato das saídas dos modelos de simulação serem provenientes de funções implícitas e expostas a ruídos. Os autores ainda afirmam que, dependendo do número de entradas no modelo de simulação, este pode se tornar um processo caro devido às exigências computacionais e ao tempo envolvido.

3.3.2 Princípios de funcionamento

O princípio de funcionamento da otimização computacional está baseado, segundo Prottil (2001), em um sistema que pode ser representado por uma relação entrada-saída, onde X é a variável de entrada, Y é a variável de saída e M é uma representação que relaciona as informações de entrada e saída.

A partir deste conceito de sistema, é possível fazer uma comparação entre modelagem, simulação e otimização. A modelagem busca as inter-relações existentes entre os dados de entrada e os dados de saída de um determinado sistema, ou seja, o que se procura é 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, alterando a composição das entradas (PINHO, 2008; PINHO e MORAIS, 2010; PROTIL, 2001; TORGA, 2007). Tal relação pode ser verificada na *Figura 3.4*.

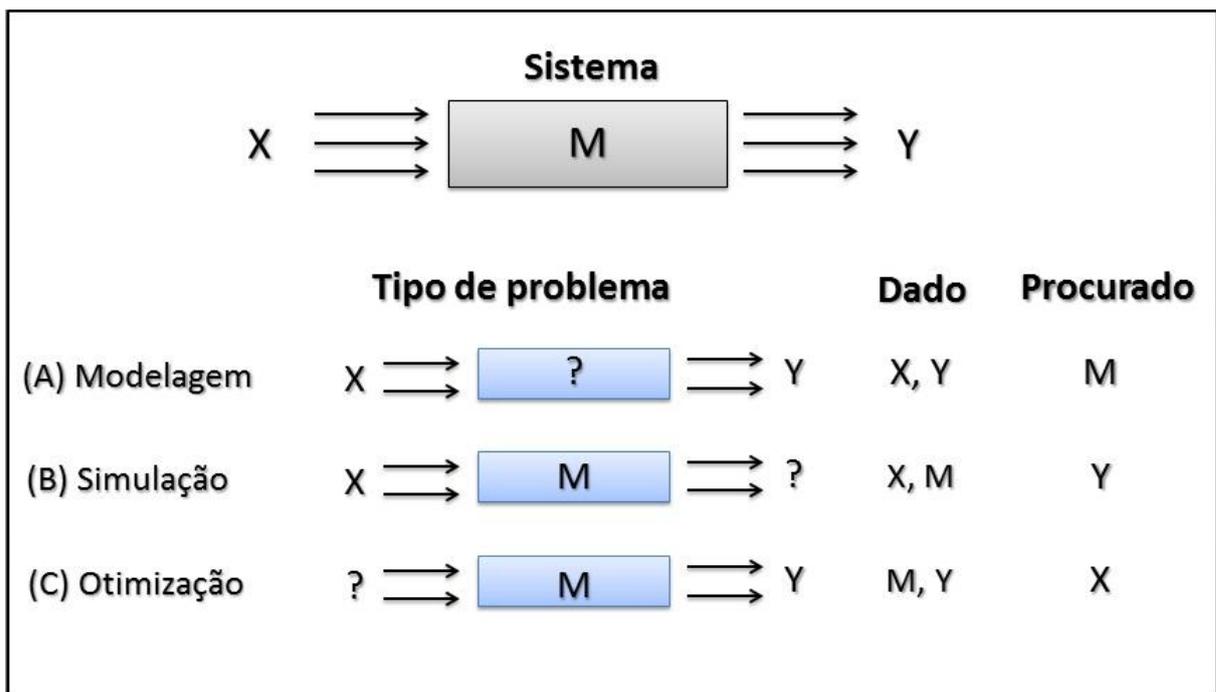


Figura 3.4 - Representação modelagem, simulação e otimização
 Fonte: Adaptado de PROTIL (2001)

Law (2007) apresenta com mais detalhes o princípio de funcionamento de um pacote de otimização integrado a um *software* de simulação.

Segundo o autor, o módulo de otimização do *software* instrui o modelo de simulação a gerar as configurações iniciais do sistema (combinações iniciais das variáveis de decisão). O modelo de simulação avalia e calcula a função objetivo para cada configuração analisada. Com base nos resultados, o modelo de otimização seleciona novas combinações para as variáveis de decisão a serem simuladas, até que as melhorias tornam-se não significativas.

Ou seja, os resultados das simulações são repassados para o módulo de otimização, que então usa seu algoritmo de busca para gerar configurações adicionais. Todo o processo é repetido, enquanto todas as restrições do sistema são satisfeitas, até que o ponto de parada do módulo de otimização seja atingido. Esse relacionamento pode ser verificado na **Figura 3.5**.

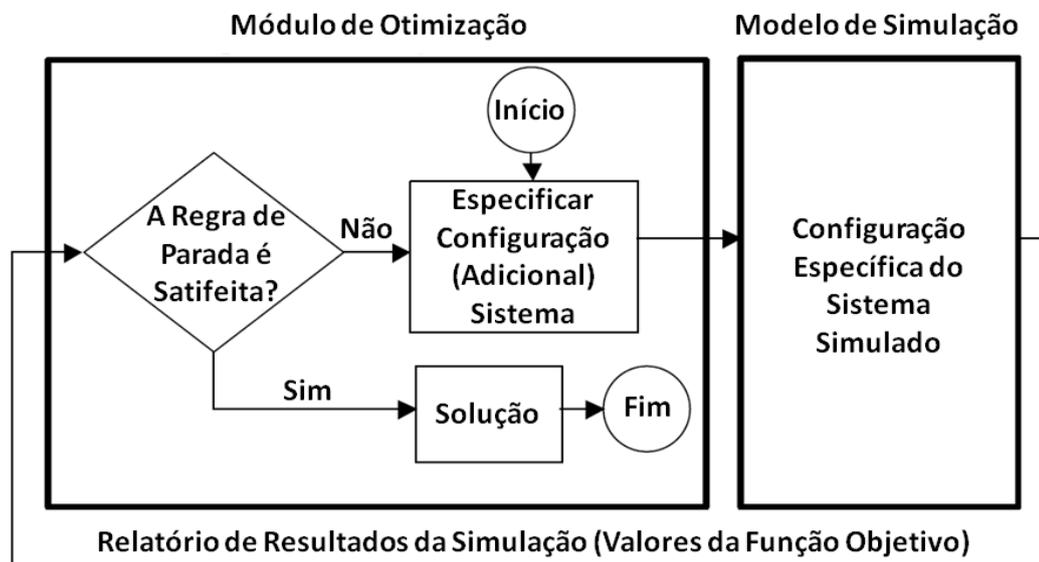


Figura 3.5 - Princípio de funcionamento de um módulo de otimização integrado a um *software* de simulação
Fonte: Adaptado de Law (2007)

No entanto, não existem garantias que os resultados encontrados sejam os ideais. Os resultados dependem do método de otimização utilizado e como as opções, parâmetros e tolerâncias foram especificados. Um bom modelo de otimização pode atingir de forma eficiente uma configuração próxima à ideal. Na prática, a diferença entre o ótimo global e a solução apresentada pelo *software* é normalmente insignificante considerando as incertezas nas entradas e nas relações funcionais (WANG e SCHONFELD, 2006).

3.3.3 Softwares de otimização via simulação

Para Fu (2002), uma das interfaces mais bem-sucedidas entre a pesquisa operacional e a computação tem sido o desenvolvimento de *softwares* de simulação a eventos discretos. Várias técnicas de otimização tem sido integradas a simulação, principalmente por meio de *softwares* de simulação comerciais. Hoje, a inclusão de rotinas de otimização tornou-se quase onipresente na maioria dos pacotes de simulação a eventos discretos.

No entanto, até a pouco tempo a comunidade de simulação foi relutante em usar ferramentas de otimização. April *et al.* (2005) apontam que esta resistência começou a diminuir com o início das pesquisas na área de metaheurísticas, juntamente com a melhoria dos métodos de análise estatística.

Para Fu *et al.* (2000), a integração entre *softwares* de simulação e rotinas de otimização se deu recentemente, visto que a primeira vez que tal tema surgiu em dois dos mais renomados livros de simulação, Law e Kelton (2000) e Banks *et al.* (2000), foi no início do século XXI.

Para Silva, Galhardo e Montevechi (2004), a otimização via simulação vem sendo difundida, principalmente, pelo surgimento de pacotes de simulação integrados a rotinas de otimização.

O objetivo da inclusão destas rotinas em *softwares* de simulação é o de buscar definições melhoradas para os parâmetros do sistema em relação ao seu desempenho. No entanto, ao contrário dos pacotes de programação matemáticos, o usuário não tem como saber se um ponto de ótimo foi realmente atingido (FU *et al.*, 2000).

Para Harrel *et al.* (2002), o progresso no desenvolvimento de ferramentas computacionais para análise de simulação foi especialmente lento na área de otimização da simulação. O uso de técnicas tradicionais para otimização fez com que apenas pessoas com alto grau de especialização compreendessem os benefícios trazidos. Isso vem sendo resolvido com a inserção de novas técnicas de otimização, como os Algoritmos Evolutivos (*Evolutionary Algorithms - Eas*).

Law (2007) destaca as seguintes características como desejáveis para um pacote de otimização integrado a um *software* de simulação:

- Quanto mais rápido for o *software*, menos tempo será gasto para se encontrar uma solução; no entanto a qualidade da resposta obtida pode ser prejudicada;
- A quantidade de informações oferecidas pelo *software* aos usuários é de extrema importância, tanto durante quanto após a otimização;
- É importante que restrições lineares e não lineares, bem como variáveis de decisões, possam fazer parte da formulação do problema;
- Os pacotes de otimização devem incluir regras de paradas;
- Um intervalo de confiança para cada solução deve ser fornecido pelo *software*;
- Os *softwares* de simulação que possuem módulos de otimização integrados deveriam retornar às suas configurações originais depois de utilizados;
- Certos problemas de otimização necessitam que réplicas sejam realizadas; sendo assim, é desejável que os *softwares* permitam a execução das réplicas.

A **Tabela 3.1** agrupa os principais *softwares* de otimização existentes no mercado e citados em vários trabalhos presentes na literatura, assim como os pacotes de simulação aos

quais estão integrados. Apresentam-se, também, as técnicas de otimização utilizadas por esses pacotes.

<i>Software de Otimização</i>	<i>Pacote de simulação</i>	<i>Técnica de otimização</i>
<i>AutoStat</i> ®	<i>AutoMod</i> ®, <i>AutoSched</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos
<i>OptQuest</i> ®	<i>Arena</i> ®	Busca <i>Scatter</i> , Tabu e Redes Neurais
<i>Optimiz</i> ®	<i>Simul8</i> ®	Redes Neurais
<i>Optimizer</i> ®	<i>Witness</i> ®	<i>Simulated Annealing</i> e BuscaTabu
<i>WizardGA</i> ®	<i>Tecnomatix Plant Simulation</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos
<i>SimRunner</i> ®	<i>ProModel</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos

Tabela 3.1 - *Softwares* de otimização

Fonte: Adaptado de Fu (2002), Law (2007), Law e Kelton (2000), Law e McComas (2002)

Como pode se ver pela **Tabela 3.1**, os *softwares* de otimização utilizam diferentes métodos de busca, tais como: Algoritmos Evolucionários (COELLO, LAMONT, VAN VELDHUIZEN, 2007), Algoritmos Genéticos (HOLLAND, 1992), Busca *Scatter* (MARTÍ, LAGUNA e GLOVER, 2006), Busca Tabu (GLOVER, LAGUNA e MARTÍ, 2005), Redes Neurais (RIPLEY, 1996) e a *Simulated Annealing* (AARTS, KORST e MICHIELS, 2005).

3.3.4 Metodologia para otimização via simulação

A grande maioria das metodologias de otimização via simulação partem de um modelo computacional já existente, verificado e validado. Geralmente, em uma primeira etapa são definidas as variáveis de decisão, seguida pela determinação da função objetivo, cujo resultado será avaliado pelos algoritmos de otimização na busca de um valor ótimo em função de seu objetivo: maximização ou minimização. O passo seguinte é a definição das restrições do problema, seguido pela configuração de parâmetros, tais como: número de replicações, precisão e critério de parada (PINHO, 2008; SILVA, 2005; TORGA, 2007).

Harrel, Ghosh e Bowden (2004) propuseram uma metodologia para o uso do *SimRunner*®, um *software* de otimização que utiliza técnicas de otimização baseadas nos algoritmos genéticos. Partindo-se de um modelo computacional já construído e validado, algumas etapas são necessárias para que a otimização seja bem sucedida. Os autores definiram cinco passos:

- **1º. Passo:** Definir as variáveis de decisão que irão afetar as saídas do modelo de simulação e que serão testadas pelo algoritmo de otimização. Estas variáveis terão seus valores alterados a cada rodada de simulação;
- **2º. Passo:** Para cada variável de decisão, definir o tipo de variável (real ou inteira) e os limites inferiores e superiores. O algoritmo de otimização buscará soluções

compreendidas entre os limites impostos e respeitando o tipo de variável. Quanto maior o número de variáveis e os limites definidos, maior a dificuldade e o tempo consumido para identificar a solução ótima;

- **3º. Passo:** Definir a função objetivo para avaliar as soluções testadas pelo algoritmo. Embora apresentada como uma terceira etapa do método, a função objetivo poderia ser estabelecida durante a fase de projeto do estudo de simulação. A função construída será minimizada, maximizada ou fazer uso de ambos em diferentes variáveis, dependendo dos objetivos em estudo;
- **4º. Passo:** Selecionar o tamanho da população (número de candidatas a soluções) do algoritmo genético. O tamanho da população afeta a confiabilidade e o tempo requerido para a condução de busca. Nesta fase, são também definidos outros parâmetros, tais como: a precisão requerida, o nível de significância e o número de replicações;
- **5º. Passo:** Após a conclusão da busca, um analista deve estudar as soluções encontradas, uma vez que, além da melhor solução encontrada, o algoritmo encontra várias outras soluções competitivas. Uma boa prática é comparar todas as soluções tendo como base a função objetivo.

Apesar de definida para uso exclusivo do *SimRunner*®, a metodologia proposta por Harrel, Ghosh e Bowden (2004), devido a seu caráter generalista, pode ser estendida e aplicada a outros *softwares* que utilizam como técnica de otimização os AG.

3.3.5 Casos na literatura

A seguir, são apresentados alguns casos da aplicação da otimização via simulação. Artigos com este tipo de aplicação foram selecionados para exemplificar a utilização da otimização em modelos de simulação a eventos discretos nas mais variadas áreas.

Cheng e Chan (2011) simularam e otimizaram um sistema flexível de manufatura de uma empresa produtora de componentes usinados. Usando uma interface com o *Excel*®, os autores definiram a demanda como uma entrada do modelo de simulação. O *software* de simulação utilizado possuía um módulo de otimização integrado que permitiu otimizar o sequenciamento da produção que conduzisse ao maior tempo de folga.

Eskandari *et al.* (2011) conduziram um estudo comparativo entre dois pacotes de otimização comercial: o *OptQuest*® (*Arena*®) e o *Optimizer*® (*Witness*®). Os modelos de simulação otimizados representavam um sistema puxado e um sistema de estoque. Duas variáveis de resposta foram analisadas: a resposta encontrada pelos otimizadores e o esforço

computacional. Os resultados experimentais indicaram que o desempenho de ambos os pacotes de otimização foram semelhantes, encontrando boas soluções em um tempo computacional próximo.

Dimitrakiev, Nikolova e Tenekedjiev (2010) discutem a utilização da simulação na otimização do fluxo da fila de aviões em um aeroporto. O trabalho buscou maximizar a controlabilidade da fila e ao mesmo tempo a minimização do consumo de combustível de cada aeronave. Dois algoritmos de otimização foram utilizados visando atender aos objetivos do trabalho.

Yoo, Cho e Yücesan (2010) propuseram um algoritmo híbrido para redução do tempo computacional para melhorar a eficiência da otimização da cadeia de abastecimento através da simulação a eventos discretos. O método proposto é uma estratégia de amostragem global que está continuamente adaptado através de uma compartimentação da região de solução viável. O número de alternativas de candidatos a serem avaliados pode ser assim reduzido.

Ahmed e Alkhamis (2009) integraram a simulação e a otimização para projetar uma ferramenta de apoio à tomada de decisão para a operação de uma unidade de pronto-socorro de um hospital no Kuwait. No trabalho, os autores otimizaram o número de médicos, técnicos de laboratório e enfermeiros necessários para maximizar o atendimento e reduzir o tempo dos pacientes aguardando atendimento.

Roux *et al.* (2008) utilizaram uma nova abordagem integrando algoritmos de otimização e métodos de simulação. Tal abordagem é proposta para analisar o desempenho das estratégias de manutenção para a fabricação de sistemas nos quais características operacionais deterioram com o uso e cuja vida útil e o tempo de reparo são aleatórios. Os autores conseguiram otimizar as políticas de manutenção da empresa.

Lavoie, Kenne e Gharbi (2007) utilizaram-se da otimização via simulação para encontrar as taxas de produção das máquinas que minimizassem o estoque total e os custos decorrentes de atrasos na produção.

El Hayek, Van Voorthuysen e Kelly (2005) desenvolveram um modelo de simulação que auxilia a tomada de decisão da gerência de manutenção ao desenvolverem um modelo que otimiza o custo de manutenção do ciclo de vida de máquinas complexas.

Zhang e Li (2004) utilizaram uma metodologia de otimização que integra a simulação a eventos discretos com um algoritmo heurístico para otimizar a alocação de recursos para a construção civil. Este algoritmo heurístico foi utilizado com o objetivo de minimizar a duração do projeto e otimizar o fluxo de recursos disponíveis.

3.4 Algoritmos Genéticos

3.4.1 AG: Definições básicas

Os Algoritmos Genéticos (AG) vem sendo usados com sucesso para encontrar soluções ótimas ou quase ótimas para uma ampla variedade de problemas de otimização (GEN e CHENG, 1997) desde sua introdução por Holland na década de 1970 (HOLLAND, 1992). Os AG são uma família de técnicas de busca aleatória. E levam este nome em função de sua analogia com a evolução das espécies (HOLLAND, 1975).

A técnica de busca aleatória de um AG combina reprodução e recombinação, imitando o processo da evolução natural das espécies. Em um AG, o espaço de solução é normalmente representado por uma população de cromossomos, onde cada cromossomo, em geral, é uma solução possível para o problema (TORABI, GHOMI e KARIMI, 2006).

A partir de conceitos da genética, que pais mais aptos produzem descendentes mais adaptados, novos cromossomos (filhos) são gerados pela aplicação de operadores genéticos, tais como: *crossover*, mutação e inversão. Os membros com maior aptidão na população terão maior probabilidade de serem escolhidos como pais, o que é semelhante ao conceito de Darwin da sobrevivência dos mais aptos. Este procedimento é repetido em uma busca adaptativa para se encontrar uma solução ótima ou próxima à ela (NEPPALLI, CHEN e GUPTA, 1996).

Desde sua criação, há um interesse crescente na utilização dos AG como uma ferramenta para resolver problemas complexos de otimização (GEN e CHENG, 2000; HOUPPT e HOUPPT, 1998). Para Asllani e Lari (2007), embora os AG sejam mais gerais e abstratos do que outros métodos de otimização e, embora nem sempre ofereçam a solução ideal, eles são considerados flexíveis e aplicáveis a uma grande variedade de problemas.

No entanto, uma crítica frequente é feita aos AG. Eles apresentam um bom desempenho em buscas globais, mas são relativamente lentos na convergência para um ótimo local (WANG e WU, 2003; WANG e WU, 2004).

Para Rivera *et al.* (2006), os AG superam inúmeras técnicas e ferramentas de auxílio à tomada de decisão, tornando-se uma técnica poderosa e eficaz para resolução de inúmeros problemas de otimização em diversas áreas da engenharia.

Linden (2006) destaca as seguintes vantagens dos AG sob outras técnicas de otimização:

- Os AG consideram uma população de soluções que são avaliadas simultaneamente;

- Os AG não usam apenas informações locais, e deste modo não ficam presos a máximos ou mínimos locais. Tal característica faz com que os AG sejam uma técnica adequada para um grande número de funções de perfis complexos;
- Os AG não utilizam métodos de busca totalmente aleatórios;
- Os AG não são afetados por descontinuidades na função ou em suas derivadas. Isso faz com que os AG sejam adequados para funções com descontinuidades, ou para funções com as quais não se pode calcular derivadas;
- Os AG são capazes de lidar com funções discretas e contínuas, podendo, inclusive, trabalhar com funções mistas;
- Os AG são apropriados para resolver problemas de busca com espaços de busca grandes demais para serem resolvidos por técnicas de otimização tradicionais.

3.4.2 Componentes básicos dos AG

Segundo Pinho (2008), 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.

Para Konak, Coit e Smith (2006), nesta terminologia, um vetor solução é chamado de indivíduo ou cromossomo. Os cromossomos são formados por unidades discretas chamados genes. Cada gene controla uma ou mais características do cromossomo. Na concepção original dos AG, os genes eram considerados estruturas binárias. Mais tarde, outros tipos de estruturas foram introduzidos, como a representação real.

Um cromossomo corresponde a uma solução única no espaço de solução. Os AG operam sobre um conjunto de cromossomos, chamado de população. A população é normalmente inicializada aleatoriamente. À medida que a busca se desenvolve, a população inclui soluções mais aptas, e, finalmente, ao convergir, significa que a busca é dominada por uma única solução (KONAK, COIT E SMITH, 2006).

Para Aytug, Khouja e Vergara (2003), os AG têm oito componentes básicos: sua representação genética, a população inicial, a função avaliação, o método de seleção de reprodução, os operadores genéticos, o método de seleção de gerações, os critérios de parada e os parâmetros de configuração dos AG.

Para Linden (2006), os AG são altamente genéricos, sendo que vários de seus componentes são invariáveis de um problema para outro. Desta forma, uma proposta de

metodologia para os AG é apresentada na **Figura 3.6** (LINDEN, 2006). Esta abordagem, embora genérica, consegue abordar a grande maioria dos AG.

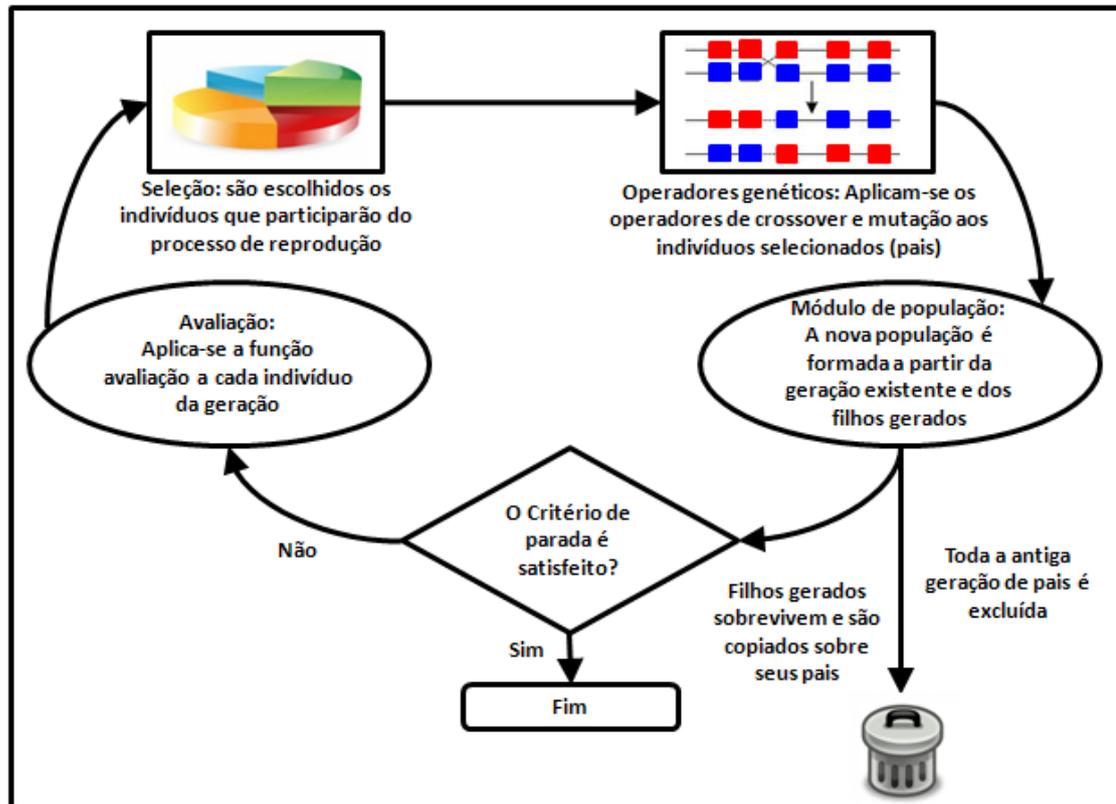


Figura 3.6 - Esquema básico de um algoritmo genético
Fonte: Linden (2006)

Para Pierreval e Tautou (1997), os AG evoluem de uma população inicial até uma população que contém a melhor solução. Eles utilizam o ciclo de reprodução seguinte para avaliar cada iteração. Os cromossomos da população inicial são selecionados com uma certa probabilidade. A seleção de cromossomos baseia-se na sua aptidão em relação à população atual, isto é, os cromossomos mais fortes terão uma maior probabilidade de serem selecionados.

Para Paris e Pierreval (2001), o ciclo é seguido pela avaliação da função aptidão pelo modelo de simulação. Os cromossomos selecionados são submetidos à mutação e *crossover*. O mecanismo de cruzamento permite a ocorrência de mistura de informação dos pais e passagem dessas informações a seus descendentes. O processo de mutação introduz inovações à população, de forma que de uma geração para a seguinte, a população tende, globalmente, para uma melhor condição. O ciclo é interrompido quando o critério de parada é satisfeito.

3.4.3 Representação Genética

Para Linden (2006), a representação cromossomial consiste em uma maneira de traduzir as informações presentes no problema estudado para uma maneira que esta possa ser compreendida por computadores. Quanto mais adequada ao problema esta representação for, maior a qualidade dos resultados obtidos.

Para Almeida *et al.* (2007), a representação do cromossomo na modelagem de um AG deve possuir a capacidade de descrever corretamente o espaço de busca relevante do problema. Concilio (2000) alerta que a representação é uma das etapas mais críticas na definição de um AG. Segundo o autor, uma definição inadequada poderia levar a problemas de convergência prematura.

Duas abordagens distintas são as mais comumente utilizadas para realizar a codificação de um AG: a codificação binária (ou clássica) e a codificação real (MEDEIROS, 2002). Há, ainda, uma terceira abordagem, a codificação inteira, mas que possui aplicação muito restrita.

Medeiros (2002) diferencia a representação binária da representação real com base nos domínios de cada componente de um indivíduo representado. Para ele, na representação binária, os indivíduos são formados por estruturas compostas somente por zero e um. Todos os domínios estão na base binária. Já, na representação real, os componentes do indivíduo pertencem ao conjunto dos números reais. Nesta representação, os domínios devem ser subconjuntos do conjunto dos números reais, ou o próprio conjunto dos números reais.

Pinho (2008) ressalta a importância histórica da representação binária, uma vez que esta foi utilizada nos trabalhos iniciais com AG, proposta por Holland na década de 1970. Segundo o autor, a representação binária é de fácil utilização e manipulação, sendo, ainda, simples de se analisar teoricamente.

Já para Michalewicz (1996), a representação real apresenta vantagens sobre a binária no que diz respeito à velocidade de processamento, consistência dos resultados entre as rodadas e precisão, apresentando maior exatidão e capacidade de representação dos domínios de um problema.

Para Soares (1997), a representação por inteiros é mais indicada para problemas que envolvam números inteiros, como análise combinatória, arranjos e permutação.

3.4.4 População inicial

Segundo Soares (2006), a população inicial pode ser obtida de duas formas. Na primeira delas, os indivíduos são gerados aleatoriamente, enquanto que na segunda, a população é

gerada por meio de uma heurística, relacionada às características específicas do problema.

Para Azadeh e Tarverdian (2007), na maioria das aplicações com AG, a população inicial de cromossomos é criada aleatoriamente, sendo o número de populações diferentes de um problema para outro.

Para Torabi, Ghomi e Karimi (2006), uma boa definição de uma população inicial, com tamanho razoável, aumenta em grande parte a eficiência de um AG. Uma população pequena diminui o espaço de busca, podendo convergir prematuramente, mas reduzindo as possibilidades de se atingir o ótimo global. Por outro lado, populações muito grandes acarretam maior consumo de tempo computacional, demandando muito tempo para se chegar a uma solução (FALCONE, 2004; MICHALEWICZ, 1996).

3.4.5 Função avaliação

Para Katayama, Hirabayashi e Narihisa (2003), os indivíduos de uma população são representados por um cromossomo que codifica as variáveis do problema. Cada indivíduo possui uma aptidão numérica, valor este que mede o quão bem o indivíduo se encaixa em uma determinada geração. Assim, a aptidão de um indivíduo é determinada como o valor da função avaliação para um determinado problema.

Para McCall (2005), a função avaliação mede a qualidade do cromossomo como uma solução para um problema em particular. O cálculo da função avalia o sucesso do cromossomo como solução em termos de vários critérios e objetivos, tais como: tempo de conclusão, utilização de recursos e assim por diante.

A fim de imitar o processo natural de sobrevivência do mais apto, a função avaliação atribui a cada membro da população um valor, refletindo sua relativa superioridade ou inferioridade (TORABI, GHOMI E KARIMI, 2006).

Para Jozwiak e Postuła (2002), indivíduos que são melhores que outros em uma mesma população, de acordo com a função avaliação, têm maiores chances de gerarem filhos de acordo com o princípio da sobrevivência do mais apto.

A função avaliação deve ser escolhida com cuidado e deve agregar todo o conhecimento sobre o problema a ser resolvido, tais como suas restrições e seus objetivos. Além disso, ela deve ser capaz de distinguir entre duas soluções sub-ótimas, sendo capaz de dizer qual delas está mais próxima da solução procurada (LINDEN, 2006). Para Gosselin, Gingras e Potvin (2009), o cálculo da função avaliação é normalmente a etapa mais demorada do processo de um AG, uma vez que envolve várias simulações.

3.4.6 Métodos de seleção de reprodução

O método de seleção de reprodução é o processo que define como, dada uma geração t com n indivíduos, é selecionado um conjunto de indivíduos m e, em seguida, gerada uma nova geração $t+1$ (GOLDBERG, 1989). Para Hicks (2006), os métodos de seleção de reprodução são utilizados para selecionar os cromossomos que serão expostos aos operadores genéticos.

Para Linden (2006), o método de seleção deve simular o mecanismo de seleção natural, segundo o qual pais mais capazes geram mais filhos que os pais menos aptos. Assim, deve-se privilegiar os indivíduos com função avaliação alta, sem, no entanto, desprezar os indivíduos com funções baixas, de modo a garantir diversidade à população.

Segundo Bäck, Fogel e Michalewicz (2000), o operador de seleção direciona o processo de busca para melhores regiões, sendo sua principal função selecionar indivíduos mais aptos à reprodução.

Várias abordagens têm sido utilizadas para implementar os métodos de seleção de reprodução. Algumas das abordagens utilizadas são o método de roleta, que seleciona os cromossomos de acordo com a sua aptidão, a seleção por torneio, que coloca os indivíduos de uma população uns contra os outros e a seleção elitista, que conduz um certo número de cromossomos mais aptos para a próxima geração (HICKS, 2006).

3.4.7 Operadores de seleção de gerações

Uma vez definidos os principais conceitos relacionados aos métodos de seleção de reprodução, cabe aqui aprofundar as abordagens mais comumente utilizadas para a criação de novas gerações. Serão abordados aqui três métodos de seleção: o método de roleta (simples e ponderada), o método de torneio e a seleção elitista.

3.4.7.1 Roleta simples ou seleção proporcional

Segundo Pinho (2008), esse método foi proposto por Holland e é até hoje um dos mais utilizados. O método consiste em se atribuir a cada cromossomo uma probabilidade de ser selecionado como pai em função de sua aptidão. Dessa forma, indivíduos com função aptidão maior terão mais chances de seguirem na formação de uma nova população. No entanto, todos os indivíduos possuem alguma probabilidade de serem selecionados, mesmo aqueles com baixa aptidão. Esse método garante uma grande amplitude de recombinação, garantindo a geração de indivíduos diversificados (CAMPOS, YOSHIZAKI e BELFIORE, 2006).

Para Falcone (2004), no método da roleta, cada indivíduo tem seu valor aptidão representado proporcionalmente em relação ao valor total das aptidões na população. Assim, a roleta é girada e selecionam-se os indivíduos através deste sorteio. Aqueles que apresentarem maior participação terão maiores chances de serem selecionados. Cada vez que a roleta é girada, um novo subconjunto é formado.

3.4.7.2 Roleta ponderada ou seleção por ordenação

Segundo Barboza (2005), a técnica de seleção por ordenação ou roleta ponderada ordena os indivíduos de uma dada população conforme seu desempenho. De acordo com esse método, a distância entre os indivíduos próximos é reduzida, diminuindo-se a pressão seletiva. Cada indivíduo recebe uma nota, sendo que o pior recebe nota “1” e o melhor recebe uma nota no valor do tamanho da população. Portanto, o primeiro em aptidão tem a maior probabilidade de ser selecionado, uma vez que a pressão seletiva é atenuada.

3.4.7.3 Seleção por torneio

Para Teles e Gomes (2010), a seleção por torneio é um método de seleção amplamente utilizado, devido, principalmente à sua eficiência e simplicidade de implementação. Esse método preserva melhor a diversidade da população, uma vez que a escolha é realizada comparando o valor da função aptidão entre os indivíduos que participam do torneio.

Segundo Linden (2006), na seleção por torneio, existe um parâmetro denominado tamanho do torneio (K). Este parâmetro define quantos indivíduos serão selecionados de forma aleatória dentro da população para competir. Uma vez definidos os competidores, aquele que possuir a melhor avaliação é selecionado para a aplicação do operador genético. Contudo, quanto maior o tamanho do torneio, maior a perda da diversidade.

Uma das vantagens do método é que os indivíduos são selecionados aleatoriamente para competir, não existindo, desta forma, favorecimento aos indivíduos com maior aptidão, como no caso da seleção por roleta (LINDEN, 2006).

3.4.7.4 Seleção elitista

Para Bento e Kagan (2008), a maioria dos métodos de seleção descartam a geração anterior e consideram apenas os descendentes obtidos para composição da geração futura. Dessa forma, a técnica elitista consiste em reintroduzir o indivíduo melhor avaliado de uma geração para a seguinte, evitando a perda de informações importantes presentes em indivíduos de alta avaliação, aos quais podem ser perdidas durante os processos de seleção e cruzamento.

Segundo Barboza (2005), o método elitista tem como principal vantagem garantir a convergência, de tal forma que se o melhor resultado da busca for alcançado, o AG convergirá para tal solução. Como desvantagem, pode-se citar a possibilidade de se forçar uma busca, pela presença de mais de uma cópia do melhor indivíduo em direção a algum bom resultado.

3.4.8 Operadores genéticos

Os operadores genéticos promovem a recombinação dos cromossomos de uma população para outra. Neste processo, os cromossomos selecionados de uma população inicial são recombinados para formar membros de uma nova população. A ideia é simular a mistura de material genético que ocorre quando os organismos se reproduzem, objetivando a formação de filhos melhores, a partir de pais previamente selecionados em função de sua aptidão (McCALL, 2005).

Existem três operadores genéticos básicos utilizados em AG: *crossover* (cruzamento), mutação e inversão. Desses três operadores, dois são mais comumente utilizados: o *crossover* e a mutação (NEPPALLI, CHEN e GUPTA, 1996).

3.4.8.1 Operador de *Crossover*

Segundo Konak, Coit e Smith (2006), o operador de *crossover* é o mais importante dos operadores genéticos. Em uma operação de *crossover*, dois cromossomos são combinados para formar novos cromossomos. Aplicando iterativamente este operador, é esperado que os genes dos cromossomos bons apareçam com maior frequência na população e, eventualmente, convirjam para uma boa solução global.

Em uma operação de *crossover*, uma posição no cromossomo é escolhida aleatoriamente, e este é quebrado nessa posição. Sendo os fragmentos resultantes recombinados e dois novos cromossomos criados. Em outras formas de *crossover*, o cromossomo pode ser quebrado de forma aleatória em uma ou mais posições e ser recombinado com outro cromossomo quebrado de forma semelhante. Existem ainda outras formas de *crossover* utilizados nos AG (AZADIVAR e TOMPKINS, 1999). As formas mais comuns presentes na literatura são apresentadas a seguir:

- *Crossover* uniforme: para Linden (2006), esta recombinação consiste no emparelhamento de dois cromossomos pais, no qual cada *locus* do cromossomo tem 50% de chance de ser trocado;
- *Crossover* de um ponto: segundo Barboza (2005), neste tipo de recombinação, um ponto de corte é escolhido aleatoriamente, e, a partir deste ponto, as informações do

código genético dos pais são trocados para a formação dos filhos;

- *Crossover* de dois pontos: segundo Linden (2006), nesta operação dois pontos são escolhidos aleatoriamente, e, a partir desses pontos, as informações dos pais são trocadas para a formação dos filhos;
- *Crossover* baseado na maioria: segundo Linden (2006), essa operação consiste em sortear n pais e fazer com que cada posição k do filho seja igual ao valor da maioria dos pais escolhidos. Contudo, este tipo de recombinação não é muito usado, uma vez que tende a fazer com que a convergência genética ocorra prematuramente.

3.4.8.2 Operador de Mutação

O operador de mutação introduz mudanças aleatórias em determinadas características dos cromossomos. Este operador geralmente é aplicado ao nível do gene e, dessa forma, os cromossomos produzidos não são muito diferentes dos originais. No entanto, a mutação reintroduz a diversidade genética de volta à população e auxilia o algoritmo a fugir de ótimos locais (KONAK, COIT E SMITH, 2006).

Para Paris e Pierreval (2001), o operador de mutação introduz inovação à população, sendo que de uma geração para a outra, a população tende, globalmente, para uma melhor condição.

Segundo Yang, Kuo e Cho (2007), ao se utilizar o operador de mutação, qualquer solução do espaço de busca pode ser gerada aleatoriamente na população inicial. Além disso, qualquer solução pode ser alcançada a partir de qualquer outra solução, utilizando uma sequência finita de mutações.

Para Cantú-Paz (1998), a mutação geralmente é considerada como um operador secundário, sendo sua função principal a de restaurar a diversidade na população, que pode ser perdida a partir da aplicação repetida dos operadores de seleção e do *crossover*.

Barrico (2007) destaca a utilização dos seguintes tipos de mutações:

- Quando são utilizadas representações com conjuntos de valores inteiros, como o binário, o operador de mutação consiste em determinar aleatoriamente uma posição no cromossomo, para, depois, substituir o valor que se encontra nessa posição por um dos outros valores do conjunto associado à representação usada;
- Quando as representações usadas são baseadas em permutações, uma forma simples de utilização deste operador consiste em trocar a posição de dois elementos;
- A mutação múltipla consiste em aplicar este operador genético a todos os elementos do cromossomo, o que é vantajoso no sentido de escapar dos ótimos locais;

- Na mutação localizada, só são afetados pela mutação os genes menos significativos do cromossomo, o que conduz a pequenas perturbações nos indivíduos.

3.4.9 Critérios de parada

Segundo Hicks (2006), os critérios de parada são abordagens que delimitam o número de buscas depois que certo número de gerações são concluídas em um AG. Estes critérios podem ser implementados por meio de um tempo máximo, pela diminuição da diversidade populacional ou quando uma população não melhora em sucessivas gerações.

Aytug e Koehler (2000) estabelecem uma crítica aos AG ao afirmarem que todos os componentes de um AG são bem definidos na literatura, à exceção dos critérios de parada. Para os autores, muitos usuários dos AG acabam utilizando algum critério de parada com base em experiências anteriores ou acabam por utilizar algum tipo de regra ou alguma heurística para implementá-la.

Segundo Yang, Kuo e Cho (2007), existem vários critérios de parada comumente utilizados. Um deles parte do princípio que, quando várias gerações consecutivas alcançam a mesma solução, a busca por novas soluções deve ser interrompida. Outro critério utilizado interrompe a busca quando a melhoria na qualidade da solução torna-se insignificante.

Ainda segundo os autores, levando-se em conta a eficiência computacional, outro critério que pode vir a ser utilizado delimita um número máximo de simulações que podem ser executadas, tornando-se esse número o critério de parada. Este critério é muitas vezes associado à otimização de modelos de simulação a eventos discretos, onde o tempo de processamento é significativo.

3.4.10 Parâmetros de configuração

Segundo Yang, Kuo e Cho (2007), apesar dos AG resolverem problemas de otimização eficazmente, eles são sensíveis a seus parâmetros de configuração, sendo seus principais parâmetros: o tamanho da população, o critério de parada, a taxa de *crossover* e a taxa de mutação. Azadeh e Tarverdian (2007) acrescentam mais um parâmetro aos já mencionados: o número de gerações.

Para Neppalli, Chen e Gupta (1996), a determinação dos valores dos parâmetros de um AG é um processo complexo. Geralmente, na maioria das aplicações, os valores dos parâmetros são ajustados com base em trabalhos previamente conduzidos e relatados.

Gosselin, Gingras e Potvin (2009) destacam que configurações específicas de parâmetros utilizados na configuração de AG nem sempre estão disponíveis na literatura,

podendo complicar a repetibilidade dos resultados ou a extensão de um trabalho para um problema similar. Para os autores, a escolha dos parâmetros do AG possui uma grande influência na velocidade de convergência, bem como no sucesso da otimização.

Segundo Núñez-Letamendia (2007), não existe consenso a respeito das definições dos parâmetros dos AG. No entanto, Pinho (2008) ressalta que conhecer o problema que está sendo tratado é importante, uma vez que cada parâmetro influencia diretamente no desempenho do AG.

Apesar de não existirem regras para a definição dos parâmetros dos algoritmos genéticos, são apresentados aqui os valores mais comumente utilizados na literatura para a configuração dos parâmetros referentes ao tamanho da população, ao número de gerações, à taxa de *crossover* e à taxa de mutação.

Para Linden (2006), o desempenho do AG é muito sensível ao tamanho da população e alerta que este parâmetro deve ser definido com extremo cuidado. Se a população for pequena, não haverá espaço suficiente para uma variedade genética muito grande, o que incapacitará o algoritmo a encontrar boas soluções. Por outro lado, se a população for muito grande, o algoritmo gastará muito tempo até encontrar uma solução.

Para Tanomaru (1995), populações entre 50 a 200 cromossomos resolvem grande parte dos problemas. Mitchell (1996) indica que o melhor tamanho de uma população está entre 50 e 100. Já no trabalho de Aytung, Khouja e Vergara (2003), verificaram-se populações variando de 20 a 1024 indivíduos. Santos e Monteagudo (2010) utilizaram uma população de 1000 indivíduos. Aytug e Koehler (2000) trabalharam com um número variável entre 100 e 200. Aryanezhad e Hemati (2008) utilizaram uma população que variou de 20 a 2000. Linden (2006), no entanto, afirma que a maioria dos trabalhos publicados adota o tamanho da população igual a 100.

Com relação ao número de gerações, este varia de acordo com a complexidade do problema que está sendo tratado e deve ser determinado experimentalmente (YUN e GEN, 2003). Não há um acordo entre os usuários dos AG com relação ao número de gerações. Hwang e He (2006) definem um número de gerações igual a 600, enquanto que Núñez-Letamendia (2007) define esse valor em 25, Zhang e Ishikawa (2004) utilizaram 10 gerações. Asllani e Lari (2007), Kamei e Ishikawa (2004) e Martin (2009) trabalharam com 100 gerações.

Segundo Linden (2006), o operador de *crossover* recebe uma probabilidade maior que o operador de mutação, uma vez que a reprodução é a principal característica de um AG. Ainda, segundo o autor, utiliza-se, geralmente, uma taxa superior a 80% para o operador de

crossover, sendo que em muitos casos a taxa de mutação pode ser considerada como 100% menos a probabilidade definida para o operador de *crossover*.

Para Barboza (2005), normalmente o valor da taxa de *crossover* fica entre 60% e 65%. Já, segundo Tanomaru (1995), estudos empíricos mostram que bons resultados são obtidos com valores superiores a 70%. Yang, Kuo e Cho (2007) utilizaram 60% para a taxa de *crossover*. Deb e Tiwari (2008) usaram o valor de 50%. Já Lobo e Goldberg (2004) e Hwang e He (2006) utilizaram em seus experimentos um valor de 70%. Já Núñez-Letamendia (2007) utilizou um valor de 95%. Rees e Koehler (2006) conduziram estudos variando a taxa de *crossover* entre 10% e 90%, enquanto que Al-Aomar e Al-Okaily (2006) e Matous *et al.* (2000) utilizaram valores entre 60% e 100%.

Para a taxa de mutação, Barboza (2005) afirma que, geralmente, os valores encontrados na literatura ficam em torno de 0,1% a 5%. Para Tanomaru (1995), essa taxa deve ser menor que 1%. Azadeh e Tarverdian (2007) recomendam que a taxa de mutação deva estar entre 1% e 5%. Ainda nesta linha, Matous *et al.* (2000) recomendam que a taxa deve estar entre 0,1% e 1%.

Corroborando com essas afirmações, McCall (2005) e Mitchell (1996) afirmam que, na grande maioria das vezes, a taxa de mutação é muito baixa, geralmente igual a 0,1%. Hwang e He (2006), Lobo e Goldberg (2004) e Núñez-Letamendia (2007) utilizaram em seus experimentos um valor de 1%. Zhang e Ishikawa (2004) utilizaram o valor de 10%. Já no trabalho de Gosselin, Gingras e Potvin (2009), várias taxas de mutação e *crossover* foram utilizadas.

3.4.11 Técnicas de adaptação de parâmetros em AG

Segundo Linden (2006), muitos pesquisadores procuram determinar o melhor conjunto de parâmetros do AG visando sua máxima eficiência. No entanto, o grande problema em se determinar os parâmetros antes do início da execução do algoritmo é que os AG constituem um processo dinâmico, que evolui no tempo e no espaço de soluções. Sendo assim, torna-se praticamente impossível determinar um conjunto de parâmetros que sejam adequados para a resolução de um problema em todos os seus estágios, uma vez que em cada um deles a população tem diferentes características de dispersão no espaço de solução.

Para resolver a esta questão, Linden (2006) propõe a utilização de técnicas de adaptação para os parâmetros do AG, cujos valores mudariam de acordo com o progresso do algoritmo e não permaneceriam constantes.

Para Chen, Zhu e Li (2010), a baixa velocidade para se alcançar resultados satisfatórios e a convergência prematura dos AG para soluções de baixa qualidade em diversas aplicações, conduziram a inúmeras pesquisas dedicadas à melhoria dos AG, e levaram à criação dos algoritmos genéticos adaptativos (AGA).

De acordo com Sung e Liu (2010), muitas tentativas para melhorar o desempenho dos AG têm sido realizadas desde as primeiras pesquisas envolvendo os AG. Segundo os autores, várias formas alternativas de *crossover*, reprodução e mutação têm melhorado muito o desempenho dos AG.

Para Hinterding, Michalewicz e Eiben (1997), existem três principais técnicas de adaptação para os valores dos parâmetros de um AG:

- Determinística: ocorre quando a mudança no valor dos parâmetros acontece devido a uma regra determinística, que modifica os parâmetros sem nenhum tipo de *feedback* do AG;
- Adaptativa: ocorre quando existe algum tipo de *feedback* por parte do AG que é usado para determinar o valor do parâmetro na geração seguinte;
- Auto adaptativa: consiste em usar a evolução do algoritmo para determinar seus parâmetros, ou seja, os parâmetros do AG evoluem em conjunto com as soluções do problema.

A literatura apresenta inúmeros trabalhos que evidenciam a utilização das técnicas de adaptação de parâmetros para AG, ao mesmo tempo em que confirmam que tais técnicas realmente incrementam sua eficiência.

Para San José-Revuelta (2007), as técnicas adaptativas permitem reduzir o tamanho da população do AG e, mesmo assim, alcançar boas propriedades de convergência e um baixo tempo de processamento computacional, o que segundo Ye, Li e Xie (2010), é uma propriedade desejada para o AG em aplicações em problemas de engenharia. Em ambos os trabalhos foram utilizadas técnicas adaptativas para as taxas de *crossover* e mutação.

Ou *et al.* (2005), utilizaram probabilidades adaptativas para os operadores de *crossover* e mutação. No AGA desenvolvido por estes autores, as taxas de *crossover* e mutação variavam de acordo com a aptidão de cada cromossomo, e as taxas não necessitam ser especificadas antes da execução do AGA. Os autores provaram que o AGA mostrou-se melhor que o AG tradicional.

Balamurugan, Ramakrishnan e Singh (2007) desenvolveram um AGA de duas etapas. Na primeira, o AGA utiliza estratégias adaptativas para determinação das taxas dos

operadores de *crossover* e mutação. Estas foram definidas em função das melhores soluções de cada geração. Na segunda, apenas as melhores soluções foram expostas aos operadores genéticos, objetivando acelerar a busca pela melhor resposta.

Para Kaveh e Shahrouzi (2007), o parâmetro tamanho da população é considerado como um dos mais importantes em um AG, e levantaram a questão de qual o tamanho ideal para esse parâmetro. Os autores propuseram uma técnica adaptativa, segundo a qual, a população seria incrementada a cada geração em até no máximo 50%, porém, sempre iniciando com um baixo valor. Os autores conseguiram bons resultados para convergência com o AGA desenvolvido.

Nesta mesma linha, Gong *et al.* (2007) e Ma e Zhang (2008) utilizam técnicas adaptativas para o tamanho da população. No primeiro trabalho, a cada geração do AG, um tamanho de população diferente é utilizado visando reduzir o tempo de processamento e, ao mesmo tempo, evitar a convergência prematura do algoritmo. Já no trabalho de Ma e Zhang (2008), é proposta uma técnica adaptativa que não descarta alguns dos cromossomos utilizados na operação de *crossover*. Assim, a cada nova geração do algoritmo, tem-se um número maior para o tamanho da população.

Por fim, Pinho (2008) destaca que vários outros tipos de adaptações em AG têm sido propostas ao longo do tempo, como a adaptação na função de aptidão, nos tipos de operadores de *crossover* e mutação e na forma como o AG faz sua evolução.

3.5 Projeto e análise de experimentos

Segundo Montgomery (2005), um experimento pode ser definido como um teste, ou uma série de testes, nos quais são realizadas mudanças propositalmente nas variáveis de entrada de um processo, de modo a se observar e identificar mudanças correspondentes nas respostas de saída. Sendo considerado pelo autor como parte vital do método científico em várias aplicações em engenharia.

Montgomery (2009) define dois tipos de variáveis em um processo (**Figura 3.7**): as variáveis controláveis (x_1, x_2, \dots, x_p), e as variáveis não controláveis (z_1, z_2, \dots, z_q), muitas vezes chamadas de ruídos. Para o autor, os objetivos do experimento podem ser:

- Determinar quais variáveis mais influenciam na resposta (y);
- Determinar os valores de x (significativos) de modo que a resposta esteja perto da exigência nominal;

- Determinar os valores de x (significativos) de modo que a variabilidade em y seja pequena;
- Determinar os valores de x (significativos) de modo que os efeitos das variáveis não controláveis sejam minimizados.

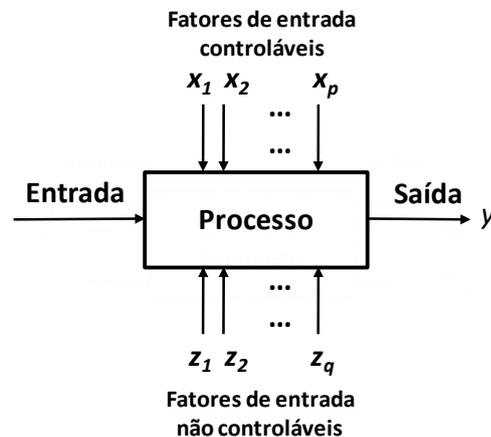


Figura 3.7 - Modelo geral de um processo
Fonte: Montgomery (2009)

Definidos os principais conceitos e objetivos de um experimento, pode-se passar para a conceituação de Projeto e Análise de Experimentos (*Design of Experiments* - DOE).

Para Montgomery (2005), o DOE pode ser definido como o processo de planejamento de experimentos para que dados apropriados sejam coletados e depois analisados por métodos estatísticos, resultando em conclusões válidas e objetivas. Sendo que qualquer problema experimental, segundo Gomes (2010) e Costa (2010), deve ser sustentado por dois elementos: o projeto dos experimentos e a análise estatística dos dados.

Para Gomes (2010), as técnicas do DOE têm encontrado uma ampla aplicação nas mais variadas áreas do conhecimento, mostrando-se como um conjunto de ferramentas de grande importância para o desenvolvimento de produtos e processos.

Montgomery (2009) alerta para a necessidade de que os envolvidos no experimento tenham uma ideia prévia do objetivo do experimento, de quais fatores serão estudados, de como o experimento deve ser conduzido e que tenham pelo menos uma compreensão de como os dados serão analisados.

Montgomery (2005) propõe que o DOE deve considerar as seguintes etapas:

- 1. Reconhecimento e definição do problema:** desenvolver completamente todas as ideias sobre o problema e sobre os objetivos a serem alcançados com o experimento; isso contribui para uma melhor compreensão do processo e para uma eventual solução do problema;

2. **Escolha dos fatores e dos níveis de trabalho:** devem-se escolher os fatores que irão variar, os intervalos sobre os quais esses fatores variarão e os níveis específicos nos quais cada rodada será realizada;
3. **Seleção das variáveis de resposta:** o experimentador deve determinar as variáveis de resposta que realmente forneçam as informações úteis sobre o processo em estudo;
4. **Escolha do projeto experimental:** esse planejamento envolve consideração sobre o tamanho da amostra (número de replicações), seleção da ordem correta das rodadas para as tentativas experimentais, ou se a formação de blocos ou outras restrições de aleatorização estão envolvidas;
5. **Realização dos experimentos:** quando da realização dos experimentos, é importante monitorar o processo para garantir que tudo está sendo feito de acordo com o planejamento; erros nesta etapa podem destruir a validade do experimento;
6. **Análise estatística dos dados:** métodos estatísticos devem ser utilizados para analisar os dados de modo que os resultados e conclusões sejam objetivos e não fruto de opiniões; a análise dos resíduos e a verificação da validade do modelo, também são importantes nesta etapa;
7. **Conclusões e recomendações:** analisados os dados, o experimento deve conduzir a conclusões práticas sobre os resultados e recomendar um plano de ação. Sequências de acompanhamento e testes de confirmação devem ser conduzidos para validar as conclusões do experimento.

Montgomery (2009) ressalta que as etapas de 1 a 3 são comumente chamadas de planejamento pré-experimental e afirma que para o sucesso do experimento é importante que esses passos sejam realizados tão bem como possível.

Para Gomes (2010) e Costa (2010), as técnicas de projetos experimentais mais utilizadas compreendem: o Planejamento Fatorial Completo, o Planejamento Fatorial Fracionado, os arranjos de Taguchi e a Metodologia de Superfície de Resposta.

A **Tabela 3.2**, adaptada de Gomes (2010), apresenta as principais características dos projetos experimentais mais utilizados. Esse trabalho fez uso do Planejamento Fatorial Completo para a seleção dos parâmetros do AG que mais influenciam no tempo de convergência do algoritmo e na qualidade de resposta apresentada, razão pela qual essa técnica experimental é apresentada com mais detalhes no item 3.5.1.

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

Tabela 3.2 - Características das principais técnicas de Projeto e Análise de Experimentos
Fonte: Adaptado de Gomes (2010)

Apesar dos métodos de planejamento de experimentos terem sido desenvolvidos visando experimentos físicos, eles podem ser facilmente utilizados em experimentos simulados. O planejamento de experimentos simulados apresenta muitas oportunidades para a melhoria de inúmeros sistemas, principalmente, aqueles onde a realização de um experimento físico seja difícil ou até mesmo impossível de ser realizado na prática (KELTON, 2003).

Montevecchi *et al.* (2007) destacam que os benefícios do DOE na simulação incluem a possibilidade da melhoria do desempenho no processo de simulação, evitando a técnica da tentativa e erro para a busca de soluções.

3.5.1 Planejamento fatorial completo

O arranjo experimental mais comum é o fatorial completo, para o qual o número de experimentos é igual ao número de níveis experimentais elevado ao número de fatores. No caso típico de fatoriais em dois níveis, o número de experimentos (N) para se avaliar os k fatores é dado por $N = 2^k$ (PAIVA, 2008). Para Montgomery (2009), esses planejamentos têm uma análise simplificada e formam a base de muitos outros planejamentos.

De acordo com Montgomery e Runger (2003), no planejamento fatorial completo os fatores são alterados conjuntamente e não um por vez, o que significa que, para cada corrida ou réplica completa, todas as combinações dos níveis possíveis são investigadas.

Montgomery (2005) ressalta que os planejamentos fatoriais são mais eficientes que a abordagem de um fator por vez, uma vez que eles permitem que os efeitos dos fatores sejam estimados a partir dos níveis dos outros fatores, conduzindo a conclusões válidas dentro do escopo experimental; além de serem a única maneira de se descobrir interações entre as variáveis, evitando assim conclusões erradas quando interações entre fatores estão presentes.

Para Paiva (2008), os fatoriais completos cobrem todo o espaço experimental, porém, enquanto o número de fatores cresce linearmente, o número de experimentos cresce exponencialmente. Uma quantidade muito grande de fatores pode tornar um processo de experimentação inviável.

3.6 Considerações finais

Este capítulo apresentou o referencial teórico deste trabalho. Foram abordados os principais temas envolvendo a simulação a eventos discretos, otimização via simulação, algoritmos genéticos e projeto e análise de experimentos. Dessa forma, tentou-se aqui facilitar a compreensão do trabalho que será desenvolvido ao longo dessa dissertação.

4. ANÁLISE DOS PARÂMETROS DO ALGORITMO GENÉTICO

4.1 Considerações iniciais

Este capítulo se propõe a apresentar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade de resposta, na otimização de modelos de simulação a eventos discretos não lineares, utilizando para isso um AG clássico, ou seja, um algoritmo sem qualquer tipo de adaptação em seus parâmetros.

A influência dos parâmetros será evidenciada através da técnica de experimentação (DOE), onde se verificará quais parâmetros do AG são realmente significativos. Serão utilizados os seguintes parâmetros do AG: tamanho de população, número de gerações, taxa de *crossover* e taxa de mutação. Três modelos de simulação serão utilizados como objetos de estudos. O objetivo desse capítulo é apontar quais parâmetros do AG, por apresentarem uma influência significativa, devem possuir adaptações.

Este capítulo inicia o ciclo metodológico utilizado nesta dissertação (MITROFF *et al.*,1974). A primeira etapa do ciclo, conceitualização, será apresentada ao longo de todo esse capítulo.

4.2 Análise dos parâmetros do AG no tempo de convergência e na qualidade de resposta

A análise dos parâmetros do AG no tempo de convergência e na qualidade de resposta na otimização dos modelos de simulação a eventos discretos será realizada por meio da técnica de Projeto e Análise de Experimentos.

Para a condução dos experimentos, será utilizado um AG em sua forma clássica, tal como proposto em sua criação por Holland (1975). Quatro parâmetros serão analisados: tamanho de população, número de gerações, taxa de *crossover* e taxa de mutação.

A **Figura 4.1** apresenta a estrutura clássica de um AG, bem como onde atuam os parâmetros analisados na estrutura do AG.

Três modelos de simulação servirão de objetos de estudo para otimização e análise dos parâmetros. Como o algoritmo de otimização a ser desenvolvido será utilizado para otimização de modelos de simulação, optou-se por realizar a experimentação em modelos de simulação e não em funções matemáticas, como é o mais comum na literatura.

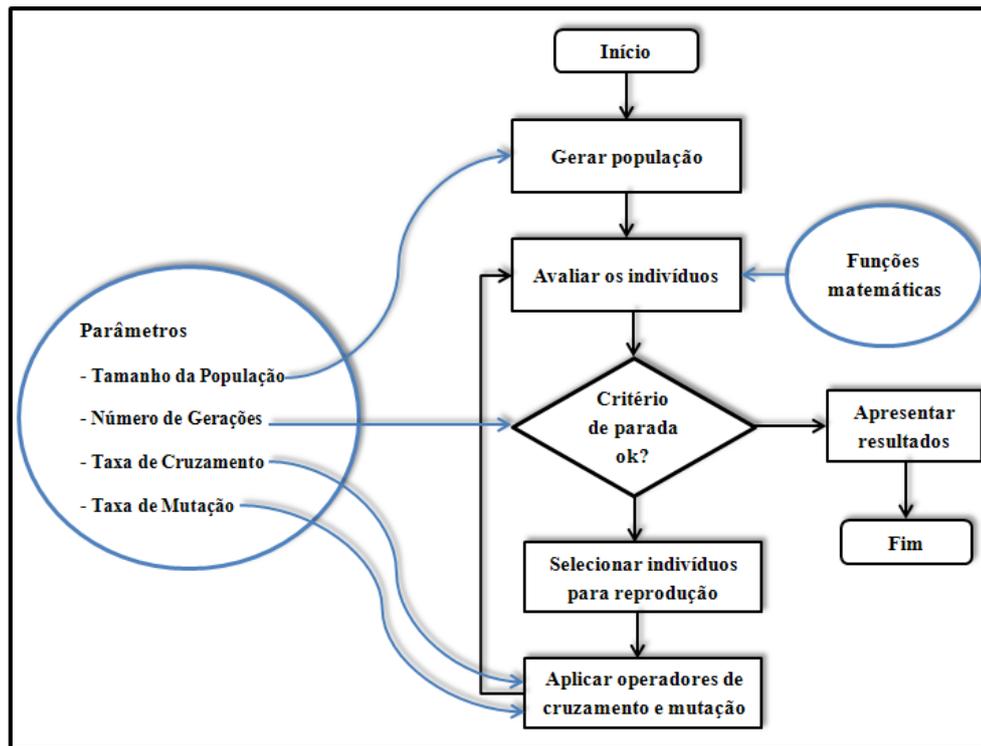


Figura 4.1 - Estrutura clássica de um AG e parâmetros analisados
Fonte: adaptado de Pinho (2008)

Tal fato é justificado, uma vez que os AG são muito sensíveis à escolha de seus parâmetros, sendo fortemente influenciado por estes (YANG, KUO e CHO, 2007). Desta forma, se a análise dos parâmetros fosse realizada em funções matemáticas poderia levar a conclusões divergentes daquelas encontradas com a experimentação em modelos de simulação, e que quando aplicadas ao algoritmo proposto, poderia levar a resultados não satisfatórios.

Para a condução dos experimentos, será utilizada a metodologia proposta por Montgomery (2005). Tal método, já apresentado na seção 3.5, pode ser sumarizado nos seguintes tópicos:

1. Reconhecimento e definição do problema;
2. Escolha dos fatores e dos níveis de trabalho;
3. Seleção das variáveis de resposta;
4. Escolha do projeto experimental;
5. Realização dos experimentos;
6. Análise estatística dos dados;
7. Conclusões e recomendações.

As seções seguintes irão explorar a metodologia proposta por Montgomery (2005) na condução dos experimentos.

4.2.1 Reconhecimento e definição do problema

Três modelos de simulação desenvolvidos pelo grupo de pesquisa do pesquisador e voltados à área de manufatura serão utilizados para otimização e análise dos parâmetros do AG. Todos os modelos utilizados foram adaptados para otimização de funções objetivas não lineares.

O primeiro modelo representa uma linha de produção de uma multinacional do setor de autopeças. Todas as etapas referentes à construção e validação do modelo de simulação podem ser verificadas em Montevechi *et al.* (2008a). Para esse objeto de estudo, foram definidas como variáveis de decisão: o número de operadores do tipo 1 (x_1), o número de operadores do tipo 2 (x_2) e o número de operadores do tipo 3 (x_3). As três variáveis foram definidas como sendo inteiras, com limite inferior igual a 1 e limite superior igual a 9. A **Figura 4.2** ilustra o modelo implementado no *software ProModel®*, e a **Figura 4.3** apresenta o modelo conceitual através da técnica IDEF-SIM (LEAL, ALMEIDA e MONTEVECHI, 2008).

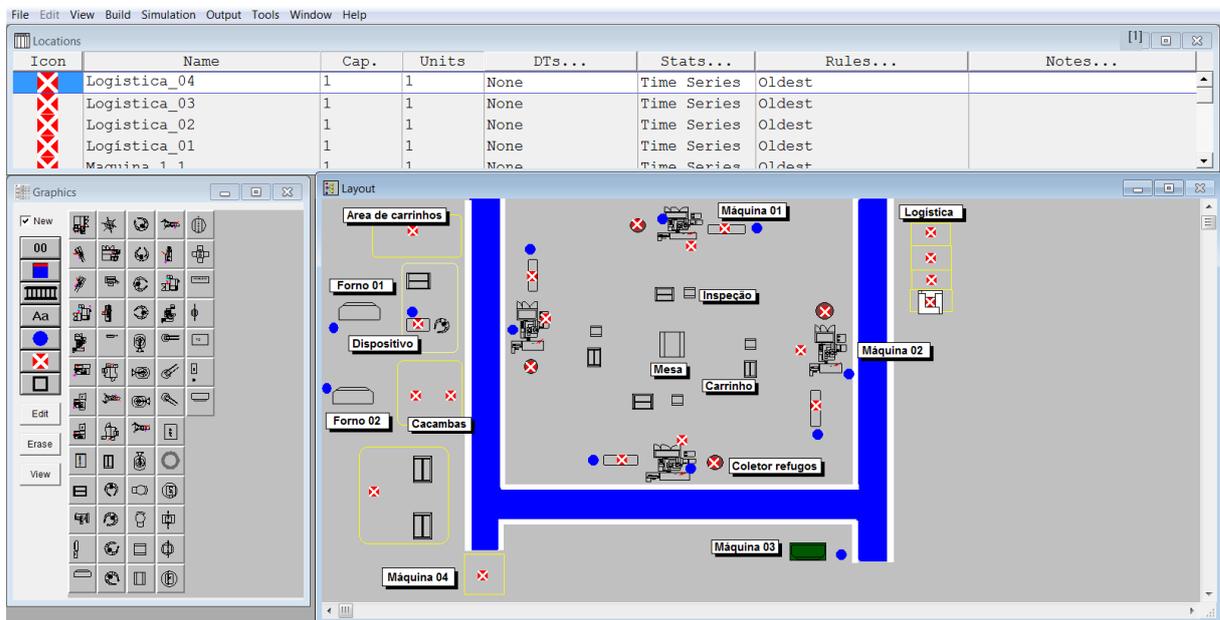


Figura 4.2 - Modelo implementado no *ProModel®* para o primeiro objeto de estudo

Para uma melhor compreensão dos modelos conceituais em IDEF-SIM, são apresentados, no **Apêndice A**, todos os símbolos desta técnica de modelagem.

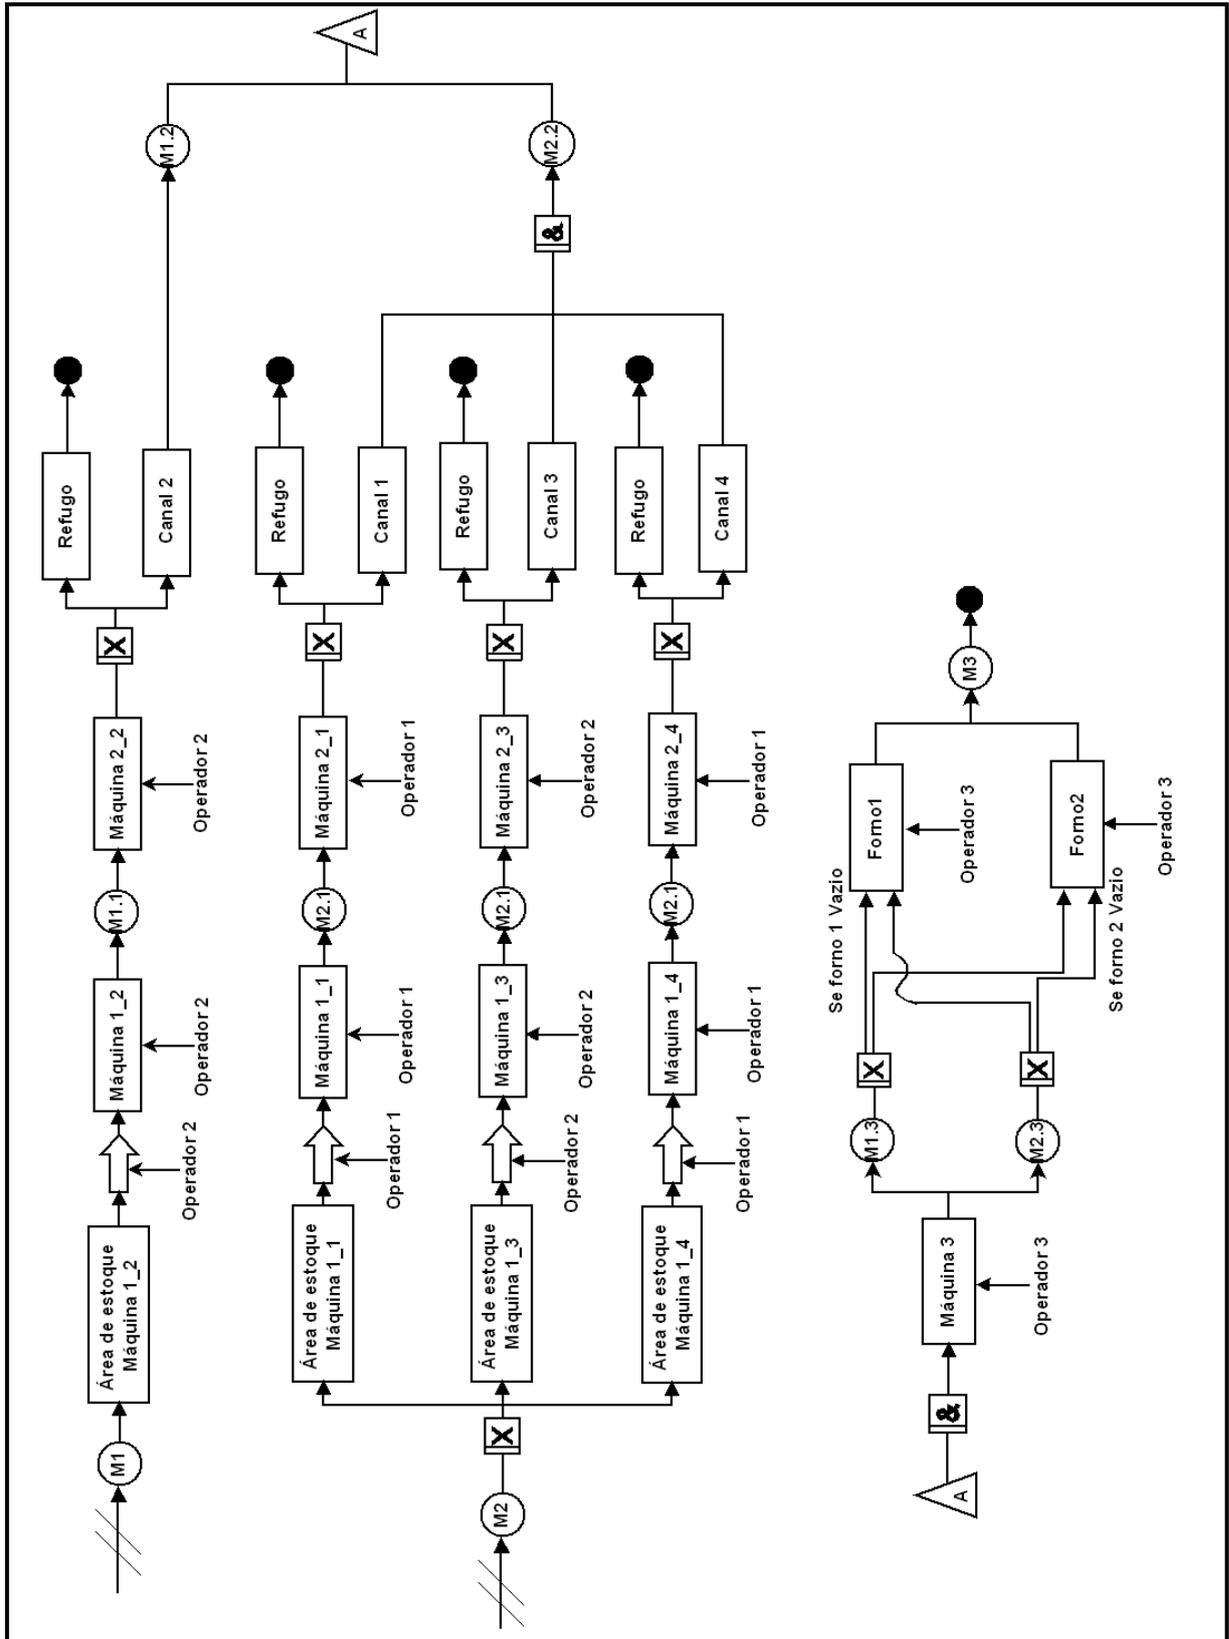


Figura 4.3 - Modelo conceitual para o primeiro objeto de estudo

O segundo modelo refere-se à uma célula de produção de uma empresa nacional de alta tecnologia produtora de equipamentos para a comunicação óptica. A célula de produção modelada é responsável pela produção de *transponders* de 2,5 Gb. As etapas de construção e validação desse modelo podem ser verificadas em Montevechi *et al.* (2008b).

Para esse objeto de estudo, foram definidas como variáveis de decisão: a quantidade de operadores na célula (x_1), o número de bancadas com *setup* (x_2), o número de bancadas sem *setup* (x_3) e se há ou não organização de material feita pela produção (x_4). Definiu-se que as três primeiras variáveis de decisão (quantidade de operadores na célula, número de bancadas com *setup*, número de bancadas sem *setup*) seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9. A quarta variável de decisão (se há ou não organização de material) foi determinada como sendo do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

A **Figura 4.4** ilustra o modelo implementado no *software ProModel®*, e a **Figura 4.5** apresenta o modelo conceitual através da técnica IDEF-SIM.

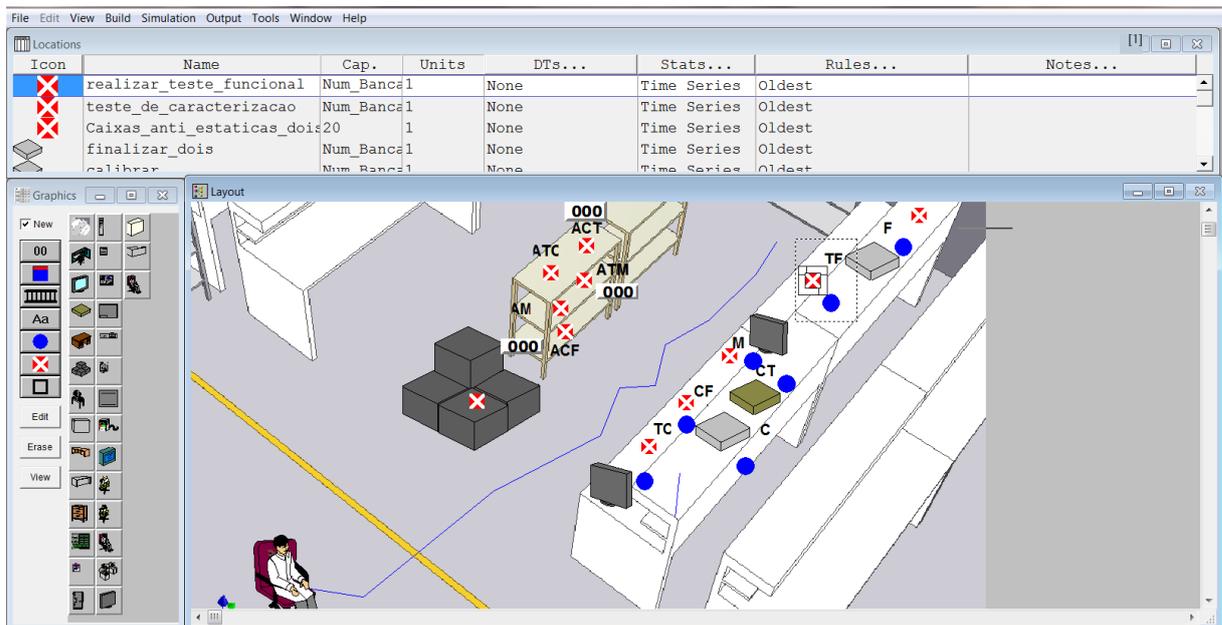


Figura 4.4 - Modelo implementado no *ProModel®* para o segundo objeto de estudo

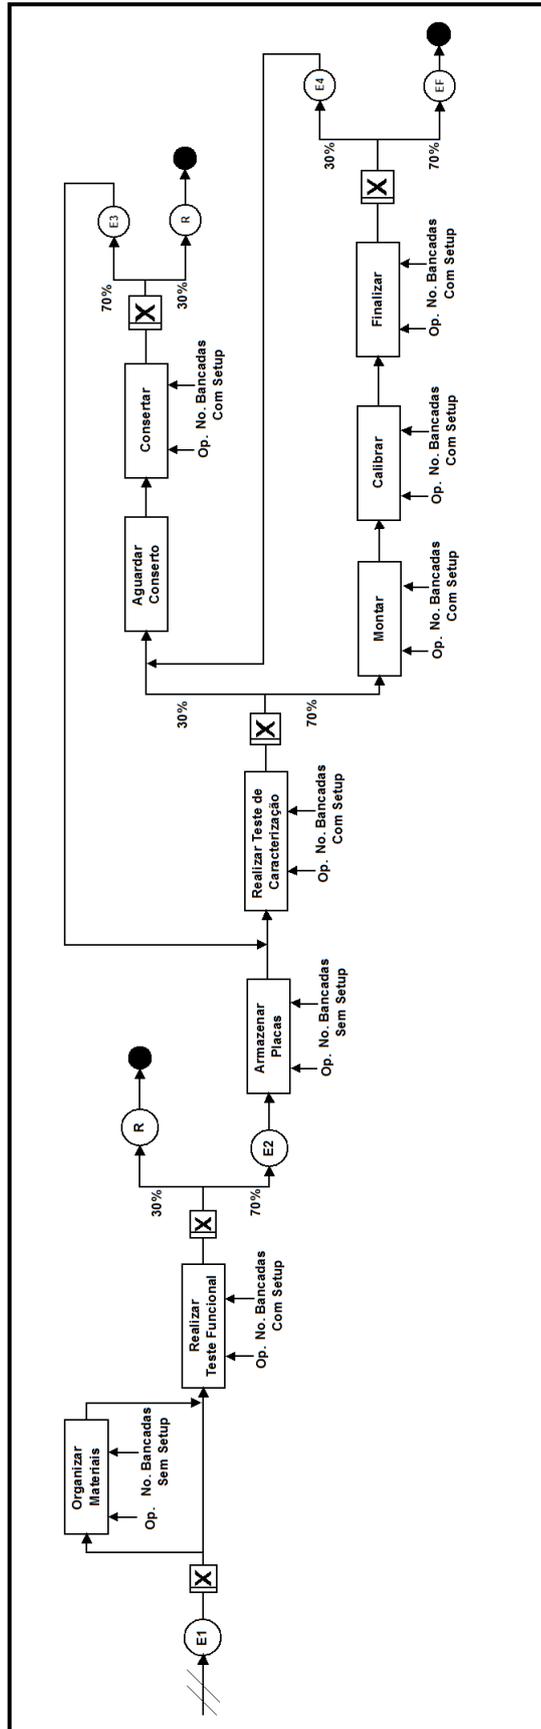


Figura 4.5 - Modelo conceitual para o segundo objeto de estudo

O terceiro modelo foi desenvolvido na mesma empresa do objeto de estudo apresentado anteriormente. A diferença foi a célula modelada. Nesse caso, o modelo de simulação representa a célula responsável pela produção do *transponder* de 10 Gb.

Para esse objeto de estudo foram definidas como variáveis de decisão: o número de bancadas com equipamentos (x_1), o número de bancadas sem equipamentos (x_2), a quantidade de operadores na célula (x_3), se há ou não organização de material feita pela produção (x_4) e se há ou não a atividade atualizar projeto (x_5). Definiu-se que as três primeiras variáveis de decisão (número de bancadas com equipamentos, número de bancadas sem equipamentos, quantidade de operadores na célula) seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9. A quarta e quinta variáveis de decisão (se há ou não organização de material e se há ou não a atividade atualizar projeto) foram determinadas como sendo do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há). A função objetivo contemplou um modelo quadrático com interações de segunda ordem. As etapas de construção e validação desse modelo podem ser verificadas em Montevechi *et al.* (2008b).

A **Figura 4.6** ilustra o modelo implementado no *software ProModel®*, e a **Figura 4.7** apresenta o modelo conceitual através da técnica IDEF-SIM.

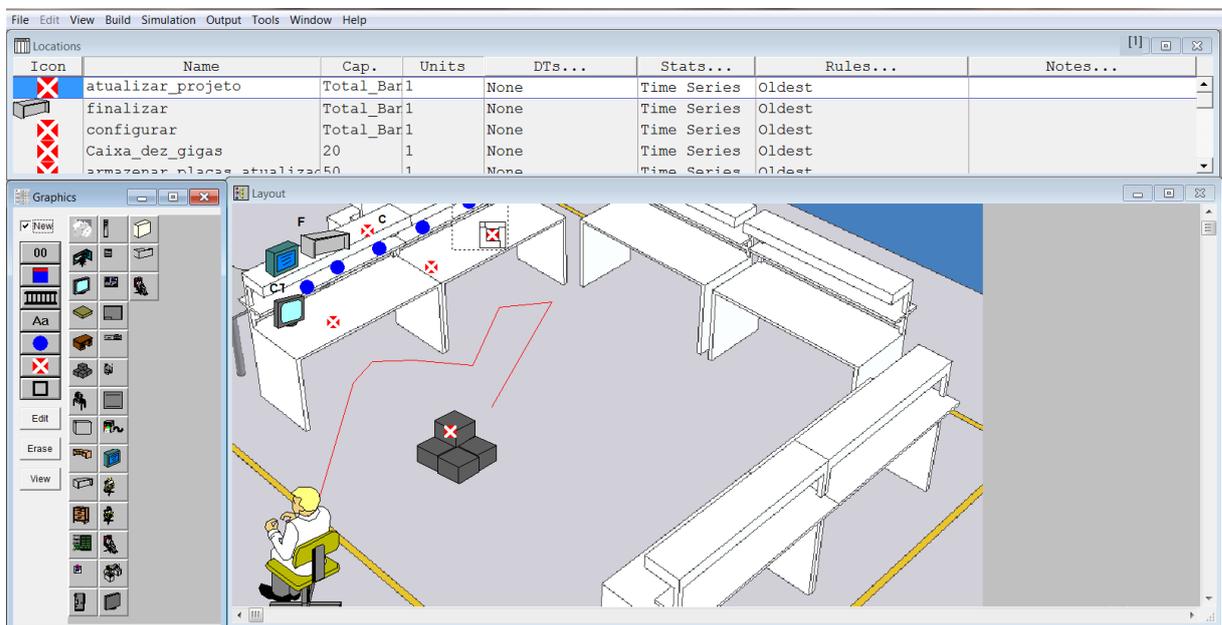


Figura 4.6 - Modelo implementado no *ProModel®* para o terceiro objeto de estudo

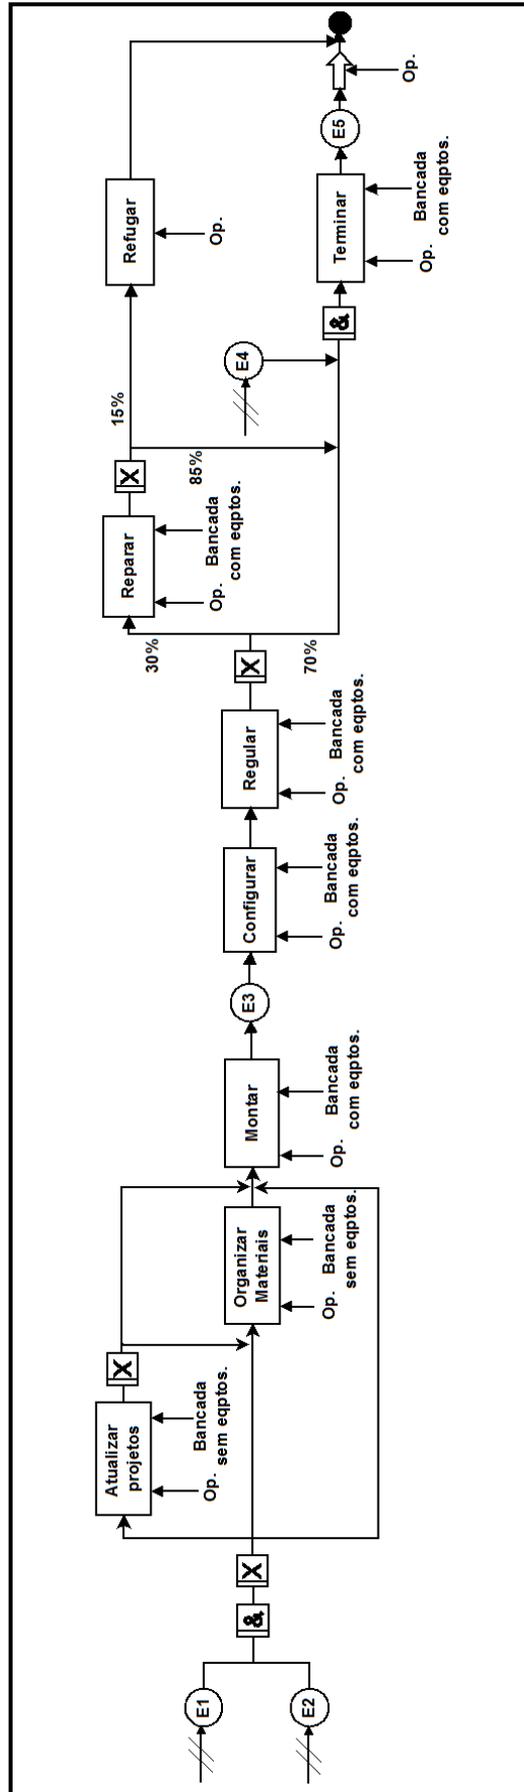


Figura 4.7 - Modelo conceitual para o terceiro objeto de estudo

4.2.2 Escolha dos fatores e dos níveis de trabalho

Foram selecionados quatro parâmetros do AG como fatores para experimentação. São eles: tamanho de população, número de gerações, taxa de *crossover* e taxa de mutação.

Todos esses parâmetros foram apresentados e discutidos no **Capítulo 3**. A escolha se deu devido ao fato de a literatura trazê-los como os principais parâmetros dos AG, influenciando diretamente no tempo necessário para se alcançar uma resposta, bem como para a qualidade da resposta alcançada. Para este experimento, optou-se em trabalhar com dois níveis para cada fator. Esses níveis e suas variações para cada fator são apresentados na **Tabela 4.1**.

Fatores	Níveis	
	-	+
A Tamanho de população	20	80
B Número de gerações	5	30
C Taxa de <i>crossover</i>	50%	90%
D Taxa de Mutação	1%	10%

Tabela 4.1 - Fatores, níveis e variações do projeto de experimentos

A escolha dos níveis foi realizada mediante um pré-teste realizado com o AG clássico na otimização de modelos de simulação e com base nos valores mais comumente encontrados na literatura.

4.2.3 Seleção das variáveis de resposta

Duas variáveis de resposta serão analisadas nesse projeto experimental. A primeira verificará a qualidade da resposta apresentada pelo AG clássico na otimização dos modelos de simulação, enquanto a segunda analisará o tempo necessário para que o algoritmo chegue à solução. Dessa forma, pretende-se verificar o impacto dos parâmetros escolhidos tanto na qualidade da resposta apresentada pelo AG como no tempo gasto para tal.

4.2.4 Escolha do projeto experimental

Para este trabalho, será utilizado o planejamento fatorial completo. Tal escolha se deve ao fato de que um fatorial completo permite estimar os efeitos principais dos fatores analisados, bem como quaisquer possíveis interações de qualquer ordem entre os fatores (MONTGOMERY, 2005).

Conforme apresentado no **Capítulo 3**, enquanto o número de fatores cresce linearmente, o número de experimentos em um fatorial completo cresce exponencialmente. Para o caso em

questão, com 4 fatores, tem-se um total de 16 experimentos a serem realizados ($2^4 = 16$) (PAIVA, 2008).

Para o projeto em questão, foram definidas 5 réplicas para cada experimento, totalizando 80 experimentos para cada modelo de simulação. Como serão utilizados 3 modelos de simulação para o estudo, ao final da etapa de realização dos experimentos ter-se-á um total de 240 experimentos realizados.

A **Tabela 4.2** apresenta a matriz experimental, onde os sinais - e + representam respectivamente os níveis inferior e superior dos fatores, como apresentado na **Tabela 4.1**.

Experimento	Tamanho da população	Número de gerações	Taxa de <i>Crossover</i>	Taxa de Mutação
1	-	-	-	-
2	+	-	-	-
3	-	+	-	-
4	+	+	-	-
5	-	-	+	-
6	+	-	+	-
7	-	+	+	-
8	+	+	+	-
9	-	-	-	+
10	+	-	-	+
11	-	+	-	+
12	+	+	-	+
13	-	-	+	+
14	+	-	+	+
15	-	+	+	+
16	+	+	+	+

Tabela 4.2 - Matriz experimental

4.2.5 Realização dos experimentos

Para a realização dos experimentos, foi necessário desenvolver uma ferramenta computacional. Para tal, foi implementado um AG em sua forma clássica, tal como preconizado em sua criação. Tomou-se o cuidado de permitir que os parâmetros sob análise (tamanho da população, número de gerações, taxa de *crossover* e taxa de mutação) fossem facilmente manipulados pelo pesquisador.

À exceção dos parâmetros do AG, todos os demais componentes do algoritmo permaneceram constante durante toda experimentação, garantindo, assim, a mesma estrutura básica a todos os experimentos. Com relação aos parâmetros do AG, estes foram se alterando conforme a matriz experimental apresentada na **Tabela 4.2**.

Os resultados encontrados para cada experimento, realizado em cada um dos três modelos de simulação, são apresentados nas **Tabelas 4.3, 4.4, 4.5, 4.6, 4.7 e 4.8**. Os dados coletados referem-se ao resultado da otimização dos modelos (valor da função objetivo) e o tempo necessário para convergência do algoritmo. Cada uma das tabelas apresenta os resultados das 5 réplicas realizadas em cada modelo.

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Solução 1	Solução 2	Solução 3	Solução 4	Solução 5
1	-	-	-	-	497400	513000	492400	506100	490000
2	+	-	-	-	506600	513000	511400	506100	507300
3	-	+	-	-	493500	513000	511400	498600	503800
4	+	+	-	-	506600	513000	511400	506100	520300
5	-	-	+	-	497400	492400	494800	498000	503800
6	+	-	+	-	506600	506400	511400	506100	507300
7	-	+	+	-	506600	506400	511400	506100	503800
8	+	+	+	-	506600	513000	511400	506100	520000
9	-	-	-	+	492400	492400	511400	506100	520000
10	+	-	-	+	506600	513000	511400	506100	506600
11	-	+	-	+	506600	506400	511400	498600	520300
12	+	+	-	+	506600	513000	511400	506100	520300
13	-	-	+	+	506600	506400	494800	506100	506600
14	+	-	+	+	506600	506400	511400	506100	507300
15	-	+	+	+	506600	513000	511400	506100	520300
16	+	+	+	+	506600	513000	511400	506100	520300

Tabela 4.3 - Resultados da otimização do primeiro modelo de simulação

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Tempo 1 (Seg)	Tempo 2 (Seg)	Tempo 3 (Seg)	Tempo 4 (Seg)	Tempo 5 (Seg)
1	-	-	-	-	573	582	595	579	582
2	+	-	-	-	2366	2372	2309	2266	2372
3	-	+	-	-	3588	3487	3381	3609	3546
4	+	+	-	-	13831	13763	13347	13179	13581
5	-	-	+	-	568	602	588	570	584
6	+	-	+	-	2320	2360	2337	2345	2389
7	-	+	+	-	3589	3559	3372	3345	3423
8	+	+	+	-	13369	13903	13388	13147	13751
9	-	-	-	+	568	593	566	573	594
10	+	-	-	+	2321	2379	2326	2386	2428
11	-	+	-	+	3328	3407	3331	3598	3572
12	+	+	-	+	13092	13641	13227	13567	13989
13	-	-	+	+	577	570	572	573	571
14	+	-	+	+	2357	2340	2311	2365	2284
15	-	+	+	+	3345	3766	3306	3378	3419
16	+	+	+	+	13503	13938	13298	13064	13329

Tabela 4.4 - Tempo necessário para convergência do primeiro modelo de simulação

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Solução 1	Solução 2	Solução 3	Solução 4	Solução 5
1	-	-	-	-	2900	3200	1700	2300	3100
2	+	-	-	-	2900	3200	3100	3600	3500
3	-	+	-	-	3600	3500	1400	2000	2400
4	+	+	-	-	4400	3400	3300	4200	3500
5	-	-	+	-	2400	2700	3500	3900	2700
6	+	-	+	-	3700	3500	3500	3600	3900
7	-	+	+	-	2900	2200	1800	3200	3300
8	+	+	+	-	3300	3500	3200	3500	3500
9	-	-	-	+	2500	3500	3200	3400	2200
10	+	-	-	+	4200	3500	3500	3600	3800
11	-	+	-	+	3500	3500	3200	2500	2900
12	+	+	-	+	4100	3500	3300	3300	3900
13	-	-	+	+	3500	2500	3500	3100	1900
14	+	-	+	+	4500	3500	3500	3200	3700
15	-	+	+	+	2600	2700	3100	3500	3900
16	+	+	+	+	3400	3500	3500	3600	4000

Tabela 4.5 - Resultados da otimização do segundo modelo de simulação

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Tempo 1 (Seg)	Tempo 2 (Seg)	Tempo 3 (Seg)	Tempo 4 (Seg)	Tempo 5 (Seg)
1	-	-	-	-	412	418	423	438	526
2	+	-	-	-	1685	1673	1653	1697	1699
3	-	+	-	-	2609	2562	2541	2723	2514
4	+	+	-	-	10231	10432	10277	10397	10104
5	-	-	+	-	432	414	407	477	420
6	+	-	+	-	1690	1648	1650	1655	1667
7	-	+	+	-	2544	2594	2455	2423	2475
8	+	+	+	-	10231	9916	9962	10194	10208
9	-	-	-	+	418	404	425	418	407
10	+	-	-	+	1683	1661	1663	1678	1701
11	-	+	-	+	2525	2474	2525	2562	2462
12	+	+	-	+	9994	10053	10080	10116	10032
13	-	-	+	+	414	409	407	415	458
14	+	-	+	+	1658	1640	1765	1631	1651
15	-	+	+	+	2648	2584	2543	2832	2558
16	+	+	+	+	10148	10215	10181	10065	10150

Tabela 4.6 - Tempo necessário para convergência do segundo modelo de simulação

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Solução 1	Solução 2	Solução 3	Solução 4	Solução 5
1	-	-	-	-	28975	28130	29230	28575	27650
2	+	-	-	-	29525	28695	31375	29220	29375
3	-	+	-	-	28975	28305	29950	28575	28720
4	+	+	-	-	29525	28695	29330	28925	29375
5	-	-	+	-	28225	27620	28625	29305	28730
6	+	-	+	-	28975	28695	28200	27675	28775
7	-	+	+	-	27945	27020	28075	29305	29375
8	+	+	+	-	28975	28695	30305	30320	29375
9	-	-	-	+	28975	28695	29375	29795	28775
10	+	-	-	+	29525	28305	30475	28530	29375
11	-	+	-	+	28975	28275	29525	28895	28695
12	+	+	-	+	29575	28695	28775	28525	29375
13	-	-	+	+	28625	26920	30425	30030	29375
14	+	-	+	+	29575	28695	30305	29405	28730
15	-	+	+	+	27945	28305	30025	29825	29375
16	+	+	+	+	29575	28695	28775	28850	29375

Tabela 4.7 - Resultados da otimização do terceiro modelo de simulação

Exp	Tam. população	No. de gerações	Taxa de Crossover	Taxa de Mutação	Tempo 1 (Seg)	Tempo 2 (Seg)	Tempo 3 (Seg)	Tempo 4 (Seg)	Tempo 5 (Seg)
1	-	-	-	-	471	435	472	420	482
2	+	-	-	-	1843	2008	1688	1707	1956
3	-	+	-	-	2643	2675	2622	2597	2549
4	+	+	-	-	10383	10258	10611	10272	10358
5	-	-	+	-	429	456	436	452	475
6	+	-	+	-	1737	1715	1789	2051	1746
7	-	+	+	-	2787	2623	3192	2684	2689
8	+	+	+	-	10450	10705	10638	10385	10582
9	-	-	-	+	457	461	462	428	438
10	+	-	-	+	2004	2017	1751	1727	2347
11	-	+	-	+	2578	3089	3135	2567	2720
12	+	+	-	+	10630	10580	10404	10331	10489
13	-	-	+	+	434	436	433	434	462
14	+	-	+	+	1744	1727	2029	1723	1715
15	-	+	+	+	2704	2546	2639	2570	2540
16	+	+	+	+	10549	10531	10536	10483	10758

Tabela 4.8 - Tempo necessário para convergência do terceiro modelo de simulação

4.2.6 Análise estatística dos dados

Toda a análise estatística foi conduzida com auxílio do *software Minitab*® 15. Antes de iniciar a análise estatística dos dados obtidos, foi necessário realizar a análise dos resíduos. Segundo Montgomery (2005), os resíduos devem ser normais, aleatórios e não

correlacionados. Desta forma, para cada um dos seis experimentos realizados, foi necessário testar se tais condições foram atendidas.

Para todos os casos, foi possível alcançar tais condições. A questão da aleatoriedade e o fato dos resíduos não estarem correlacionados foram facilmente verificados por meio de cartas de controle, geradas pelo *Minitab*®, onde não foram observados nenhum padrão não-aleatório, de agrupamento ou tendencioso por parte dos resíduos. A normalidade dos resíduos foi verificada por meio de testes de normalidade, onde, após a retirada dos *outliers* das amostras analisadas, pode-se verificar a normalidade dos resíduos analisados nos seis experimentos.

A seguir, apresenta-se a análise estatística dos dados dos três modelos de simulação otimizados.

4.2.6.1 Análise estatística do primeiro modelo

Uma vez assegurada a validade dos resíduos, podem-se analisar estatisticamente os resultados do DOE para todos os modelos otimizados para as variáveis de resposta Solução e Tempo. A **Tabela 4.9** apresenta a análise de variâncias (ANOVA) para a variável de resposta Solução considerando um nível de significância $\alpha = 0,05$.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média Quadrática	F	P-Value
Efeitos Principais	4	1146940500	286735125	7,42	< 0,001
Interações 2a. Ordem	6	231833500	38638917	1	0,433
Interações 3a. Ordem	4	16035500	4008875	0,1	0,981
Interações 4a. Ordem	1	1300500	1300500	0,03	0,855
Erro residual	64	2472228000	38628563		
Total	79	3868338000			

Tabela 4.9 - Análise de variâncias para a resposta Solução

Pode-se constatar que as interações de segunda, terceira e quarta ordens podem ser desconsideradas para a resposta Solução, uma vez que os *P-Values* da ANOVA ficaram acima do nível de significância ($\alpha = 0,05$), mostrando que essas interações não são significativas para que o algoritmo encontre uma solução de elevada qualidade.

A análise dos efeitos principais de cada fator, apresentada na **Figura 4.8**, mostra que os fatores tamanho de população, número de gerações e taxa de mutação possuem efeitos positivos sobre a resposta final. Isso significa que a alteração do nível (-) para o nível (+) aumenta a qualidade da solução obtida pelo algoritmo genético na otimização do modelo de simulação.

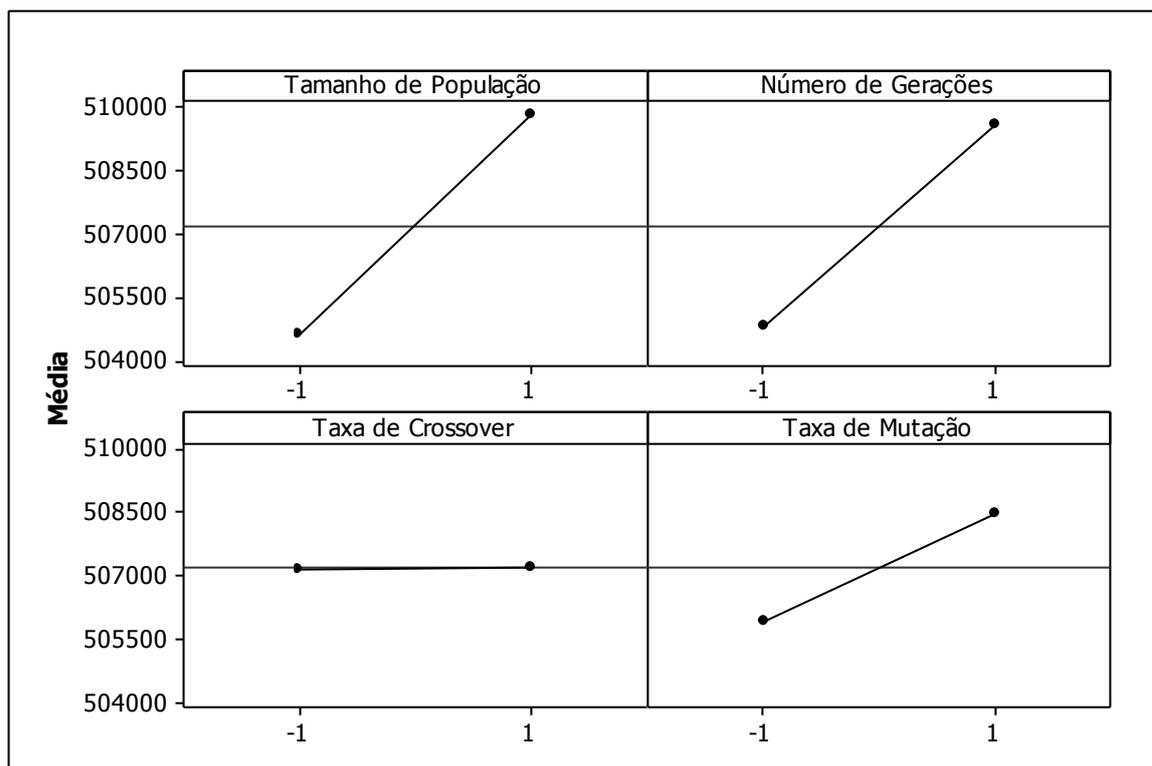


Figura 4.8 - Gráfico dos efeitos principais para Solução

O peso dos efeitos dos fatores e suas interações na qualidade da solução obtida pelo AG pode ser visualizada através do gráfico de Pareto apresentado na **Figura 4.9**. Pela análise desse gráfico, verifica-se que apenas os fatores tamanho de população (A) e número de gerações (B) possuem efeitos significativos para a qualidade da solução apresentada.

Destaca-se também, que os demais fatores principais (taxa de *crossover* e taxa de mutação) não foram significativos ao nível de confiança de 95%. Como já apresentado pelos resultados da ANOVA, o gráfico de Pareto reforça que nenhuma interação entre os fatores principais mostrou-se significativa.

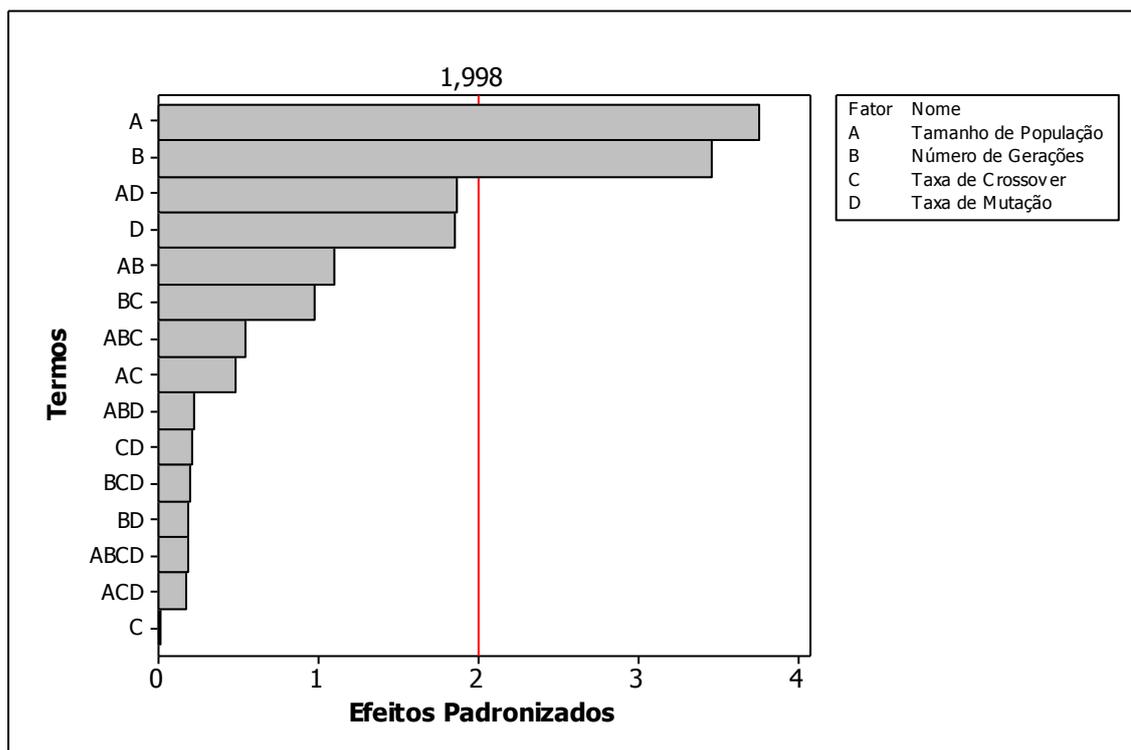


Figura 4.9 - Gráfico de Pareto dos efeitos padronizados para Solução

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto da **Figura 4.9** pode ser facilmente comprovada pela análise da **Tabela 4.10**. Nesta tabela, todos os termos com *P-Value* < 0,05 são significativos, ou seja, exercem influência na variável de resposta solução. Os demais termos são considerados não significativos para o nível de significância adotado ($\alpha = 0,05$).

Termo	Efeito	Coefficiente	ErroCoeficiente	T	P-Value
A	5240	2620	694,9	3,77	< 0,001
B	4820	2410	694,9	3,47	0,001
C	25	13	694,9	0,02	0,986
D	2580	1290	694,9	1,86	0,068
AB	-1540	-770	694,9	-1,11	0,272
AC	-665	-332	694,9	-0,48	0,634
AD	-2600	-1300	694,9	-1,87	0,066
BC	1365	682	694,9	0,98	0,33
BD	-260	-130	694,9	-0,19	0,852
CD	295	147	694,9	0,21	0,833
ABC	-755	-377	694,9	-0,54	0,589
ABD	310	155	694,9	0,22	0,824
ACD	-245	-123	694,9	-0,18	0,861
BCD	-275	-138	694,9	-0,2	0,844
ABCD	255	128	694,9	0,18	0,855

Tabela 4.10 - Efeitos estimados e coeficientes para Solução

Com relação aos resultados da análise de variâncias para a variável de resposta Tempo, essa pode ser visualizada na **Tabela 4.11**. Assim como para a análise da resposta Solução, foi considerado um nível de confiança de 95%.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média quadrática	F	P-Value
Efeitos Principais	4	1680910057	420227514	13965,82	< 0,001
Interações 2a. Ordem	6	341180664	56863444	1889,8	< 0,001
Interações 3a. Ordem	4	9811	2453	0,08	0,988
Interações 4a. Ordem	1	1320	1320	0,04	0,835
Erro residual	64	1925742	30090		
Total	79	2024027594			

Tabela 4.11 - Análise de Variâncias para a resposta Tempo

Ao contrário do caso anterior, em que nenhuma interação mostrou-se significativa para a varável Tempo as interações de segunda ordem mostraram-se significativas. No entanto, as interações de terceira e quarta ordens continuaram a ser não significativas, uma vez que os *P-Values* da ANOVA ficaram acima do nível de significância ($\alpha = 0,05$).

A análise dos efeitos principais, apresentada na **Figura 4.10**, mostra que os fatores tamanho da população e número de gerações possuem efeito positivo sobre a resposta final. Isso significa que a alteração do nível (-) para o nível (+) aumenta o tempo necessário para que o AG chegue a uma solução.

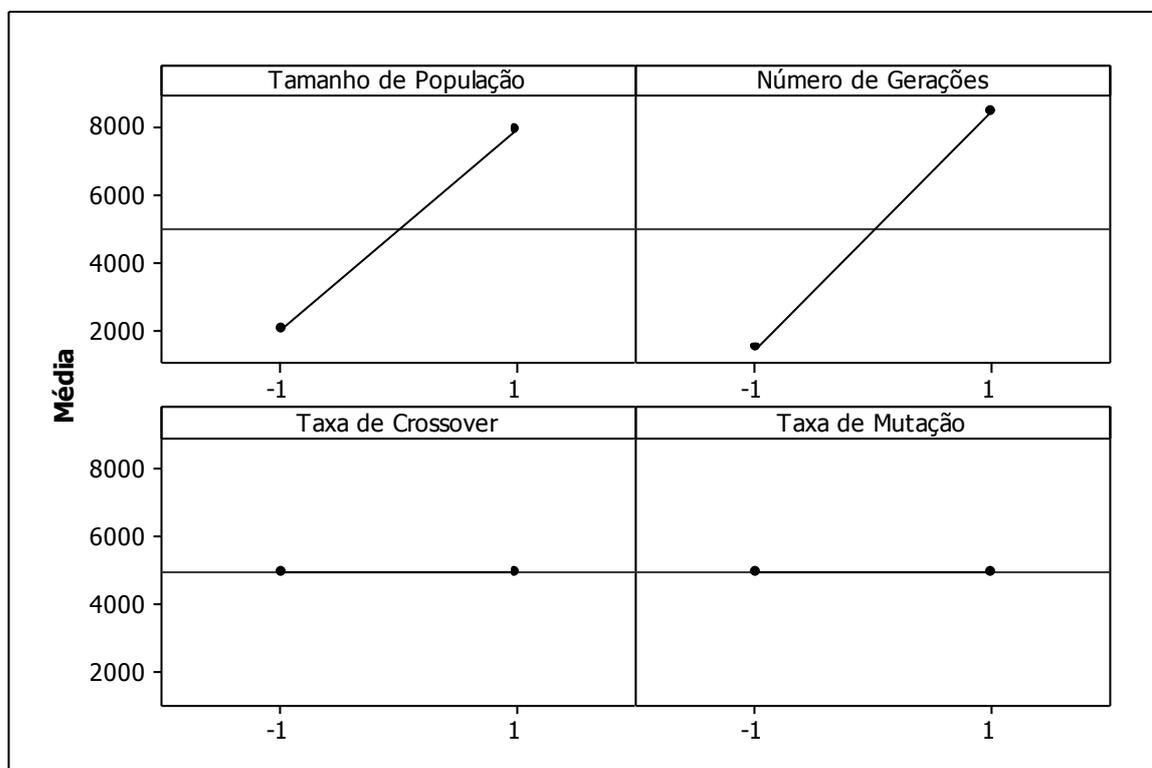


Figura 4.10 - Gráfico dos efeitos principais para Tempo

O peso dos efeitos dos fatores e suas interações no tempo necessário para o AG convergir para uma solução pode ser visualizado através do gráfico de Pareto apresentado na **Figura 4.11**. Pela análise desse gráfico, verifica-se que os fatores tamanho de população (A) e número de gerações (B), bem como a interação dupla entre esses dois fatores principais (AB), possuem efeitos significativos no tempo para convergência do algoritmo.

Destaca-se também, que os demais fatores principais (taxa de *crossover* e taxa de mutação) e outras interações de segunda, terceira e quarta ordens não foram significativos ao nível de confiança de 95%.

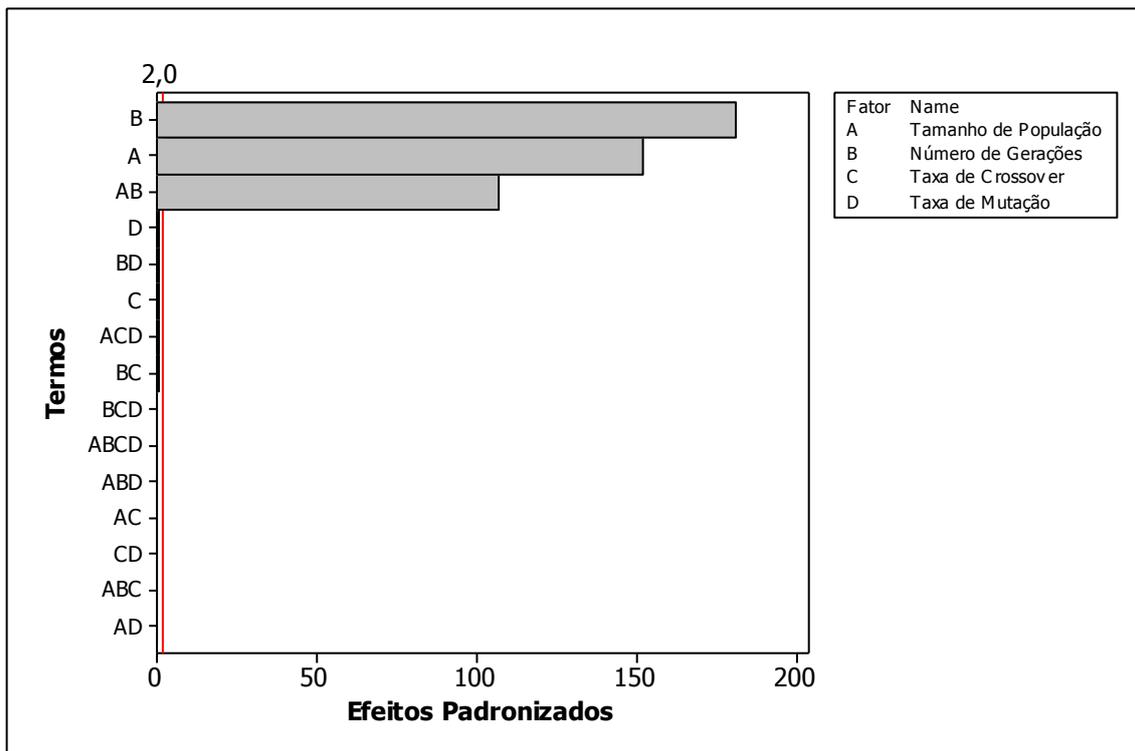


Figura 4.11 - Gráfico de Pareto dos efeitos padronizados para Tempo

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto dos efeitos padronizados da **Figura 4.11** pode ser facilmente comprovada pela análise da **Tabela 4.12**. As mesmas considerações feitas para a interpretação da **Tabela 4.10** são válidas para a interpretação da **Tabela 4.12**.

Termo	Efeito	Coefficiente	Erro Coeficiente	T	P-Value
A	5897,78	2948,89	19,39	152,05	< 0,001
B	7018,57	3509,29	19,39	180,95	< 0,001
C	-25,47	-12,74	19,39	-0,66	0,514
D	-26,62	-13,31	19,39	-0,69	0,495
AB	4130,12	2065,06	19,39	106,48	< 0,001
AC	-6,73	-3,36	19,39	-0,17	0,863
AD	-0,88	-0,44	19,39	-0,02	0,982
BC	-18,12	-9,06	19,39	-0,47	0,642
BD	-26,37	-13,19	19,39	-0,68	0,499
CD	-5,53	-2,76	19,39	-0,14	0,887
ABC	-2,37	-1,19	19,39	-0,06	0,951
ABD	-7,22	-3,61	19,39	-0,19	0,853
ACD	-18,98	-9,49	19,39	-0,49	0,626
BCD	8,52	4,26	19,39	0,22	0,827
ABCD	-8,13	-4,06	19,39	-0,21	0,835

Tabela 4.12 - Efeitos estimados e coeficientes para Tempo

4.2.6.2 Análise estatística do segundo modelo

Toda a análise estatística conduzida para o primeiro modelo foi replicada na análise do segundo modelo. A **Tabela 4.13** apresenta a análise de variâncias para a variável de resposta Solução considerando um nível de confiança de 95%.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média Quadrática	F	P-Value
Efeitos Principais	4	10830500	2707625	10,01	< 0,001
Interações 2a. Ordem	6	641500	106917	0,4	0,879
Interações 3a. Ordem	4	1077500	269375	1	0,416
Interações 4a. Ordem	1	40500	40500	0,15	0,700
Erro residual	64	17312000	270500		
Total	79	29902000			

Tabela 4.13 - Análise de Variâncias para a resposta Solução

Assim como na análise da variável de resposta Solução do primeiro modelo, nenhuma interação de segunda, terceira e quarta ordens mostraram-se significativas, uma vez que os *P-Values* da ANOVA foram superiores ao nível de significância ($\alpha = 0,05$), mostrando que essas interações não são significativas para que o algoritmo encontre uma solução de elevada qualidade. Nesse caso, apenas os efeitos principais mostraram-se significativos (*P-Values* < 0,05).

A análise dos efeitos principais, apresentada na **Figura 4.12**, mostra que todos os fatores principais apresentam efeito positivo sobre a resposta final. Para esse caso os fatores

tamanho de população e taxa de mutação possuem um efeito mais acentuado para a qualidade de resposta que os demais fatores. Esse efeito faz com que a alteração do nível (-) para o nível (+) aumente a qualidade da resposta alcançada pelo AG na otimização do modelo de simulação.

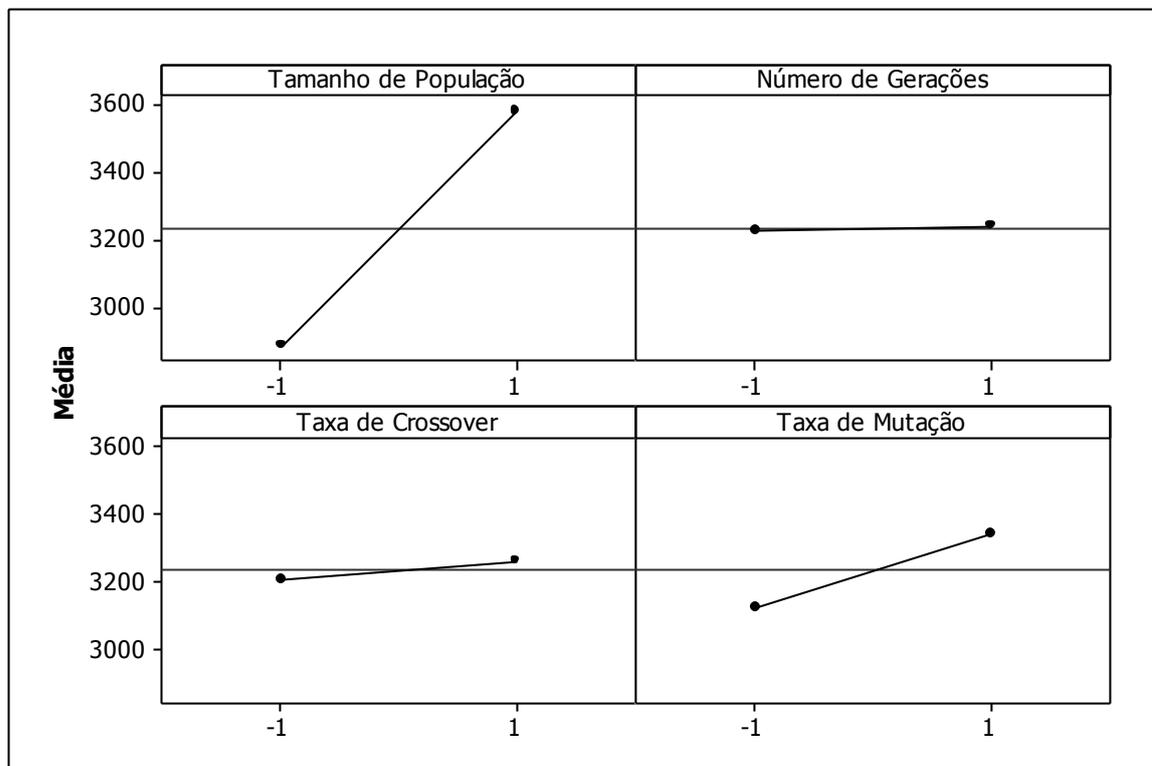


Figura 4.12 - Gráfico dos efeitos principais para Solução

O gráfico de Pareto, apresentado na **Figura 4.13**, apresenta o peso dos efeitos dos fatores e suas interações para a qualidade da solução obtida pelo AG.

Como já apresentado pelos resultados da ANOVA, nenhuma interação entre os fatores mostrou-se significativa para qualidade de resposta, e, dentre os fatores principais, apenas o fator tamanho de população (A) mostrou-se significativo para a qualidade da solução apresentada. Nesse sentido, quanto maior o tamanho da população, melhor a qualidade da resposta encontrada pelo algoritmo.

Destaca-se também, que os demais fatores principais (número de gerações - B, taxa de *crossover* - C e taxa de mutação - D) não foram significativos ao nível de confiança de 95%. Como já apresentado pelos resultados da ANOVA, o gráfico de Pareto reforça que nenhuma interação entre os fatores principais mostrou-se significante.

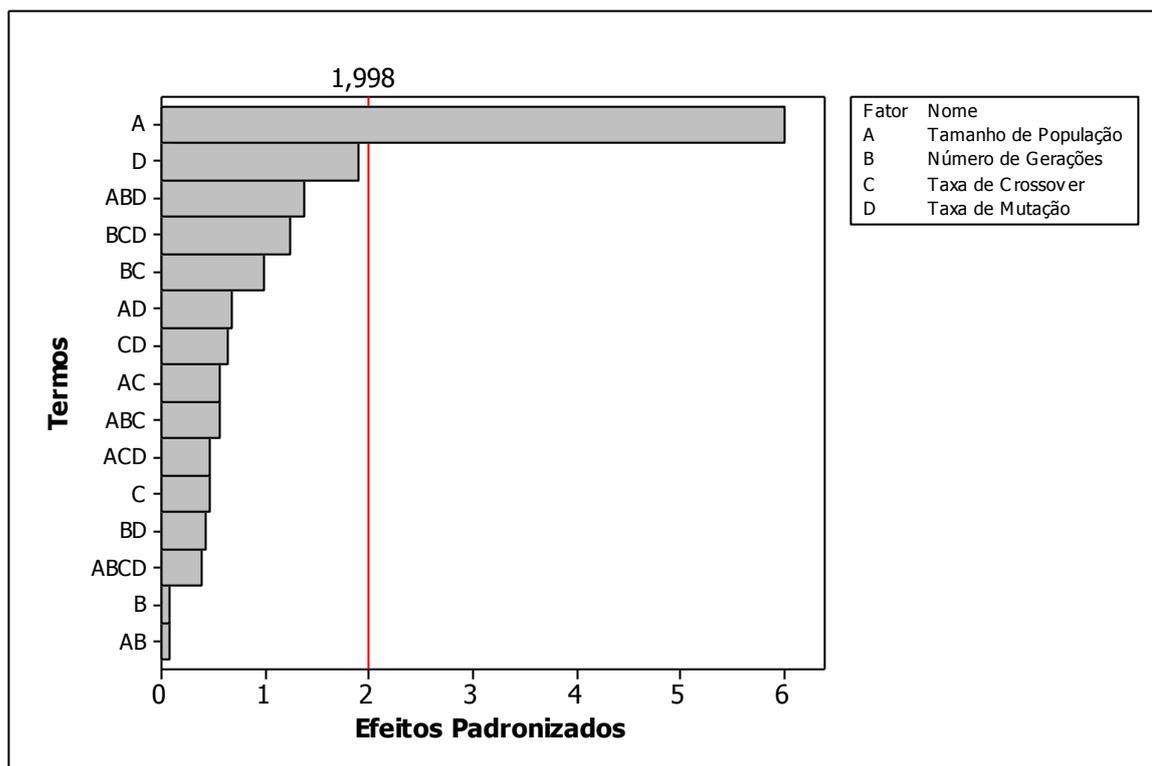


Figura 4.13 - Gráfico de Pareto dos efeitos padronizados para Solução

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto dos efeitos padronizados da **Figura 4.13** pode ser facilmente comprovada pela análise da **Tabela 4.14**.

Termo	Efeito	Coefficiente	Erro Coeficiente	T	P-Value
A	700	350	58,15	6,02	< 0,001
B	10	5	58,15	0,09	0,932
C	55	27,5	58,15	0,47	0,638
D	220	110	58,15	1,89	0,063
AB	10	5	58,15	0,09	0,932
AC	-65	-32,5	58,15	-0,56	0,578
AD	-80	-40	58,15	-0,69	0,494
BC	-115	-57,5	58,15	-0,99	0,326
BD	50	25	58,15	0,43	0,669
CD	-75	-37,5	58,15	-0,64	0,521
ABC	-65	-32,5	58,15	-0,56	0,578
ABD	-160	-80	58,15	-1,38	0,174
ACD	55	27,5	58,15	0,47	0,638
BCD	145	72,5	58,15	1,25	0,217
ABCD	45	22,5	58,15	0,39	0,700

Tabela 4.14 - Efeitos estimados e coeficientes para Solução

Com relação aos resultados da análise de variância do segundo modelo otimizado para a variável de resposta Tempo, essa pode ser visualizada na **Tabela 4.15**. Assim como nos casos

anteriores, foi considerado um nível de confiança de 95%.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média Quadrática	F	P-Value
Efeitos Principais	4	953059527	238264882	47627,26	< 0,001
Interações 2a. Ordem	6	201489371	33581562	6712,69	< 0,001
Interações 3a. Ordem	4	96813	24203	4,84	0,002
Interações 4a. Ordem	1	1815	1815	0,36	0,549
Erro residual	64	320173	5003		
Total	79	1154967699			

Tabela 4.15 - Análise de Variâncias para a resposta Tempo

Para esse cenário, pode-se verificar que as interações de segunda e terceira ordens mostraram-se significativas, bem como os efeitos principais. Apenas as interações de quarta ordem não foram significativas para o nível de significância adotado.

A análise dos efeitos principais, apresentada na **Figura 4.14**, mostra que os fatores tamanho de população e número de gerações possuem efeito positivo sobre o tempo necessário para a convergência do algoritmo. Isso significa que a alteração do nível (-) para o nível (+) acarreta em um aumento no tempo necessário para convergência do algoritmo.

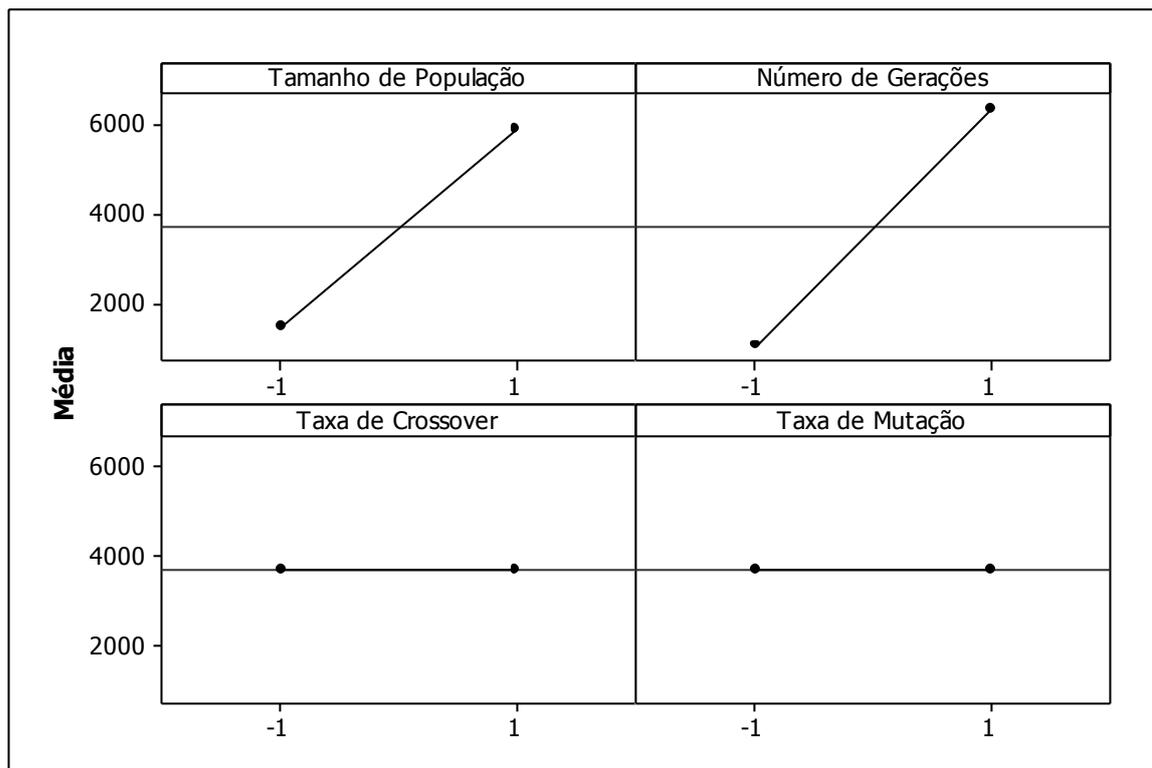


Figura 4.14 - Gráfico dos efeitos principais para Tempo

A **Figura 4.15** apresenta o peso dos efeitos dos fatores e suas interações no tempo necessário para o AG convergir. Pela análise desse gráfico, verifica-se que os fatores principais número de gerações (B) e tamanho de população (A) são significativos para o nível

de significância adotado. As interações duplas ente esses fatores (AB) e as interações entre os fatores taxa de *crossover* e taxa de mutação (CD) também se mostraram significativas, bem como as interações triplas: número de gerações, taxa de *crossover* e taxa de mutação (BCD); e tamanho de população, número de gerações e taxa de mutação (ABD). Todas essas interações possuem efeitos significativos no tempo para convergência do algoritmo.

Vale ressaltar que os demais fatores principais (taxa de *crossover* - C e taxa de mutação - D) e outras interações de segunda, terceira e quarta ordens não foram significativos ao nível de confiança de 95%.

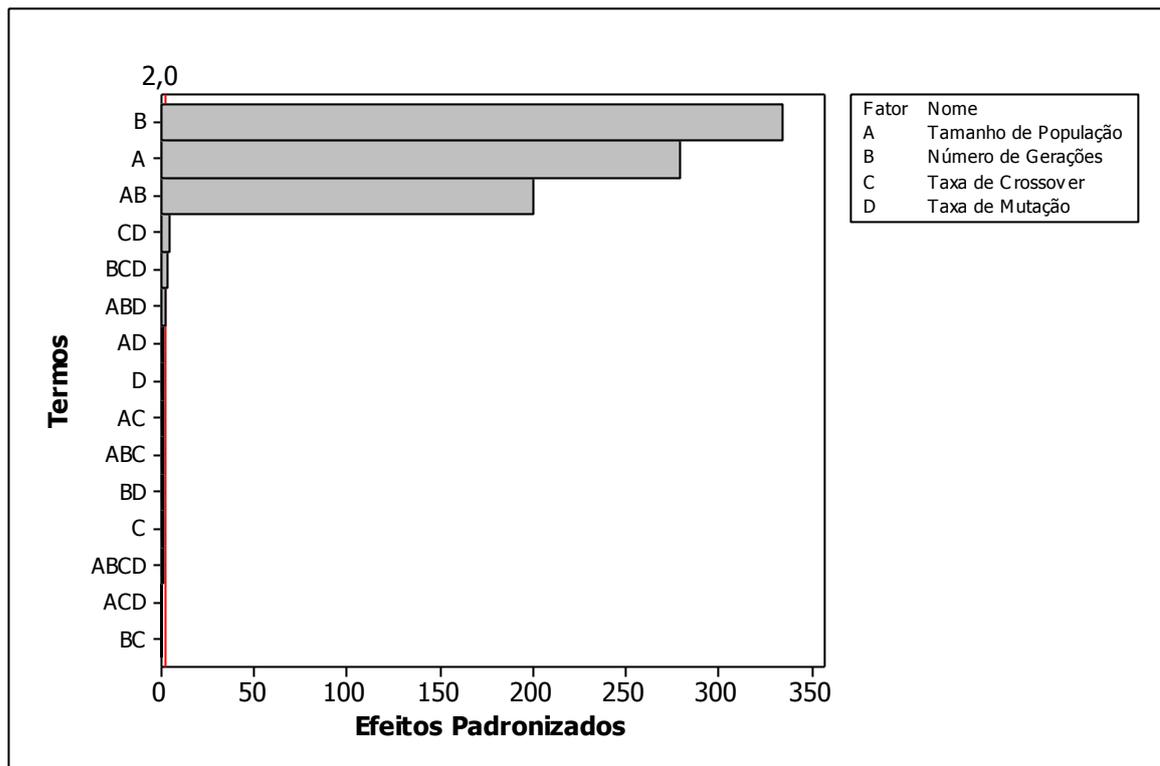


Figura 4.15 - Gráfico de Pareto dos efeitos padronizados para Tempo

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto dos efeitos padronizados da **Figura 4.15** pode ser facilmente comprovada pela análise da **Tabela 4.16**.

Termo	Efeito	Coefficiente	Erro Coeficiente	T	P-Value
A	4418,48	2209,24	7,908	279,37	< 0,001
B	5303,72	2651,86	7,908	335,35	< 0,001
C	-11,52	-5,76	7,908	-0,73	0,469
D	-20,57	-10,29	7,908	-1,3	0,198
AB	3173,17	1586,59	7,908	200,64	< 0,001
AC	-17,68	-8,84	7,908	-1,12	0,268
AD	-24,63	-12,31	7,908	-1,56	0,124
BC	-2,82	-1,41	7,908	-0,18	0,859
BD	-11,67	-5,84	7,908	-0,74	0,463
CD	66,07	33,04	7,908	4,18	< 0,001
ABC	-12,57	-6,29	7,908	-0,8	0,429
ABD	-34,92	-17,46	7,908	-2,21	0,031
ACD	7,42	3,71	7,908	0,47	0,64
BCD	58,38	29,19	7,908	3,69	< 0,001
ABCD	9,53	4,76	7,908	0,6	0,549

Tabela 4.16 - Efeitos estimados e coeficientes para Tempo

4.2.6.3 Análise estatística do terceiro modelo

Por fim, a análise estatística foi aplicada aos resultados da otimização do terceiro modelo de simulação. A análise de variância para a variável de resposta solução pode ser visualizada na *Tabela 4.17*.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média Quadrática	F	P-Value
Efeitos Principais	4	4093121	1023280	1,83	0,134
Interações 2a. Ordem	6	3577929	596322	1,07	0,392
Interações 3a. Ordem	4	1330271	332568	0,6	0,667
Interações 4a. Ordem	1	1789515	1789515	3,2	0,078
Erro residual	64	35765100	558830		
Total	79	46555937			

Tabela 4.17 - Análise de Variâncias para a resposta Solução

Ao contrário do que ocorreu nas análises anteriores, nem os efeitos principais nem a interação entre os fatores (de qualquer ordem) mostraram-se significativos ao nível de confiança adotado para condução da análise estatística ($\alpha = 0,05$).

A análise dos efeitos principais, apresentada na *Figura 4.16*, mostra que os fatores principais tamanho de população, número de gerações e taxa de mutação apresentam efeito positivo sobre a resposta final, sendo o efeito do fator número de gerações muito pequeno quando comparado aos demais fatores principais. Já, o fator taxa de *crossover* apresentou um efeito negativo sobre a resposta final.

Esse efeito faz com que a alteração do nível (-) para o nível (+) diminua a qualidade da

resposta alcançada pelo AG na otimização do modelo de simulação.

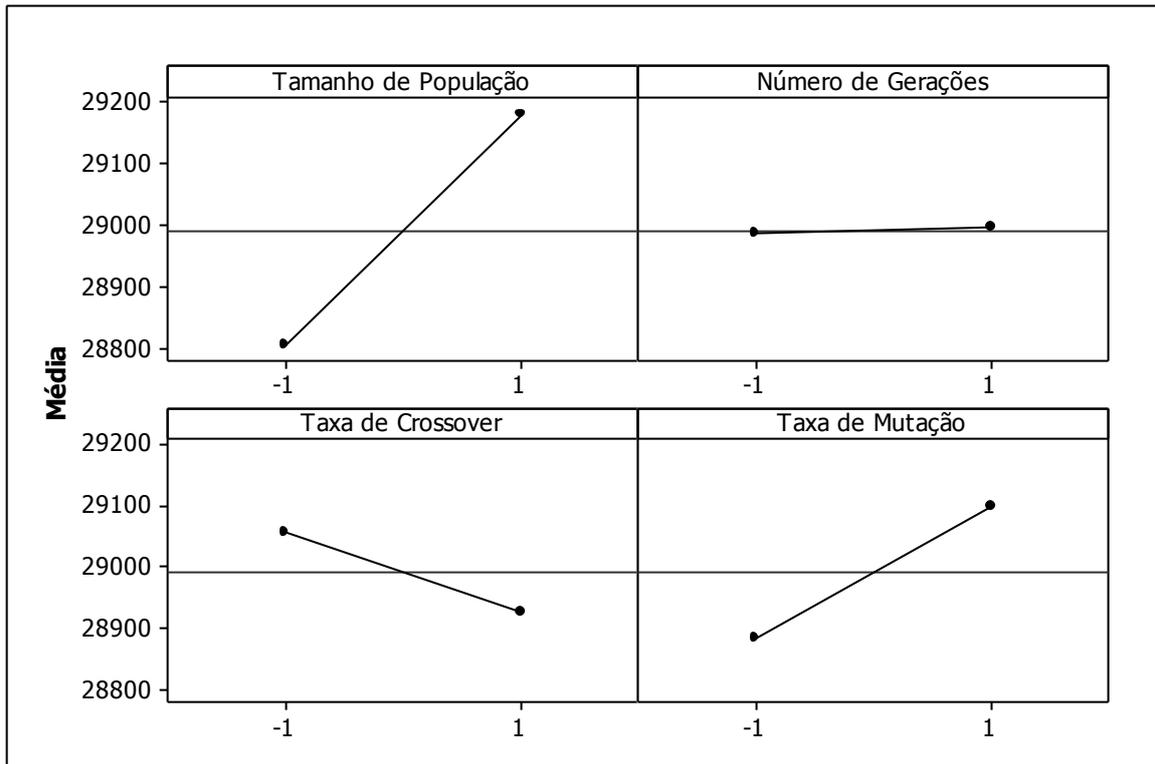


Figura 4.16 - Gráfico dos efeitos principais para Solução

A **Figura 4.17** apresenta o peso dos efeitos dos fatores e suas interações para a qualidade da solução obtida pelo AG. Nenhuma interação entre os fatores mostrou-se significativa para qualidade de resposta, e, dentre os fatores principais, apenas o fator tamanho de população (A) mostrou-se significativo para a solução apresentada pelo algoritmo. Nesse caso, quanto maior o tamanho da população melhor a qualidade da resposta encontrada pelo AG.

Destaca-se também, que os demais fatores principais (número de gerações - B, taxa de *crossover* - C e taxa de mutação - D) não foram significativos ao nível de confiança de 95%. Como já apresentado pelos resultados da ANOVA, o gráfico de Pareto reforça que nenhuma interação entre os fatores principais mostrou-se significativa.

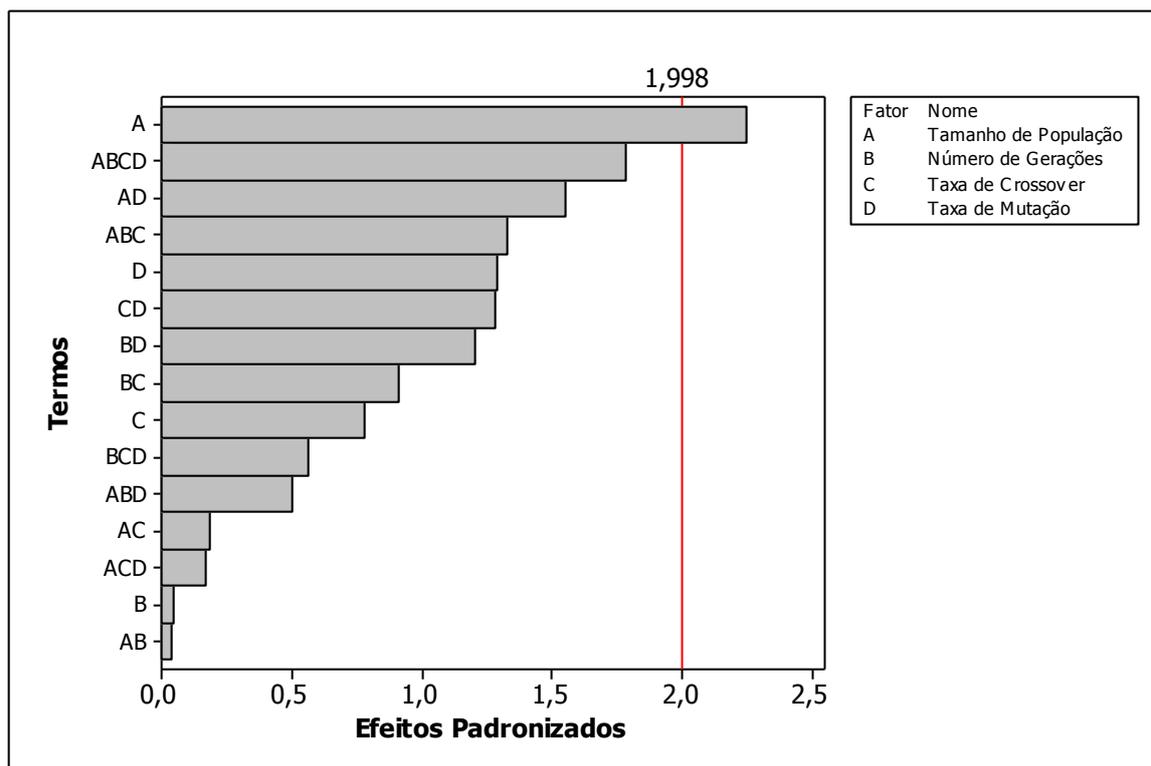


Figura 4.17 - Gráfico de Pareto dos efeitos padronizados para Solução

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto dos efeitos padronizados da **Figura 4.17** pode ser facilmente comprovada pela análise da **Tabela 4.18**.

Termo	Efeito	Coefficiente	Erro Coeficiente	T	P-Value
A	375,6	187,8	83,58	2,25	0,028
B	8,4	4,2	83,58	0,05	0,960
C	-130,4	-65,2	83,58	-0,78	0,438
D	215,6	107,8	83,58	1,29	0,202
AB	6,9	3,4	83,58	0,04	0,967
AC	-30,9	-15,4	83,58	-0,18	0,854
AD	-260,4	-130,2	83,58	-1,56	0,124
BC	152,9	76,4	83,58	0,91	0,364
BD	-201,1	-100,6	83,58	-1,2	0,233
CD	215,1	107,6	83,58	1,29	0,203
ABC	222,9	111,4	83,58	1,33	0,187
ABD	-84,6	-42,3	83,58	-0,51	0,614
ACD	28,6	14,3	83,58	0,17	0,865
BCD	-94,1	-47,1	83,58	-0,56	0,575
ABCD	-299,1	-149,6	83,58	-1,79	0,078

Tabela 4.18 - Efeitos estimados e coeficientes para Solução

Concluída a análise estatística para a variável Solução, foi realizada a análise de variância para a variável de resposta Tempo. Os resultados da ANOVA podem ser

visualizados na **Tabela 4.19**.

Fonte de Variação	Graus de Liberdade	Soma dos Quadrados	Média Quadrática	F	P-Value
Efeitos Principais	4	1016970873	254242718	12599,48	< 0,001
Interações 2a. Ordem	6	204160586	34026764	1686,26	< 0,001
Interações 3a. Ordem	4	120784	30196	1,5	0,214
Interações 4a. Ordem	1	63450	63450	3,14	0,081
Erro residual	64	1291445	20179		
Total	79	1222607137			

Tabela 4.19 - Análise de Variâncias para a resposta Tempo

Nesse cenário, os efeitos principais e as interações de segunda ordem mostraram-se significativas. Já as interações de terceira e quarta ordens não foram significativas para o nível de significância adotado ($\alpha = 0,05$).

A análise dos efeitos principais, apresentada na **Figura 4.18**, mostra que os fatores tamanho de população e número de gerações possuem efeito positivo sobre o tempo necessário para a convergência do algoritmo. Isso significa que a alteração do nível (-) para o nível (+) acarreta o aumento do tempo para convergência. Quanto maior o tamanho de população e o número de gerações, maior será o tempo gasto para que o algoritmo chegue a uma solução.

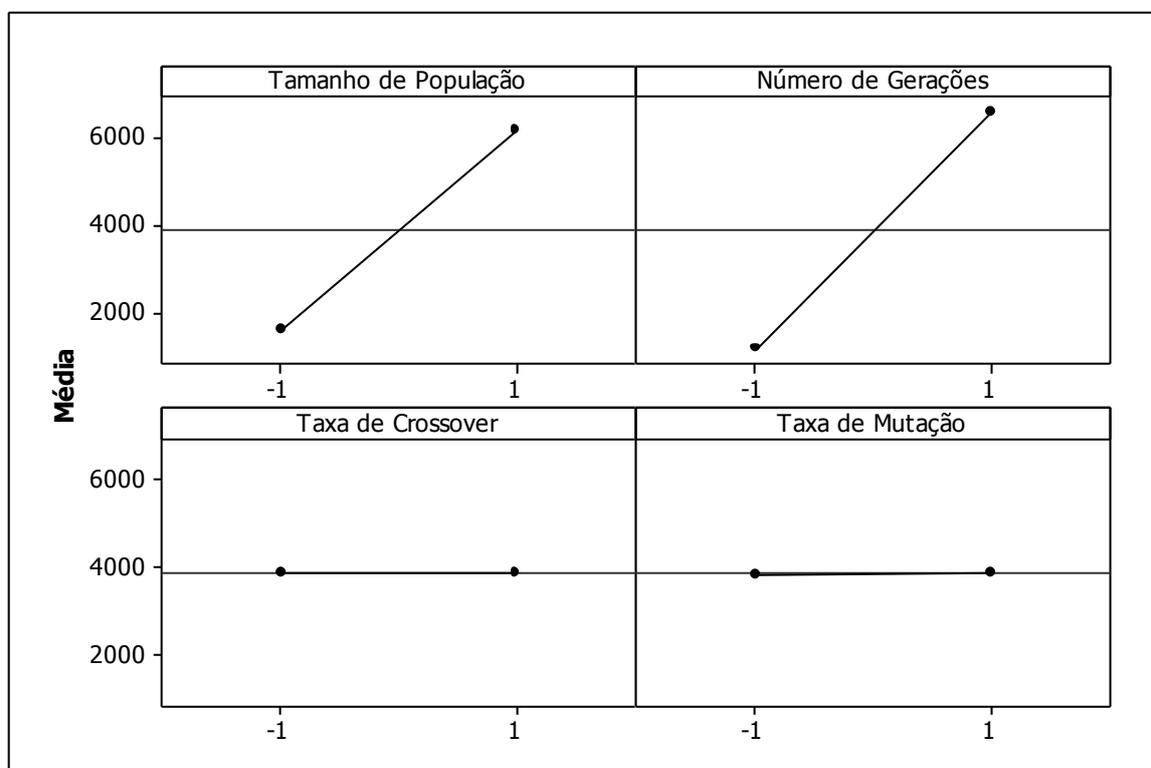


Figura 4.18 - Gráfico dos efeitos principais para Tempo

A **Figura 4.19** apresenta o peso dos efeitos dos fatores e suas interações no tempo necessário para o AG convergir. Pela análise desse gráfico, verifica-se que os fatores principais: número de gerações (B) e tamanho de população (A) são significativos para o nível de significância adotado. As interações duplas entre esses fatores AB e as interações entre os fatores taxa de *crossover* e taxa de mutação (CD) também se mostraram significativas.

Os demais fatores principais (taxa de *crossover* - C e taxa de mutação - D) e outras interações de segunda, terceira e quarta ordens não foram significativos ao nível de confiança de 95%.

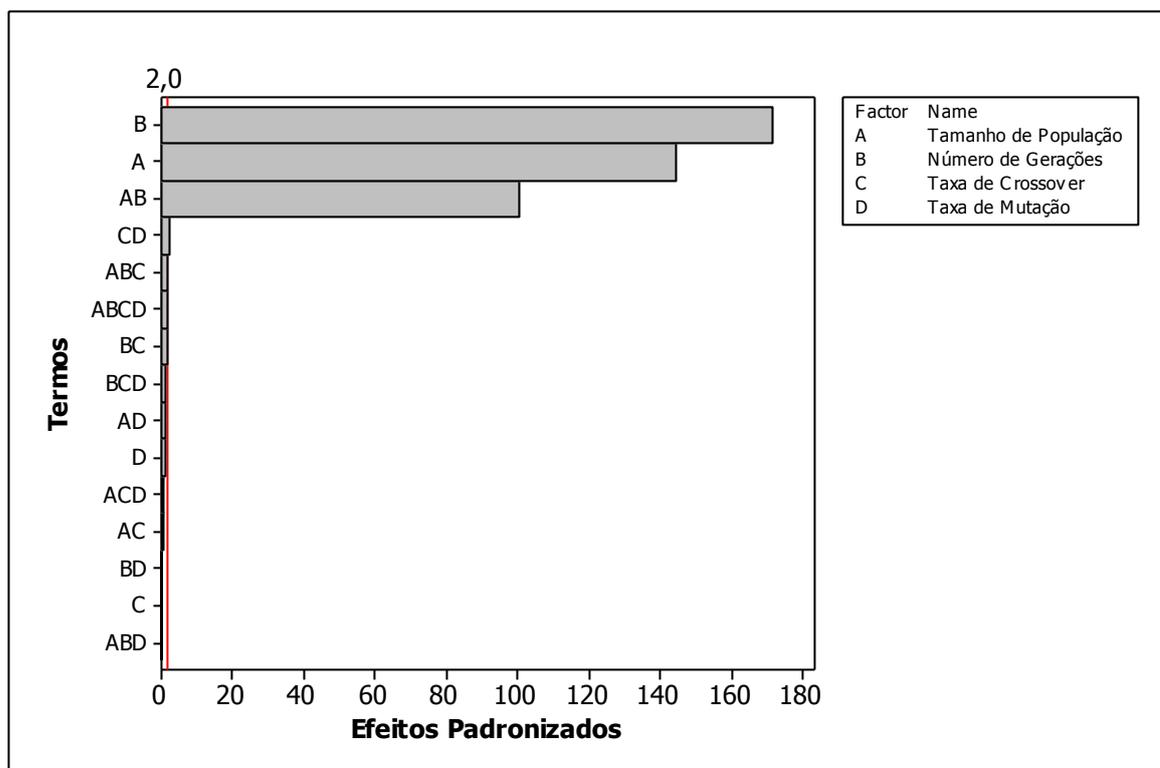


Figura 4.19 - Gráfico de Pareto dos efeitos padronizados para Tempo

Toda a análise de significância dos parâmetros e interações realizada com base no gráfico de Pareto dos efeitos padronizados da **Figura 4.19** pode ser facilmente comprovada pela análise da **Tabela 4.20**.

Termo	Efeito	Coefficiente	Erro Coeficiente	T	P-Value
A	4595,88	2297,94	15,88	144,69	< 0,001
B	5452,12	2726,06	15,88	171,65	< 0,001
C	-1,27	-0,64	15,88	-0,04	0,968
D	28,42	14,21	15,88	0,89	0,374
AB	3193,32	1596,66	15,88	100,53	< 0,001
AC	12,72	6,36	15,88	0,4	0,690
AD	31,22	15,61	15,88	0,98	0,329
BC	56,28	28,14	15,88	1,77	0,081
BD	5,38	2,69	15,88	0,17	0,866
CD	-79,83	-39,91	15,88	-2,51	0,014
ABC	62,38	31,19	15,88	1,96	0,054
ABD	-0,12	-0,06	15,88	0	0,997
ACD	19,88	9,94	15,88	0,63	0,534
BCD	-41,88	-20,94	15,88	-1,32	0,192
ABCD	56,32	28,16	15,88	1,77	0,081

Tabela 4.20 - Efeitos estimados e coeficientes para Tempo

4.2.7 Conclusões e Recomendações

A experimentação conduzida nesse capítulo utilizou o planejamento fatorial completo como meio de análise da significância dos principais parâmetros dos algoritmos genéticos, tanto para a qualidade das soluções apresentadas pelo algoritmo, como para o tempo necessário para sua convergência.

Assim como aponta a literatura, o parâmetro tamanho de população é aquele que merece a maior atenção para sua definição, visto que se mostrou significativo em todas as análises de variâncias, tanto na questão do tempo necessário para o algoritmo convergir, como para a qualidade de resposta.

Para esse parâmetro, no entanto, há um impasse. Quanto maior for o tamanho da população, melhor será a resposta encontrada pelo algoritmo, porém, maior será o tempo necessário para que o algoritmo chegue a esta solução. Nessa situação, o usuário deve optar por uma solução de elevada qualidade associada a um tempo computacional elevado, ou, então por uma solução rápida, porém, de baixa qualidade ao se trabalhar com um AG clássico.

O fator número de gerações apresentou comportamento semelhante ao fator tamanho de população para a variável de resposta tempo, sendo o mais significativo para o tempo de convergência do algoritmo. Para esse fator, quanto maior for o número de gerações, maior será o tempo para que o algoritmo chegue a uma solução. A interação dupla entre os fatores número de gerações e tamanho de população também se mostrou significativa para todos os

três casos analisados para a variável tempo, assim como outras interações duplas e triplas, porém com efeitos reduzidos quando comparados àquela interação.

Um fato curioso proveniente das análises de variância foi que os parâmetros: taxa de *crossover* e taxa de mutação, quando analisados isoladamente, não foram significativos em nenhum dos dois experimentos para o nível de confiança adotado no estudo.

Porém, isso não quer dizer que estes parâmetros podem ser excluídos do algoritmo. Esses operadores são responsáveis pela reprodução em um AG e garantem a diversidade populacional do algoritmo. Somando-se a isto, estes operadores estiveram próximos de serem significativos, como a taxa de mutação para a qualidade das soluções no segundo experimento. E foram significativos em interações de segunda e terceira ordem, como a interação entre a taxa de *crossover* e mutação para o tempo de convergência do algoritmo nos segundo e terceiro experimentos.

4.3 Considerações finais

Com a realização da experimentação, foi possível analisar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade de resposta, na otimização de modelos de simulação a eventos discretos com funções objetivas não lineares.

Para a realização do DOE, foram utilizados os parâmetros do AG: tamanho de população, número de gerações, taxa de *crossover* e taxa de mutação. Três modelos de simulação foram utilizados como objetos de estudos. Um AG clássico foi implementado por meio de uma ferramenta computacional, desenvolvida exclusivamente para otimização dos modelos de simulação.

Com a condução da experimentação, verificou-se que os parâmetros tamanho de população e número de gerações impactam de forma mais significativa a qualidade de resposta e o tempo necessário para se alcançar essa resposta.

Para a proposição do método de otimização que será explorado no próximo capítulo, esses dois parâmetros merecerão maior atenção para a definição de estratégias adaptativas. Dessa forma, pode-se concluir a primeira etapa do ciclo metodológico (conceitualização) proposto por Mitroff *et al.*(1974).

5. MÉTODO DE OTIMIZAÇÃO PROPOSTO

5.1 Considerações iniciais

Neste capítulo, será apresentado e discutido o algoritmo genético adaptativo desenvolvido para otimização de modelos de simulação a eventos discretos não lineares.

Inicialmente, são apresentadas as adaptações propostas para o AG, começando pelas adaptações para o parâmetro tamanho de população que não produziram resultados satisfatórios, mas que foram importantes dentro do processo de pesquisa, e posteriormente as adaptações que produziram os resultados desejados. Por fim, apresentam-se a estrutura do algoritmo de otimização e o *software* desenvolvido para operacionalizar o AGA proposto.

O capítulo que será aqui desenvolvido inicia a segunda etapa do método de pesquisa utilizado: a fase de modelagem (MITROFF *et al.*, 1974).

5.2 Adaptações necessárias para os parâmetros do algoritmo de otimização

Da análise realizada por meio do DOE apresentado no capítulo anterior, pode-se concluir que dois parâmetros do AG influem significativamente para a qualidade de resposta e para o tempo de convergência do algoritmo: o tamanho de população e o número de gerações.

O parâmetro tamanho de população foi o mais significativo para obtenção de uma solução de elevada qualidade, sendo também significativo para o tempo necessário para a convergência do algoritmo. Para esta última variável, o parâmetro número de gerações mostrou-se como o mais significativo. Desta forma, serão propostas adaptações para o parâmetro tamanho de população e será definido um critério de parada para o AGA não baseado no número de gerações, já que o mesmo acarreta um maior tempo de processamento.

Para os parâmetros taxa de *crossover* e taxa de mutação, que não se mostraram significativos em nenhum dos experimentos, não serão apresentadas adaptações, porém serão discutidas taxas para estes parâmetros com base na experimentação realizada e na revisão de literatura.

Todas as adaptações propostas bem como as alterações na estrutura do algoritmo, como a definição das taxas dos parâmetros foram realizadas objetivando a melhoria da qualidade da resposta apresentada pelo algoritmo de otimização e ao mesmo tempo a redução do tempo de processamento do algoritmo.

5.2.1 Adaptações para o parâmetro tamanho de população

Neste trabalho cada indivíduo de uma população é representado por uma solução do tipo binária. Dessa forma, considerando-se as condições de contorno desta pesquisa (variáveis discretas, determinísticas e inteiras) e seguindo os passos do trabalho de Pinho (2008), faz-se necessário, inicialmente, determinar a quantidade de *bits* para representar cada possível solução do problema de otimização.

Assim, foi utilizada a equação proposta por Mitchell (1996), onde a quantidade de *bits* necessários para representar um determinado indivíduo é dada pela Eq.(2).

$$k = \log_2 \frac{sup_i - inf_i}{precisão} + 1 \quad (2)$$

Onde:

- k - número de *bits* (tamanho do indivíduo);
- precisão - precisão desejada para representar a solução;
- inf_i, sup_i - limites inferior e superior da faixa de operação (variação).

Considerando as condições limites dessa pesquisa, com variação máxima entre os limites superior e inferior igual a 8 ($inf_i = 1$, $sup_i = 9$) e a precisão exigida de 1 (variáveis do tipo inteiras), o número de *bits* necessários nos modelos de simulação testados nessa dissertação será igual a 4.

Pinho (2008) ressalta que o número de *bits* será pequeno para os problemas de otimização de modelos de simulação a eventos discretos com mais de uma variável de entrada. Mesmo para os casos onde o número de *bits* tenham que contemplar, para cada uma destas variáveis, a variação entre seus limites inferiores e superiores e a precisão desejada.

Definido o número de *bits* necessários para representar cada solução, deve-se então determinar o número de indivíduos a serem gerados pelo algoritmo para compor sua população inicial. Esse número, como apresentado anteriormente, deve ser escolhido cuidadosamente, pois influenciará diretamente na qualidade da resposta encontrada pelo algoritmo, bem como no tempo gasto para se encontrar essa solução.

Três estratégias foram utilizadas objetivando-se a determinação do tamanho da população inicial do algoritmo. Duas dessas tentativas buscaram na literatura proposições já validadas que propuseram um equacionamento para o cálculo do tamanho da população e outra tentou fixar o tamanho da população inicial.

A primeira estratégia utilizada foi de empregar o equacionamento proposto por Goldberg (1989), que estabelece uma relação entre tamanho da população e tamanho do indivíduo, calculada segundo a Eq. 2. A proposta de Goldberg (1989) pode ser visualizada na Eq. 3.

$$\text{Tamanho população} = 1,65 \times 2^{0,21k} \quad (3)$$

Onde:

- k - número de *bits* (tamanho do indivíduo);

A escolha dessa proposta justifica-se pelos bons resultados alcançados no trabalho de Pinho (2008), que utilizou essa equação para definir o tamanho da população inicial de seu algoritmo na otimização de modelos de simulação a eventos discretos lineares. O algoritmo proposto em sua tese alcançou excelentes resultados em termos de qualidade de resposta e tempo de convergência, quando comparado à uma ferramenta de otimização comercial. Outros resultados alcançados na utilização desse algoritmo podem ser verificados em Pinho, Montevechi e Marins (2008) e Pinho, Montevechi e Marins (2009).

No entanto, a utilização desse equacionamento não apresentou bons resultados na otimização de modelos não lineares. Os testes realizados com a população inicial, calculada segundo a Eq. 3, conduziram à convergência prematura do algoritmo para soluções de baixa qualidade. Isto pode ser explicado devido ao fato que, para um tamanho de indivíduo pequeno, o tamanho da população também será pequeno. E, como apontado pelas análises de variâncias realizadas no capítulo anterior, quanto menor o tamanho da população, pior a qualidade da resposta encontrada pelo algoritmo.

A **Tabela 5.1** estabelece a relação entre o tamanho do indivíduo e o tamanho da população proposta por Goldberg (1989). Para o problema de pesquisa dessa dissertação, onde o tamanho dos indivíduos é igual a 4 *bits*, a população inicial, segundo Goldberg (1989), seria de 3 indivíduos por geração. Um número relativamente baixo quando observado os valores mais comumente utilizados na literatura.

Tamanho do indivíduo	Tamanho da População
4	3
5	4
10	8
15	15
20	31
30	131
40	558
50	2390

Tabela 5.1 - Relação entre tamanho do indivíduo e tamanho da população segundo Goldberg (1989)

Visto que tal estratégia não resultou nos resultados esperados, optou-se por trabalhar com um número fixo para o tamanho da população. Dessa forma, adotou-se o tamanho de população igual a 80, o maior tamanho de população utilizado na etapa de análise dos parâmetros dos algoritmos genéticos (*Capítulo 4*).

Tal alteração resultou em respostas de elevada qualidade computacional; como apresentado por Miranda, Pinho e Montevechi (2011). Porém o algoritmo foi penalizado na questão do tempo necessário para a convergência, gastando mais tempo que um *software* de otimização comercial na otimização de modelos de simulação não lineares.

Uma terceira estratégia foi utilizada para determinação do número de indivíduos componentes da população inicial e alcançou os resultados esperados nessa dissertação. Assim como no trabalho de Goldberg (1989), Reeves (1993) propõe um equacionamento para o cálculo do tamanho ideal para a composição da população de um AG.

Seu trabalho é focado em aplicações de AG com pequenas populações e estabelece um equacionamento matemático para uma população mínima, mas que ao mesmo tempo possua diversidade suficiente para poder representar qualquer possível solução de um problema de otimização apenas por meio do operador genético de *crossover*.

Em sua proposta, Reeves (1993) relaciona o número de indivíduos de uma população com o tamanho do indivíduo (número de *bits*) e a probabilidade que a população gerada possa, apenas com o operador de *crossover*, gerar qualquer possível solução para o problema. Sua proposta pode ser visualizada na Eq. 4.

$$\text{Tamanho população} = \log_{0,5} 1 - {}^k \overline{P}_2 + 1 \quad (4)$$

Onde:

- k - número de *bits* (tamanho do indivíduo);
- P_2 - probabilidade de que a população gerada (representada por meio de uma

representação binária) possa, por meio da reprodução utilizando apenas o operador de crossover gerar, todas as possíveis soluções do problema de otimização.

A proposta de Reeves (1993) pode ser estendida para outros tipos de representações genéticas além da representação binária. Porém estas fogem do escopo dessa dissertação. A **Tabela 5.2** estabelece a relação entre o tamanho da população e a variação de probabilidade, mantendo-se constante o tamanho do indivíduo como sendo igual a 4.

Probabilidade	Tamanho da População
60%	5
70%	5
80%	6
90%	7
95%	8
99%	9
99,9%	13
99,99%	17
99,999%	20
99,9999%	23

Tabela 5.2 - Relação entre tamanho do indivíduo e tamanho da população segundo Reeves (1993)

Pela análise da tabela, verifica-se que quanto maior a probabilidade de que a população consiga representar as possíveis soluções para um dado problema, maior o tamanho da população. Porém, a taxa de crescimento da população é menor quando comparada àquela proposta por Goldberg (1989). Ainda segundo Reeves (1993), um tamanho de população igual a 30 é capaz de resolver uma grande variedade de problemas de otimização que utilizem a representação binária.

Pode-se verificar também que, para um indivíduo de tamanho 4 *bits*, a proposta elaborada por Reeves (1993), mesmo com baixas taxas de probabilidade, ainda supera o tamanho de população indicada por Goldberg (1989) com apenas 3 indivíduos. Dessa forma, optou-se por utilizar a formulação para o cálculo da população inicial proposta por Reeves (1993) como forma de definir a população inicial do AGA proposto nesta dissertação.

Optou-se também por incrementar o valor da população a cada geração, visto que o tamanho de população calculado pela Eq. 4 fornecer o menor tamanho de população capaz de representar todas as possíveis soluções para um determinado problema pela reprodução de seus indivíduos por *crossover*. E, como já apresentado no capítulo anterior, quanto maior o tamanho da população, melhor será a qualidade de resposta. Devido a isso e aos resultados

alcançados no trabalho de Ma e Zhang (2008), Pinho (2008) e Kaveh e Shahrouzi (2007), optou-se por incrementar a população inicial calculada segundo Reeves (1993) em 50% a cada nova geração do algoritmo.

Esse incremento populacional em 50% a cada nova geração justifica-se, segundo Pinho (2008), pelo fato de a população inicial sempre começar com um valor pequeno, quando comparado aos valores mais comumente utilizados em problemas de otimização que utilizam AG.

Uma segunda observação foi realizada ao longo das discussões acerca da elaboração do AGA. Como os problemas de otimização via simulação são problemas de otimização combinatória, o número de possíveis soluções para um determinado problema é diretamente proporcional ao número de variáveis de decisão e à faixa de variação dessas variáveis. Dessa forma, optou-se, primeiro por analisar o número de possíveis soluções de um problema de otimização, e, em função desse espaço de busca, determinar qual o valor da probabilidade a ser definida como parâmetro de entrada da equação 4. Quanto maior o número de possíveis soluções para um problema, maior deverá ser a probabilidade utilizada.

5.2.2 Alteração do parâmetro número de gerações

Na versão clássica do AG implementada nesse trabalho no *Capítulo 4*, o número de gerações estava relacionado diretamente ao critério de parada do algoritmo. Assim que realizasse o número de gerações especificadas na experimentação, o algoritmo convergia, apresentando a melhor resposta.

Neste cenário, as análises de variâncias apontaram que o fator número de gerações impactava na qualidade de resposta e, principalmente, no tempo gasto pelo algoritmo. Outro fato a se destacar foi a forte interação entre esses dois parâmetros, agindo de forma a aumentar o tempo de processamento do algoritmo.

Segundo Hicks (2006), além da abordagem clássica de utilização do número de gerações como critério de parada, outros critérios podem ser implementados, como: a adoção de um tempo máximo de processamento, a diminuição da diversidade populacional ou quando uma população não melhora ao longo de sucessivas gerações. Yang, Kuo e Cho (2007) destacam ainda a interrupção do processo de busca do algoritmo quando a melhoria na qualidade da solução torna-se insignificante.

Desta forma, para o AGA proposto nesta dissertação, optou-se pela utilização desse último critério de parada, baseado na melhoria da qualidade de resposta entre diferentes gerações. Ou seja, ao final da quarta geração, o AGA sempre irá comparar a melhor solução

encontrada com a melhor solução encontrada na geração anterior. Se a diferença entre essas soluções for inferior a 5%, o algoritmo converge, apresentando o melhor resultado encontrado. Esse critério pode ser visualizado por meio da Eq. 5.

$$CP = \frac{y_i - y_{i-1}}{y_{i-1}} \quad (5)$$

Onde:

- CP -critério de parada;
- y_i -melhor solução encontrada na geração i ;
- y_{i-1} - melhor solução encontrada na geração $i - 1$;

Sempre após o término de uma geração (a partir da quarta geração), o AGA realizará o seguinte teste:

- Se $CP \geq 0,05$ o algoritmo realiza uma nova geração;
- Se $CP < 0,05$ o algoritmo converge apresentando a melhor solução encontrada na geração i .

Para evitar que ocorresse uma convergência prematura do algoritmo proposto logo nas primeiras gerações, visto que nelas se concentram as menores populações do AGA, foi acrescentado o critério de que o algoritmo obrigatoriamente deveria executar um número mínimo de 3 gerações, e só a partir daí aplicaria o critério de parada.

Vale ressaltar também que y_i sempre será maior, ou na pior das hipóteses, igual a y_{i-1} , devido ao elitismo que sempre levará as melhores soluções encontradas para a geração seguinte, de maneira a não se perder uma solução de elevada qualidade durante o processamento do algoritmo.

Por fim, apesar de todas as precauções relacionadas ao parâmetro número de gerações, as alterações introduzidas para esse parâmetro não se classificam como adaptações, visto que o critério não é mutável ao longo do processamento do AGA. No entanto, tais alterações contribuem decisivamente para a diminuição do tempo de convergência do algoritmo e com a melhoria da qualidade de resposta.

5.2.3 Parâmetros taxa de *crossover*, taxa de mutação e taxa de elitismo

Para Konak, Coit e Smith (2006), o operador de *crossover* é o operador mais importante dentre todos os operadores genéticos. Esse fato também é levado em consideração no trabalho de Reeves (1993), que recomenda o uso apenas do operador de *crossover* quando da

utilização de sua proposição para o número de indivíduos mínimo para a formação da população inicial.

Como já apresentado anteriormente, o cálculo do tamanho da população proposto por Reeves (1993) leva em consideração o tamanho mínimo de população para que apenas com o operador de *crossover* qualquer possível solução para um dado problema possa ser gerado.

Dessa forma, o autor recomenda a utilização de elevadas taxas para esse operador genético, recomendando a utilização de baixas taxas para o operador de mutação ou, até mesmo, sua não utilização, visto que, para uma população pequena, tal operador contribuiria pouco para a melhoria da qualidade de resposta.

Sendo assim, e devido ao fato que nenhum dos operadores genéticos se mostrou significativo nas análises de variâncias realizadas no capítulo anterior, optou-se por trabalhar com dois conjuntos de valores para as taxas de *crossover* e de mutação, seguindo as orientações de Reeves (1993) e de outros trabalhos presentes na literatura.

Reeves (1993) afirma em seu trabalho que 30 indivíduos são mais que necessários para compor uma população inicial que utilize a representação binária. Para esses casos, o autor recomenda a utilização de uma elevada taxa de *crossover* e de baixas taxas de mutação (ou até mesmo sua não utilização). Dessa forma, quando o tamanho de população calculada for inferior a 30 indivíduos, o AGA adotará as taxas de 99% para o operador de *crossover* e 1% para o operador de mutação. Nos casos em que a população inicial for maior que 30, o AGA adotará as taxas de 90% para o operador de *crossover* e 10% para o operador de mutação.

Esses valores utilizados encontram-se em acordo com os valores geralmente utilizados em trabalhos presentes na literatura e atendem à relação proposta por Linden (2006), expressa na Eq. 6.

$$P_m = 100\% - P_c \quad (6)$$

Onde:

- P_m - taxa do operador de mutação;
- P_c - taxa do operador de *crossover*.

As taxas de elitismo também foram definidas em função do tamanho da população inicial do algoritmo. Quando o tamanho de população calculada for inferior a 30 indivíduos, o AGA adotará a taxa de 20%, e, em caso contrário, a taxa adotada será de 10%. Tais valores apresentaram bons resultados em pré-testes realizados com o algoritmo.

5.3 Estrutura do AGA proposto

Discutidas e apresentadas as adaptações necessárias para o método de otimização, a estrutura do AGA proposto pode ser resumida segundo o fluxograma apresentado na **Figura 5.1**. A utilização do método de otimização aqui proposto pressupõe a otimização de modelos de simulação a eventos discretos não lineares em que as variáveis de decisão atendam às condições de contorno dessa dissertação (variáveis discretas, determinísticas e inteiras).

Ao iniciar a primeira geração, o algoritmo calcula o número de cenários possíveis de serem processados e, na sequência, calcula o número de *bits* necessários para representar um indivíduo da população segundo Mitchell (1996). Logo a seguir é calculado o tamanho da população inicial segundo a proposta de Reeves (1993). Com isso, a primeira população do AGA é gerada.

Dependendo do tamanho da população gerada, um determinado conjunto de parâmetros para os operadores de *crossover*, mutação e elitismo são adotados pelo algoritmo. Se a população inicial possuir menos de 30 indivíduos, o AGA adotará as taxas de 99% para o operador de *crossover*, 1% para o operador de mutação e 20% para o elitismo. Em caso contrário, o AGA assumirá os valores de 90% para o operador de *crossover*, 10% para o operador de mutação e 10% para o elitismo.

Essa sequência de passos só é executada na primeira geração do AGA. A partir da segunda geração, a população será incrementada em 50% (MA e ZHANG, 2008; KAVEH e SHAHROUZI, 2007; PINHO, 2008) a cada nova iteração do algoritmo. Esses novos indivíduos são gerados aleatoriamente e somados àqueles gerados por meio de reprodução, compondo, assim, uma nova geração.

Por meio de recursos computacionais, foi adicionado ao AGA um critério impedindo que, um indivíduo já gerado (por reprodução ou criado aleatoriamente) e avaliado pelo algoritmo, não é mais testado pelo AGA caso este indivíduo seja gerado uma segunda vez, visto que seu resultado já é conhecido.

Seguindo os passos do algoritmo, cada possível solução do problema (indivíduo gerado) é avaliada por meio do simulador a eventos discretos. Cada indivíduo (que armazena uma determinada configuração das variáveis de decisão) é enviado para o simulador, que “roda” essa configuração no modelo de simulação e envia para o otimizador a resposta referente a cada indivíduo com base na função objetivo introduzida no modelo de simulação.

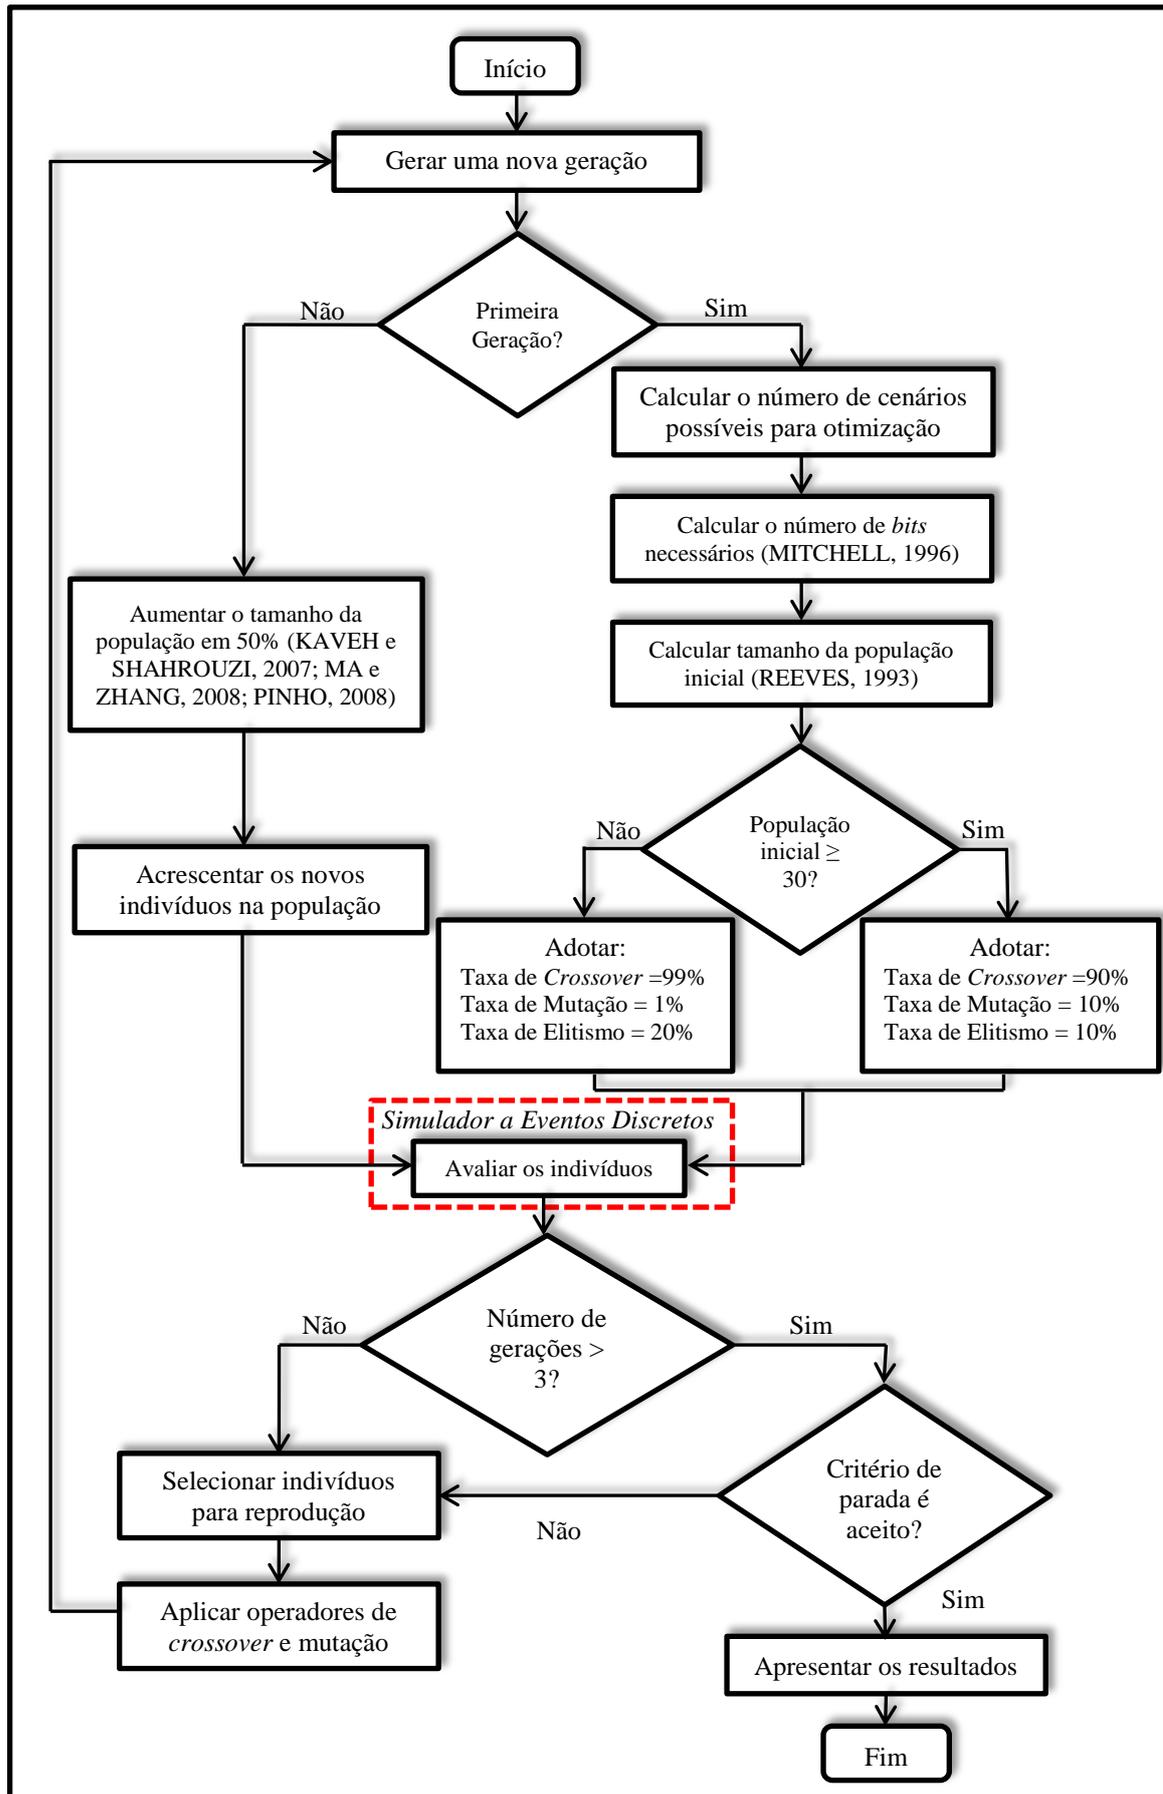


Figura 5.1 - Estrutura do AGA proposto

Todos os indivíduos gerados nas três primeiras gerações do algoritmo são avaliados sem que passem pelo critério de parada. Para essas três primeiras gerações após a avaliação, os indivíduos são selecionados pelo método da roleta para reprodução, sendo utilizados nessa etapa os operadores de *crossover* e mutação segundo as taxas definidas de acordo com o tamanho da população inicial.

Esses novos indivíduos gerados comporão uma nova população que a cada geração é incrementada em 50% por novos indivíduos gerados aleatoriamente. Dessa forma, a cada geração, a partir da segunda, as populações serão formadas por indivíduos gerados por meio de reprodução através dos operadores genéticos (*crossover* e mutação) e por indivíduos gerados aleatoriamente; garantindo, assim, uma maior diversidade populacional no algoritmo proposto.

A partir da quarta geração o indivíduo melhor avaliado é comparado com o melhor indivíduo da geração anterior, conforme o critério de parada estabelecido. Se a diferença entre os indivíduos não for significativa, ou seja, menor que 5%, considera-se que o critério de parada foi atendido e o algoritmo converge, apresentando a melhor solução encontrada. Caso contrário, o algoritmo inicia a composição de uma nova geração e todo o processo é reiniciado.

5.4 Software desenvolvido

Para que o AGA desenvolvido pudesse ser utilizado na otimização de modelos de simulação, tornou-se necessário implementar sua estrutura por meio de uma ferramenta computacional. Desta forma, um *software* foi desenvolvido objetivando facilitar o processo de otimização dos modelos de simulação, assim como permitir a visualização dos resultados obtidos. Toda a interface gráfica foi desenvolvida utilizando-se a linguagem de programação *visual studio.net*®.

A ferramenta desenvolvida permite a otimização de modelos de simulação programados no simulador *Promodel*®, da *Promodel Corporation*, um dos *softwares* de simulação mais utilizados no mercado (DOLOI e JAAFARI, 2002).

Para que o método de otimização se tornasse operacional, foi necessário ainda a utilização de uma terceira ferramenta computacional, o *ProActiveX*®. Essa ferramenta, desenvolvida pelo fabricante do simulador, faz com que seja possível ocorrer a interação entre a ferramenta de otimização desenvolvida e o simulador a eventos discretos.

Esse relacionamento entre o método de otimização desenvolvido e o simulador via objeto (*ProActiveX*®) pode ser simplificado por meio da **Figura 5.2**

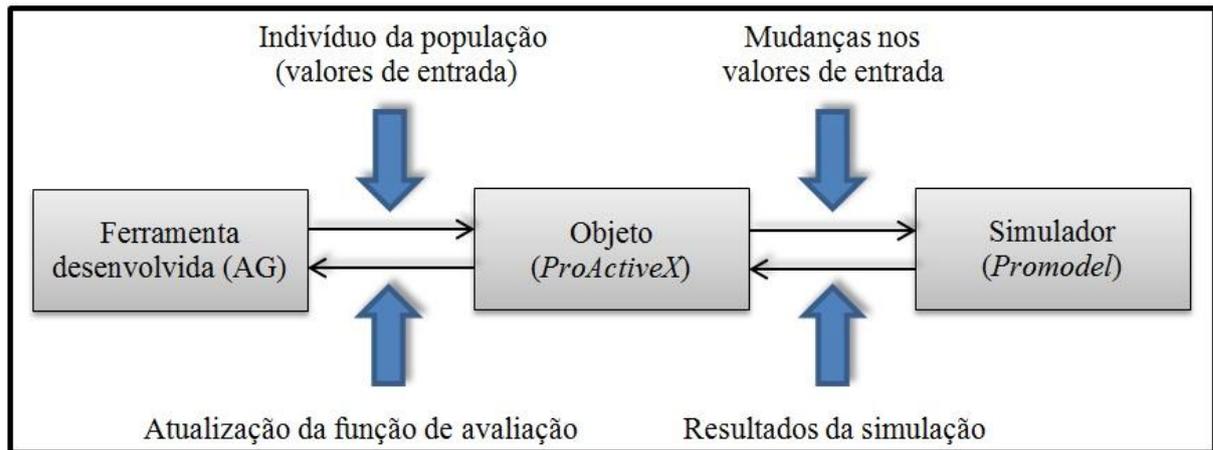


Figura 5.2 - Relacionamento entre o método de otimização e o simulador via objeto
 Fonte: adaptado de Pinho (2008)

Durante a execução do método de otimização, o *software* desenvolvido envia para o objeto (*ProActiveX*) os indivíduos da população gerados pelo AGA. Esses indivíduos representam as variáveis de entrada do modelo de simulação. O objeto insere as variáveis de entrada no simulador, aguarda a execução da simulação e armazena os resultados gerados pelo simulador retornando tais resultados para a ferramenta desenvolvida. Esses resultados serão utilizados na avaliação de cada indivíduo.

Terminada a avaliação de todos os indivíduos componentes da população, o método de otimização faz uma verificação entre os resultados encontrados para a geração atual e o da geração anterior. Caso não ocorram melhorias significativas, considera-se que o critério de parada foi satisfeito. Neste caso, o AGA converge, apresentando os resultados alcançados. Caso contrário, um novo ciclo do algoritmo é realizado.

5.5 Considerações finais

Neste capítulo, foi apresentada a estrutura do AGA proposta para otimização de modelos de simulação a eventos discretos não lineares e a ferramenta computacional que tornou tal relacionamento possível.

Buscou-se também apresentar as adaptações para o algoritmo genético que o tornaram um algoritmo genético adaptativo, embasado por trabalhos presentes na literatura e observando os resultados da análise dos parâmetros do AG realizados no **Capítulo 4**. As definições das taxas dos parâmetros também foram apresentadas e discutidas.

Com isso, pode-se considerar encerrada a segunda etapa do método de pesquisa proposto por Mitroff *et al.* (1974) e cumprido o objetivo referente ao desenvolvimento de um AGA para otimização de modelos de simulação não linear.

6. APLICAÇÃO DO MÉTODO DE OTIMIZAÇÃO PROPOSTO

6.1 Considerações iniciais

Este capítulo inicia a terceira etapa do método de pesquisa: a etapa de Solução pelo Modelo (MITROFF *et al.*, 1974). Nela, o AGA proposto será utilizado na otimização de modelos de simulação a eventos discretos não lineares e os resultados alcançados serão confrontados com os resultados obtidos com a utilização de um *software* de otimização comercial, o *SimRunner*®.

Antes de iniciar a aplicação do método de otimização proposto, este capítulo apresenta e justifica a utilização do *SimRunner*®. Devido ao caráter comercial deste otimizador, não é possível apresentar a estrutura do AG que suporta este método de otimização. No entanto, serão apresentadas suas principais características.

Na sequência, são apresentados a metodologia utilizada para a condução do estudo comparativo e os modelos de simulação, que serão utilizados como objetos de estudo para otimização. Finalmente, os modelos de simulação serão otimizados com a utilização dos dois métodos de otimização e os resultados alcançados serão analisados segundo três critérios: a qualidade de resposta, o tempo necessário para a convergência e o número de experimentos realizados por cada método.

6.2 *Software* de simulação e otimização utilizados

6.2.1 *Promodel*® e *SimRunner*®

Para Saife, Seliaman e Ahmad (2006), o *ProModel*® é uma ferramenta de simulação que permite a fácil modelagem de todos os tipos de sistemas de produção, sendo, dessa forma, uma poderosa ferramenta de apoio à tomada de decisão.

Para os autores, o *ProModel*® possui uma interface gráfica orientada à modelagem de objetos, eliminando a necessidade de programação. Dessa forma, ele combina a flexibilidade de uma linguagem geral de simulação com a conveniência de um simulador.

Neste contexto, segundo Torga (2007), em 1995, a *ProModel Corporation* decidiu incorporar o *SimRunner*® ao seu *software* de simulação, com o objetivo de facilitar o trabalho de seus usuários, que desejavam associar otimização e simulação.

Para Carson e Maria (1997), o *SimRunner*® integra recursos para analisar e otimizar modelos de simulação, promovendo uma otimização multivariável que testa várias combinações de fatores em busca da combinação que conduza o melhor valor para a função objetivo.

Embora o *SimRunner*® não garanta que a solução encontrada seja a ideal, assim como outros *softwares* de otimização baseados em AG, o *software* irá encontrar soluções melhores que aquelas encontradas por meio de tentativa e erro. Cada projeto de otimização requer a validação do modelo de simulação, um padrão de desempenho (função objetivo) e um grupo de fatores que podem ser alterados visando à melhoria de desempenho do sistema (SIMRUNNER USER GUIDE, 2002).

Apesar de não conhecida a estrutura do algoritmo do *SimRunner*®, o usuário do otimizador deve fornecer por meio da interface gráfica do *software* alguns parâmetros. O primeiro parâmetro a ser definido é o perfil de otimização. O *SimRunner*® possui três perfis de otimização: o *Aggressive* (Agressivo), o *Moderate* (Moderado) e o *Cautious* (Cauteloso). Os perfis estão diretamente relacionados à confiabilidade da solução encontrada e ao tempo necessário para encontrar esta solução.

O perfil de otimização é um reflexo do número de soluções possíveis que o *SimRunner*® examinará. O Perfil Cauteloso considera um maior número de possíveis soluções e mais completa será a busca por melhores soluções. Contudo, o tempo necessário para seu processamento será elevado quando comparado aos outros perfis. O Perfil Agressivo trabalha com uma pequena população, a qual permite convergir para uma solução mais rapidamente, porém a confiabilidade de sua solução será menor comparada aos demais perfis. Por fim, o Perfil Moderado apresenta o equilíbrio entre os perfis cauteloso e agressivo (TORGA, 2007; SIMRUNNER USER GUIDE, 2002).

Outro parâmetro a ser fornecido ao *software* é a taxa de convergência. Essa taxa funciona como um critério de parada do *software*, controlando o quão perto os melhores resultados estão do valor médio. Uma vez alcançado o valor da taxa de convergência adotado, o algoritmo para e fornece o melhor resultado encontrado. Um percentual elevado irá parar a busca precocemente, enquanto um valor muito pequeno exigirá maior tempo computacional até a convergência (SIMRUNNER USER GUIDE, 2002).

O *SimRunner*® permite ainda, como uma opção avançada, que o usuário determine o número máximo e/ou mínimo de gerações, ou seja, o usuário pode controlar o número de iterações que o algoritmo poderá executar antes de fornecer a melhor solução encontrada. Um número muito grande para o número de gerações forçará o *software* a continuar a busca por

uma solução, até mesmo se o valor da taxa de convergência já tiver sido alcançado (SIMRUNNER USER GUIDE, 2002).

A interface gráfica do *software* com o usuário do *SimRunner*® pode ser visualizada na **Figura 6.1**.

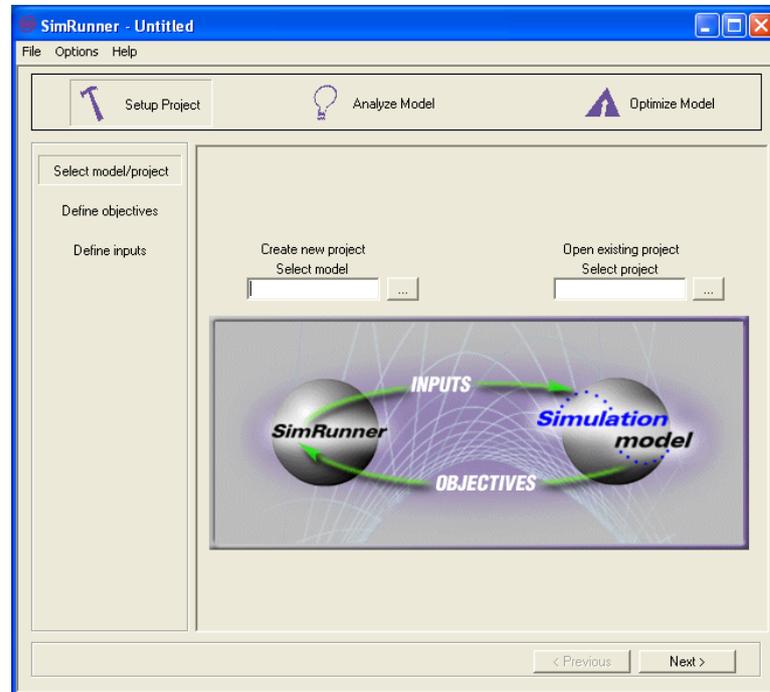


Figura 6.1 - Interface gráfica do *software* *SimRunner*®

Verifica-se na literatura vários trabalhos que utilizaram o simulador *Promodel*® e seu otimizador o *SimRunner*® (FU *et al.*, 2000; PINHO e MORAIS, 2010; PINHO, 2008; SAIFE, SELIAMAN e AHMAD, 2006; SILVA, GALHARDO e MONTEVECHI, 2004; SRISUWANRAT, IOANNOU e TSIMHONI, 2008; TORGA, 2007).

6.3 Metodologia para condução do estudo comparativo

Nesse capítulo, será empregada a metodologia proposta por Harrel, Ghosh e Bowden (2004) (apresentada com maiores detalhes no **Capítulo 3**) para a otimização dos modelos de simulação. Resumidamente os passos do método proposto pelos autores são descritos a seguir.

- **1º. Passo:** Definir as variáveis de decisão que irão afetar as saídas do modelo de simulação e que serão testadas pelo algoritmo de otimização;
- **2º. Passo:** Para cada variável de decisão, definir o tipo de variável e os limites inferiores e superiores;
- **3º. Passo:** Definir a função objetivo para avaliar as soluções testadas pelo algoritmo;

- **4º. Passo:** Selecionar os parâmetros de configuração do *software*, tais como: perfil de otimização, precisão requerida, nível de significância, número de replicações, *etc.*;
- **5º. Passo:** Após a convergência do *software* de otimização, um analista deve estudar as soluções encontradas.

Os três primeiros passos da metodologia são desenvolvidos ainda no simulador a eventos discretos. Só após esta configuração, o modelo de simulação estará apto a ser otimizado (Passos 4 e 5).

Segundo Pinho (2008), alguns fatores afetam diretamente o desempenho do algoritmo de otimização, entre eles: a precisão do modelo, número de variáveis, número de réplicas, complexidade da função objetivo, valores iniciais das variáveis e seus limites. Dessa forma, apesar de se tratarem de dois métodos de otimização diferentes utilizados para a condução do estudo comparativo, serão mantidas as mesmas condições e parâmetros para todos os objetos de estudo.

6.4 Objetos de estudo

O método de otimização proposto nesta dissertação será testado na otimização de oito modelos de simulação a eventos discretos desenvolvidos pelo grupo de pesquisa do pesquisador. Todos os modelos utilizados foram verificados e validados em trabalhos anteriores e focaram aplicações em sistemas de manufatura.

Dos oito modelos de simulação utilizados, quatro representam processos de uma empresa brasileira de alta tecnologia do setor de telecomunicações, dois representam os processos fabris de uma multinacional do setor automotivo, um representa uma célula produtora de uma empresa do setor bélico e um representa a unidade de processamento de roupas de um hospital (*Tabela 6.1*).

Modelo	Setor	Número de Variáveis de decisão	Número de possíveis soluções para o problema
Primeiro objeto de estudo	Automotivo	3	729
Segundo objeto de estudo	Hospitalar	3	729
Terceiro objeto de estudo	Telecomunicações	4	1458
Quarto objeto de estudo	Bélico	4	6561
Quinto objeto de estudo	Telecomunicações	5	59049
Sexto objeto de estudo	Telecomunicações	5	59049
Sétimo objeto de estudo	Telecomunicações	6	531441
Oitavo objeto de estudo	Automotivo	6	531441

Tabela 6.1 - Apresentação dos objetos de estudos

Por questões de confidencialidade dos dados, maiores informações sobre os processos produtivos das empresas serão omitidos. Porém, todos os modelos foram construídos, verificados e validados segundo a metodologia proposta em Montevechi *et al.* (2010) e encontram-se aptos a serem otimizados.

As seções seguintes irão explorar as definições dos sistemas modelados definindo os 3 primeiros passos do método proposto por Harrel, Ghosh e Bowden (2004). O quarto passo do método, definição dos parâmetros do *software*, será realizado em separado, dado que todas as otimizações realizadas seguirão a mesma configuração do *software*.

6.4.1 Primeiro objeto de estudo

O primeiro objeto de estudo representa uma célula de produção do setor automobilístico. Existem nesta célula 3 grupos de operadores que executam diferentes tipos de trabalhos. A **Figura 6.2** representa o modelo implementado no *software ProModel*®, e a **Figura 6.3** apresenta o modelo conceitual através da técnica IDEF-SIM.

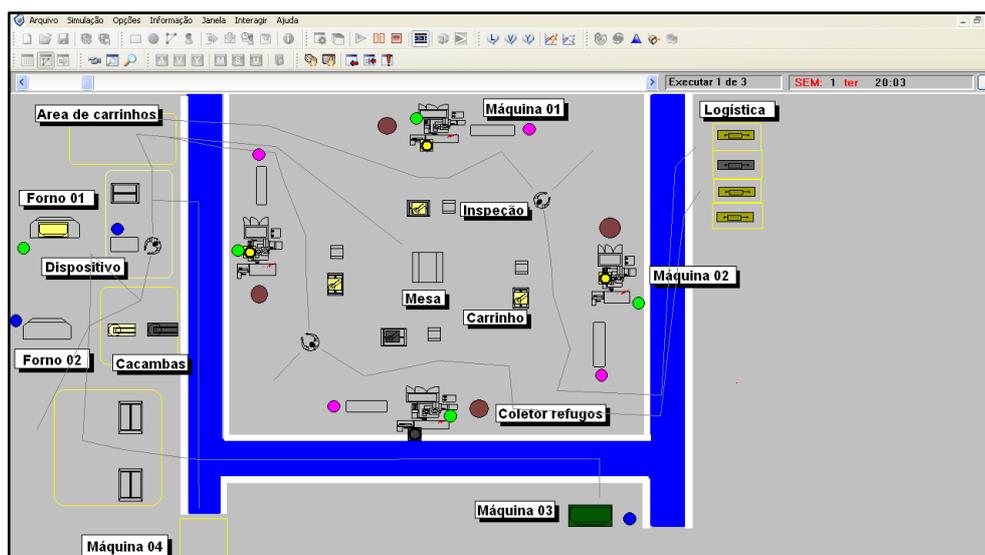


Figura 6.2 - Modelo implementado no *ProModel*® para o primeiro objeto de estudo

As variáveis de decisão desse problema de otimização foram definidas como sendo o número de operadores por grupo de trabalho na célula (Passo 1). Todas as variáveis foram definidas como sendo do tipo inteiras com limite superior igual 9 e limite inferior igual a 1 (Passo 2). A **Tabela 6.2** apresenta essas informações.

1º. Passo		2º. Passo	
Variáveis de decisão	Tipo	Limite Inferior	Limite Superior
Número operadores 1	Inteira	1	9
Número operadores 2	Inteira	1	9
Número operadores 3	Inteira	1	9

Tabela 6.2 - Variáveis de decisão, tipo e limites para o primeiro objeto de estudo

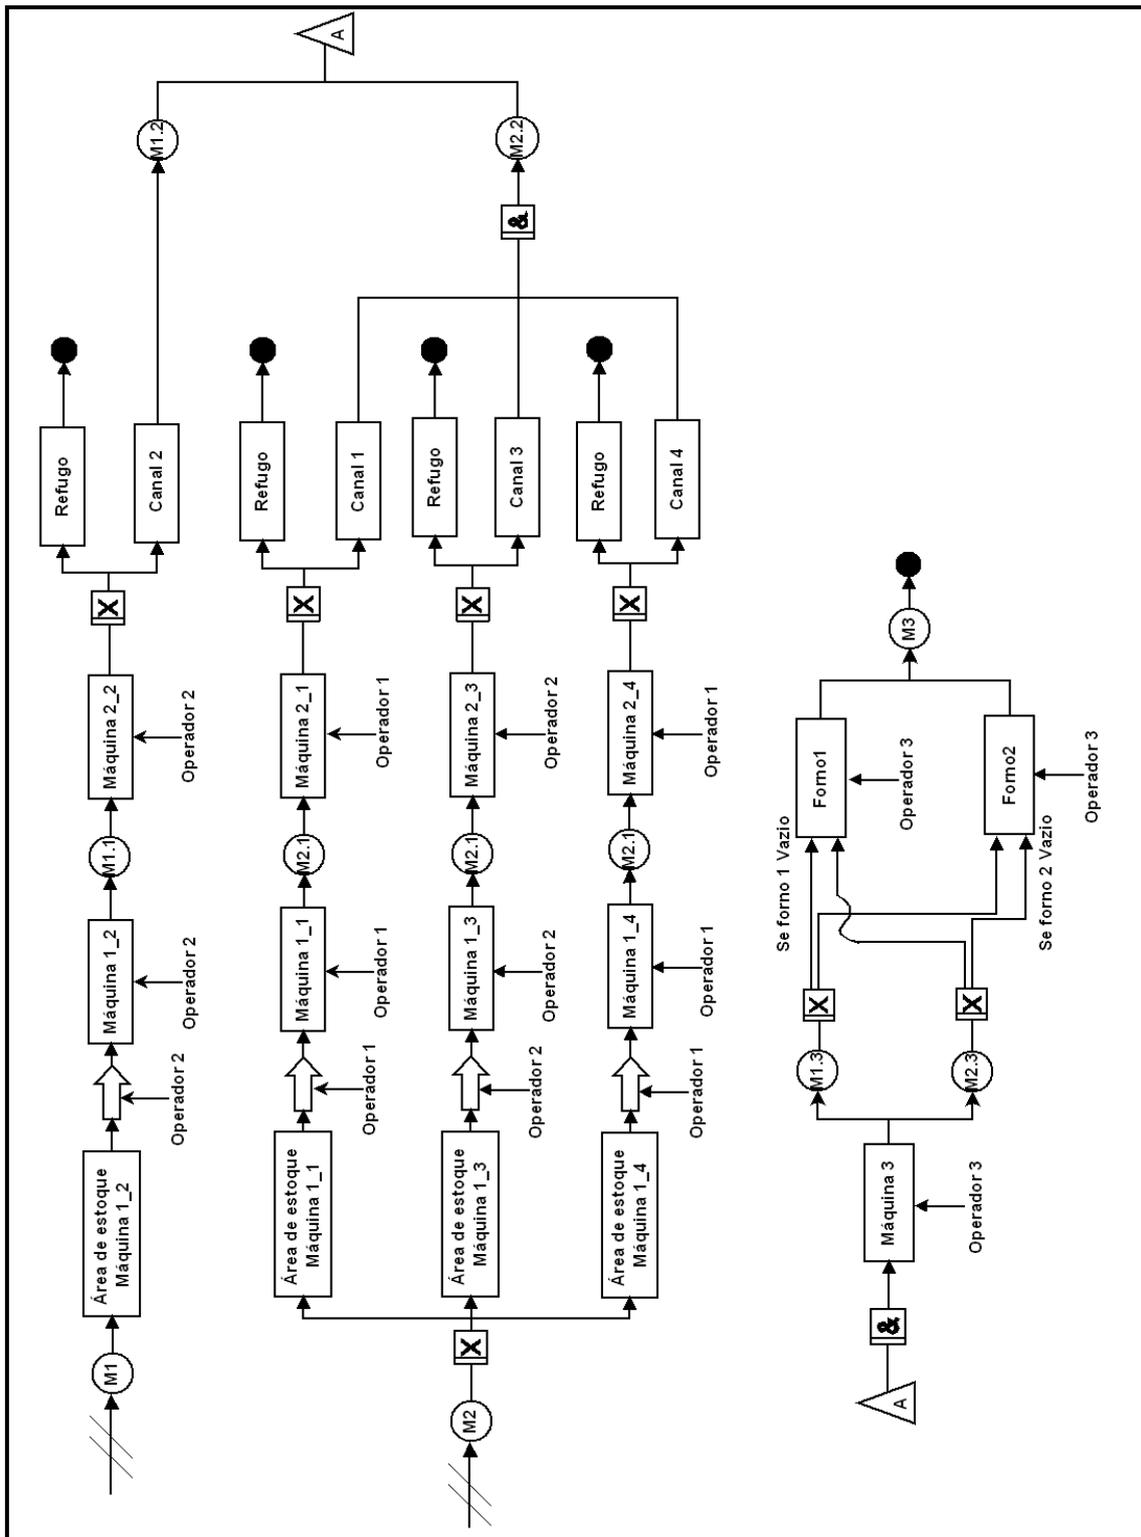


Figura 6.3 - Modelo conceitual para o primeiro objeto de estudo

Foi introduzido, no modelo de simulação, um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar o melhor conjunto de operadores de forma a maximizar o lucro da célula.

Para o problema em questão, com 3 variáveis de decisão e variação de 1 até 9 operadores, existe um total de 729 cenários possíveis para a busca da melhor configuração.

6.4.2 Segundo objeto de estudo

O segundo objeto de estudo representa a unidade de processamento de roupas de um hospital. Existem na unidade modelada 3 grupos de máquinas que requerem atenção especial da direção do hospital em função das mesmas apresentarem elevado tempo de processamento. A **Figura 6.4** representa o modelo implementado no *software ProModel®*, e a **Figura 6.5** apresenta o modelo conceitual através da técnica IDEF-SIM.

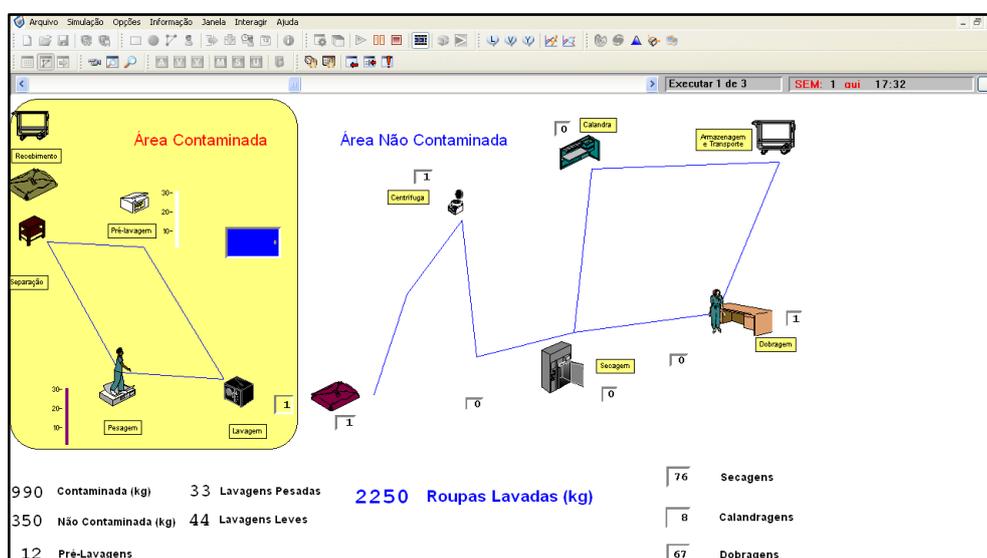


Figura 6.4 - Modelo implementado no *ProModel®* para o segundo objeto de estudo

Diante dos fatos, as variáveis de decisão desse problema foram definidas como sendo o número de lavadoras, o número de centrifugas e o número de secadores (Passo 1). Todas as variáveis foram definidas como sendo do tipo inteiras com limite superior igual 9 e limite inferior igual a 1 (Passo 2). A **Tabela 6.3** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número de lavadoras	Inteira	1	9
Número de centrifugas	Inteira	1	9
Número secadores	Inteira	1	9

Tabela 6.3 - Variáveis de decisão, tipo e limites para o segundo objeto de estudo

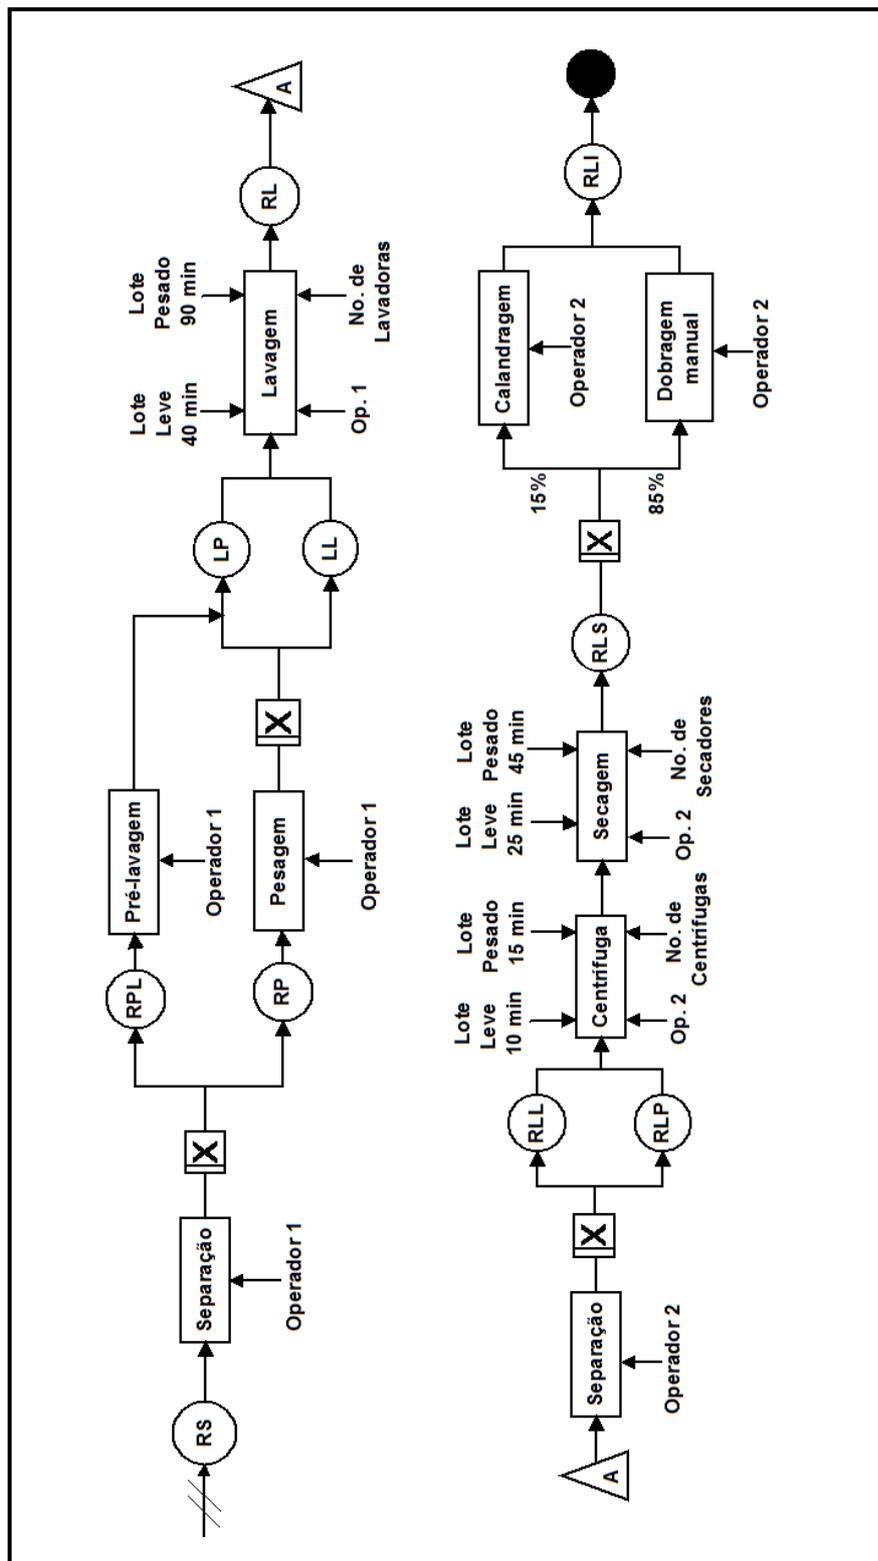


Figura 6.5 - Modelo conceitual para o segundo objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar o melhor conjunto de máquinas de forma a maximizar o lucro da célula.

Para o problema em questão, assim como no caso anterior, existe um total de 729 cenários possíveis para a busca da melhor configuração.

6.4.3 Terceiro objeto de estudo

O terceiro objeto de estudo representa uma célula de produção de uma empresa do setor de telecomunicações. A **Figura 6.6** representa o modelo implementado no *software ProModel®*, e a **Figura 6.7** apresenta o modelo conceitual através da técnica IDEF-SIM.

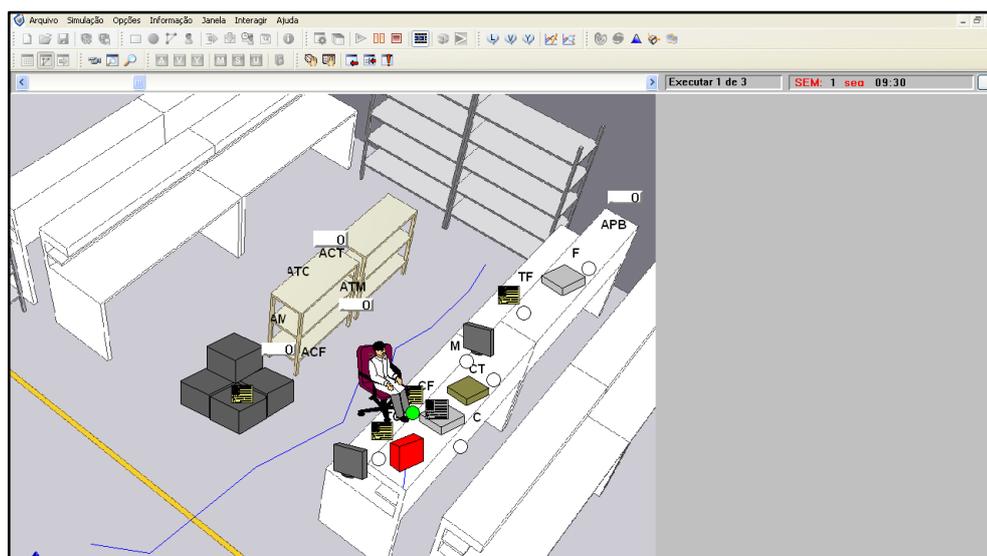


Figura 6.6 - Modelo implementado no *ProModel®* para o terceiro objeto de estudo

Para esse objeto de estudo, foram definidas como variáveis de decisão a quantidade de operadores na célula, o número de bancadas com *setup*, o número de bancadas sem *setup* e se há ou não organização de material feita pela produção. As três primeiras variáveis de decisão foram definidas como inteiras, com limite inferior igual a 1 e limite superior igual a 9. A quarta variável de decisão (se há ou não organização de material) foi determinada como sendo do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há). A **Tabela 6.4** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número operadores	Inteira	1	9
Número de bancadas com <i>setup</i>	Inteira	1	9
Número de bancadas sem <i>setup</i>	Inteira	1	9
Se há ou não organização de material na célula	Binária	0	1

Tabela 6.4 - Variáveis de decisão, tipo e limites para o terceiro objeto de estudo

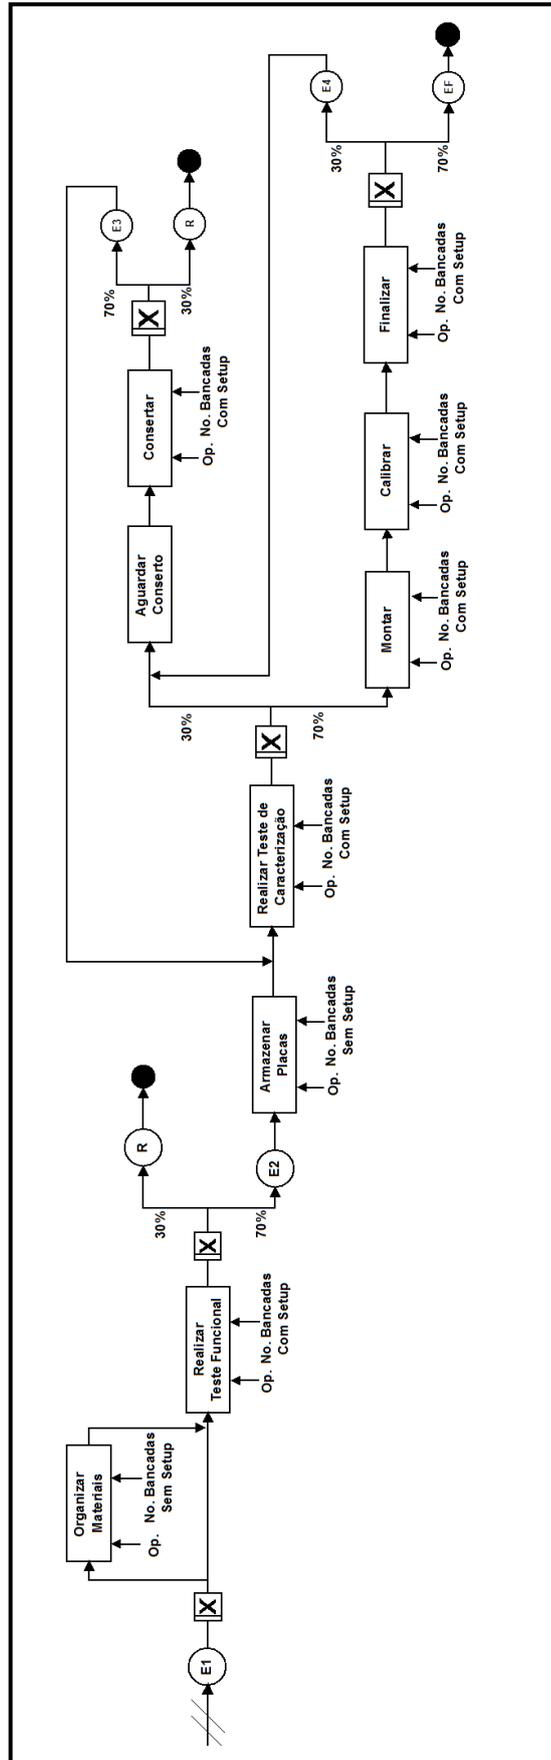


Figura 6.7 - Modelo conceitual para o terceiro objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula.

Para o problema em questão, considerando o número de variáveis e suas variações máximas, existe um total de 1458 cenários possíveis para a busca da melhor configuração.

6.4.4 Quarto objeto de estudo

O quarto objeto de estudo representa uma célula de produção de uma empresa do setor bélico. Assim como no primeiro objeto de estudo, essa célula é dividida em 4 grupos de atividades, sendo cada grupo composto por um determinado número de operadores. A **Figura 6.8** representa o modelo de simulação implementado no *software ProModel®*, e a **Figura 6.9** apresenta o modelo conceitual através da técnica IDEF-SIM.

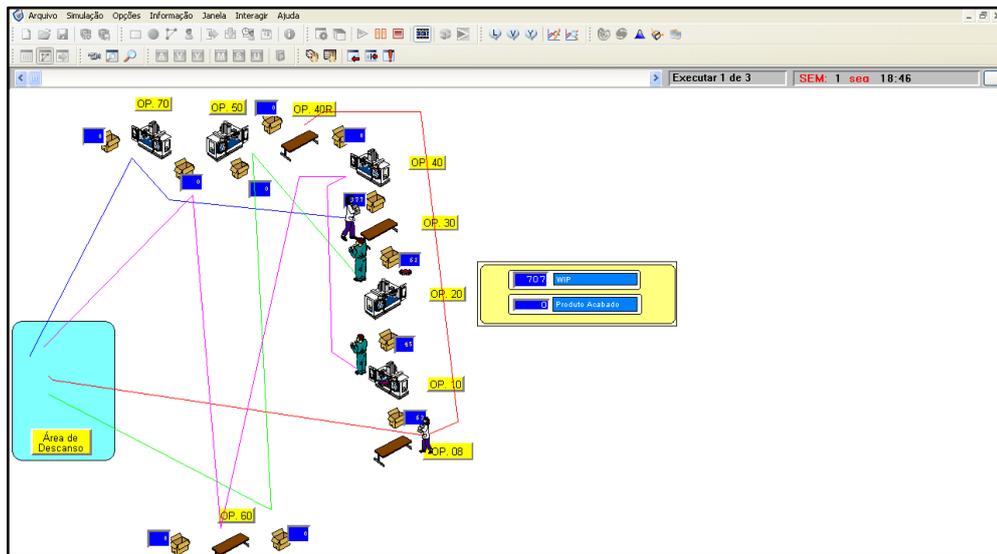


Figura 6.8 - Modelo implementado no *ProModel®* para o quarto objeto de estudo

Dessa forma, para esse objeto de estudo, foram definidas como variáveis de decisão a quantidade de operadores em cada um desses grupos (Passo 1). Todas as variáveis de decisão foram definidas como inteiras, com limite inferior igual a 1 e limite superior igual a 9 (Passo 2). A **Tabela 6.5** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número operadores 1	Inteira	1	9
Número operadores 2	Inteira	1	9
Número operadores 3	Inteira	1	9
Número operadores 4	Inteira	1	9

Tabela 6.5 - Variáveis de decisão, tipo e limites para o quarto objeto de estudo

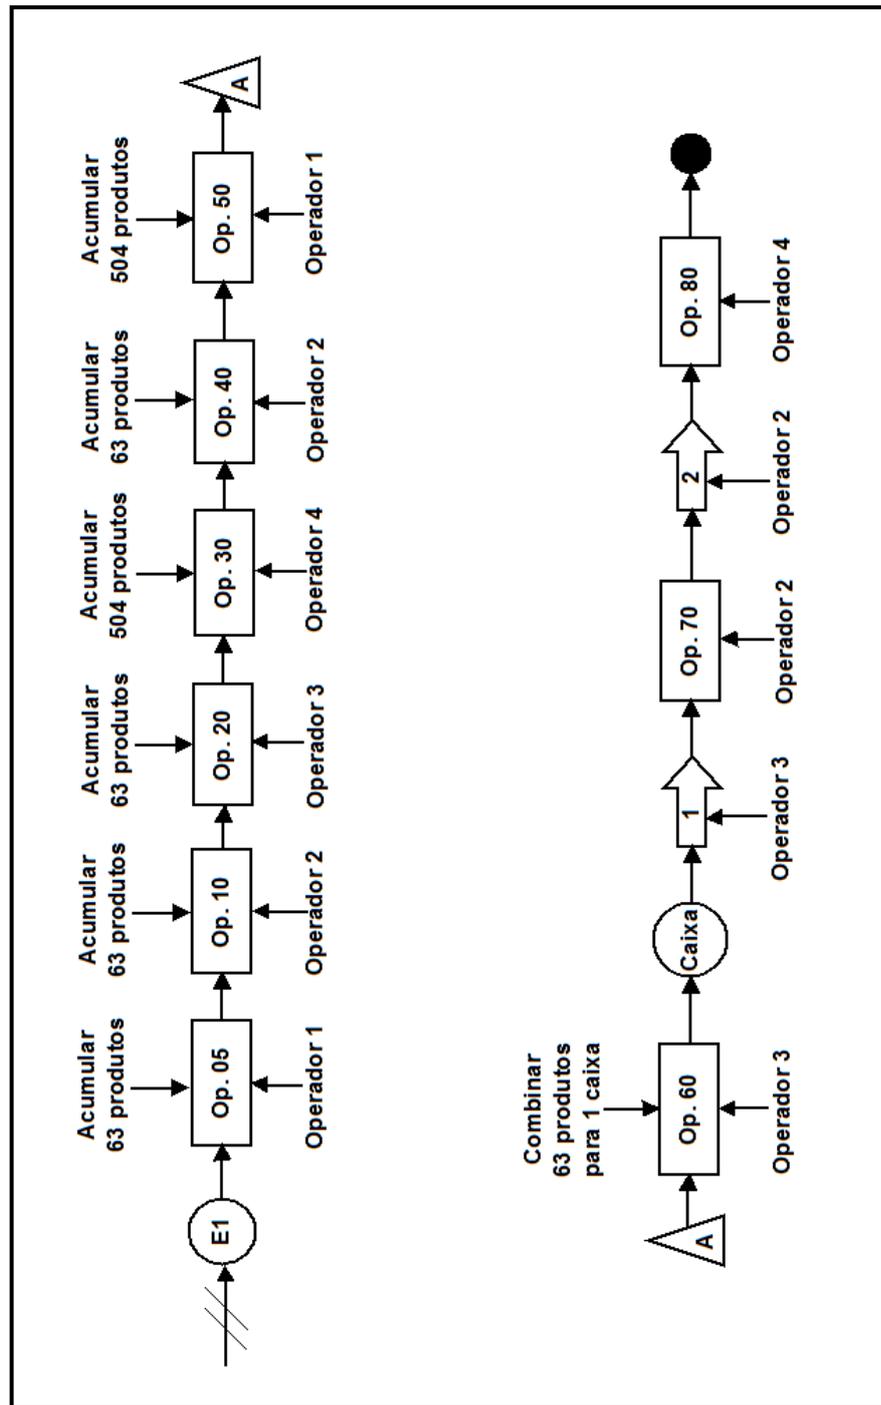


Figura 6.9 - Modelo conceitual para o quarto objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula. Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 6561 cenários possíveis para a busca da melhor configuração.

6.4.5 Quinto objeto de estudo

O quinto objeto de estudo foi desenvolvido na mesma empresa do terceiro objeto de estudo. A diferença foi a célula modelada, responsável pela produção de outro tipo de *transponder*. A **Figura 6.10** representa o modelo implementado no *software ProModel®*, e a **Figura 6.11** apresenta o modelo conceitual através da técnica IDEF-SIM.

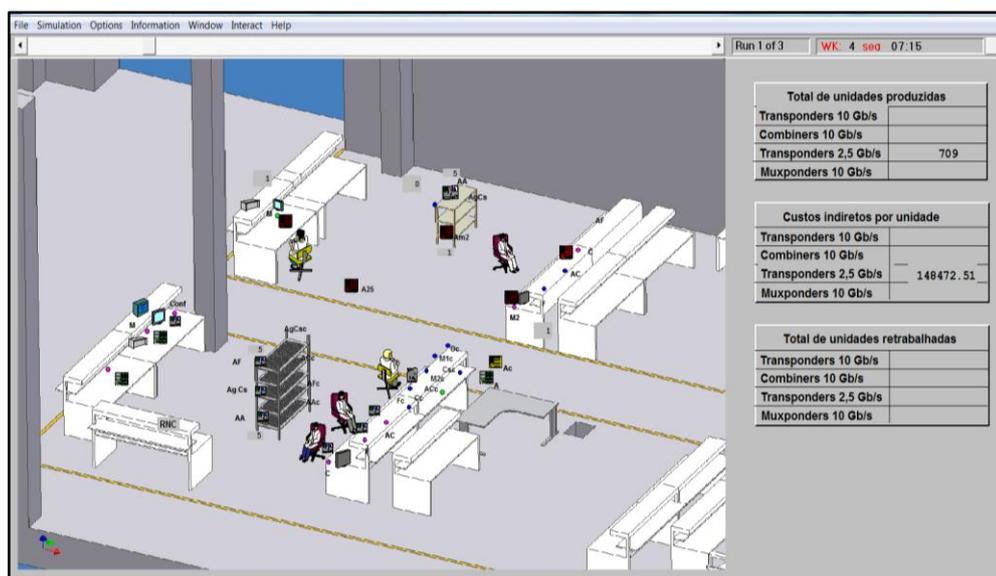


Figura 6.10 - Modelo implementado no *ProModel®* para o quinto objeto de estudo

Para esse objeto de estudo, foram definidas como variáveis de decisão o número de bancadas dos tipos 1 e 2, e o número de funcionários dos tipos 1, 2 e 3 (Passo 1). Foi definido que as variáveis de decisão seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9. (Passo 2). A **Tabela 6.6** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número de bancadas do tipo 1	Inteira	1	9
Número de bancadas do tipo 2	Inteira	1	9
Número de operadores 1	Inteira	1	9
Número de operadores 2	Inteira	1	9
Número de operadores 3	Inteira	1	9

Tabela 6.6 - Variáveis de decisão, tipo e limites para o quinto objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula.

Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 59049 cenários possíveis para a busca da melhor configuração.

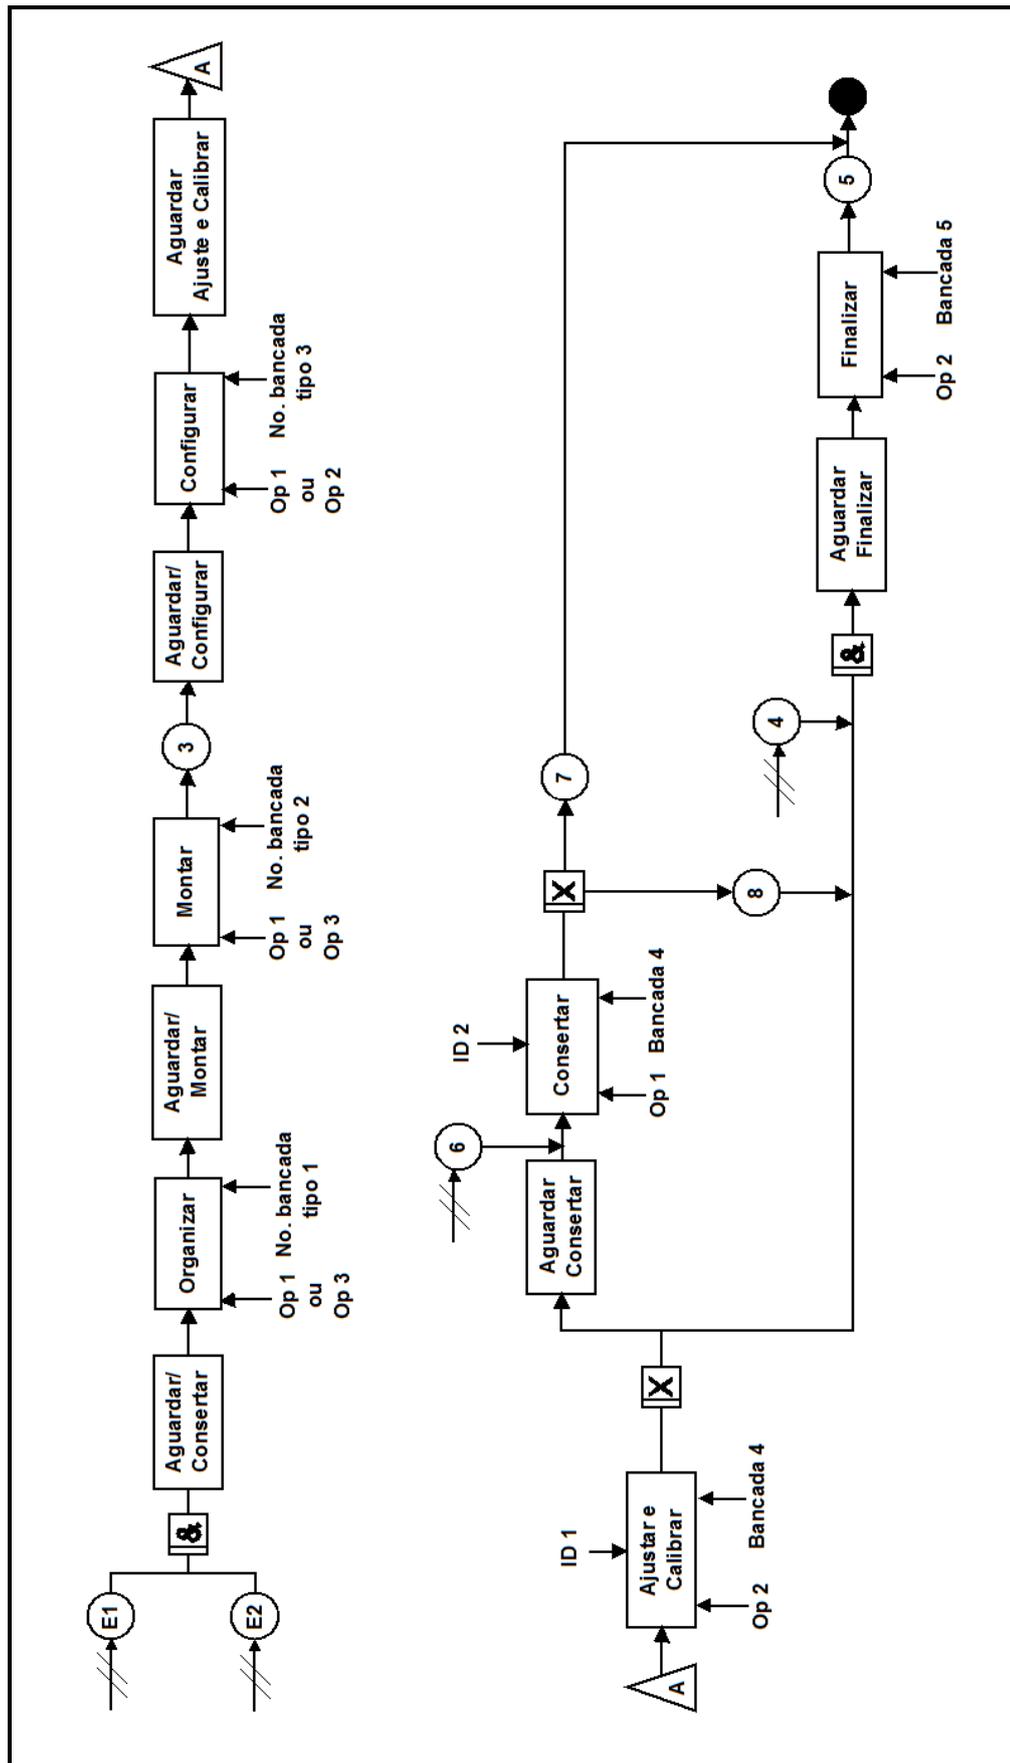


Figura 6.11 - Modelo conceitual para o quinto e sexto objetos de estudo
 Fonte: Adaptado de Costa (2010)

6.4.6 Sexto objeto de estudo

O sexto objeto de estudo corresponde à mesma célula de produção do quinto objeto de estudo. A diferença entre eles consiste no produto fabricado. Os dois produtos utilizam o mesmo fluxo produtivo, mas são diferentes entre si pelo tempo de execução de cada atividade e pelos operadores que executam as atividades. A **Figura 6.12** representa o modelo implementado no *software ProModel®*.

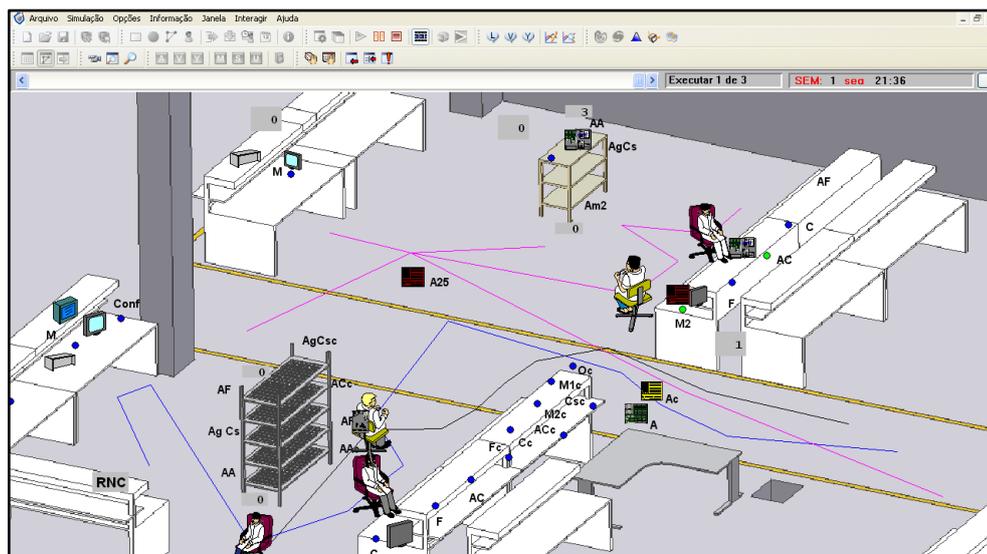


Figura 6.12 - Modelo implementado no *ProModel®* para o sexto objeto de estudo

Para esse objeto de estudo, foram definidas como variáveis de decisão o número de bancadas dos tipos 1 e 2, e o número de funcionários dos tipos 1, 2 e 3 (Passo 1). Foi definido que as variáveis de decisão seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9. (Passo 2). A **Tabela 6.7** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número de bancadas do tipo 1	Inteira	1	9
Número de bancadas do tipo 2	Inteira	1	9
Número de operadores 1	Inteira	1	9
Número de operadores 2	Inteira	1	9
Número de operadores 3	Inteira	1	9

Tabela 6.7 - Variáveis de decisão, tipo e limites para o sexto objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula.

Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 59049 cenários possíveis para a busca da melhor configuração.

6.4.7 Sétimo objeto de estudo

O sétimo objeto de estudo foi desenvolvido na mesma empresa do terceiro, quinto e sexto objetos de estudo. A célula modelada agora não representa uma célula de produção, mas sim o controle de qualidade (CQ) da empresa. Essa célula é responsável pela aprovação ou não dos equipamentos produzidos. A **Figura 6.13** representa o modelo implementado no *software ProModel®*, e a **Figura 6.14** apresenta o modelo conceitual através da técnica IDEF-SIM.

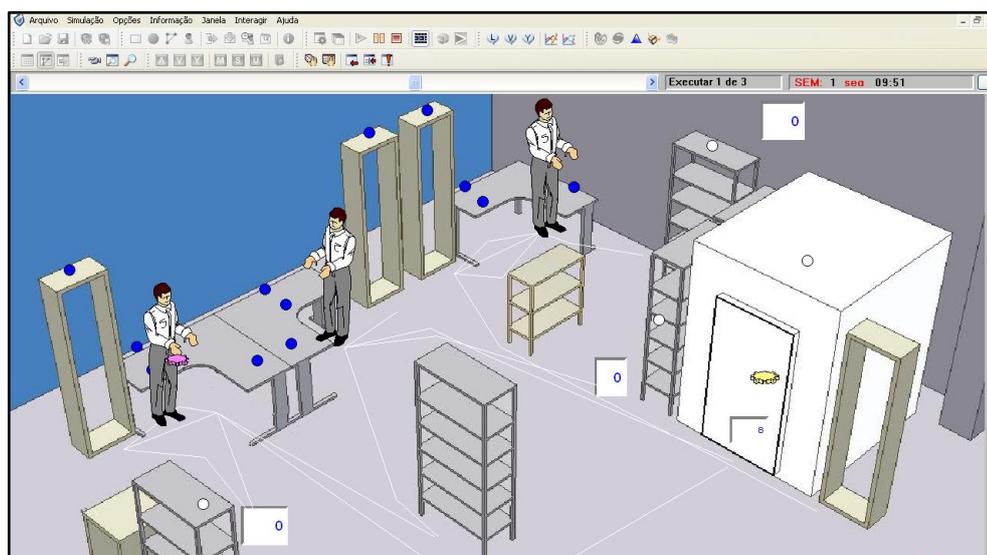


Figura 6.13 - Modelo implementado no *ProModel®* para o sétimo objeto de estudo

Para esse objeto de estudo foram definidas como variáveis de decisão: o número de operadores responsáveis por cada uma das três etapas do CQ e o número de bancadas dos tipos 1, 2 e 3 (Passo 1). Todas as variáveis foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9 (Passo 2). A **Tabela 6.8** apresenta essas informações.

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número operadores 1	Inteira	1	9
Número operadores 2	Inteira	1	9
Número operadores 3	Inteira	1	9
Número bancadas 1	Inteira	1	9
Número bancadas 2	Inteira	1	9
Número bancadas 3	Inteira	1	9

Tabela 6.8 - Variáveis de decisão, tipo e limites para o sétimo objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula.

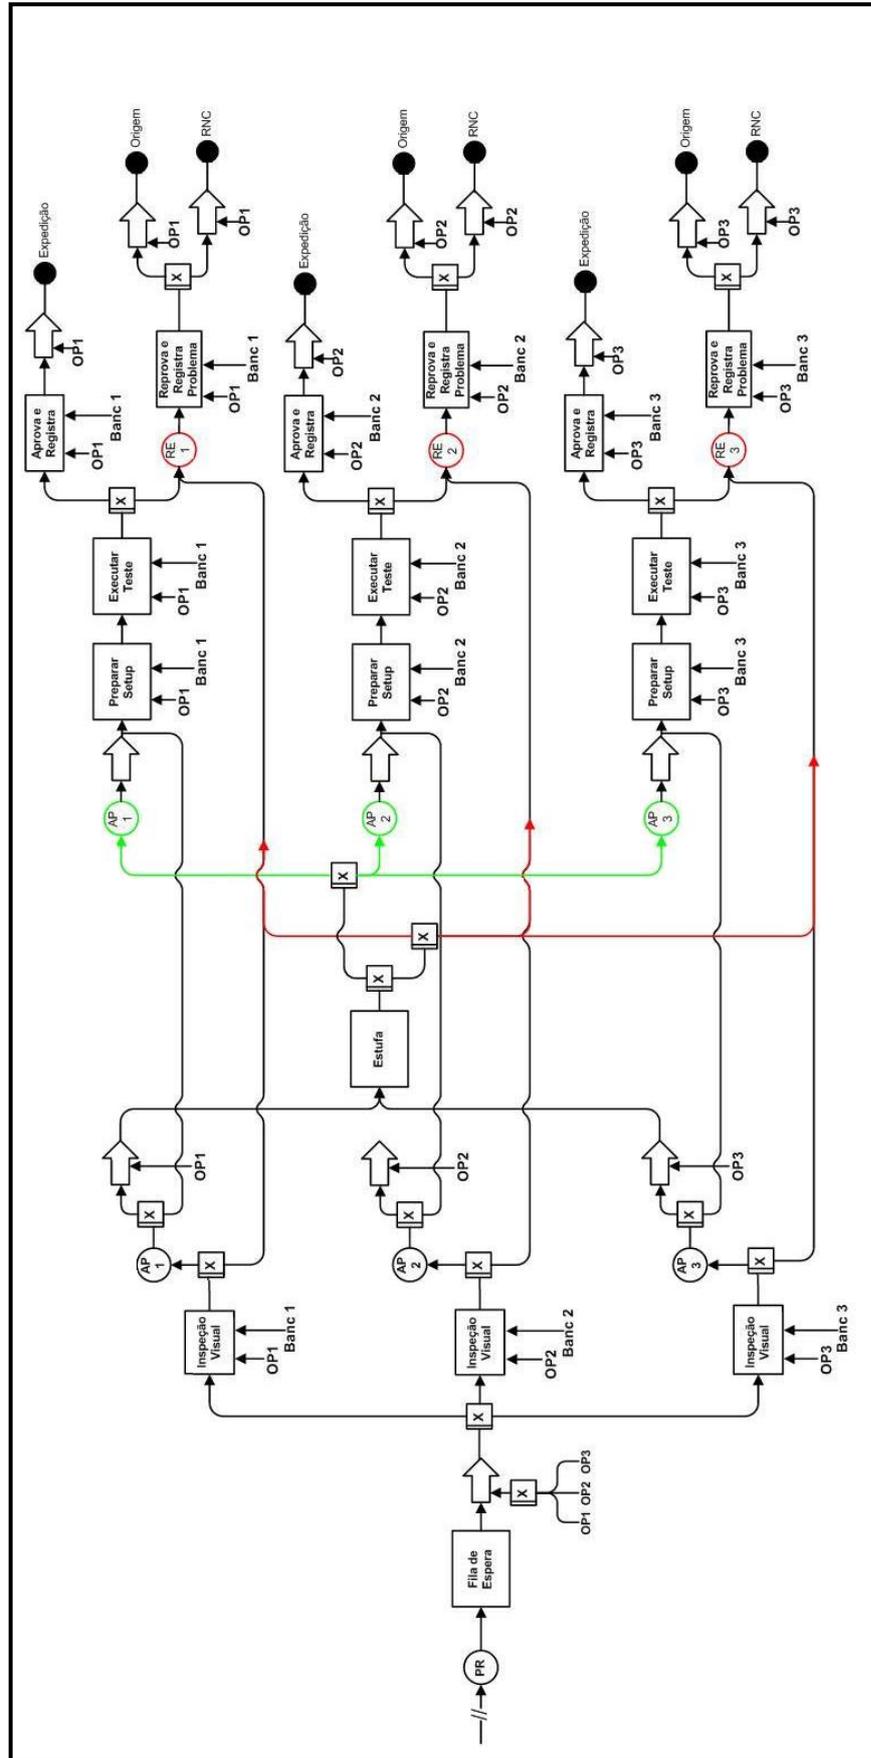


Figura 6.14 - Modelo conceitual para o sétimo objeto de estudo
 Fonte: Oliveira *et al.* (2010)

Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 531441 cenários possíveis para a busca da melhor configuração.

6.4.8 Oitavo objeto de estudo

O oitavo objeto de estudo foi desenvolvido em uma empresa do setor automobilístico. A célula modelada representa uma célula de produção da empresa, formada por duas unidades com o mesmo conjunto de máquinas e operadores. A **Figura 6.15** representa o modelo implementado no *software ProModel®*, e a **Figura 6.16** apresenta o modelo conceitual através da técnica IDEF-SIM.

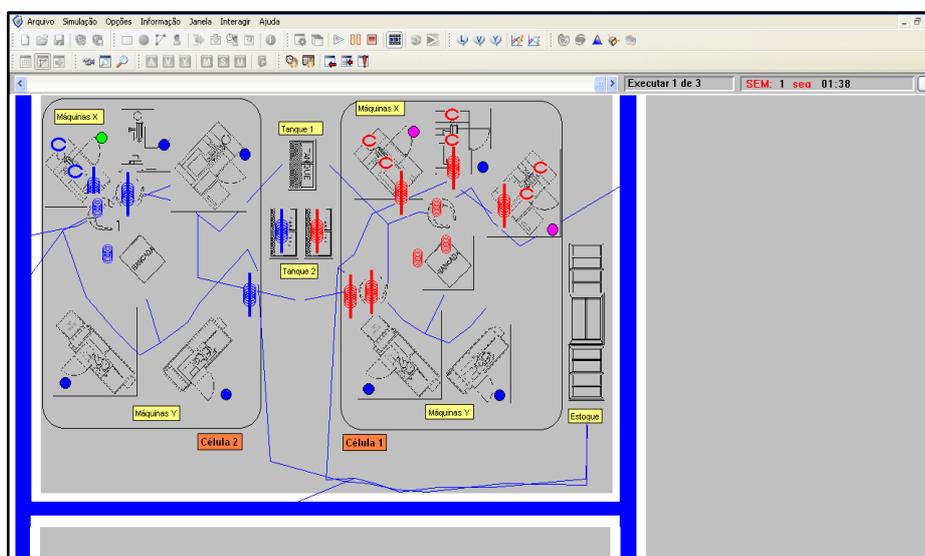


Figura 6.15 - Modelo implementado no *ProModel®* para o oitavo objeto de estudo

Para esse objeto de estudo, foram definidas como variáveis de decisão o número de operadores de retífica (1 e 2), o número de operadores de lapidadora (1 e 2), o número de retíficas (1 e 2) e o número de lapidadoras (1 e 2) (Passo 1). Todas as variáveis foram definidas como sendo do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9 (Passo 2). A **Tabela 6.9** apresenta essas informações (Passo 2).

1º. Passo		2º. Passo	
Variável	Tipo	Limite Inferior	Limite Superior
Número operadores retífica 1	Inteira	1	9
Número operadores lapidadora 1	Inteira	1	9
Número operadores retífica 2	Inteira	1	9
Número operadores lapidadora 2	Inteira	1	9
Número de retíficas 1	Inteira	1	9
Número de retíficas 2	Inteira	1	9

Tabela 6.9 - Variáveis de decisão, tipo e limites para o oitavo objeto de estudo

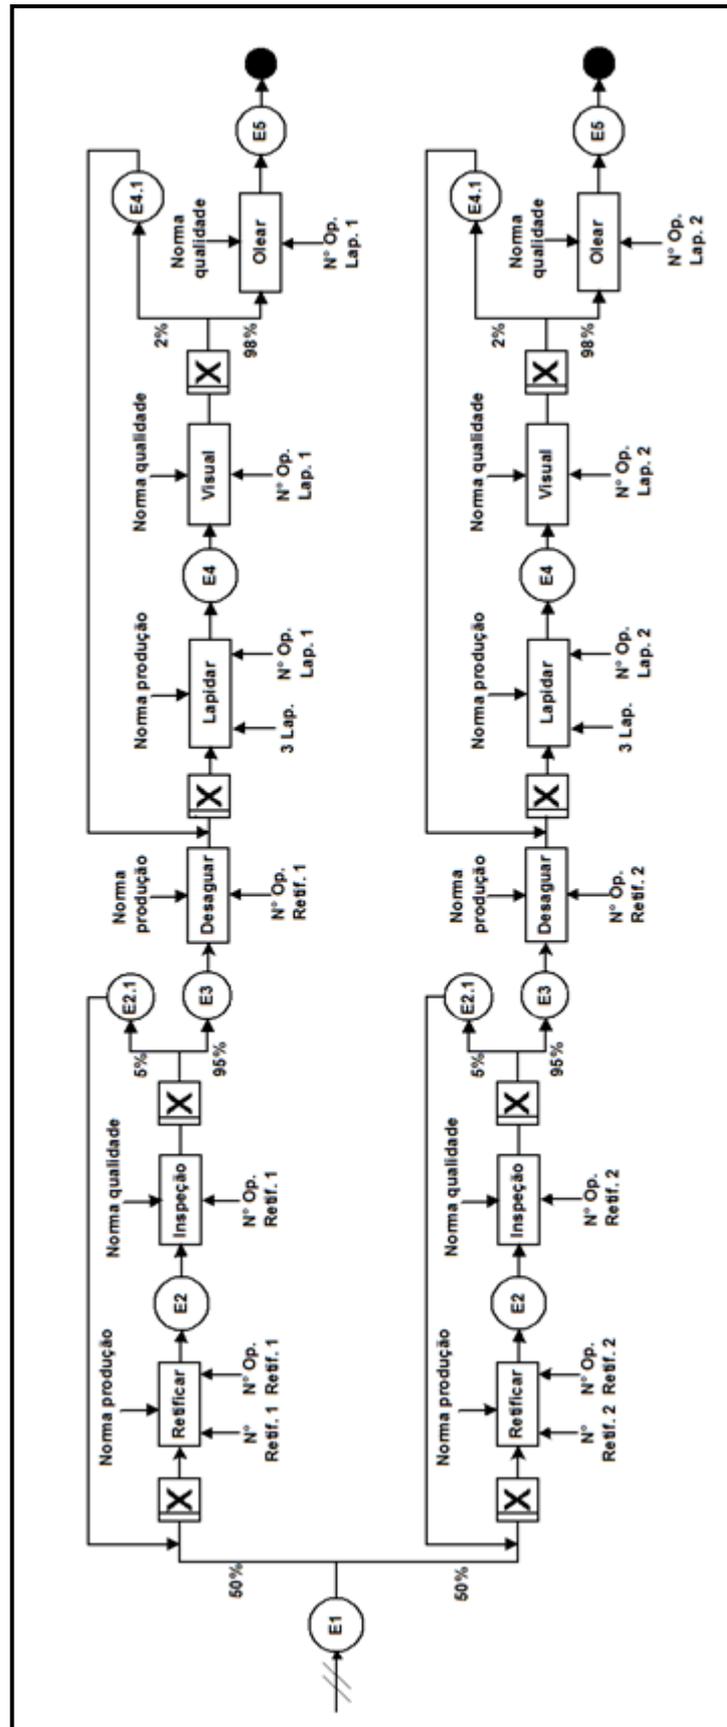


Figura 6.16 - Modelo conceitual para o oitavo objeto de estudo

Foi introduzido no modelo de simulação um modelo matemático não linear (Passo 3). O objetivo da otimização era de encontrar a melhor combinação das variáveis de decisão de forma a maximizar o lucro da célula.

Para o problema em questão, considerando o número de variáveis e sua variação máxima, existe um total de 531441 cenários possíveis para a busca da melhor configuração.

6.5 Otimização dos objetos de estudo

A otimização dos objetos de estudo foi realizada em um mesmo computador, garantindo, desta forma, as mesmas condições em termos de eficiência, tanto para o *SimRunner*® como para o método de otimização proposto, para efeitos de comparação.

As especificações do computador onde os testes foram realizados foram as seguintes:

- Processador: *Intel Core 2 Duo CPU + 1.58 GHz*;
- Memória RAM: *2 Gb*;
- Sistema Operacional: *Windows XP (Service Pack 3)*;

A **Tabela 6.10** resume as principais características do simulador e do otimizador.

Característica	<i>ProModel Professional</i> ®	<i>SimRunner</i> ®
Versão	8.5.1.858	3.2.1.10
Ano	2011	2006

Tabela 6.10 - Características dos *softwares* utilizados

A seguir, os resultados da otimização dos oito objetos de estudo citados anteriormente são apresentados e analisados individualmente. Apresenta-se também a formulação matemática de cada problema de otimização. Os modelos matemáticos utilizados foram desenvolvidos exclusivamente para fins de teste do algoritmo. Serão comparados os resultados obtidos através do *SimRunner*® e do método de otimização proposto quanto a resposta apresentada pelos métodos, ao tempo necessário para convergência e quanto ao número de experimentos realizados por cada método.

Especificamente para o *SimRunner*®, serão analisados os resultados para os três perfis do *software* (agressivo, moderado e cauteloso). Tanto para o método de otimização proposto, como para o *SimRunner*®, foram adotadas três replicações do modelo de simulação.

Como os parâmetros do AG do algoritmo proposto já se encontram definidos e como o *SimRunner*® não permite a alteração desses parâmetros, pode-se considerar o quarto passo do método proposto por Harrel, Ghosh e Bowden (2004) como cumprido. Com os 4 passos do método definidos, passa-se, agora, à última etapa.

6.5.1 Otimização do primeiro objeto de estudo

6.5.1.1 Formulação matemática

$$\text{Max } Z = Y_1 - 3500x_1^2 - 4000x_2^2 - 3750x_3^2 \quad (7)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (8)$$

$$1 \leq x_2 \leq 9 \quad (9)$$

$$1 \leq x_3 \leq 9 \quad (10)$$

$$x_1, x_2, x_3 \geq 0 \text{ e inteiros} \quad (11)$$

Onde:

- Y_1 : Total produzido no modelo de simulação (esse valor é conhecido após a execução do modelo de simulação para um determinado conjunto de parâmetros de entrada).

Variáveis de decisão:

- x_1 : número de operadores 1
- x_2 : número de operadores 2
- x_3 : número de operadores 3

6.5.1.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o primeiro objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.11**.

Na tabela, um resultado positivo para eficiência ($+\xi$) indica quanto melhor o *software* comercial foi em relação ao método proposto. Já um resultado negativo ($-\xi$) indica quanto pior o *software* comercial foi em relação ao método proposto. Esta interpretação é válida também para os demais objetos de estudo.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	360	+22%	355083,00	-5%	75	+9%
Perfil Moderado	591	-28%	364750,00	-2%	125	-52%
Perfil Cauteloso	960	-108%	372583,00	0%	200	-144%
Método proposto	461		372583,00		82	

Tabela 6.11 - Resultados Otimização primeiro objeto de estudo

Na otimização do primeiro modelo de simulação, o método proposto alcançou a mesma

qualidade de resposta do Perfil Cauteloso do *software* comercial, com a vantagem de alcançar a mesma qualidade em menor tempo (menos da metade do tempo do otimizador comercial) e com a realização de menos experimentos. Em relação ao tempo e ao número de experimentos, o método proposto só perde para o Perfil Agressivo do *software* comercial. Porém a resposta alcançada nesse perfil foi consideravelmente inferior à alcançada pelo método proposto.

6.5.2 Otimização do segundo objeto de estudo

6.5.2.1 Formulação matemática

$$\text{Max } Z = 100Y_1 - 80x_1^2 - 120x_2^2 - 150x_3^2 \quad (12)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (13)$$

$$1 \leq x_2 \leq 9 \quad (14)$$

$$1 \leq x_3 \leq 9 \quad (15)$$

$$x_1, x_2, x_3 \geq 0 \text{ e inteiros} \quad (16)$$

Onde:

- Y1: Total produzido no modelo de simulação

Variáveis de decisão:

- x_1 : número de lavadoras
- x_2 : número de centrífugas
- x_3 : número de secadoras

6.5.2.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o segundo objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.12**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	798	+6%	26482,00	-1,30%	77	+6%
Perfil Moderado	1362	-60%	26491,60	-1,27%	131	-60%
Perfil Cauteloso	1998	-135%	26494,00	-1,26%	189	-130%
Método proposto	851		26832,00		82	

Tabela 6.12 - Resultados Otimização segundo objeto de estudo

Na otimização do segundo modelo de simulação, o método proposto alcançou um resultado superior a todos os perfis do otimizador comercial, sendo mais rápido e realizando um número menor de experimentos que os Perfis Moderado e Cauteloso do *software* comercial. O Perfil Agressivo, assim como no caso anterior, convergiu em um tempo menor que o método proposto e realizou menos experimentos. Porém alcançou a pior resposta dentre todos os métodos.

6.5.3 Otimização do terceiro objeto de estudo

6.5.3.1 Formulação matemática

$$\text{Max } Z = 25Y_1 - 35x_1^2 - 22x_2^2 - 28x_3^2 - 15x_4 \quad (17)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (18)$$

$$1 \leq x_2 \leq 9 \quad (19)$$

$$1 \leq x_3 \leq 9 \quad (20)$$

$$x_4 \in \{0, 1\} \quad (21)$$

$$x_1, x_2, x_3, x_4 \geq 0 \text{ e inteiros} \quad (22)$$

Onde:

- Y_1 : Total produzido no modelo de simulação

Variáveis de decisão:

- x_1 : número de operadores
- x_2 : número de bancadas com setup
- x_3 : número de bancadas sem setup
- x_4 : se existe ou não organização de materiais na célula de produção

6.5.3.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o terceiro objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.13**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	263	+33%	1426,67	-23,7%	84	-2%
Perfil Moderado	544	-39%	1870,00	0%	166	-102%
Perfil Cauteloso	843	-116%	1870,00	0%	258	-215%
Método proposto	390		1870,00		82	

Tabela 6.13 - Resultados Otimização terceiro objeto de estudo

Na otimização do terceiro objeto de estudo, o método proposto alcançou uma solução com a mesma qualidade dos perfis Moderado e Cauteloso. Porém, conseguiu fazê-lo com um tempo menor e com um número de experimentos menor que esses perfis. Com relação ao número de experimentos, o método proposto foi mais eficiente até mesmo que Perfil Agressivo do *software* comercial.

6.5.4 Otimização do quarto objeto de estudo

6.5.4.1 Formulação matemática

$$Max Z = 50Y_1 - 10Y_2 - 900x_1^2 - 875x_2^2 - 855x_3^2 - 860x_4^2 \quad (23)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (24)$$

$$1 \leq x_2 \leq 9 \quad (25)$$

$$1 \leq x_3 \leq 9 \quad (26)$$

$$1 \leq x_4 \leq 9 \quad (27)$$

$$x_1, x_2, x_3, x_4 \geq 0 \text{ e inteiros} \quad (28)$$

Onde

- Y_1 : Total produzido no modelo de simulação
- Y_2 : *Work in process*

Variáveis de decisão

- x_1 : número de operadores 1
- x_2 : número de operadores 2
- x_3 : número de operadores 3
- x_4 : número de operadores 4

6.5.4.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o quarto objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.14**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	2028	+56%	504388,33	-4%	120	+67%
Perfil Moderado	3405	+25%	521231,00	-0,8%	201	+45%
Perfil Cauteloso	5634	-24%	525531,00	0%	332	+10%
Método proposto	4560		525531,00		367	

Tabela 6.14 - Resultados Otimização quarto objeto de estudo

Na otimização do quarto objeto de estudo, o método proposto alcançou uma solução de igual qualidade à encontrada pelo otimizador comercial no Perfil Cauteloso. Para este objeto de estudo, o método proposto realizou mais experimentos que todos os perfis do *software* comercial. Porém conseguiu manter sua eficiência em relação ao tempo, levando menos tempo para convergir que o otimizador comercial para alcançar uma resposta de mesma qualidade.

6.5.5 Otimização do quinto objeto de estudo

6.5.5.1 Formulação matemática

$$\text{Max } Z = 175Y_1 - 650x_1^2 - 600x_2^2 - 800x_3^2 - 1350x_4^2 - 1425x_5^2 \quad (29)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (30)$$

$$1 \leq x_2 \leq 9 \quad (31)$$

$$1 \leq x_3 \leq 9 \quad (32)$$

$$1 \leq x_4 \leq 9 \quad (33)$$

$$1 \leq x_5 \leq 9 \quad (34)$$

$$x_1, x_2, x_3, x_4, x_5 \geq 0 \text{ e inteiros} \quad (35)$$

Onde:

- Y_1 : Total produzido no modelo de simulação

Variáveis de decisão:

- x_1 : número de bancadas do tipo 1

- x_2 : número de bancadas do tipo 2
- x_3 : número de operadores 1
- x_4 : número de operadores 2
- x_5 : número de operadores 3

6.5.5.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o quinto objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.15**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	1663	+44%	231617,00	-1,89%	109	+56%
Perfil Moderado	2788	+7%	234324,00	-0,75%	183	+25%
Perfil Cauteloso	5220	-75%	236083,00	0%	343	-40%
Método proposto	2987		236083,00		245	

Tabela 6.15 - Resultados Otimização quinto objeto de estudo

Na otimização do quinto objeto de estudo, o método proposto alcançou uma solução de mesma qualidade que o Perfil Cauteloso do *software* comercial, com o diferencial que o fez realizando menos experimentos e em menos tempo. Os outros perfis do *software* comercial realizaram menos experimentos e levaram menos tempo para convergir. Porém, alcançaram respostas inferiores a alcançada pelo Perfil Cauteloso e pelo método proposto.

6.5.6 Otimização do sexto objeto de estudo

6.5.6.1 Formulação matemática

$$Max Z = 1000Y_1 - Y_2 - 80x_1^2 - 45x_2^2 - 250x_3^2 - 350x_4^2 - 425x_5^2 \quad (36)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (37)$$

$$1 \leq x_2 \leq 9 \quad (38)$$

$$1 \leq x_3 \leq 9 \quad (39)$$

$$1 \leq x_4 \leq 9 \quad (40)$$

$$1 \leq x_5 \leq 9 \quad (41)$$

$$x_1, x_2, x_3, x_4, x_5 \geq 0 \text{ e inteiros} \quad (42)$$

Onde:

- Y1: Total produzido no modelo de simulação
- Y2: Custo da utilização dos equipamentos produtivos

Variáveis de decisão:

- x_1 : número de bancadas do tipo 1
- x_2 : número de bancadas do tipo 2
- x_3 : número de operadores 1
- x_4 : número de operadores 2
- x_5 : número de operadores 3

6.5.6.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o sexto objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.16**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	2376	-15%	1102218,57	-1,01%	160	+2%
Perfil Moderado	3714	-79%	1105897,67	-0,68%	246	-51%
Perfil Cauteloso	7983	-286%	1110532,16	-0,27%	543	-233%
Método proposto	2070		1113505,00		163	

Tabela 6.16 - Resultados Otimização sexto objeto de estudo

Na otimização do sexto modelo de simulação, o método proposto alcançou a melhor solução dentre todos os perfis do *software* comercial e se mostrou mais eficiente em termos de tempo que todos os perfis, visto que chegou à melhor solução no menor tempo dentre todos. Em relação ao número de experimentos, o método proposto realizou apenas 3 experimentos a mais que o Perfil Agressivo do *software* comercial.

6.5.7 Otimização do sétimo objeto de estudo

6.5.7.1 Formulação matemática

$$MaxZ = 1000Y_1 - 150Y_2 - 150x_1^2 - 120x_2^2 - 95x_3^2 - 35x_4^2 - 40x_5^2 - 50x_6^2 \quad (43)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (44)$$

$$1 \leq x_2 \leq 9 \quad (45)$$

$$1 \leq x_3 \leq 9 \quad (46)$$

$$1 \leq x_4 \leq 9 \quad (47)$$

$$1 \leq x_5 \leq 9 \quad (48)$$

$$1 \leq x_6 \leq 9 \quad (49)$$

$$x_1, x_2, x_3, x_4, x_5, x_6 \geq 0 \text{ e inteiros} \quad (50)$$

Onde:

- Y1: Total produzido no modelo de simulação
- Y2: Produtos reprovados pelo controle de qualidade

Variáveis de decisão:

- x_1 : número de operadores 1
- x_2 : número de operadores 2
- x_3 : número de operadores 3
- x_4 : número de bancadas 1
- x_5 : número de bancadas 2
- x_6 : número de bancadas 3

6.5.7.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o sétimo objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.17**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	1630	+6%	5061936,67	-0,05%	135	+17%
Perfil Moderado	2883	-66%	5061936,67	-0,05%	243	-49%
Perfil Cauteloso	3090	-78%	5062776,67	-0,03%	255	-56%
Método proposto	1733		5064232,00		163	

Tabela 6.17 - Resultados Otimização sétimo objeto de estudo

Na otimização do sétimo modelo de simulação, o método proposto alcançou a melhor resposta dentre todos os perfis do *software* comercial, levando menos tempo para alcançar a solução que os Perfis Moderado e Cauteloso e realizando um número menor de experimentos que estes perfis. Em questão de tempo e número de experimentos realizados, o método proposto só foi inferior ao Perfil Agressivo do *software* comercial. Porém esse alcançou uma qualidade de resposta baixa.

6.5.8 Otimização do oitavo objeto de estudo

6.5.8.1 Formulação matemática

$$\text{Max } Z = Y_1 - 15x_1^2 - 20x_2^2 - 25x_3^2 - 32x_4^2 - 40x_5^2 - 56x_6^2 \quad (51)$$

Sujeito a

$$1 \leq x_1 \leq 9 \quad (52)$$

$$1 \leq x_2 \leq 9 \quad (53)$$

$$1 \leq x_3 \leq 9 \quad (54)$$

$$1 \leq x_4 \leq 9 \quad (55)$$

$$1 \leq x_5 \leq 9 \quad (56)$$

$$1 \leq x_6 \leq 9 \quad (60)$$

$$x_1, x_2, x_3, x_4, x_5, x_6 \geq 0 \text{ e inteiros} \quad (61)$$

Onde:

- Y1: Total produzido no modelo de simulação

Variáveis de decisão:

- x_1 : número operadores retífica 1
- x_2 : número operadores lapidadora 1
- x_3 : número operadores retífica 2
- x_4 : número operadores lapidadora 2
- x_5 : número de retíficas 1
- x_6 : número de retíficas 2

6.5.8.2 Análise dos resultados

Os resultados alcançados com a realização dos testes para o oitavo objeto de estudo, bem como o comparativo de eficiência (ξ) entre os resultados alcançados com o método proposto e os perfis do *software* comercial, podem ser visualizados na **Tabela 6.18**.

Otimizador	Tempo (segundos)		Resposta		Experimentos realizados	
	Valor	ξ	Valor	ξ	Valor	ξ
Perfil Agressivo	24900	+13%	511861,00	-0,57%	197	+46%
Perfil Moderado	43980	-55%	511904,00	-0,56%	348	+5%
Perfil Cauteloso	53640	-88%	513390,00	-0,27%	424	-16%
Método proposto	28464		514804,00		367	

Tabela 6.18 - Resultados Otimização oitavo objeto de estudo

Na otimização do último modelo de simulação, o método proposto alcançou a melhor qualidade de resposta dentre todos os perfis do *software* comercial. No entanto, com relação ao número de experimentos realizados, o método proposto só realizou menos experimentos que o Perfil Cauteloso do *software* comercial. Com relação ao tempo, o método proposto foi mais eficiente que os Perfis Moderado e Cauteloso do otimizador.

6.6 Considerações finais

O capítulo aqui desenvolvido apresentou os resultados do estudo comparativo envolvendo o *SimRunner*® e o AGA proposto nesta dissertação, na otimização de oito modelos de simulação a eventos discretos não lineares. Foi utilizada a metodologia para otimização de modelos de simulação proposta por Harrel, Ghosh e Bowden (2004).

Os resultados alcançados mostraram que o método de otimização aqui desenvolvido se mostrou tão eficiente quanto o otimizador comercial, alcançando respostas de igual qualidade às alcançadas pelo *software* comercial ou até mesmo superior. Com relação ao tempo gasto para se atingir uma resposta, verifica-se que o AGA proposto é mais eficiente quando comparado ao tempo gasto pelo otimizador comercial para encontrar sua melhor solução.

Dessa forma, pode-se considerar como completa a terceira etapa do método de pesquisa que suporta esta dissertação, a etapa de Solução pelo Modelo (MITROFF *et al.*, 1974).

7. CONCLUSÃO

7.1 Considerações iniciais

Este capítulo apresenta as principais conclusões e contribuições geradas com esse trabalho. Ao final desse capítulo sugestões para trabalhos futuros serão apresentadas.

Este capítulo encerra a última etapa do método de pesquisa proposto por Mitroff *et al.* (1974), a fase de implementação. Nesta etapa, os resultados alcançados com a utilização do método desenvolvido são implementados, ou seja, o AGA desenvolvido, passa a ser utilizado.

7.2 Conclusões gerais

O trabalho aqui desenvolvido permitiu elaborar um método de otimização baseado em algoritmos genéticos para otimização de modelos de simulação, tão eficiente quanto um otimizador comercial. E o fez de forma abrangente, apresentando todas as etapas necessárias a seu desenvolvimento, bem como discutiu seus principais parâmetros de configuração e as adaptações necessárias para sua estrutura.

A partir de uma ampla revisão de literatura e da análise de significância dos principais parâmetros de um algoritmo genético, pode-se verificar quais parâmetros do AG e suas interações mais influenciavam na obtenção de soluções de elevada qualidade e no aumento do tempo de processamento do algoritmo.

Nesse sentido, dois parâmetros se destacaram: o tamanho de população e o número de gerações, sendo o primeiro mais significativo para obtenção de soluções de elevada qualidade e o segundo mais significativo para o tempo de convergência do algoritmo. Para ambos os parâmetros, adaptações foram propostas de maneira a garantir boas soluções e ao mesmo tempo a eficiência do algoritmo proposto.

Para o parâmetro tamanho de população, foi utilizada a proposta de equacionamento de população mínima proposta por Reeves (1993), e para o número de gerações foi adotado um critério de parada baseado na melhoria das soluções encontradas ao longo das gerações. Com relação aos operadores genéticos (*Crossover* e *Mutação*), optou-se por trabalhar com dois conjuntos de valores conforme o tamanho da população inicial, seguindo os princípios contidos no trabalho de Reeves (1993).

Seguindo os passos do método de pesquisa, o algoritmo de otimização foi implementado e testado na otimização de oito modelos de simulação a eventos discretos. Os

resultados alcançados foram comparados com os resultados de um *software* comercial amplamente utilizado no mercado.

Para a condução dos testes, os modelos de simulação utilizados tiveram seu grau de complexidade tanto em termos de número de variáveis de decisão como em número de possíveis soluções para o problema aumentado. A comparação entre o algoritmo desenvolvido e o *software* comercial se deu em função de três variáveis: qualidade da resposta, tempo para convergência e número de experimentos realizados.

Os resultados alcançados com a realização dos testes mostraram que o algoritmo proposto alcança respostas de igual qualidade ou até mesmo superiores que o otimizador comercial em seu melhor perfil de otimização. E o faz com maior eficiência de tempo e número de experimentos que o *software* comercial.

Com relação ao tempo gasto para se atingir uma resposta, verifica-se que o AGA proposto é mais eficiente quando comparado ao tempo gasto pelo otimizador comercial para encontrar sua melhor solução dentre seus três perfis. Isso fica mais evidente conforme se aumenta a complexidade do modelo de simulação.

Para o sexto objeto de estudo, o otimizador comercial levou 2,2 horas para chegar a uma resposta, enquanto o método proposto levou pouco mais de 0,5 hora para chegar a uma resposta melhor. Para o oitavo objeto de estudo, o método proposto gastou por volta de 8 horas para encontrar uma solução melhor que a do Perfil Cauteloso do *software* comercial, que gastou por volta de 15 horas e encontrou uma solução pior.

Os casos em que o *software* comercial levou menos tempo para convergir geralmente estão associados ao seu pior perfil de otimização (Perfil Agressivo). Nesses casos, a solução encontrada pelo otimizador sempre foi inferior à encontrada pelo AGA proposto e pelos outros perfis do otimizador comercial.

Ainda com relação ao número de experimentos realizados, o método aqui desenvolvido oscila entre os perfis de otimização do *software* comercial. No geral, o número de experimentos é maior que os experimentos realizados no Perfil Agressivo. Porém, menor que os realizados no Perfil Moderado. Em alguns casos, o número de experimentos do AGA proposto consegue até mesmo ser menor que o do Perfil Agressivo e para um dos modelos o número de experimentos realizados foi maior que os realizados pelo otimizador comercial. Porém, nesse caso, o método proposto consegue ser mais eficiente, realizando um número maior de experimentos em menos tempo que o *software* comercial.

O AGA proposto neste trabalho para otimização de modelos de simulação a eventos discretos não lineares apresentou bons resultados tanto em termos de qualidade de resposta

como em eficiência (tempo e número de experimentos realizados). Desta forma, o método aqui desenvolvido apresenta-se como uma ferramenta de otimização alternativa aos pacotes comerciais existentes (respeitando as condições de contorno dessa dissertação), capaz de realizar a otimização de modelos de simulação de forma ágil (baixo tempo computacional) e confiável, oferecendo soluções de elevada qualidade. Vale ainda ressaltar que novos testes deverão ser realizados com outros modelos de simulação e novos modelos matemáticos, de forma a explorar outros modelos não lineares.

7.3 Verificação dos objetivos específicos

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

1) Analisar a influência dos parâmetros dos algoritmos genéticos no tempo de convergência e na qualidade de resposta na otimização de modelos de simulação a eventos discretos.

Este objetivo foi atendido de duas maneiras. A primeira, por meio de uma vasta revisão de literatura sobre os valores mais comuns para os parâmetros do AG e o impacto de sua definição sobre o algoritmo. Posteriormente, utilizou-se do delineamento de experimentos (DOE) para analisar a significância dos parâmetros do AG e suas interações sobre a qualidade de resposta e sobre o tempo para convergência. Dois parâmetros e sua interação mostraram-se fortemente significativos: o tamanho da população e o número de gerações. O primeiro parâmetro apresentou um forte efeito sobre a variável qualidade de resposta; enquanto que o segundo parâmetro e a interação entre eles apresenta um efeito consideravelmente significativo sobre o tempo necessário para a convergência. Todos os passos que levaram a atender esse objetivo podem ser verificados ao longo dos *Capítulos 3 e 4*.

2) Desenvolver a estrutura e propor as adaptações necessárias ao AGA.

Com a definição dos parâmetros do AG que mais impactavam para a obtenção de soluções de elevada qualidade e para o aumento do tempo de processamento do algoritmo, foi possível discutir e propor adaptações a esses parâmetros. As adaptações se concentraram principalmente na definição do tamanho da população inicial, e no seu incremento ao longo das iterações realizadas pelo algoritmo. Um novo critério de parada, não baseado no número de gerações, também foi desenvolvido. E dois conjuntos de valores foram definidos para os parâmetros *Crossover* e *Mutação*. Toda a discussão envolvendo a estrutura do AGA proposto nesta dissertação pode ser visualizada ao longo de todo o *Capítulo 5*.

3) Desenvolver uma ferramenta computacional capaz de operacionalizar o AGA proposto.

Uma vez proposta a estrutura do AGA para otimização de modelos de simulação, tornou-se necessário implementar sua estrutura por meio de uma ferramenta computacional. Desta forma, um *software* foi desenvolvido objetivando facilitar o processo de otimização dos modelos de simulação, assim como permitir a visualização dos resultados obtidos. Só com a criação desse *software* o método de otimização aqui desenvolvido tornou-se operacional e permitiu realizar a otimização dos modelos de simulação. O processo de desenvolvimento da ferramenta computacional pode ser verificado no **Capítulo 5**.

4) Comparar o AGA proposto com um *software* comercial de otimização de modelos de simulação.

Com o método de otimização implementado em um *software*, tornou-se fácil realizar sua comparação com um *software* comercial. Para a comparação, foi utilizado o *software SimRunner®*. Oito modelos de simulação foram otimizados utilizando ambos os métodos de otimização e três variáveis de reposta foram analisadas: a qualidade de resposta, o tempo necessário para convergência e o número de experimentos realizados. Pode-se constatar que o AGA proposto foi tão eficiente e até mesmo melhor que o otimizador comercial. Todo o estudo comparativo realizado pode ser visualizado ao longo de todo o **Capítulo 6**.

7.4 Sugestões para trabalhos futuros

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

- Realizar novos testes com o método de otimização proposto explorando outras funções não lineares, além das já utilizadas nessa dissertação;
- Realizar estudos comparativos com outros otimizadores comerciais baseados em AG e outras metaheurísticas;
- Desenvolver um novo método que permita a utilização de variáveis não inteiras;
- Desenvolver um AGA que incorpore a codificação real, no lugar da codificação binária;
- Desenvolver um método de otimização que primeiro determine a melhor faixa de operação para cada variável e só depois aplique o AGA proposto nessa dissertação.

REFERÊNCIAS BIBLIOGRÁFICAS

- AARTS, E. H. L.; KORST, J.; MICHIELS, W. *Simulated Annealing*. In: BURKE, E.K.; KENDALL, G. (eds.). *Introductory tutorials in optimisation, decision support and search methodologies*. Springer, 2005. p. 187-211.
- AGHAIE, A.; POPPLEWELL, K. Simulation for TQM - the unused tool? *The TQM Magazine*, v.9, n.2, p. 111-116, 1997.
- AHMED, M. A.; ALKHAMIS, T. M. Simulation optimization for an emergency department healthcare unit in Kuwait. *European Journal of Operational Research*, v.198, n.3, p. 936-942, 2009.
- AKERA, A. *The early computers*. In: AKERA, A.; NEBEKER, F. (eds.) *From 0 to 1: An authoritative history of modern computing*. Oxford: Oxford University Press, 2002. p. 63-75.
- 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, n.3, p.317-337, 2006.
- ALMEIDA, L. F.; VALDIVIA, Y. T.; VELLASCO, M. M. B. R.; PACHECO, M. A. C. Otimização de alternativas para o desenvolvimento de campos de petróleo. *Gestão & Produção*, v.14, n.3, p. 489-503, 2007.
- APRIL, J.; BETTER, M. GLOVER, F.; KELLY, J. P.; LAGUNA, M. Enhancing business process management with simulation optimization. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Monterey, CA, USA, 2005.
- APRIL, J.; GLOVER, F.; KELLY, J. P.; LAGUNA, M. Practical introduction to simulation optimization. In: WINTER SIMULATION CONFERENCE, *Proceedings...* New Orleans, LA, USA, 2003.
- ARYANEZHAD, M. B.; HEMATI, M. A new genetic algorithm for solving nonconvex nonlinear programming problems. *Applied Mathematics and Computation*, v.199, n.1, p.186-194, 2008.
- ASLLANI, A.; LARI, A. Using genetic algorithm for dynamic and multiple criteria web-site optimizations. *European Journal of Operational Research*, v.176, n.3, p.1767-1777, 2007.
- AYTUG, H.; KHOUJA, M.; VERGARA, F. A review of the use of genetic algorithms to solve production and operations management problems. *International Journal of Production Research*, v.41, n.17, p. 3955-4009, 2003.
- AYTUG, H.; KOEHLER, G. J. New stopping criterion for genetic algorithms, *European Journal of Operational Research*, v.126, n.3, p. 662-674, 2000.
- AZADEH, A.; TABATABAEE, M.; MAGHSOUDI, A. Design of Intelligent Simulation Software with Capability of Optimization. *Australian Journal of Basic and Applied Sciences*, v.3, n.4, p.4478-4483, 2009.

- AZADEH, A.; TARVERDIAN, S. Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption. *Energy Policy*, v.35, n.10, p.5229-5241, 2007.
- AZADIVAR, F.; TOMPKINS, G. Simulation optimization with qualitative variables and structural model changes: A genetic algorithm approach. *European Journal of Operational Research*, v.113, p. 169-182, 1999.
- BÄCK, T; FOGEL, D. B.; MICHALEWICZ, Z. *Evolutionary Computation 2: Advanced Algorithms and Operators*. London, U.K.: IOP Publishing, 2000, vol. 2.
- BALAMURUGAN, R.; RAMAKRISHNAN, C. V.; SINGH, N. Performance evaluation of a two stage adaptive genetic algorithm (TSAGA) in structural topology optimization. *Applied Soft Computing*, v.8, n.4, p.1607–1624, 2007.
- BANKS, J. *Handbook of simulation: Principles, Methodology, Advances, Applications, and Practice*. New York: John Wiley & Sons, Inc., 1998. 864p.
- BANKS, J. Panel Session: The Future of Simulation. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Arlington, VA, USA, 2001.
- BANKS, J.; CARSON II, J. S.; NELSON, B. L.; NICOL, D. M. *Discrete event system simulation*, 3rd. ed., New Jersey: Prentice-Hall, 2000.
- BANKS, J.; CARSON II, J. S.; NELSON, B. L.; NICOL, D. M. *Discrete-event Simulation*. 4th. ed. New Jersey: Prentice-Hall, 2005.
- BANKS, J.; CARSON II, J. S.; NELSON, B. L.; NICOL, D. M. *Discrete-event Simulation*. 5th. ed., New Jersey: Prentice-Hall, 2009.
- BARBOZA, A. O. *Simulação e Técnicas da Computação Evolucionária Aplicadas a Problemas de Programação Linear Inteira Mista*. 2005. 236 f. Tese (Doutorado em Ciências – Informática Industrial). Universidade Tecnológica Federal do Paraná (UTFPR), Curitiba, PR, 2005.
- BARRICO, C. C. S. *Optimização Evolucionária Multi-Objectivo em Ambientes Incertos - Pesquisa de Soluções Robustas*. 2007. 215 f. Tese (Doutorado em Engenharia Electrotécnica e de Computadores, Especialidade em Informática). Faculdade de Ciências e Tecnologia Universidade de Coimbra, Coimbra, Portugal, 2007.
- BENTO, E. P.; KAGAN, N. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. *Revista Controle & Automação*, v.19, n.3, p.302-315, 2008.
- BERTO, R. M. V. S.; NAKANO, D. N. A. Produção científica nos anais do encontro nacional de engenharia de produção: um levantamento de métodos e tipos de pesquisa. *Produção*, v.9, n.2, p.65-76, 2000.
- 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.

- BETTONVIL, B. W. M.; CASTILLO, E.; KLEIJNEN, J. P. C. Statistical testing of optimality conditions in multiresponse simulation-based optimization. *European Journal of Operational Research*, v.199, n.2, p.448-458, 2009.
- BRUZZONE, A. G.; BOCCA, E.; LONGO, F.; MASSEI, M. Training and recruitment in logistics node design by using web-based simulation. *International Journal of internet Manufacturing and Services*, v.1, n.1, p. 32-50. 2007.
- CAMPOS, G. G.; YOSHIZAKI, H. T. Y.; BELFIORE, P. P. Algoritmos genéticos e computação paralela para problemas de roteirização de veículos com janelas de tempo e entregas fracionadas. *Gestão & Produção*, v.13, n.2, p. 271-281, 2006.
- CANTÚ-PAZ, E. A survey of parallel genetic algorithms. *Calculateurs Parallèles, Réseaux et Systèmes Répartis*, v.10, n. 2, p. 141-171, 1998.
- CARSON, J. S. Introduction to modeling and simulation. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Washington, D.C., USA, 2004.
- CARSON, Y.; MARIA, A. Simulation optimization: methods and applications. In: WINTER SIMULATION CONFERENCE, *Proceedings...*, Atlanta, GA, USA, 1997.
- CHEN, P.; ZHU, L.; LI, X. Multi-resource Balanced Scheduling Optimization Based on Self-adaptive Genetic Algorithm. *Communications in Computer and Information Science*, v.107, n.1, p.19-28, 2010.
- CHENG, H. C.; CHAN, D. Y. K. Simulation optimization of part input sequence in a flexible manufacturing system. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Phoenix, AZ, USA, 2011.
- CHUNG, C. A. *Simulation Modeling Handbook: a practical approach*. Washington, D.C: CRC Press, 2004.
- CHWIF, L.; MEDINA, A. C. *Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações*. 2ª. Ed. São Paulo: Editora dos Autores, 2010.
- COELLO, C. A. C.; LAMONT, G.B.; VAN VELDHUIZEN, D. A. *Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation)*. 2nd ed. New York: Springer, 2007.
- CONCILIO, R. *Contribuições à Solução de Problemas de Escalonamento pela Aplicação Conjunta de Computação Evolutiva e Otimização com Restrições*. 2000. 121 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Estadual de Campinas (Unicamp), Campinas, SP, 2000.
- COSTA, R. F. S. *Abordagem sistemática para avaliação econômica de cenários para modelos de simulação discreta em manufatura*. 2010. 139 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2010.
- DEB, K.; TIWARI, S. Omni-optimizer: A generic evolutionary algorithm for single and multi-objective optimization. *European Journal of Operational Research*, v.185, n.3, p.1062-1087, 2008.

- DIMITRAKIEV, D.; NIKOLOVA, N.; TENEKEDJIEV, K. Simulation and Discrete Event Optimization for Automated Decisions for In-Queue Flights. *International Journal of Intelligent Systems*, v.25, n. 5, p.460-487, 2010.
- DOLOI, H.; JAAFARI, A. Conceptual simulation model for strategic decision evaluation in project management. *Logistics Information Management*, v.15, n.2, p.88-104, 2002.
- EL HAYEK, M.; VAN VOORTHUYSEN, E.; KELLY, D. W. Optimizing life cycle cost of complex machinery with rotatable modules using simulation. *Journal of Quality in Maintenance Engineering*, v.11, n.4, p.333-347, 2005.
- ESKANDARI, H.; MAHMOODI, E.; FALLAH, H.; GEIGER, C. D. Performance analysis of comercial simulation-based optimization packages: OptQuest and Witness Optimizer. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Phoenix, AZ, USA, 2011.
- FALCONE, M. A. G. *Estudo comparativo entre algoritmos genéticos e evolução diferencial para otimização de um modelo de cadeia de suprimento simplificada*. 2004. 93 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas). Pontifícia Universidade Católica do Paraná (PUC-PR), Curitiba, PR, 2004.
- FILIPPINI, R. Operations Management research: some reflections on evolution, models and empirical studies in OM. *International Journal of Operations & Production Management*, v.17, n.7, p. 655-670, 1997.
- FU, M. C. Optimization via simulation: A review. *Annals of Operations Research*, v.53, p.199-247, 1994.
- FU, M. C. Optimization for Simulation: Theory vs. Practice. *Journal on Computing*, v.14, n.3, p. 192-215, 2002.
- FU, M. C.; ANDRADÓTTIR, S.; CARSON, J. S.; GLOVER, F.; HARRELL, C. R.; HO, Y. C.; KELLY, J. P.; ROBINSON, S. M. Integrating optimization and simulation: research and practice. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Orlando, FL, USA, 2000.
- GAVIRA, M. O. *Simulação computacional como uma ferramenta de aquisição de conhecimento*. 2003. 163 f. Dissertação (Mestrado em Engenharia de Produção). Universidade de São Paulo (USP), São Carlos, SP, 2003.
- GEN, M.; CHENG, R. *Genetic algorithms and engineering design*. New York: John Wiley and Sons, 1997.
- GEN, M.; CHENG, R. *Genetic algorithms and engineering optimization*. New York: John Wiley and Sons. 2000.
- GLOVER, F.; LAGUNA, M.; MARTÍ, R. *Principles of Tabu Search*, In: Gonzalez, T. (Ed), *Approximation Algorithms and Metaheuristics*. Chapman & Hall/CRC, 2005.
- GOLDBERG, D. E. *Genetic Algorithm in Search, Optimization and Machine Learning*. Redwood City: Addison-Wesley Publishing Company, Inc., 1989.
- GOLDSMAN, D.; NANCE, R. E.; WILSON, J. R. A brief history of simulation. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Austin, TX, USA, 2009

- GOMES, J. H. F. *Análise e otimização da soldagem de revestimento de chapas de aço carbono utilizando arame tubular inoxidável austenítico*. 2010. 136 p. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2010.
- 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, n.2, p.1098-1108, 2007.
- GOSSELIN, L.; TYE-GINGRAS, M.; MATHIEU-POTVIN; F. Review of utilization of genetic algorithms in heat transfer problems. *International Journal of Heat Mass Transfer*, v.52, n.9, p.2169-2188, 2009.
- HARREL, C. R.; MOTT, J. R. A; BATEMAN, R. E.; BOWDEN, R. G.; GOGG, T. J. *Simulação: otimizando os sistemas*. 2ed. São Paulo: IMAM, 2002.
- HARREL, C. R.; GHOSH, B. K.; BOWDEN, R. *Simulation Using Promodel*. 2ed. New York: McGraw-Hill, 2004.
- HICKS, C. A Genetic Algorithm tool for optimising cellular or functional layouts in the capital goods industry. *International Journal of Production Economics*, v.104, n.2, p.598-614, 2006.
- HILLIER, F. S.; LIEBERMAN, G. J.; *Introduction to Operations Research*. 9th. Ed. New York: McGraw-Hill, 2010.
- HINTERDING, R.; MICHALEWICZ, Z.; EIBEN, A. E. Adaptation in evolutionary computation: A survey. In: *Proceedings... IEEE International Conference on Evolutionary Computation*, 1997.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press, 1975.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Cambridge: MIT Press, 1992.
- HOUPY, R. L.; HOUPY, S.E. *Practical Genetic Algorithms*. New York: John Wiley and Sons, Inc., 1998.
- HWANG, S. F.; HE, R. S. A hybrid real-parameter genetic algorithm for function optimization. *Advanced Engineering Informatics*, v.20, n.1, p.7-21, 2006.
- JAHANGIRIAN, M.; ELDABI, T.; NASEER, A.; STERGIOLAS, L. K.; YOUNG, T. Simulation in manufacturing and business: A review. *European Journal of Operational Research*, v.203, n.1, p.1-13, 2010.
- JENKINS, C. M.; RICE, S. V. Resource modeling in discrete-event simulation environments: a fifty-year perspective. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Austin, TX, USA, 2009.
- JOZWIAK, L.; POSTUŁA, A. Genetic engineering versus natural evolution Genetic algorithms with deterministic operators. *Journal of Systems Architecture*, v.48, n.1-3, p.99-112. 2002.
- KAMEI, K.; ISHIKAWA, M. *Determination of the optimal values of parameters in reinforcement learning for mobile robot navigation by a genetic algorithm*. In: Nakagawa, N.

(Ed). Brain-Inspired IT I, International Congress Series 1269, (pp. 193-196). Amsterdam: Elsevier, 2004.

KATAYAMA, K.; HIRABAYASHI, H.; NARIHISA, H. Analysis of crossovers and selections in a coarse-grained parallel genetic algorithm. *Mathematical and Computer Modelling*, v.38, n.11-13, p.1275-1282, 2003.

KAVEH, A.; SHAHROUZI, M. A hybrid ant strategy and genetic algorithm to tune the population size for efficient structural optimization. *Engineering Computations*, v.24, n.3, p.237-254, 2007.

KELTON, W. D. Designing simulation experiments. In: WINTER SIMULATION CONFERENCE, *Proceedings...* New Orleans, LA, USA, 2003.

KELTON, W. D.; SADOWSKI, R. P. E.; STURROCK, D. T. *Simulation with Arena*, 4th. Edition, New York: McGraw-Hill, 2007.

KLEIJNEN, J. P. C.; VAN BEERS, W.; VAN NIEUWENHUYSE, I. Constrained optimization in simulation: A novel approach. *European Journal of Operational Research*, v.202, n.1, p.164-174, 2010.

KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering and System Safety*, v.91, n.9, p.992-1007, 2006.

LAVOIE, P.; KENNE, J. P.; GHARBI, A. Production control and combined discrete/continuous simulation modeling in failure-prone Transfer Lines. *International Journal of Production Research*, v.45, n.24, p.5667-5685, 2007.

LAW, A. M. *Simulation modeling and analysis*, 4th. ed. New York: McGraw-Hill, 2007.

LAW, A. M. How to build valid and credible simulation models. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Austin, TX, USA, 2009.

LAW, A. M.; KELTON, W. D. *Simulation modeling and analysis*. 3rd. ed. New York: McGraw-Hill, 2000.

LAW, A. M.; MCCOMAS, M. G. Simulation-Based Optimization, In: WINTER SIMULATION CONFERENCE, *Proceedings...* San Diego, CA, USA, 2002.

LEAL, F.; ALMEIDA, D. A. de; MONTEVECHI, J. A. B. Uma Proposta de Técnica de Modelagem Conceitual para a Simulação através de elementos do IDEF. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, *Anais...* João Pessoa, PB, 2008.

LINDEN, R. *Algoritmos Genéticos: Uma Importante Ferramenta da Inteligência Computacional*. Rio de Janeiro: Editora Brasport, 2006.

LOBO, F. G.; GOLDBERG, D. E. The parameter-less genetic algorithm in practice. *Information Sciences*, v.167, n.4, p.217-232, 2004.

MA, Y.; ZHANG, C. Quick convergence of genetic algorithm for QoS-driven web service selection. *Computer Networks*, v.52, n.5, p.1093-1104, 2008.

MARTÍ, R.; LAGUNA, M.; GLOVER, F. Principles of Scatter Search. *European Journal of Operational Research*, v.169, n.2, p.359-372, 2006.

- MARTIN, C. H. A hybrid genetic algorithm/mathematical programming approach to the multi-family flowshop scheduling problem with lot streaming. *Omega*, v.37, n.1, p.126-137, 2009.
- MARTINS, R. A. *Abordagens quantitativa e qualitativa*. In: MIGUEL, P. A. C. (Org). Metodologia de pesquisa em engenharia de produção e gestão de operações. Rio de Janeiro: Elsevier, 2010. Cap. 3, p.45-61.
- MATOUS, K.; LEPS, M.; ZEMAN, J.; SEJNOHA, M. Applying genetic algorithms to selected topics commonly encountered in engineering practice. *Computer Methods in Applied Mechanics and Engineering*, v.190, n.13, p.1629-1650, 2000.
- MCCALL, J. Genetic algorithms for modelling and optimisation. *Journal of Computational and Applied Mathematics*, v.184, n.1, p. 205-222, 2005.
- MEDEIROS, F. L. L. *Algoritmo genético híbrido como um método de busca de estados estacionários de sistemas dinâmicos*. 2002. 191 f. Dissertação (Mestrado em Computação Aplicada). Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, 2002.
- MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. 3rd. ed. London: Springer-Verlag, 1996.
- MIGUEL, P. A. C. Estudo de caso na engenharia de produção: estruturação e recomendações para sua condução. *Produção*, v.17, n.1, p. 216-229, 2007.
- MIRANDA, R. C.; COUTINHO, B. F.; RIBEIRO, J. R.; MONTEVECHI, J. A. B.; PINHO, A. F. Avaliação da operação de *setup* em uma célula de manufatura de uma indústria de autopeças através da simulação a eventos discretos. *Revista Gestão Industrial*, v.6, n.3, p.01-21, 2010.
- MIRANDA, R. C.; PINHO, A. F.; MONTEVECHI, J. A. B. Otimização em modelos de simulação: um estudo comparativo envolvendo métodos de otimização não lineares baseados em algoritmos genéticos. In: XLIII Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Ubatuba, SP, 2011.
- MITCHELL, M. *An Introduction a Genetic Algorithm*. Cambridge: MIT Press, 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.; LEAL, F.; PINHO, A. F.; COSTA, R. F. 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: WINTER SIMULATION CONFERENCE, *Proceedings...* Miami, FL, USA, 2008a.
- 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: 20 Symposium Europeo de Modelado y Simulacion (SCS), *Proceedings...* Briatico, Itália, 2008b.
- MONTEVECHI, J. A. B.; LEAL, F.; PINHO, A. F.; COSTA, R. F. S.; OLIVEIRA, M. L. M.; SILVA, A. L. F. Conceptual modeling in simulation projects by mean adapted IDEF: an

- application in a Brazilian tech company. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Baltimore, MD, USA, 2010.
- MONTEVECHI, J. A. B.; PINHO, A. F.; LEAL, F.; MARINS, F. A. S. Application of design of experiments on the simulation of a process in an automotive industry. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Washington, DC, USA, 2007.
- MONTGOMERY, D. C. *Design and Analysis of Experiments*. 6th ed., New York: Wiley, 2005.
- MONTGOMERY, D. C. *Introdução ao controle estatístico da qualidade*. 4a. ed., Rio de Janeiro: LTC, 2009.
- MONTGOMERY, D. C.; RUNGER, G. C. *Estatística Aplicada e Probabilidade para Engenheiros*. 2 a. ed. Editora LTC, 2003.
- NAKANO, N. N. *Métodos de Pesquisa Adotados na Engenharia de Produção e Gestão de Operações*. In: MIGUEL, Paulo A. C. (Org). *Metodologia de pesquisa em engenharia de produção e gestão de operações*. Rio de Janeiro: Elsevier, 2010. Cap 4, p.63-72.
- NANCE, R. E. Simulation Programming Languages: An Abridged History. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Arlington, VA, USA, 1995.
- NANCE, R. E.; SARGENT, R. Perspectives on the evolution of simulation. *Operations Research*, v.50, n.1, p.161-172, 2002.
- NEPALLI, R. V.; CHEN, C. L.; GUPTA, J. N. Genetic algorithms for the two-stage bicriteria flow shop problem. *European Journal of Operational Research*, v.95, n.2, p. 356-373, 1996.
- 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, n.3, 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.
- ÓLAFSSON, S.; KIM, J. Simulation Optimization. In: WINTER SIMULATION CONFERENCE, *Proceedings...* San Diego, CA, USA, 2002.
- OLIVEIRA, M. L. M.; MIRANDA, R. C.; MONTEVECHI, J. A. B.; LEAL, F. Desenvolvimento de um projeto de simulação a eventos discretos em uma célula de controle de qualidade de uma empresa de alta tecnologia. In: XLII Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Bento Gonçalves, RS, 2010.
- OU, S. C.; CHUNG, C. Y.; CHUNG, H. Y.; SUNG, W. T.; CHENG, C. C. Molecular docking for protein folding structure and drug likeness prediction. *International Journal on Biology and Biomedicine*, v.2, n.1, p. 57-63, 2005.
- PAIVA, E. J. *Otimização de processos de manufatura com múltiplas respostas baseada em índices de capacidade*. 2008. 118 p. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2008.

- PARIS, J. L.; PIERREVAL, H. A distributed evolutionary simulation optimization approach for the configuration of multiproduct kanban systems. *International Journal of Computer Integrated Manufacturing*, v.14, n.5, p.421-430, 2001.
- PERERA, T.; LIYANAGE, K. Methodology for rapid identification and collection of input data in the simulation of the manufacturing systems. *Simulation Practice and Theory*, v.7, p. 645-656, 2000.
- PIDD, M. *Computer simulation in management science*. 5.ed. New Jersey: John Wiley & Sons, 2004.
- PIERREVAL, H.; TAUTOU, L. Using evolutionary algorithms and simulation for the optimization of manufacturing systems. *IIE Transactions*, v. 29, n. 3, p. 181-189, 1997.
- PINHO, A. F. *Proposta de um método de otimização de modelos de simulação a eventos discretos*. 2008. 189 f. Tese (Doutorado em Engenharia Mecânica). Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista (UNESP), Guaratinguetá, SP, 2008.
- PINHO, A. F.; MORAIS, N. S. Utilização da simulação computacional combinada à técnica de otimização em um processo produtivo. *Revista P&D em Engenharia de Produção*, v.8, n.2, p.88-101, 2010.
- PINHO, A. F.; 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, *Anais...* João Pessoa, 2008.
- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S. Avaliação de um método de otimização proposto para modelos de simulação a eventos discretos. In: XLI Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Porto Seguro, 2009.
- PROTIL, R. M. Otimização do processo decisório utilizando simulação computacional. In: XXXIII Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Campos do Jordão, SP, Brasil, p.1535-1546, 2001.
- REES, J.; KOEHLER, G. J. Learning genetic algorithm parameters using hidden Markov models. *European Journal of Operational Research*, v.175, n.2, p.806-820, 2006.
- REEVES, C. R. Using genetic algorithms with small populations. In: 5th International Conference on Genetic Algorithms, *Proceedings...* Morgan Kaufmann, San Mateo, CA, USA, 1993.
- RIPLEY, B. *Pattern Recognition and Neural Networks*. Cambridge: University Press, 1996.
- 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.
- ROBINSON, S. Conceptual modelling for simulation Part I: definition and requirements. *Journal of the Operational Research Society*, v.59, n.3, p.278-290, 2008.

- ROSEN, S. L.; HARMONOSKY, C. H.; TRABAND, M. T. Optimization of Systems with Multiple Performance Measures via Simulation: Survey and Recommendations. *Computers and Industrial Engineering*, v.54, p.327- 339, 2007.
- ROUX, O.; JAMALI, M. A.; KADI, D. A.; CHATELET, E.; Development of simulation and optimization platform to analyse. *International Journal of Computer Integrated Manufacturing*, v.21, n.4, p.407-414, 2008.
- RYAN, J.; HEAVEY, C. Process modeling for simulation. *Computers in Industry*, v.57, n.5, p.437-450, 2006.
- SAIF, A. W. A.; SELIAMAN, M. E.; AHMAD, A. R. Simulation Optimization of a Four-Stage Supply Chain System. *Information and Communication Technologies*, v.2, p.2798-2802, 2006.
- SAN JOSE-REVUELTA, L. M. A new adaptive genetic algorithm for fixed channel assignment. *Information Sciences*, v.177, n.13, 2655-2678, 2007.
- SÁNCHEZ, P. J. Fundamentals of simulation modeling. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Washington, DC, USA, 2007.
- SANTOS, J.; MONTEAGUDO, A. Study of the genetic code adaptability by means of a genetic algorithm. *Journal of Theoretical Biology*, v.264, n.3, p.854-865, 2010.
- SARGENT, R. G. Verification and validation of simulation models. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Austin, TX, USA, 2009.
- SILVA, W. A. *Otimização de parâmetros da gestão baseada em atividades aplicada em uma célula de manufatura*. 2005. 120 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2005.
- SILVA, W. A.; GALHARDO, M. R.; MONTEVECHI, J. A. B. Otimização de uma célula de manufatura usando simulação computacional. In: XXIV Encontro Nacional de Engenharia de Produção (XXIV ENEGEP), *Anais...* Florianópolis, SC, Brasil, p.3062-3069, 2004.
- SIMRUNNER USER GUIDE. ProModel Corporation: Orem, UT. USA. 2002.
- SOARES, G. L. *Algoritmos Genéticos : Estudo, Novas Técnicas e Aplicações*. 1997. 145 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, MG, 1997.
- SOARES, M. M. *Análise do uso de algoritmos genéticos na otimização do planejamento mestre da produção*. 2006. 156 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas). Pontifícia Universidade Católica do Paraná (PUC-PR), Curitiba, PR, 2006.
- SRISUWANRAT, C.; IOANNOU, P. G.; TSIMHONI, O. 2008. Simulation and optimization for construction repetitive projects using ProModel and *SimRunner*. In: WINTER SIMULATION CONFERENCE, *Proceedings...* Miami, FL, USA, 2008.
- STUCKMAN, B.; EVANS, G.; MOLLAGHASEMI, M. Comparison of global search methods for design optimization using simulation, In: WINTER SIMULATION CONFERENCE, *Proceedings...* Phoenix, AZ, USA, 1991.

- SUNG, W. T.; LIU, Y. F. Energy minimum theorem based on AGA, Lyapunov and force field for CADD techniques. *Computers in Biology and Medicine*, v.40, n.2, p. 215–222, 2010.
- TANOMARU, J. Motivação, fundamentos e Aplicações de Algoritmos Genéticos. In: II Congresso Brasileiro de Redes Neurais, *Anais...* Curitiba, PR, Brasil, p.373-403, 1995.
- TELES, M. L.; GOMES, H. M. Comparação de algoritmos genéticos e programação quadrática seqüencial para otimização de problemas em engenharia. *Teoria e Prática na Engenharia Civil*, v.10, n.15, p.29-39, 2010.
- TORABI, S. A.; GHOMI, S. M. T. F.; KARIMI, B. A hybrid genetic algorithm for the finite horizon economic lot and delivery scheduling in supply chains. *European Journal of Operational Research*, v.173, n.1, p. 173-189, 2006.
- TORGA, B. L. M. *Modelagem, Simulação e Otimização em Sistemas Puxados de Manufatura*. 2007. 126 f. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2007.
- TYNI, T.; YLINEN, J. Evolutionary bi-objective optimization in the elevator car routing problem. *European Journal of Operational Research*, v.169, n.3, p.960-977, 2006.
- WANG, S.; SCHONFELD, P. Genetic Algorithm for Selecting and Scheduling Waterway Projects. *NETS Report*, 2006.
- WANG, H. F.; WU, K. Y. Modeling and analysis for multi-period, multi-product and multi-resource production scheduling. *Journal of Intelligent Manufacturing*, v.14, n.3, p.297-309, 2003.
- WANG, H. F.; WU, K. Y. Hybrid genetic algorithm for optimization problems with permutation property. *Computers and Operations Research*, v.31, n.14, p. 2453-2471, 2004.
- YANG, T.; KUO, Y.; CHO, C. A genetic algorithms simulation approach for the multi-attribute combinatorial dispatching decision problem. *European Journal of Operational Research*, v.176, n. 3, p.1859-1873, 2007.
- YE, Z.; LI, Z.; XIE, M. Some improvements on adaptive genetic algorithms for reliability-related applications. *Reliability Engineering and System Safety*, v.95, n.2, p.120–126, 2010.
- YOO, T.; CHO, H.; YÜCESAN, E. Hybrid algorithm for discrete event simulation based supply chain optimization. *Expert Systems with Applications*, v.37, p. 2354-2361, 2010.
- 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*. In: Nakagawa, N. (Ed). *Brain-Inspired IT I*, International Congress Series 1269, (pp. 149-152). Amsterdam: Elsevier, 2004.
- ZHANG, H.; LI, H. Simulation-based optimization for dynamic resource allocation. *Automation in Construction*, v.13, p.409– 420, 2004.

ANEXO - Símbolos IDEF-SIM

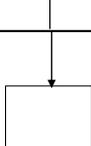
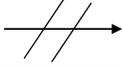
Elementos	Simbologia	Técnica de origem	
Entidade		IDEF3 (modo descrição das transições)	
Funções		IDEF0	
Fluxo da entidade		IDEF0 e IDEF3	
Recursos		IDEF0	
Controles		IDEF0	
Regras para fluxos paralelos e/ou alternativos	 &	Regra E	IDEF3
	 x	Regra OU	
	 o	Regra E/OU	
Movimentação		Fluxograma	
Informação explicativa		IDEF0 e IDEF3	
Fluxo de entrada no sistema modelado			
Ponto final do sistema			
Conexão com outra figura			

Tabela A - Simbologia utilizada na técnica IDEF-SIM

APÊNDICE - Artigos publicados em congressos e periódicos

Artigo publicado em periódico:

- MIRANDA, R. C.; COUTINHO, B. F.; RIBEIRO, J. R.; MONTEVECHI, J. A. B.; PINHO, A. F. Avaliação da operação de *setup* em uma célula de manufatura de uma indústria de autopeças através da simulação a eventos discretos. *Revista Gestão Industrial*, v. 6, p. 3, 2010.

Artigos publicados em anais de congressos:

- MIRANDA, R. C.; PINHO, A. F.; MONTEVECHI, J. A. B. Otimização em modelos de simulação: um estudo comparativo envolvendo métodos de otimização não lineares baseados em algoritmos genéticos. In: XLIII Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Ubatuba, SP, 2011.
- MIRANDA, R. C.; PINHO, A. F.; MONTEVECHI, J. A. B. Utilização do planejamento de experimentos para análise de significância dos parâmetros de um algoritmo genético. In: XVIII SIMPEP, *Anais...* Bauru, SP, 2011.
- OLIVEIRA, M. L. M.; MIRANDA, R. C.; MONTEVECHI, J. A. B.; LEAL, F. Desenvolvimento de um projeto de simulação a eventos discretos em uma célula de controle de qualidade de uma empresa de alta tecnologia. In: XLII Simpósio Brasileiro de Pesquisa Operacional, *Anais...* Bento Gonçalves, RS, 2010.
- SILVA, F. H. M. R.; COSTA, R. F. S; MONTEVECHI, J. A. B.; MIRANDA, R. C. Desenvolvimento de um modelo de simulação para uma célula de manufatura de uma empresa de alta tecnologia. In: XVII SIMPEP, *Anais...* Bauru, SP, 2010.

Resumos publicados em anais de congressos:

- MONTEVECHI, J. A. B.; MIRANDA, R. C. Development of an adaptive genetic algorithm for nonlinear optimization of discrete events simulation models. In: Winter Simulation Conference, *Proceedings...* Phoenix, AZ, USA, 2011.
- MONTEVECHI, J. A. B.; MIRANDA, R. C. Otimização em modelos de simulação computacional: um estudo comparativo envolvendo métodos de otimização baseados em algoritmos genéticos. In: Encontro Regional de Pesquisa Operacional da Região

Sudeste (ERPO). Livro de Resumos do Encontro Regional de Pesquisa Operacional da Região Sudeste, Rio de Janeiro, RJ, 2010.

Artigos submetidos para publicação em periódicos:

- MONTEVECHI, J. A. B.; COSTA, R. F. S.; MIRANDA, R. C.; PINHO, A. F. SILVA, A. L. F. Aplicação do planejamento de experimentos simulados para auxílio à tomada de decisões em uma célula de manufatura de alta tecnologia. Artigo submetido a *Revista Produção Online*. Data da submissão: 17/08/2010.
- PAIVA, C. N.; MONTEVECHI, J. A. B.; MIRANDA, R. C. Fator humano: ainda um desafio para simulação a eventos discretos? Artigo submetido à *Revista Gestão e Produção*. Data da submissão: 01/06/2011.
- MIRANDA, R. C.; MONTEVECHI, J. A. B.; PENTEADO, K. M.; AGUIAR, M. S.; PINHO, A. F. Análise de uma unidade de processamento de roupas de um hospital através da simulação a eventos discretos. Artigo submetido à *Revista Produto e Produção*. Data da submissão: 26/07/2011.
- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; COSTA, R. F. S.; MIRANDA, R. C.; FRIEND, J. D. Evaluation of a proposed optimization method for discrete event simulation models. Artigo submetido à *Revista Pesquisa Operacional*. Data da submissão: 09/09/2011.

Capítulos de livros submetidos:

- PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; MIRANDA, R. C. Algoritmos Genéticos – Fundamentos e Aplicações. Capítulo submetido ao livro *Metaheurísticas em Pesquisa Operacional*. Data da submissão: 01/12/2011.
- MONTEVECHI, J. A. B.; MIRANDA, R. C. Sensitivity analysis in discrete-event simulation using design of experiments. Capítulo submetido ao livro *Discrete Event Simulations*. Data da submissão: 20/12/2011.